

Prädiktive Situationsanalyse auf Basis verteilter Fahrzeuginformationen

Markus Strassberger
BMW Group Forschung und Technik
Markus.Strassberger@bmw.de

Abstract—Je detaillierter ein Fahrer über den Streckenabschnitt informiert ist, den er in naher Zukunft befahren wird, desto größer ist die Wahrscheinlichkeit, dass er rechtzeitig und angemessen auf komplexe Verkehrssituationen reagiert. Die umfassende Verfügbarkeit von qualitativ hochwertigen Kontextinformationen im Fahrzeug leistet vor diesem Hintergrund einen wichtigen Beitrag zur Erhöhung der Verkehrssicherheit und -effizienz. Dieser Beitrag beschreibt in diesem Zusammenhang einen zweistufigen Bewertungsprozess, der es erlaubt, auf Basis verteilter Sensorbeobachtungen unterschiedlicher Fahrzeuge ein Wahrscheinlichkeitsmaß für das Eintreten eines konkreten Zustands eines relevanten Fahrkontexts abzuleiten. Die räumlichen und zeitlichen Eigenschaften des Kontextaspekts werden dabei gewichtet interpoliert. Anschließend werden auf Basis eines Bayesschen Netzes die kausalen Zusammenhänge unterschiedlicher Kontextaspekte quervalidiert. Das vorgestellte Verfahren erlaubt so die Detektion und Vorhersage von kritischen Verkehrssituationen unter Beachtung der räumlichen und zeitlichen Wechselwirkungen der einzelnen Fahraspekte.

Abstract—Driver Assistance Systems are the key technology to improve traffic safety and lower the number of deadly accidents. Direct communication between cars will further enhance this field of driver safety. In the context of foresighted driving, Bayesian networks can be used to determine a traffic situation at the current position of a car. Communicating this awareness for the current time and position will help other traffic participants. However, situations change dynamically and cars cannot trust all the information provided by other cars over time. Reasoning with this information is difficult as Bayesian networks cannot use spatial and temporal data in an appropriate way. This article outlines the spatial and temporal problems in car-2-car-communication and demonstrates how they can be solved by considering spatial and temporal influences by applying interpolation techniques. The pre-processed information is utilized again by a Bayesian network for further refinement. Thus, the proposed approach enables the detection and correct prediction of traffic situations using the spatial and temporal aspects of information sources. The approach is evaluated by predicting hazard situations in a car by means of information received from other cars.

I. EINLEITUNG UND MOTIVATION

Menschliche Fehler können in komplexen Verkehrssituationen nicht vollständig ausgeschlossen werden. Deshalb ist es umso entscheidender, durch eine gezielte Gestaltung der Rahmenbedingungen die auf den Fahrer einwirkende Komplexität des Verkehrsgeschehens zu minimieren. Neben straßenbaulichen Maßnahmen spielen dabei vor allem weiterführende Assistenzkonzepte in den Fahrzeugen eine entscheidende

Rolle. Die Aufmerksamkeit der Fahrer soll in komplexen Verkehrssituationen gezielt auf relevante Sachverhalte und mögliche Gefährdungspotentiale gelenkt werden. Je genauer der Fahrer über den Streckenabschnitt informiert ist, den er in naher Zukunft befahren wird, desto größer ist die Wahrscheinlichkeit, dass er rechtzeitig und angemessen auf die entsprechende Situation reagiert.

Daher setzt man seit einigen Jahren in zunehmendem Maße auf Assistenzsysteme, die die unmittelbare Fahrzeugumgebung erfassen und so frühzeitig agieren können. Als Basis hierzu dienen in der Regel dedizierte Sensorsysteme wie Radar, Lidar, Ultraschall oder Bilderkennungsverfahren.

