

Zuverlässigkeitsanalyse umfelderfassender Sensorik

Eine stochastische Methodik zur Berücksichtigung von Umgebungseinflüssen am Beispiel von LiDAR Sensoren

M. Berk, Technische Universität München¹ und AUDI AG² (INI.TUM)

H.-M. Kroll, AUDI AG², Ingolstadt

Dr. O. Schubert, AUDI AG², Ingolstadt

Dr. B. Buschardt, AUDI AG², Ingolstadt

Prof. Dr. D. Straub, Technische Universität München¹

¹ Engineering Risk Analysis Group

² Entwicklung Fahrwerkelektronik, Fahrerassistenzsysteme, Systemsicherheit

Kurzfassung

Eine wesentliche Grundlage für Fahrerassistenzsysteme und das automatisierte Fahren stellt die maschinelle Wahrnehmung mithilfe umfelderfassender Sensorik dar. Aufgrund der hohen Sicherheitsrelevanz der maschinellen Wahrnehmung ist deren Zuverlässigkeit im Entwicklungsprozess der automatisierten Fahrfunktionen nachzuweisen. Dabei stellen vor allem die kleinen Zielfehlerraten sowie der stochastische Einfluss von zahlreichen Umgebungsbedingungen auf die Sensorperformance eine große Herausforderung dar. Als Grundlage für eine zuverlässigkeitsbasierte Absicherung der Sensoren führen wir in diesem Beitrag umfassende Zuverlässigkeitsmetriken ein, um die Unsicherheiten im Fahrzeugumfeldmodell stochastisch zu beschreiben. Wegen des Einflusses der Umgebungsbedingungen sind diese Metriken jedoch nicht konstant sondern stellen selbst stochastische Größen dar. Dadurch ergibt sich eine hierarchische Unsicherheitsstruktur mit Unsicherheiten höherer Ordnung. Wir schlagen ein Bayes'sches hierarchisches Regressionsmodell vor, um den Einfluss der Umgebungsbedingungen auf die Sensorzuverlässigkeit aus Erprobungsfahrten und Versuchen zu lernen. Zur Demonstration der Methodik untersuchen wir den Einfluss der Temperatur auf die Performance eines LiDAR Sensors. Es zeigt sich, dass dieser Einfluss identifiziert und genau quantifiziert werden kann. Die hier vorgestellten Metriken und die Methodik stellen einen wichtigen Schritt in Richtung formalisierter und zuverlässigkeitsbasierter Absicherung der Umfeldwahrnehmung dar. Für eine umfassende Absicherung der Sensorik muss die hier dargestellte Vorgehensweise um weitere stochastische Methoden ergänzt werden.

Abstract

Machine vision based on automotive environment sensors is the enabling technology for advanced driver assistance systems and automated driving. Due to its important role, the reliability of environment sensing is highly safety relevant and has thus to be assessed and demonstrated during the development of the system. The main challenges associated with this task are low target error rates and the stochastic influence of different uncertain environmental conditions on the sensor performance. As a basis for the reliability assessment of environment sensors we introduce comprehensive performance metrics that allow a formal description of the uncertainties in a digital environmental model. Due to the influence of environmental conditions on the sensor performance, these metrics however are not constant but are random variables themselves. This leads to a hierarchical uncertainty structure including higher order uncertainties. To quantify the influence of the environmental conditions on the sensor reliability, we use a Bayesian hierarchical regression model. The utility of this method is demonstrated with a case study in which the influence of temperature on sensor reliability is examined. The results show that the proposed methodology is capable of identifying and quantifying the influence of the temperature on sensor performance. The introduced metrics and the proposed methodology are an important step towards a formalized reliability assessment of automotive environment sensing. In order to predict if the sensor reliability complies with the target error rates, the presented methodology has to be adapted and extended with additional stochastic methods.

1. Zuverlässigkeit von Umfeldsensoren im Kontext des automatisierten Fahrens

Die Entwicklung von Fahrerassistenzsystemen und die Erforschung automatisierter Fahrzeuge schreitet zügig voran [1 bis 8]. Der Übergang vom teilautomatisierten zum hoch- bzw. vollautomatisierten Fahren (Klassifikation nach [9]) ist für definierte Anwendungsfälle in der Serienproduktion bereits für die kommenden Jahre geplant [10 bis 12]. Eine wesentliche Rolle spielt dabei die maschinelle Wahrnehmung basierend auf Umfeldsensoren, die als Grundlage für die Fahrzeugautomatisierung angesehen wird.

Im Gegensatz zu teilautomatisierten Fahrfunktionen (Level 2) muss der Fahrer hochautomatisierte Fahrfunktionen (Level 3) nicht dauerhaft überwachen [9], das System verlässt sich für einen gewissen Zeitraum vollständig auf die Umfeldsensorik. Dadurch erlangt diese eine hohe Sicherheitsrelevanz, sie muss zuverlässig funktionieren, um potentiell Systemversagen aufgrund unzureichender maschineller Umfeldwahrnehmung auszuschließen. Diese Zuverlässigkeit (siehe [13, 14] für eine Definition aus der klassischen Hardwarezuverlässigkeitsproblematik) ist im Zuge der Fahrzeugentwicklung nachzuweisen.

1.1. Problemstellung: Absicherung der Umfeldsensorik

Herkömmliche Absicherungsmethoden für sicherheitsrelevante (Elektrik- und Elektronik-) Komponenten gemäß dem aufsteigenden Ast im etabliertem V-Modell der ISO26262 stoßen jedoch aufgrund der kontext- und umgebungsabhängigen Leistungsfähigkeit von Fahrerassistenzsystemen an ihre Grenzen [15]. Dies gilt nicht zuletzt auch für die Sensorik. Die Leistung und Genauigkeit von Umfeldsensoren hängt von unsicheren und variablen Umgebungsbedingungen ab, etwa vom Wetter, Störstrahlung, Verschmutzungen oder Objektreflexionseigenschaften [16 bis 20]. Eine wesentliche Herausforderung bei der Sensorabsicherung liegt daher in der großen Anzahl dieser räumlich und zeitlich variablen Umgebungsbedingungen mit Einfluss auf die Sensorleistungsfähigkeit.

Neben den variablen Umgebungsbedingungen stellt der hohe Absicherungsaufwand aufgrund von Zielfehlerraten des Gesamtsystems von bis zu 10^{-8} h^{-1} [21] eine wesentliche Herausforderung für die Absicherung der Zuverlässigkeit von Umfeldsensoren dar. Dieser ist empirisch mit reinen Erprobungsfahrten kaum zu bewältigen, wie in [22] für das autonome Fahren gezeigt wird. Zusätzlich zur Erprobungsfahrt selbst liegt ein beträchtlicher Teil des Aufwandes in der Erhebung von Referenzdaten (ground truth) und der Auswertung der Daten.

Um die Freigabe der Systeme für hoch- und vollautomatisiertes Fahren für zahlreiche Anwendungsfälle effizient bewältigen zu können, müssen unter anderem neue Metriken und Methoden entwickelt werden, um die Zuverlässigkeit der maschinellen Wahrnehmung nachzuweisen [23]. Eine Fragestellung ist die Formalisierung der Unsicherheiten der Umfeldsensoren [22]. Dabei reicht es keinesfalls aus, die Leistungsfähigkeit der Sensoren unter Laborbedingungen zu bestimmen, weil der stochastische Einfluss der Umgebungsbedingungen dadurch vernachlässigt werden würde. Stattdessen müssen Wege gefunden werden, die Umgebungseinflüsse adäquat zu berücksichtigen.

In diesem Beitrag skizzieren wir am Beispiel von LIDAR-Sensoren (siehe [24] für die technischen Hintergründe) ein stochastisches Konzept für eine zuverlässigkeitsbasierte Absicherung der Umfeldsensorik, welches den genannten Herausforderungen begegnet. Die wesentliche Innovation dieses Beitrags ist die konsistente Behandlung der Leistungsfähigkeit des betrachteten Sensors mit mathematisch fundierten Zuverlässigkeitsmetriken. Ebenfalls wird ein Lösungsansatz für die Absicherung der Sensoren vor dem Hintergrund von unsicheren und variablen Umgebungsbedingungen aufgezeigt.