Eine vielversprechende und kostengünstige Ergänzung zu derartigen Sensorsystemen ist die Vernetzung von Fahrzeugen (siehe hierzu beispielsweise [1]). Kernidee hierbei ist, dass viele moderne Fahrzeuge schon heute über die notwendige Sensorik verfügen, um zumindest ihre aktuelle Fahrsituation bzw. ihren aktuellen Fahrkontext hinreichend genau zu bestimmen. Erkennt ein Fahrzeug beispielsweise eine Gefahrensituation, kann es diese Erkenntnis anderen Fahrzeugen unmittelbar zur Verfügung stellen. Fahrzeuge haben auf diese Weise die Möglichkeit, den Fahrkontext der umgebenden Fahrzeuge mit zu verarbeiten. Dies ermöglicht wiederum eine erweiterte Vorausschau der zukünftigen Fahrsituation in Regionen, die von Sensorsystem nicht erfasst werden können und erzielen so eine entscheidende Vergrößerung des Handlungszeitraums.

Die bisher gängigen Sensorsysteme ermöglichen bisher lediglich individuelle und lokale Rückschlüsse der eigenen Fahrsituation. Ihre Gültigkeit beschränkt sich auf den Ort und den Zeitpunkt der Detektion, sowie gegebenenfalls auf die Konfiguration des beobachtenden Fahrzeugs.

II. KOOPERATIVE INFERENZ DER FAHRSITUATIONEN AUF BASIS RÄUMLICH UND ZEITLICH VERTEILTER BEOBACHTUNGEN

Ziel ist es, darauf aufbauend mögliche kritische Situationen zu erkennen und anderen Fahrzeugen verfügbar zu machen. Aufgrund der fortlaufenden dynamischen Veränderung der diese Situationen bestimmenden Kontextaspekte über die Zeit reicht dabei eine einmalige Beobachtung nicht aus. Vielmehr müssen fortlaufend relevante Beobachtungen ausgetauscht werden, um bekannte Gefährdungspotentiale hinsichtlich ihrer weiteren Gültigkeit validieren oder gegebenenfalls falsifizieren zu können. Dies gilt insbesondere auch vor dem Hintergrund, dass bestimmte Gefahrenpotenziale wie beispielsweise

Fahrbahnhindernisse von einzelnen Fahrzeugen individuell oft nicht mit ausreichender Sicherheit festgestellt werden können. Mehrere ähnliche unabhängige und sich daher gegenseitig in ihrer Hypothese stützende Beobachtungen erhöhen jedoch die resultierende Eintrittswahrscheinlichkeit. Dabei muss jedoch beachtet werden, dass die Beobachtungen zum einen tatsächlich unabhängig voneinander sind. Zum anderen kann ein systematischer Fehler aufgrund falscher Schließalgorithmen nur dann ausgeschlossen werden, falls für den Rückschluss eine andere Datenbasis vorliegt. Im Umkehrschluss bedeutet dies, dass sich ähnliche Hypothesen nicht gegenseitig stützen, falls dem Rückschluss die gleiche Datenbasis zu Grunde liegt. Daraus folgt unmittelbar, dass es nicht zielführend ist, eigene Rückschlüsse anderen Fahrzeugen zu übertragen. Stattdessen werden nur unabhängige Beobachtungen anderen Fahrzeugen zugänglich gemacht und bei der prädiktiven Kontextinferenz berücksichtigt.

Prinzipiell lassen sich dabei zwei Klassen von Gefahrenpotenzialen unterscheiden, nämlich statische Gefahrenquellen einerseits, die ihre Position, Ausdehnung und Intensität während ihrer Existenz über die Zeit hinweg nicht ändern, wie dies beispielsweise bei Aquaplaning der Fall ist, und dynamische Gefahrenpotenziale andererseits. Wichtigste Vertreter dynamischer Gefahrenpotenziale sind wetterbedingte Verkehrsgefährdungen beispielsweise aufgrund von Nebel oder Starkregen. Im Hinblick auf eine belastbare und stabile Vorhersage der Fahrsituation muss daher berücksichtigt werden, dass sich sowohl die aktuelle Fahrzeugposition, als auch insbesondere die Intensität, Ausdehnung und Position möglicher Gefahrenstellen dynamisch über die Zeit ändern kann.