Zunächst geben wir in Kapitel 1.2 einen Überblick über vorhandene Metriken zur Beschreibung der Sensorzuverlässigkeit von LIDAR Sensoren. In Kapitel 2 diskutieren wir die Unsicherheiten des Fahrzeugumfeldmodells und führen anschließend in Kapitel 3 mathematisch fundierte Zuverlässigkeitsmetriken für eine konsistente Behandlung der Sensor-Leistungsfähigkeit ein. In Kapitel 4 beschreiben wir ein hierarchisches Regressionsmodell, um eine Beziehung zwischen relevanten Umgebungsbedingungen und den Zuverlässigkeitsmetriken herzustellen. In Kapitel 5 präsentieren wir eine einfache Fallstudie, deren Ergebnisse in Kapitel 5.2 dargestellt und diskutiert werden. Kapitel 6 fasst die wichtigsten Aussagen dieses Beitrags zusammen.

1.2. Etablierte Metriken zur Beschreibung der Sensorzuverlässigkeit

Für die Diskussion vorhandener Metriken zur Beschreibung der Sensorzuverlässigkeit nehmen wir Bezug auf die verschiedenen Stufen der Signalverarbeitung (Bild 1). Die Signalverarbeitungskette eines LIDARs startet mit dem Rohsignal (Bild 1a), wobei zwischen Nutz- und Störsignal auf der Basis von (teilweise dynamisch anpassbaren) Detektionsgrenzwerten unterschieden werden muss. Die Zuverlässigkeit dieser Unterscheidung lässt sich über die Signalentdeckungstheorie mit einer Trefferwahrscheinlichkeit (engl. Probability of Detection) und einer Fehlalarm-

wahrscheinlichkeit (engl. Probability of False Alarm) beschreiben [25], welche vielfach für dichotome Detektionsproblemstellungen verwendet werden [26 bis 29]. Auf Stufe des analogen Rohsignals ist jedoch die Genauigkeit des Sensors bezüglich der primären Messgröße in Form von Distanzmessungen noch nicht enthalten, erst nach der Interpretation des Signals durch einen Detektionsgrenzwert lässt sich die Genauigkeit der Distanzmessungen feststellen. Daher ist es nicht zielführend die Sensorzuverlässigkeit alleine auf Basis des analogen Rohsignals zu beschreiben.

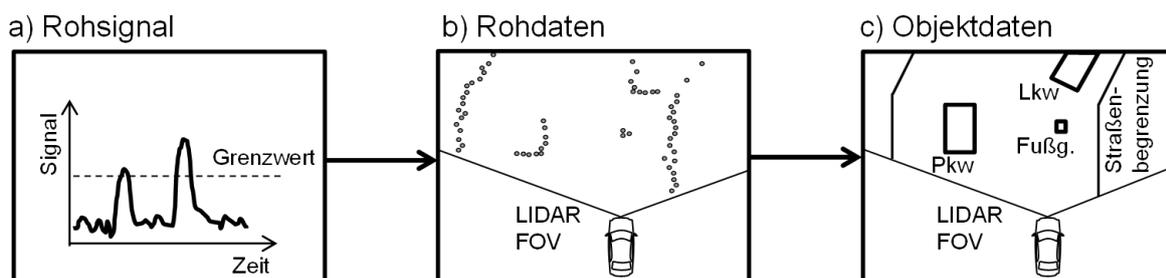


Bild 1: Signalverarbeitungskette eines LIDAR Sensors: a) Analoges Rohsignal: Nutzsignal und Störsignal b) Digitale Rohdaten: Distanzmessungen eines Messzyklus c) Objektdaten: repräsentatives dynamisches Fahrzeugumfeldmodell

Die Zuverlässigkeit der digitalen Rohdaten (Bild 1b), die bei LIDAR Sensoren aus in Messzyklen zusammengefassten Distanzmessungskarten bestehen, kann über einen als normalverteilt angenommenen Messfehler beschrieben werden [30]. Es ist geläufig, die Verteilungsparameter der Distanzmessungsfehler unter kontrollierten Bedingungen in Versuchen zu bestimmen, wie Beispiele aus der Robotik demonstrieren [31 bis 33]. Aus statistischer Sicht ist eine Beschreibung der Sensorzuverlässigkeit auf Ebene der digitalen Rohdaten zwar konzeptionell einfach, nicht enthalten sind aber Fehler, die ihren Ursprung in den Algorithmen haben, wie etwa unzutreffende Assoziationen oder fehlerhafte Objektbildung.

Diese Fehler sind erst in den Objektdaten (Bild 1c) enthalten – dem dynamischen Fahrzeugumfeldmodell [34]. Da die Fahrerassistenzfunktion bzw. die automatisierte Fahrfunktion auf diesen basieren, wird im Rahmen dieser Studie die Zuverlässigkeit der Objektdaten beschrieben. Es ist anzumerken, dass das dynamische Fahrzeugumfeldmodell in der Regel auf der Fusion der Umfeldwahrnehmung von mehreren Sensoren basiert [35], worauf die nachfolgend präsentierten Zuverlässigkeitsmetriken übertragen werden können. Vorerst gilt der Fokus jedoch der Absicherung eines einzelnen Sensors. Eine Möglichkeit

dieser Absicherung liegt in dem Nachweis, dass bestimmte Zuverlässigkeitsmetriken gewisse funktionsabhängige Grenzwerte einhalten. Diese Grenzwerte können für die Einzelsensoren aus Systemsicherheitsanforderungen abgeleitet werden.

2. Unsicherheiten im Fahrzeugumfeldmodell und Unsicherheiten höherer Ordnung

Zur Einführung von umfassenden Zuverlässigkeitsmetriken auf Basis der Objektdaten mit dem Ziel der Sensorabsicherung ist es notwendig, verschiedene Arten von Unsicherheiten im Fahrzeugumfeldmodell zu berücksichtigen. Diese sind nach [36]:

- Existenzunsicherheit: Unsicherheit über die Existenz eines Objektes im Fahrzeugumfeldmodell. Existiert dieses in Realität oder ist es eine Falschdetektion (Geist)?
- Zustandsunsicherheit: Unsicherheit über die physikalischen Messgrößen der Objekte (Distanz, Position, Größe, Orientierung, Geschwindigkeit, Beschleunigung...) ausgelöst durch zufällige und systematische Messabweichungen vom „wahren“ Wert. Diese Abweichungen können auf Messfehler und fehlerhafte Objektbildung oder Assoziation zurückgeführt werden.
- Klassenunsicherheit: Korrekte semantische Kategorisierung der Objekte. Beispiel: Pkw wird als Pkw erkannt und nicht als Fahrradfahrer.

Alle genannten Unsicherheiten können im Zusammenhang mit automatisierten Fahrfunktionen zu sicherheitsrelevanten Fehlern führen. Daher muss die Leistungsfähigkeit der Sensoren hinsichtlich Objektdetektion, Genauigkeit der physikalischen Messgrößen und Objektklassifikation nachgewiesen werden.

Die Schwierigkeit dieses Nachweises liegt – wie einleitend festgestellt – unter anderem in den variablen Umgebungsbedingungen, welche die Leistungsfähigkeit der Sensoren wesentlich beeinflussen [16 bis 20]. Die Einflüsse der unsicheren Umgebungsbedingungen führen dazu, dass die Existenzunsicherheiten, die Zustandsunsicherheiten und die Klassenunsicherheiten keine konstanten Größen sondern selbst Zufallsvariablen sind. Wir schlagen deswegen vor, zur Liste der relevanten Unsicherheiten einen weiteren Punkt aufzunehmen: Die Unsicherheiten höherer Ordnung, die die Unsicherheiten in den Existenz-, Zustands- und Klassenunsicherheiten selbst darstellen.