Zudem müssen mögliche räumliche und zeitliche Wechselwirkungen zwischen einzelnen verteilten Beobachtungen berücksichtigt werden. Liegen beispielsweise Beobachtungen hinsichtlich Starkregen an einer bestimmten Position vor, so ist es auch wahrscheinlich, dass es in der nahen Umgebung stark regnet. Zudem erhöht eine entsprechende Beobachtung auch die Wahrscheinlichkeit für das Auftreten von Aquaplaning in der Umgebung. Ein anderes Beispiel ist eine Unfallmeldung, welche die Wahrscheinlichkeit für eine anschließend auftretende Verkehrsbehinderung im Vorfeld der Unfallstelle erhöht. Auch scheinbar statische Ereignisse haben also letztlich in der Anwendungsdomäne räumliche Einflussfaktoren. Ähnliches gilt für den zeitlichen Einfluss von Beobachtungen, welche in Abhängigkeit der charakteristischen Dynamik des Kontextaspekts über die Zeit hinweg an Aussagekraft verliert.

Die Deduktion höherwertiger Kontextaspekte ist systeminhärent aufgrund der hohen Situationsdynamik mit Unsicherheit behaftet. Bayessche Netze stellen in diesem Zusammenhang ein weit verbreitetes und vielfach eingesetztes Paradigma zum Schließen auf unsicheren und unvollständigen Daten dar. Im Hinblick auf die Prädiktion der zukünftigen Fahrsituation auf Basis verteilter Beobachtungen von Fahrzeugen ist die Zuverlässigkeit und Aussagekraft dieser Beobachtungen abhängig von den relativen räumlichen und zeitlichen Abständen zwischen den Beobachtungen und der eigenen Fahrzeugposition. Räumliche Wirkzusammenhänge und Einflussfaktoren

können mit Hilfe von Bayesschen Netzen jedoch nicht adäquat abgebildet werden.

Im Folgenden wird daher ein Verfahren vorgestellt, das es ermöglicht, räumliche und zeitliche Wechselwirkungen und kausale Einflussfaktoren in einheitlicher Weise zur Vorhersage statischer und dynamischer Gefahrenpotenziale zu berücksichtigen. Zuvor soll jedoch kurz die prinzipielle Vorhersagestrategie bei der Auswertung der dem Fahrzeug bekannten Beobachtungen vorgestellt werden.

A. Vorhersagestrategie des Fahrkontextes

Wie eben erläutert, ist es das Ziel, den Fahrer zum richtigen Zeitpunkt mit der richtigen (Kontext-) Information zu versorgen. Informationen, die für den Fahrer keine Relevanz besitzen, müssen folglich nicht zwingend in guter Qualität vorliegen. Eine prädiktive Inferenz der zukünftigen Fahrsituation bedingt also keine kontinuierliche Auswertung aller der Anwendung zur Verfügung stehenden Beobachtungen. Die Notwendigkeit richtet sich vielmehr nach den individuellen Informationsstrategien der entsprechenden Anwendung. Anders ausgedrückt müssen die jeweiligen Kontextaspekte lediglich dann prognostiziert werden, wenn es die Fahrerinformationsstrategie der Anwendung erfordert. So haben beispielsweise Analysen zum optimalen Warnzeitpunkt vor möglichen Gefahrenstellen ergeben, dass eine zu frühe Information nahezu wirkungslos ist, da sie vom Fahrer schnell wieder vergessen wird (siehe beispielsweise [2]). Eine zu späte Warnung wirkt sich andererseits nachteilig auf das Fahrgeschehen aus.