Mithin reicht es nicht aus die Existenz-, Zustands- und Klassenunsicherheiten einmal unter kontrollierten Bedingungen zu bestimmen, es muss auch deren Variabilität berücksichtigt werden, um Aussagen über die Zuverlässigkeit von Sensoren im realen Fahrbetrieb treffen zu können. Eine weitere wichtige Rolle der Unsicherheiten höherer Ordnung für die Sensorzuverlässigkeit ist in Verbindung mit der sensoreigenen Schätzung der Unsicherheiten bzw. der Genauigkeit zum Zeitpunkt der Messung selbst zu sehen (siehe [36] für eine Diskussion der etablierten Methoden). Mithilfe der Unsicherheiten höherer Ordnung lässt sich quantifizieren, wie zuverlässig ein Sensor seine eigene, möglicherweise zu einem Zeitpunkt vorherrschende unzureichende Leistungsfähigkeit erkennt. Die Genauigkeit dieser Eigendiagnose spielt eine wesentliche Rolle für die Sicherheit, da die Eigenschätzung der Leistungsfähigkeit eine wichtige Eingangsgröße für die Gewichtung der Informationen der einzelnen Sensoren in der Sensordatenfusion ist.

3. Metriken zur Beschreibung der Sensorzuverlässigkeit

Zur formalisierten Behandlung der im letzten Kapitel genannten Unsicherheiten führen wir in diesem Kapitel auf Basis bestehender Konzepte mathematisch fundierte Metriken zur Quantifizierung der Sensorzuverlässigkeit ein.

3.1. Existenzunsicherheiten

Zur Beschreibung der Existenzunsicherheiten eignet sich die Signalentdeckungstheorie [25], die bereits in Kapitel 2 vorgestellt wurde. Die Fähigkeit des Sensors, Objekte korrekt zu detektieren, kann als Probability of Detection (*POD*) bezeichnet werden. Detektionen sind über die Sensorsensitivität immer auch mit Fehldetektionen verbunden, welche über eine Probability of False Alarm (*PFA*) beschrieben werden. Mathematisch betrachtet ist die *POD* die konditionale Wahrscheinlichkeit der Objektdetektion *D*, bedingt darauf dass dieses Objekt existiert (Ereignis *O*):

$$POD = \Pr(D|O) \quad (1)$$

Äquivalent ist die *PFA* die konditionale Wahrscheinlichkeit der Objektdetektion *D*, bedingt darauf dass dieses nicht Objekt existiert (Ereignis \bar{O}):

$$PFA = \Pr(D|\bar{O}) \quad (2)$$

Das jeweilige Komplement ist die Wahrscheinlichkeit ein Objekt nicht zu detektieren bzw. keine Fehldetektionen auszulösen. Der Vollständigkeit halber wird an dieser Stelle auch auf

die Receiver Operating Characteristics (ROC) Kurven verwiesen [25], welche die *POD* und *PFA* in Abhängigkeit eines Detektionsgrenzwertes beschreiben. Weil es aber nicht das Ziel dieser Analyse ist die *POD* und *PFA* zu optimieren, sondern diese für eine bestimmte Konfiguration zu bestimmen, wird die Verwendung von ROC-Kurven zur Beschreibung der Existenzunsicherheiten hier nicht weiter verfolgt.

3.2. Zustandsunsicherheiten

Für Objekte, die in Realität existieren, lassen sich die Zustandsunsicherheiten über ein geeignetes statistisches Modell der Messabweichungen Δx vom „wahren“ Wert x_{Wahr} der relevanten physikalischen Messgrößen beschreiben. Dem dafür geläufigsten statistischen Modell liegt die Annahme von additiven gaußverteilten Messabweichungen zugrunde:

$$x_{Messung} = x_{Wahr} + \Delta x \quad (3)$$

$$\Delta X \sim Normal(\mu_{\Delta X}, \sigma_{\Delta X}^2) \quad (4)$$

Unter diesen Annahmen beschreibt der Mittelwert $\mu_{\Delta X}$ und die Standardabweichung $\sigma_{\Delta X}^2$ die Zustandsunsicherheit der physikalischen Größe X vollständig. Für die Bestimmung der Messabweichung Δx wird sowohl der Messwert $x_{Messung}$ als auch die Referenz x_{Wahr} benötigt. Die technischen Schwierigkeiten und die Unsicherheiten bei der Bestimmung der Referenz x_{Wahr} gehen über den Rahmen dieses Beitrages hinaus.

Es ist hinzuzufügen, dass zur Absicherung der Sensorzuverlässigkeit das Interesse hauptsächlich in extremen, seltenen Messfehlern liegt. Es ist nicht davon auszugehen, dass die Normalverteilung das Verhalten in den Extremen korrekt wiedergibt. Eventuell gibt ein anderes statistisches Modell der Messfehler das Verhalten in den Extremen besser wieder. Am Ende muss auf Basis der Daten entschieden werden, welches Modell die Zustandsunsicherheiten am besten beschreibt.

Eine Alternative zur Modellierung extremer Messfehler bietet die Extremwerttheorie [37]. Unter Verwendung des Block-Maxima-Ansatzes wird der maximale Messfehler $\max[\Delta X_1, \dots, \Delta X_n]$ von unabhängigen und gleichverteilten Messfehlern ΔX_i in einem gewissen Zeitintervall (z.B. 5 min) unter der Voraussetzung der statistischen Unabhängigkeit aufeinanderfolgender Zeitblöcke über eine Extremwertverteilung beschrieben. Durch die Fokussierung auf extreme Messabweichungen wird erreicht, dass die resultierende Statistik

von den sicherheitsrelevanten Extremwerten und nicht von den weniger relevanten kleineren Messabweichungen dominiert wird. Ein weiterer positiver Nebeneffekt besteht in der drastischen Reduktion der für die Auswertung relevanten Daten und damit des Rechenaufwands zum Lernen der Modellparameter.

3.3. Klassenunsicherheiten

Neben der Existenz- und Zustandsunsicherheit ist die Unsicherheit über die Klassifikation von Objekten zu beurteilen. Diese Klassenunsicherheit kann über eine Konfusionsmatrix beschrieben werden. Eine beispielhafte Konfusionsmatrix ist in Tabelle 1 dargestellt.

Die einzelnen Zellen enthalten jeweils die konditionale Wahrscheinlichkeit der Objektklassifikation K durch den Sensor, bedingt dass in Realität die Objektklasse R vorhanden ist. Die Konfusionsmatrix hängt mit den Existenzunsicherheiten zusammen, zum Beispiel ist die Summe über die ersten drei Zeilen der letzten Spalte in Tabelle 1 die PFA .

Tabelle 1: Konfusionsmatrix zur Beschreibung der Klassenunsicherheit (R : Objektklasse, die der Realität entspricht, K : Klassifikation des Objektes durch Sensor)

	$R = Pkw$	$R = Lkw$	$R = Fuß.$	$R = Kein Obj$
$K = Pkw$	$\Pr(K = Pkw R = Pkw)$	$\Pr(K = Pkw R = Lkw)$	$\Pr(K = Pkw R = Fuß.)$	$\Pr(K = Pkw R = Kein O.)$
$K = Lkw$	$\Pr(K = Lkw R = Pkw)$	$\Pr(K = Lkw R = Lkw)$	$\Pr(K = Lkw R = Fuß.)$	$\Pr(K = Lkw R = Kein O.)$
$K = Fuß.$	$\Pr(K = Fuß. R = Pkw)$	$\Pr(K = Fuß. R = Lkw)$	$\Pr(K = Fuß. R = Fuß.)$	$\Pr(K = Fuß. R = Kein O.)$
$K = Kein Obj.$	$\Pr(K = Kein O. R = Pkw)$	$\Pr(K = Kein O. R = Lkw)$	$\Pr(K = Kein O. R = Fuß.)$	$\Pr(K = Kein O. R = Kein O.)$

3.4. Unsicherheiten höherer Ordnung

Die letzte Unsicherheit zur Quantifizierung der Zuverlässigkeit des Fahrzeugumfeldmodells entspringt der Variabilität der bisher eingeführten Metriken, ausgelöst durch eine Abhängigkeit von den jeweiligen Umgebungsbedingungen. Am Beispiel der Zustandsunsicherheit, hier beschrieben durch die Standardabweichung $\sigma_{\Delta X}$ der Messabweichungen ΔX , ist dieser Zusammenhang in Bild 2 dargestellt. In Bild 2a ist die funktionale Beziehung zwischen $\sigma_{\Delta X}$ und den Umgebungsbedingungen dargestellt. Aus Gründen der Übersichtlichkeit wird hier lediglich der Einfluss des Niederschlags I auf die Sensorgenauigkeit betrachtet, in Realität handelt es sich aber um ein mehrdimensionales Problem mit verschiedenen Einflussfaktoren.

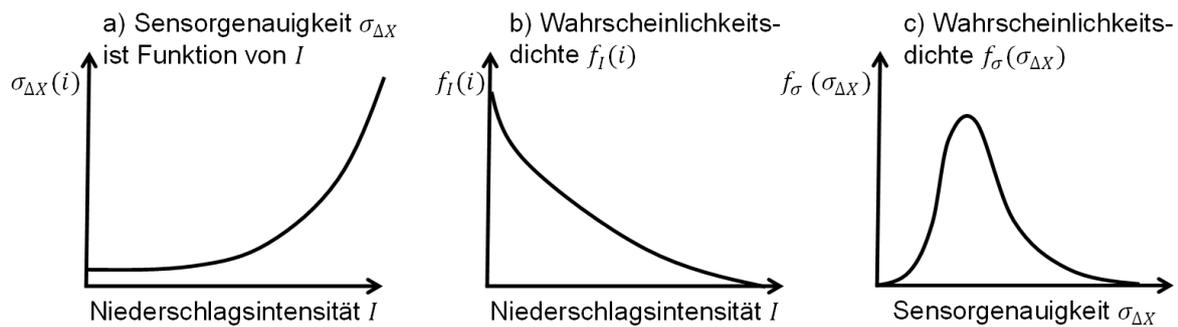


Bild 2: Schematische Darstellung der Unsicherheit höherer Ordnung am Beispiel der Zustandsunsicherheit: a) Die Sensorgenauigkeit $\sigma_{\Delta X}$ ist eine Funktion der Niederschlagsintensität I ; b) die Niederschlagsintensität I ist eine Zufallsvariable; daraus folgt c) die Sensorgenauigkeit ist selbst eine Zufallsvariable.

Wie in Bild 2a dargestellt, steigt die Variabilität der Messabweichungen $\sigma_{\Delta X}$ mit zunehmenden Niederschlag I . Der Niederschlag ist jedoch eine Zufallsvariable, die sich über eine Wahrscheinlichkeitsdichtefunktion $f_I(i)$ beschreiben lässt (Bild 2b). Aus der Kombination dieser beiden Effekte folgt, dass die Standardabweichung $\sigma_{\Delta X}$ selbst eine Zufallsvariable ist (Bild 2c). Die Verteilungsfunktion $f_\sigma(\sigma_{\Delta X})$ beschreibt diese Variabilität und damit die Unsicherheit höherer Ordnung. Es ist zu betonen, dass Bild 2c nicht die statistische Unsicherheit von $\sigma_{\Delta X}$ darstellt, sondern die tatsächliche Variabilität von $\sigma_{\Delta X}$.

Die in Bild 2 dargestellten Überlegungen lassen sich äquivalent auf die Existenz- und Klassenunsicherheit übertragen. Mit eingeführten Metriken in diesem Kapitel lassen sich die Unsicherheiten im Fahrzeugumfeldmodell innerhalb der gegebenen Modellannahmen vollständig beschreiben.

4. Hierarchische Bayes'sche Regression: Quantifizierung der Sensorzuverlässigkeit

Um die Zuverlässigkeitsmetriken aus Daten zu lernen, sind Erprobungsfahrten im Fahrzeug und Tests mit den Sensoren notwendig. Für das Lernen der Modellparameter mit einfachen Schätzmethoden ist es aber eine Voraussetzung, dass die Stichproben (z.B. Messfehler Δx_i) unabhängig und identisch verteilt sind. Weil variable Umgebungsbedingungen wie der Niederschlag jeweils über gewisse Zeitabschnitte vorliegen, sind diese Bedingungen jedoch nicht erfüllt. Fehler, wie zum Beispiel hohe Messabweichungen Δx , können miteinander korreliert sein und die Messzeitreihe weist dann eine Abhängigkeitsstruktur auf. Ebenfalls wurde bereits am Beispiel der Zustandsunsicherheiten (Bild 2) erklärt, dass die Messfehler

ΔX_i nicht identisch verteilt sind, sondern in Abhängigkeit von den Umgebungsbedingungen variable Verteilungsparameter $\sigma_{\Delta X}$ haben.

Um diese Problematik zu lösen und eine funktionale Beziehung zwischen den Umgebungsbedingungen und den Unsicherheiten im Fahrzeugumfeldmodell herzustellen, schlagen wir ein hierarchisches Bayes'sches Regressionmodell vor. Eine Einführung zur hierarchischen Regression kann [38] entnommen werden. Darauf gründen sich die nachfolgenden Überlegungen. Die Idee der hierarchischen Regression ist in Bild 3 dargestellt.

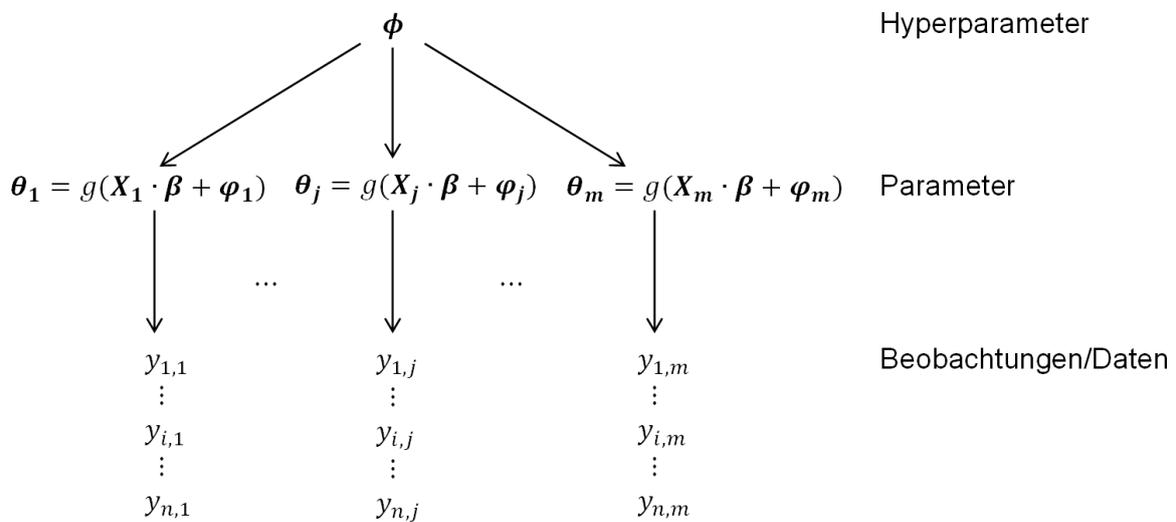


Bild 3: Struktur des hierarchischen Regressionsmodells: Die Beobachtungen/Daten $y_{i,j}$ im Zeitabschnitt j (Bsp. 30 s Intervall) haben gemeinsame Verteilungsparameter θ_j welche eine Funktion $g(\cdot)$ der Umgebungsbedingungen $X_j \cdot \beta$ und unbekanntem Zufallseffekten φ_j sind. Die Zufallseffekte werden als Stichproben einer gemeinsamen Verteilung angesehen, welche durch die Hyperparameter ϕ beschrieben wird.