Generell lässt sich feststellen, dass Kontextinformationen, die eine unmittelbare Aktion des Systems bzw. des Fahrers auslösen sollen, wie beispielsweise schlechte Wetterbedingungen, Unfallstellen oder ähnliches, in der Regel lediglich einige Sekunden vor Eintreten der Situation bekannt sein müssen. Dies bedeutet im Umkehrschluss, dass die aktuelle Ausprägung dieser Aspekte lediglich für Positionen prädiert werden muss, die das Fahrzeug in wenigen Sekunden erreichen wird. Der notwendige Vorhersagehorizont beschränkt sich daher in diesen Fällen auf einige wenige hundert Meter vor der aktuellen Fahrzeugposition, abhängig von der aktuellen Geschwindigkeit. Dabei müssen jedoch mögliche unterschiedliche Fahrtrouten berücksichtigt werden. Die Anzahl der möglichen Fahrtrouten und damit die Anzahl der notwendigen Prädiktionsorte sind aber aufgrund des kurzen Vorhersagehorizonts sehr begrenzt.

Eine weitere Vorhersage ist typischerweise lediglich für eine verkehrsadaptive Navigation nötig, da in diesem Fall der Zeitpunkt der resultierenden Handlungsentscheidung unter Umständen sehr früh sein kann, um rechtzeitig auf eine entsprechend bessere Route ausweichen zu können. Eine verkehrsadaptive Navigation erfordert aber andererseits, dass das Fahrtziel und die Fahrtroute bekannt ist. Hierdurch können wiederum die notwendigen Prädiktionsorte stark eingeschränkt werden.

Es ist daher ausreichend, Kontextaspekte lediglich dann auszuwerten, wenn

- eine oder mehrere Beobachtungen dieses Kontextaspektes, oder Beobachtungen von kausal abhängigen Aspekten, auf den aktuell möglichen Fahrtrouten in der Nähe des aktuellen Aufenthaltsortes existieren, oder
- eine oder mehrere Beobachtungen dieses Kontextaspektes, oder Beobachtungen von kausal abhängigen Aspekten, in der Umgebung der aktuell möglichen Fahrtrouten existieren und diese eine räumliche Ausdehnung aufweisen. Dies betrifft typischerweise kritische Wetterbedingungen wie Starkregen oder Nebel. In diesem Fall ist es zweckmäßig, die Auswertung für frei gewählte Orte auf den möglichen Fahrtrouten in der Nähe der aktuellen Fahrzeugposition zu wählen. Da nicht zu erwarten ist, dass sich in der unmittelbaren Umgebung des prädierten Ortes die Ausprägung dieser Kontextaspekte signifikant ändert, ist es ausreichend, diese Prädiktion in regelmäßigen Abständen mit entsprechend angepassten Prädiktionsorten zyklisch zu wiederholen. Eine kontinuierliche Berechnung für alle möglichen Orte auf den Fahrtrouten ist also nicht notwendig. Verfügt das Fahrzeug über keine digitale Karte kann als Ausweichstrategie auch eine Extrapolation der Fahrzeugposition auf Basis der aktuellen Geschwindigkeit und Fahrtrichtung dienen.

Wie eben beschrieben müssen für bestimmte Orte auf den wahrscheinlichen Fahrtrouten räumlich abhängige Hypothesen auch dann ausgewertet werden, wenn im räumlichen (und zeitlichen) Wirkbereich dieser Hypothesen entsprechende Beobachtungen desselben oder kausal korrelierter Kontextaspekte bekannt sind. Abbildung 1 zeigt beispielhaft die mögliche räumliche Beeinflussung von Beobachtungen auf die Hypothese an einem ausgewählten Ort auf der eigenen möglichen Fahrtroute, für die selbst keine weitere Beobachtung vorliegt. Auf der wahrscheinlichen Fahrtroute des abgebildeten Fahr-