Unter der Annahme, dass sich die Umgebungsbedingungen in kurzen Zeitabschnitten nicht ändern, unterteilen wir die Messreihe zunächst in Zeitblöcke $j \in \{1, \dots, m\}$ konstanter Dauer t und gruppieren entsprechend alle Daten y in die jeweiligen Blöcke ein. In Bild 3 entspricht $y_{i,j}$ dem Datenpunkt $i \in \{1, \dots, n\}$ im Zeitblock $j \in \{1, \dots, m\}$. Abhängig von der Dauer der Zeitreihe und der gewählten Blockdauer erhält man m Zeitblöcke mit n Datenpunkten. Innerhalb eines Zeitblocks j werden die Daten $y_{i,j}$ $i \in \{1, \dots, n\}$ mit einer gemeinsamen Stichprobenverteilung $f(y_{i,j}|\theta_j)$ mit Verteilungsparametern θ_j modelliert:

$$y_{i,j}|\theta_j \sim f(y_{i,j}|\theta_j) \quad (5)$$

Zusätzlich wird eine funktionale Beziehung $g(\cdot)$ zwischen der Ausprägung X_j der Umgebung des Zeitblocks j und den Parametern θ_j hergestellt:

$$\theta_j = g(X_j \cdot \beta + \varphi_j) \quad (6)$$

X_j enthält dabei Informationen über Umgebungsbedingungen wie beispielsweise Niederschlag, Temperatur und Gischt, welche bei Tests und Erprobungsfahrten mit erfasst werden. Der Vektor β enthält die Regressionskoeffizienten, welche den Einfluss der verschiedenen Umgebungseinflüsse quantifizieren. Weil es nicht möglich ist, alle relevanten Umgebungsbedingungen in den Erprobungen zu erfassen, bleibt für jeden Zeitblock ein Zufallseffekt φ_j übrig. Für den Zufallseffekt φ_j gelten die gleichen Überlegungen zu den Unsicherheiten höherer Ordnung wie in Kapitel 4.4 am Beispiel von $\sigma_{\Delta X}$ diskutiert. Der Zufallseffekt φ_j enthält den Teil der Stichprobenparameter θ_j , der nicht über die Kenntnis der Umgebungsausprägung X_j erklärt werden kann und repräsentiert damit die Auswirkung der Variabilität der nicht in X enthaltenen Umgebungsbedingungen auf den Sensor. Ausgehend von den Überlegungen zu den Unsicherheiten höherer Ordnung können die Zufallseffekte φ_j der einzelnen Zeitblöcke j als Stichproben einer gemeinsamen Superpopulation $f(\varphi_j|\phi)$ angesehen werden:

$$\varphi_j|\phi \sim f(\varphi_j|\phi) \quad (7)$$

Dabei sind ϕ die Hyperparameter, welche die Unsicherheit höherer Ordnung beschreiben. Mit dem hierarchischen Regressionsmodell soll sichergestellt werden, dass für einen gegebenen Zeitblock j mit gegebenen Parameter $\theta_j = g(X_j \cdot \beta + \varphi_j)$ die Daten $y_{i,j}$ näherungsweise konditional unabhängig und identisch verteilt sind. Dadurch wird die Unsicherheiten höherer Ordnung und die Abhängigkeitsstruktur der Daten mathematisch berücksichtigt. Für eine gegebene Zeitreihe mit Daten y und den jeweiligen Umgebungsbedingungen X können dann die Modellparameter β, φ, ϕ mit dem Ansatz nach Bayes gelernt werden:

$$f(\beta, \varphi, \phi|y, X) \propto f(\beta) \cdot f(\phi) \cdot \prod_{j=1}^m f(\varphi_j|\phi) \prod_{i=1}^n f(y_{i,j}|\varphi_j, X_j, \beta) \quad (8)$$

Dabei ist $f(\beta, \varphi, \phi|y, X)$ die a posteriori Verteilung der Modellparameter β, φ, ϕ für gegebene Beobachtungen y und Umgebungsbedingungen X , $f(\beta)$ und $f(\phi)$ sind die a priori Verteilungen der Regressionskoeffizienten und der Hyperparameter, $f(\varphi_j|\phi)$ ist die

Likelihood der Zufallseffekte φ_j und $f(y_{i,j}|\varphi_j, X_j, \beta)$ ist die Likelihood der Beobachtungen $y_{i,j}$.

5. Fallstudie: Einfluss der Temperatur auf die Sensorgenauigkeit

Zur Illustration des vorgestellten hierarchischen Modells wurde ein einfacher Versuch mit einem LIDAR-Sensor durchgeführt. Bei dem Sensor handelt es sich um einen Laserscanner mit einem mechanisch bewegtem Spiegel, über den die Raumrichtung sowohl der Sendepulse als auch der Empfangspulse eingestellt werden [39]. Ziel des Versuchs war die exemplarische Quantifizierung des Einflusses von erhöhten Temperaturen auf die Sensorleistungsfähigkeit in Form von Positionsmessabweichungen. Dazu wurde eine Heizmatte am Sensorgehäuse befestigt, um erhöhte Temperaturen im Sensor zu erzeugen.

5.1. Versuchsaufbau und Modellbeschreibung

Zur Erfassung der Positionsgenauigkeit wurde ein Fahrzeug mit dem Sensor im Abstand von 37,84 m senkrecht zu einer Holzwand abgestellt. Der Abstand wurde im Laufe des Versuchs nicht verändert, es handelt sich also um einen statischen Versuch. Der Einfallswinkel zwischen dem Laserstrahl mit Strahlrichtung 0° und der Wand betrug näherungsweise 0° . Das Wetter zum Zeitpunkt des Versuchs war bewölkt ohne Niederschlag, ein wetterinduzierter Einfluss ist also nicht zu erwarten. Insgesamt wurden 24 min 36 s Messungen aufgezeichnet, wobei während des Versuchs das Sensorgehäuse aufgeheizt wurde. Der beispielhafte zeitliche Verlauf der Positionsabweichungen Δx der Wand senkrecht zum Sensor, auf Objektdatenebene, ist in Bild 4a dargestellt. Zusätzlich zeigt Bild 4b den Verlauf der Gehäusetemperatur über die Zeit, wobei die Temperatur in willkürlichen Einheiten dargestellt ist.

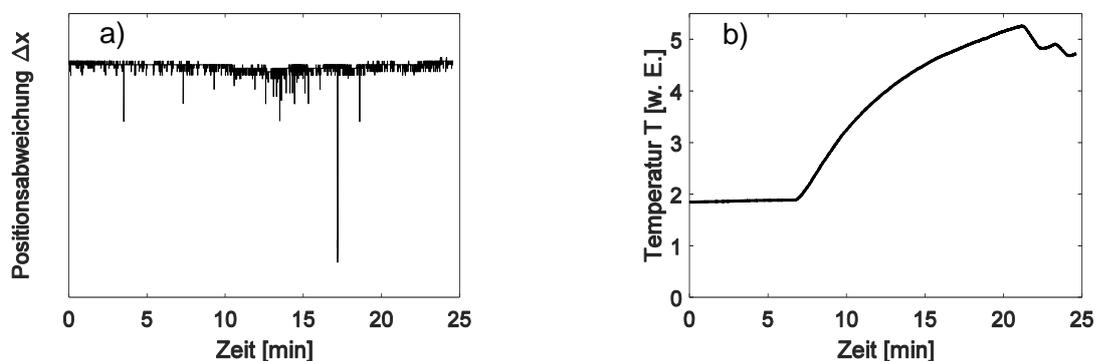


Bild 4: a) Beispielhafte Zeitreihe der Positionsabweichungen Δx und b) Verlauf der Sensortemperatur T in willkürlichen Einheiten [w. E.].

Eine erste visuelle Inspektion der Positionsabweichungen durch einen Vergleich von Bild 4a mit Bild 4b lässt keine offensichtliche Temperaturabhängigkeit erkennen. Dennoch wird nachfolgend der Einfluss der Temperatur mit einem hierarchischen Regressionsmodell näher untersucht. Dazu werden alle Positionsabweichungen in Blöcke mit einer Blockdauer von $t = 30$ s eingruppiert, insgesamt resultieren daraus 50 Blöcke. Wir modellieren die Abweichung $\Delta x_{i,j}$ der Position (in senkrechter Richtung zum Sensor) im Block j durch eine Normalverteilung mit Mittelwert $\mu_{\Delta X,j}$ und einer Standardabweichung $\sigma_{\Delta X,j}$:

$$\Delta x_{i,j} | \mu_{\Delta X,j}, \sigma_{\Delta X,j} \sim N(\mu_{\Delta X,j}, \sigma_{\Delta X,j}^2) \quad (9)$$

Die Mittelwerte $\mu_{\Delta X,j}$ der einzelnen Blöcke werden als Stichproben einer normalverteilten Superpopulation mit Hyperparametern μ_μ und σ_μ angesehen. μ_μ ist dabei der gemeinsame Mittelwert und σ_μ die Standardabweichung der Mittelwerte $\mu_{\Delta X,j}$ der einzelnen Blöcke j :

$$\mu_{\Delta X,j} | \mu_\mu, \sigma_\mu \sim N(\mu_\mu, \sigma_\mu^2) \quad (10)$$

Die Standardabweichung $\sigma_{\Delta X,j}$ der einzelnen Blöcke j wird als Funktion eines konstanten Einflusses β_0 , in Abhängigkeit der Temperatur T mit Einfluss β_1 und einem blockspezifischen Zufallseffekt φ_j modelliert. Aus mathematischen Gründen normieren wir dabei die Temperaturdaten aus Bild 4b so, dass $T_{normiert}$ einen Mittelwert von 0 und eine Standardabweichung von 1 aufweist:

$$\sigma_{\Delta X,j} = \sqrt{\exp(-\beta_0 - \beta_1 \cdot T_{normiert} - \varphi_j)} \quad (11)$$

Die Exponentialfunktion in Formel 11 stellt sicher, dass $\sigma_{\Delta X,j}$ nur positive Werte annimmt. Der Zufallseffekt φ_j wird ebenfalls als normalverteilt mit Hyperparameter $\sigma_\varphi^2 = 1/\tau_\varphi$ angenommen:

$$\varphi_j | \tau_\varphi \sim N(0, 1/\tau_\varphi) \quad (12)$$

Für alle Modellparameter werden nichtinformative a priori Verteilungen gewählt. Zum Lernen der Modellparameter wird die Software OpenBugs [40] unter Verwendung von Markov Chain Monte Carlo (siehe beispielsweise [41]) benutzt.

5.2. Ergebnisse

Dieses Kapitel beschreibt beispielhaft die Auswertung und die Ergebnisse des in Kapitel 5.1 beschriebenen Versuchs mit den zugehörigen statistischen Modellannahmen. Es ist

anzumerken, dass die Ergebnisse hier mit willkürlichen Einheiten [w. E.] wiedergegeben werden und dadurch auch nur qualitative Aussagekraft besitzen. Bild 5a stellt die Ergebnisse der Parameterschätzung der mittleren Positionsabweichungen $\mu_{\Delta X, j}$ dar.

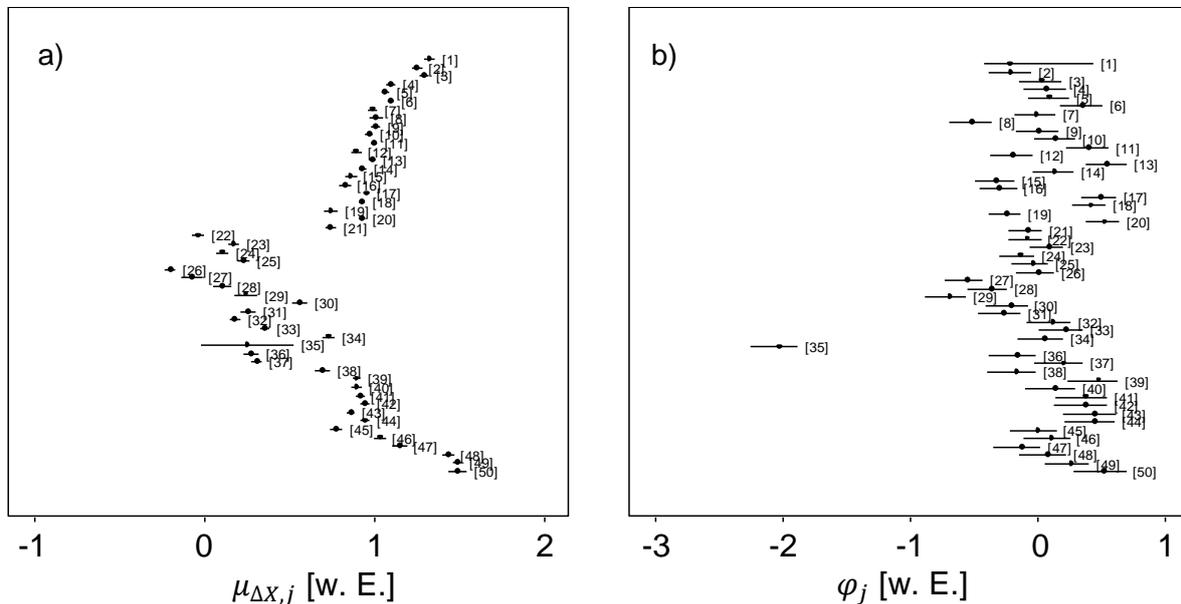


Bild 5: Caterpillar plots a) der Mittelwerte der Positionsabweichung $\mu_{\Delta X, j}$ und b) der Zufallseffekte φ_j für alle Blöcke $j \in \{1, \dots, 50\}$. Die Punkte repräsentieren die a posteriori Mittelwerte und die Striche die 95% credible intervals.

Ein hier nicht gezeigter Vergleich mit den empirischen Mittelwerten zeigt, dass das Bayes'sche hierarchische Modell die Mittelwerte korrekt schätzt. Die Unsicherheiten, ausgedrückt durch die 95% credible intervals (Striche in Bild 5) der Parameterschätzung sind für die Mittelwerte $\mu_{\Delta X, j}$ allgemein klein. Eine Ausnahme stellt Block $j = 35$ dar, in welchem eine ungewöhnlich große Positionsabweichung beobachtet wurde. Da die Positionsabweichungen sonst viel kleiner sind, entsteht dadurch eine größere Unsicherheit in der Schätzung von $\mu_{\Delta X, 35}$. Der globale Mittelwert μ_μ ausgedrückt in den Einheiten von Bild 5a wird zu 0,76 mit einem 95% credible interval von $[0,64; 0,88]$ geschätzt. Ein visueller Vergleich von Bild 5a mit dem Verlauf der Temperatur Bild 4b lässt eine quadratische Abhängigkeit zwischen $\mu_{\Delta X, j}$ und der Temperatur vermuten. Dieser Effekt wird hier jedoch nicht weiter untersucht, weil die Schwankung der mittleren Positionsabweichung $\mu_{\Delta X}$ in absoluten Werten zunächst vernachlässigbar ist. Für Anwendungsfälle, die über die veranschaulichenden Zwecke dieser Präsentation hinausgehen, sollte dieser Effekt jedoch auch Berücksichtigung finden.

Um Aussagen über die sicherheitsrelevante Performance treffen zu können, wird stattdessen der funktionale Zusammenhang zwischen der Standardabweichung $\sigma_{\Delta X, j}$ der Positionsabweichung und der Temperatur (siehe Formel 11) weiter untersucht. Eine zentrale Bedeutung hat dabei die Frage, ob die Temperatur die Variabilität der Positionsabweichung wesentlich beeinflusst. Die Ergebnisse der Parameterschätzung sind in Tabelle 2 zusammengefasst. Es zeigt sich, dass die Temperatur T durchaus einen Einfluss auf die Standardabweichung $\sigma_{\Delta X, j}$ der Positionsabweichung hat, da β_1 (siehe Formel 11) nicht zu Null geschätzt wird.

Tabelle 2: Ergebnisse der Parameterschätzung mit dem Programm OpenBugs [40]

Parameter	Mittelwert	2,5% Quantil	Median	97,5% Quantil
β_0 [w. E.]	1	0,968	1	1,039
β_1 [-]	-0,315	-0,556	-0,318	-0,098
φ_2 [w. E.]	-0,204	-0,396	0,202	0,031
φ_{35} [w. E.]	-2,056	2,270	-2,049	-1,893
τ_φ [w. E.]	5,508	3,532	5,432	7,952
μ_μ [w. E.]	0,76	0,64	0,76	0,88
σ_μ [w. E.]	0,44	0,38	0,46	0,56

Zur Visualisierung des Temperatureinflusses wird in Bild 6a die funktionale Beziehung zwischen der (nicht normierten) Temperatur T und $\sigma_{\Delta X, j}$ dargestellt. Die gefundene Beziehung gibt die empirischen Standardabweichungen $\sigma_{\Delta X, j}$ tendenziell gut wieder. Die zusätzliche Streuung in den beobachteten $\sigma_{\Delta X, j}$ um die gefundene Abhängigkeit sind durch den Zufallseffekt φ_j erklärt. Um ausschließlich den Effekt der Temperatur darzustellen, beinhalten die in Bild 6a gezeigten credible intervals nicht den Einfluss der Zufallseffekte φ_j . Diese haben unter Annahme des a posteriori Mittelwertes von $\tau_\varphi = 5,508$ [w. E.] mit 95% Wahrscheinlichkeit einen multiplikativen Einfluss zwischen 0.66 und 1.52 auf $\sigma_{\Delta X, j}$. D.h. die Zufallseffekte φ_j bestimmen die Streuung von $\sigma_{\Delta X, j}$ um die in Bild 6a gezeigte Beziehung.