Fig. 1: Räumlicher Einfluss von Beobachtungen

zeugs (im Beispiel geradeaus Richtung Norden) existieren keine vorangegangenen Beobachtungen anderer Fahrzeuge. Jedoch liegen dem Fahrzeug vier Beobachtungen hinsichtlich einer Sicht einschränkung aufgrund starken Nebels vor, die alle auf anderen Straßenabschnitten beobachtet wurden. Aufgrund der möglichen räumlichen Ausdehnung ist es trotzdem wahrscheinlicher, dass auch auf der eigenen Route eine Sicht einschränkung zu erwarten ist, die dem Fahrer im Vorfeld

signalisiert werden sollte. Der konkrete Einfluss hängt dabei von der relativen räumlichen und zeitlichen Lage der Beobachtungen zueinander ab. Dabei repräsentiert der schraffierte Kreis im Beispiel den vom Fahrzeug gewählten Auswertort der Hypothese hinsichtlich des Grades der Sicht einschränkung.

Eine enge zeitliche Korrelation angenommen, erhöhen die beiden weiß dargestellten Beobachtungen die Eintrittswahrscheinlichkeit einer Sicht einschränkung auf der Fahrtroute deutlich mehr, als die beiden schwarz dargestellten. Erstere deuten aufgrund ihrer gegenseitigen Lage im Vergleich zur eigenen Fahrtroute eher darauf hin, dass auch auf der Fahrtroute Nebel herrscht. Letztere hingegen enthalten mehr Unsicherheit über das Auftreten der Sicht behinderung. Insbesondere erhöht sich die Wahrscheinlichkeit, dass sich die Sicht einschränkung lediglich auf das Areal links des Fahrzeugs beschränkt. Zwar erhöht sich offensichtlich die Eintrittswahrscheinlichkeit auf der eigenen Fahrtroute aufgrund der räumlichen Nähe noch immer, im Vergleich mit den weiß markierten Beobachtungen fällt dieser Effekt jedoch geringer aus.

B. Das Konzept der Wahrscheinlichkeitsgebirge: Abbildung räumlich-zeitlicher Einflussfaktoren

Eine einfache Möglichkeit zur angemessenen Abbildung der räumlichen und zeitlichen Einflüsse eines Kontextaspektes ist es, die verfügbaren Beobachtungen zu inter- bzw. extrapolieren. Ausgehend von den verfügbaren Beobachtungen anderer Fahrzeuge, sowie den eigenen Beobachtungen an der aktuellen Fahrzeugposition, kann so in Abhängigkeit der jeweiligen räumlichen Entfernung zum Beobachtungsort, sowie der seit dem Zeitpunkt der Beobachtung vergangenen Zeit, für jeden beliebigen Ort des Modellraums ein gewichteter interpolierter Wert des beschriebenen Kontextaspektes berechnet werden. Dabei wird die übliche räumliche Interpolation in gleicher Weise um eine zeitliche Dimension erweitert. Die räumlich




Fig. 2: Räumliches Wahrscheinlichkeitsgebirge

und zeitlich verteilten verfügbaren Beobachtungen des gleichen Kontextaspektes der anderen Fahrzeuge bilden bildlich gesprochen einen Gebirgszug über dem Modellraum (siehe Abbildung 2). Das abgebildete Beispiel zeigt exemplarisch (aus Darstellungsgründen ohne Berücksichtigung des zeitlichen Aspektes) Beobachtungen hinsichtlich der Existenz von Regen. Die verteilten Beobachtungsorte werden durch die Balken symbolisiert, wobei die Höhe der Balken mit der an dieser Stelle beobachteten Regenintensität korreliert. Hierbei