Die Schätzung aller Zufallseffekte φ_j ist in Bild 5b dargestellt. Die hohe Variabilität in Block $j = 35$, ausgelöst durch die hohe Positionsabweichung in diesem Block, ist nicht durch den Temperatureinfluss zu erklären, sondern durch einen hohen Zufallseffekt $\varphi_{35} = -2,06$ (dies entspricht einer Erhöhung der Standardabweichung $\sigma_{\Delta X, 35}$ um den Faktor 2,79). Eine

genauere Überprüfung der Daten von Block 35 zeigt in der Tat, dass der Fehler in der Objektbildung zu finden ist und nicht auf den Einfluss der Temperatur zurückzuführen ist.

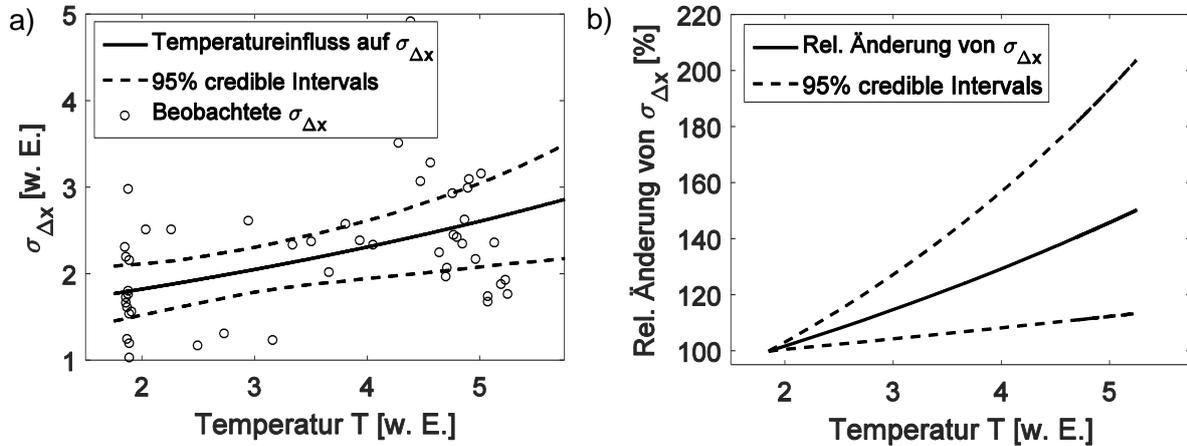


Bild 6: a) Einfluss der Temperatur auf die Standardabweichung $\sigma_{\Delta X,j}$ der Positionsabweichungen ΔX . Die 95% credible intervals geben die a posteriori Unsicherheit im konstanten Einfluss β_0 und im Temperatureinfluss β_1 an. b) Relative Änderung der Standardabweichung $\sigma_{\Delta X,j}$ mit der Temperatur. Die 95% credible intervals beziehen sich ausschließlich auf den Temperatureinfluss β_1 .

Abschließend wird in Bild 6b die relative Änderung der Standardabweichung $\sigma_{\Delta X,j}$ mit der Temperatur T dargestellt. Durch eine Steigerung der Gehäusetemperatur von 1.85 [w. E.] auf 5 [w. E.] nimmt die Standardabweichung $\sigma_{\Delta X}$ der Positionsabweichung ΔX im Mittel um 46% zu.

6. Zusammenfassung und Ausblick

Der Nachweis der Sensorzuverlässigkeit stellt einen wichtigen Schritt bei der Absicherung von Fahrerassistenzsystemen dar. Eine genaue Kenntnis der Sensorleistungsfähigkeit ist eine wesentliche Grundvoraussetzung für die Absicherung von Fahrerassistenzsystemen.

In diesem Beitrag werden umfassende Metriken für die Beschreibung der Sensorzuverlässigkeit eingeführt. Wichtig ist dabei die Berücksichtigung von Unsicherheiten höherer Ordnung, ausgelöst durch variable Umgebungseinflüsse wie etwa der Temperatur. Ein hierarchisches Regressionsmodell auf Basis der Bayes'schen Statistik erlaubt es, die Einflüsse der Umgebung und die Unsicherheiten höherer Ordnung zu quantifizieren. Die Nützlichkeit dieses Ansatzes wird in einer Fallstudie zur Untersuchung des Einflusses

erhöhter Temperaturen auf die Sensorleistungsfähigkeit gezeigt. Der geringe Umfang des dargestellten Versuchs erlaubt es jedoch nicht, weitreichende, sicherheitsrelevante Aussagen über die globale Sensorzuverlässigkeit tätigen zu können. Die hier präsentierten Methoden können aber als ein Schritt in Richtung zuverlässigkeitsbasierter Absicherung der Sensorik und der Fahrerassistenzsysteme verstanden werden.

Um Aussagen über die Sensorzuverlässigkeit mit den hier dargestellten Methoden treffen zu können, sind vor allem ausführlichere Tests mit mehreren Umgebungseinflüssen und auch Erprobungen in realen Fahrsituationen notwendig. Ebenfalls ist zu beachten, wie bereits in Kapitel 3.2 erläutert, dass bei der Sensorabsicherung das Interesse vor allem in den Extremwerten (beispielsweise der Positionsabweichungen) liegt. Methoden der Extremwerttheorie erlauben es, sich auf diese für die Sicherheitsrelevanz entscheidenden Werte zu fokussieren, wodurch die Statistik nicht mehr von nicht-extremen Werten dominiert wird. Bei Zeitreihen größeren Umfanges ist es eventuell sinnvoll das hierarchische Modell entsprechend auf die Extremwerttheorie abzustimmen.

Die Ergebnisse der hierarchischen Regression sind die Grundlage, aber noch nicht das finale Ergebnis der Zuverlässigkeitsanalyse von umfelderfassender Sensorik. Im weiteren Projektverlauf ist es geplant, stochastische Methoden auf der Basis Bayes'scher Netzwerke zu entwickeln, die in Kombination mit den Ergebnissen der hierarchischen Regression einen prädiktiven Nachweis der Sensorzuverlässigkeit erlauben. Mit einem solchem Vorgehen lässt sich voraussichtlich die Sensorzuverlässigkeit mit deutlich weniger Fahrkilometern nachweisen, als bei empirischen Erprobungsfahrten notwendig wäre [23].

Literaturangaben

- [1] Kammel, S., Ziegler, J., Pitzer, B., Werling, M., Gindele, T., Jagzent, D., Schröder, J., Thuy, M., Goebel, M., Hundelshausen, F. v., Pink, O., Frese, C. u. Stiller, C.: Team AnnieWAY's autonomous system for the 2007 DARPA Urban Challenge. *Journal of Field Robotics* 25 (2008) 9, S. 615–639
- [2] Guizzo, E.: How google's self-driving car works. *IEEE Spectrum Online*, October 18 (2011)
- [3] Franke, U., Pfeiffer, D., Rabe, C., Knoepfel, C., Enzweiler, M., Stein, F. u. Herrtwich, R. G.: Making Bertha See. 2013 IEEE International Conference on Computer Vision Workshops (ICCVW). 2013, S. 214–221

- [4] Aeberhard, M., Rauch, S., Bahram, M., Tanzmeister, G., Thomas, J., Pilat, Y., Homm, F., Huber, W. u. Kaempchen, N.: Experience, Results and Lessons Learned from Automated Driving on Germany's Highways. *IEEE Intelligent Transportation Systems Magazine* 7 (2015) 1, S. 42–57
- [5] Audi: Mission accomplished: Audi A7 piloted driving car completes 550-mile automated test drive, 2015. <https://www.audiusa.com/newsroom/news/press-releases/2015/01/550-mile-piloted-drive-from-silicon-valley-to-las-vegas>, abgerufen am: 25.02.2016
- [6] Broggi, A., Debattisti, S., Grisleri, P. u. Panciroli, M.: The deeva autonomous vehicle platform. 2015 IEEE Intelligent Vehicles Symposium (IV), S. 692–699
- [7] Google: Google Self-Driving Car Project, 2015. <http://static.googleusercontent.com/media/www.google.com/en/us/selfdrivingcar/>, abgerufen am: 25.02.2016
- [8] Beiker, A. S.: Einführungsszenarien für höhergradig automatisierte Straßenfahrzeuge. In: Maurer, M., Gerdes, C. J., Lenz, B. u. Winner, H. (Hrsg.): *Autonomes Fahren: Technische, rechtliche und gesellschaftliche Aspekte*. Berlin, Heidelberg: Springer Berlin Heidelberg 2015, S. 197–217
- [9] Gasser, T. M., Arzt, C., Ayoubi, M., Bartels, A., Bürkle, L., Eier, J., Flemisch, F., Häcker, D., Hesse, T., Huber, W., Lotz, C., Maurer, M., Ruth-Schumacher, S., Schwarz, J. u. Vogt, W.: Rechtsfolgen zunehmender Fahrzeugautomatisierung. *Gemeinsamer Schlussbericht der Projektgruppe. Berichte der Bundesanstalt für Straßenwesen: Fahrzeugtechnik*, Bd. 83. Bremerhaven: Wirtschaftsverl. NW Verl. für Neue Wiss 2012
- [10] Bernhart, W.: *Autonomes Fahren Märkte, Treiber und Geschäftsmodelle*. *ATZelektronik* 11 (2016) 2, S. 36–41
- [11] Auto Zeitung: Audi A8 (2017): Neuer A8 mit Staupilot. Neuer A8 fährt bis 60 km/h selbst, 2016. <http://www.autozeitung.de/auto-news/audi-a8-2017-staupilot>, abgerufen am: 22.06.2016
- [12] Auto Express: Audi A8 could get posher and longer to rival Maybach, 2016. <http://www.autoexpress.co.uk/audi/a8/95433/audi-a8-could-get-posher-and-longer-to-rival-maybach>, abgerufen am: 05.07.2016
- [13] 2010. *IEEE Standard Framework for Reliability Prediction of Hardware*
- [14] IEEE guide for selecting and using reliability predictions based on IEEE 1413. New York, N.Y.: Institute of Electrical and Electronics Engineers 2003
- [15] 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

- [16] 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
- [17] Sensor data integrity: Multi-sensor perception for unmanned ground vehicles, Peynot, T., Terho, S. u. Scheduling, S., Sydney Australia 2009
- [18] Pascoal, J., Marques, L. u. Almeida, A. T. de: Assessment of Laser Range Finders in risky environments. 2008 IEEE/RSJ International Conference on Intelligent Robots and Systems. 2008, S. 3533–3538
- [19] Ishimaru, A.: Wave propagation and scattering in random media and rough surfaces. *Proceedings of the IEEE* 79 (1991) 10, S. 1359–1366
- [20] Blevis, B.: Losses due to rain on radomes and antenna reflecting surfaces. *IEEE Transactions on Antennas and Propagation* 13 (1965) 1, S. 175–176
- [21] International Standard. *ISO 26262:2011(E) Road vehicles - Functional safety*
- [22] Wachenfeld, W. u. Winner, H.: Die Freigabe des autonomen Fahrens. In: Maurer, M., Gerdes, J. C., Lenz, B. u. Winner, H. (Hrsg.): *Autonomes Fahren*. Berlin, Heidelberg: Springer Berlin Heidelberg 2015, S. 439–464
- [23] Winner, H.: Quo vadis, FAS? In: Winner, H., Hakuli, S., Lotz, F. u. Singer, C. (Hrsg.): *Handbuch Fahrerassistenzsysteme*. Wiesbaden: Springer Fachmedien Wiesbaden 2015, S. 1167–1186
- [24] Gotzig, H. u. Geduld, G. O.: LIDAR-Sensorik. In: Winner, H., Hakuli, S., Lotz, F. u. Singer, C. (Hrsg.): *Handbuch Fahrerassistenzsysteme*. Wiesbaden: Springer Fachmedien Wiesbaden 2015, S. 317–334
- [25] 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
- [26] Schoefs, F., Clément, A. u. Nouy, A.: Assessment of ROC curves for inspection of random fields. *Structural Safety* 31 (2009) 5, S. 409–419
- [27] Sättele, M., Bründl, M. u. Straub, D.: Reliability and effectiveness of early warning systems for natural hazards: Concept and application to debris flow warning. *Reliability Engineering & System Safety* 142 (2015), S. 192–202
- [28] Zweig, M. H. u. Campbell, G.: Receiver-operating characteristic (ROC) plots: a fundamental evaluation tool in clinical medicine. *Clinical chemistry* 39 (1993) 4, S. 561–577

- [29] Alfieri, L., Thielen, J. u. Pappenberger, F.: Ensemble hydro-meteorological simulation for flash flood early detection in southern Switzerland. *Journal of Hydrology* 424 (2012), S. 143–153
- [30] Zheng, P. u. McDonald, M.: The effect of sensor errors on the performance of collision warning systems. 2003 IEEE International Conference on Intelligent Transportation Systems. 2003, S. 469–474
- [31] Ye, C. u. Borenstein, J.: Characterization of a 2D laser scanner for mobile robot obstacle negotiation. 2002 IEEE International Conference on Robotics and Automation. 2002, S. 2512–2518
- [32] Kneip, L., Tache, F., Caprari, G. u. Siegwart, R.: Characterization of the compact Hokuyo URG-04LX 2D laser range scanner. 2009 IEEE International Conference on Robotics and Automation (ICRA). 2009, S. 1447–1454
- [33] Lee, K.-H. u. Ehsani, R.: Comparison of two 2D laser scanners for sensing object distances, shapes, and surface patterns. *Computers and Electronics in Agriculture* 60 (2008) 2, S. 250–262
- [34] Dietmayer, K., Nuß, D. u. Reuter, S.: Repräsentation fusionierter Umfelddaten. In: Winner, H., Hakuli, S., Lotz, F. u. Singer, C. (Hrsg.): *Handbuch Fahrerassistenzsysteme*. Wiesbaden: Springer Fachmedien Wiesbaden 2015, S. 453–480
- [35] Darms, M.: Fusion umfelderfassender Sensoren. In: Winner, H., Hakuli, S., Lotz, F. u. Singer, C. (Hrsg.): *Handbuch Fahrerassistenzsysteme*. Wiesbaden: Springer Fachmedien Wiesbaden 2015, S. 439–451
- [36] Dietmayer, K.: Prädiktion von maschineller Wahrnehmungsleistung beim automatisierten Fahren. In: Maurer, M., Gerdes, J. C., Lenz, B. u. Winner, H. (Hrsg.): *Autonomes Fahren*. Berlin, Heidelberg: Springer Berlin Heidelberg 2015, S. 419–438
- [37] Coles, S.: *An Introduction to Statistical Modeling of Extreme Values*. Springer Series in Statistics. London: Springer London : Imprint: Springer 2001
- [38] Gelman, A., Carlin, J. B., Stern, H. S. u. Rubin, D. B.: *Bayesian data analysis*. Texts in statistical science. Boca Raton, Fla.: Chapman & Hall 2004
- [39] Barth, H.: *LiDAR Technology for Active Safety and Automated Driving*. 3. VDI-Konferenz - Automatisiertes Fahren. 2016
- [40] Lunn, D., Spiegelhalter, D., Thomas, A. u. Best, N.: The BUGS project: Evolution, critique and future directions. *Statistics in medicine* 28 (2009) 25, S. 3049–3067
- [41] Brooks, S.: Markov chain Monte Carlo method and its application. *Journal of the Royal Statistical Society: Series D (The Statistician)* 47 (1998) 1, S. 69–100