wird auch die aktuelle Beobachtung dieses Kontextaspekts am eigenen Aufenthaltsort mit einbezogen. Diese Beobachtungen haben einen räumlichen und zeitlichen Einfluss auf das angrenzende Gebiet. Der konkrete Einfluss variiert dabei entsprechend der spezifischen Charakteristika des Kontextaspekts und bemisst sich neben der räumlichen und zeitlichen Distanz zudem auf Basis der Eintrittswahrscheinlichkeit und des Vertrauens in die Richtigkeit der Beobachtung. Entscheidend für den räumlichen und zeitlichen Einfluss ist dabei nicht die beobachtete *Intensität* des Kontextaspekts, sondern vielmehr die Qualität der Beobachtung. Eine Beobachtung, die aktuell 4 Liter Regen pro Quadratmeter pro Stunde, mit einer Eintrittswahrscheinlichkeit von 80% zusichert, sollte demzufolge beispielsweise stärker in das interpolierte Schließergebnis eingehen als eine Beobachtung, deren Beobachtungsort in etwa gleich weit entfernt ist, jedoch lediglich mit 10%iger Eintrittswahrscheinlichkeit zusichert, dass dort aktuell 1 Liter Niederschlag pro Quadratmeter pro Stunde auftritt.

Dabei wirkt das *Vertrauen* in eine Beobachtung als zusätzlicher Hebel. Das Vertrauen spiegelt unter anderem die Anzahl und Qualität der einer Beobachtung zugrunde liegenden Sensorsysteme wider. Ein weiterer Faktor, der das Vertrauen in die Beobachtungen anderer Fahrzeuge beeinflusst, kann zudem deren Reputation sein (eine weiterführende Beschreibung des Einsatzes von Reputationsverfahren in automobilen Ad-hoc Netzen findet sich beispielsweise in [3]). So ist es beispielsweise möglich, Beobachtungen unterschiedlicher Fahrzeugklassen oder -hersteller, oder externer Informationsanbieter, unterschiedliches Gewicht im Schließverfahren zu gewähren. Bereits extern verifizierte Informationen können so privilegiert in den Schließprozess mit einbezogen werden. Beispielsweise besitzen manuell von autorisierten Einsatzkräften verbreitete Beobachtungen in der Regel uneingeschränktes Vertrauen.

Aus diesem Grund ist es nicht möglich, eine einfache Interpolation zwischen den jeweils nächstgelegenen Beobachtungsorten durchzuführen. Zudem kann nicht ausgeschlossen werden, dass an einem Ort widersprüchliche Aussagen hinsichtlich eines Kontextaspektes existieren, welche zwar gleiches Vertrauen und gleiche Wahrscheinlichkeit aufweisen, jedoch eine unterschiedliche Ausprägung. Dies führt zu vergleichsweise steilen Flanken, die das Interpolationsergebnis bei widersprüchlichen Beobachtungen einseitig negativ beeinflussen. Statt einer klassischen Interpolation soll daher, ähnlich der sogenannten *Multi Attribute Utility Theory* (MAUT) [4], [5] eine gewichtete Durchschnittssumme sowohl zur Berechnung der erwarteten Ausprägung eines Kontextaspektes an einer beliebigen Position im Modellraum, als auch der zu erwartenden resultierenden Eintrittswahrscheinlichkeit dienen.

Bezeichne daher

- \bar{X}_j die Menge der verfügbaren Beobachtungen des Kontextaspektes x_j ,
- $\bar{x}_j^i \in \bar{X}_j$ eine Beobachtung des Kontextaspektes $x_j \in \bar{X}^b$,
- \hat{x}_j^i den Parameterwert der Beobachtung \bar{x}_j^i mit der höchsten Eintrittswahrscheinlichkeit, sowie

- $p_{\Delta\delta}^{\hat{x}_j^i}$ die Eintrittswahrscheinlichkeit der wahrscheinlichsten Ausprägung \hat{x}_j^i von x_j auf Basis der Beobachtung \bar{x}_j^i .
- $rel(\bar{x}_j^i)$ das Vertrauen in die Richtigkeit einer Beobachtung,
- $dist_A^{x_j} : \mathbb{R}^+ \rightarrow [0, 1]$ die aspektspezifische Abbildung des Einflusses der räumlichen Distanz auf die Aussagekraft der Beobachtung,
- $dist_T^{x_j} : \mathbb{R}^+ \rightarrow [0, 1]$ die aspektspezifische Abbildung des Einflusses des Beobachtungsalters (zeitliche Distanz) auf die Aussagekraft der Beobachtung,
- $\Delta pos(\bar{x}_j^i)$ die (logische) räumliche Distanz des Beobachtungsortes von \bar{x}_j^i zum Auswerteort,
- $\Delta time(\bar{x}_j^i)$ das Alter der Beobachtung \bar{x}_j^i ,
- $inf(\bar{x}_j^i)$ die konsolidierte Aussagekraft einer Beobachtung, sowie
- \hat{x}_j die erwartete wahrscheinlichste Ausprägung des interpolierten Kontextaspektes x_j .

Die erwartete wahrscheinlichste Ausprägung \hat{x}_j des interpolierten Kontextaspektes x_j an einem beliebigen Ort berechnet sich entsprechend dieser Überlegungen durch das normalisierte gewichtete Produkt der konsolidierten Aussagekraft aller verfügbaren Beobachtungen $\bar{x}_j^i \in \bar{X}_j$. Es gilt somit:

$$\hat{x}_j = \frac{1}{\sum_{\bar{x}_j^i \in \bar{X}_j} inf(\bar{x}_j^i)} \cdot \sum_{\bar{x}_j^i \in \bar{X}_j} inf(\bar{x}_j^i) \cdot \hat{x}_j^i, \text{ mit}$$

$$inf(\bar{x}_j^i) = rel(\bar{x}_j^i) \cdot p_{\Delta\delta}^{\hat{x}_j^i} \cdot dist_A^{x_j}(\Delta pos(\bar{x}_j^i)) \cdot dist_T^{x_j}(\Delta time(\bar{x}_j^i))$$

Dabei können sowohl Beobachtungen statischer als auch dynamischer Kontextaspekte in gleicher einheitlicher Weise miteinander verrechnet werden. Bei statischen Kontextaspekten, wie beispielsweise einer gemeldeten und später von anderen Fahrzeugen bestätigten Unfallstelle, kann angenommen werden, dass keine räumliche Distanz vorliegt. Eine entsprechende Vorverarbeitung der Beobachtungsorte, die aufgrund von Messungenauigkeiten etwas voneinander abweichen, wird durch die gewichtete Mittelwertbildung automatisch ausgeglichen. Es muss jedoch weiterhin sicher gestellt werden, dass keine eigentlich unabhängigen Ereignisse wie beispielsweise zwei unterschiedliche Unfallstellen miteinander verrechnet werden. Gleiches gilt für sich bewegende Kontextaspekte wie beispielsweise sich sehr langsam bewegende Fahrzeuge auf Autobahnen (z.B. Schwertransporter). Hier unterstützt die zusätzliche zeitliche Gewichtung die Bewegungstendenz, wobei ohne gezielte Vorverarbeitung die resultierende wahrscheinlichste Position immer etwas hinter der tatsächlichen Position nachläuft, da ältere Beobachtungen zu einer geringen verfälschenden Ausmittlung des aktuellsten Beobachtungsortes führen. Diejenigen Beobachtungen, deren Einfluss beispielsweise aufgrund einer zu großen räumlichen Distanz unter praktischen Gesichtspunkten keinen Einfluss auf das Ergebnis haben, können dabei unberücksichtigt bleiben. Die beiden Gewichtungsfunktionen $dist_A^{x_j}$ und $dist_T^{x_j}$ spezifizieren den kontextaspektspezifischen räumlichen und zeitlichen Einfluss.

Dieser kann prinzipiell einen beliebigen, jedoch üblicherweise stetigen, Funktionsverlauf aufweisen. Dabei sei angemerkt, dass die räumliche Distanz nicht zwingend der Euklidischen Distanz im Modellraum entspricht. Vielmehr kann die räumliche Distanz auch auf Basis einer logischen Geometrie berechnet werden, die beispielsweise verschiedene Fahrspuren oder bauliche Maßnahmen zur Fahrtrichtungstrennung mit berücksichtigt. Ein Unfall auf einer Autobahn hat beispielsweise keine unmittelbaren Auswirkungen auf den Gegenverkehr. Die logische räumliche Distanz lässt sich hier auf Basis der minimalen Fahrtstrecke bis zur Unfallstelle bemessen. Für Fahrzeuge auf der Gegenfahrbahn, oder Fahrzeuge, die die Unfallstelle bereits passiert haben, entspricht diese Distanz der Distanz bis zur nächsten Umkehrmöglichkeit und zurück. Sie ist daher deutlich größer als die Euklidische Distanz. Bei wetterbedingten Kontextaspekten wie Starkregen gilt dies offensichtlich nicht. Da die mögliche räumliche Ausdehnung unabhängig vom Straßenverlauf ist, bemisst sich die räumliche Wirkung folglich anhand der Euklidischen Distanz.

Schwieriger gestaltet sich indes die weitere Einschätzung der Eintrittswahrscheinlichkeit $p_{\Delta\delta}^{\hat{x}_j}$ dieser wahrscheinlichsten Ausprägung \hat{x}_j . Dabei ist zu berücksichtigen, dass sich unabhängige ähnliche Beobachtungen gegenseitig stützen. Umgekehrt sinkt jedoch die Eintrittswahrscheinlichkeit, falls sich widersprechende Beobachtungen vorliegen. Zur Quantifizierung der Eintrittswahrscheinlichkeit muss daher auf gleicher Basis zudem auch ein Maß für die Widersprüchlichkeit der Beobachtungen mit berücksichtigt werden. Je größer dabei die Widersprüchlichkeit der Beobachtungen ausfällt, desto geringer ist die resultierende Eintrittswahrscheinlichkeit des interpolierten Kontextaspektes. Eine naheliegende Metrik aus der Statistik ist in diesem Zusammenhang die Varianz, welche die Streuung einer Zufallsvariable quantifiziert. Dies ist in sehr ähnlicher Form für die Einschätzung der Eintrittswahrscheinlichkeit übertragbar, wobei dem Erwartungswert in diesem Falle offensichtlich genau \hat{x}_j entspricht. Auch hier gilt, dass die Aussagekraft einer Beobachtung mit zunehmender Distanz und zunehmendem Alter geringer wird. Daher muss auch eine mögliche Abweichung alter und weit entfernter Beobachtungen entsprechend abgeschwächt in das Varianzmaß einbezogen werden.

Die maßgebliche Varianz hängt dabei neben der Streuung der Beobachtungen auch von der Anzahl der unabhängigen Beobachtungen und dem höchsten Vertrauen in eine Einzelbeobachtung ab. Je mehr Beobachtungen vorliegen, desto wahrscheinlicher liegt die reale Ausprägung tatsächlich zwischen den vorliegenden Beobachtungswerten. In ähnlicher Weise erhöht sich die Aussagekraft auch in Abhängigkeit der maximalen Aussagekraft einer der zugrunde liegenden Beobachtungen. Um diesem Sachverhalt Rechnung zu tragen, wird die Varianz in Abhängigkeit dieser beiden Faktoren konsolidiert. Bezeichne

- $|\bar{X}_j|$ die Anzahl der verfügbaren Beobachtungen des Kontextaspektes x_j ,
- $inf_{\bar{X}_j}^{max}$ die maximale konsolidierte Aussagekraft einer

Beobachtung \bar{x}_j^i des Kontextaspektes x_j ,

- $\sigma_{\bar{X}_j}^2$ die gewichtete Varianz der $|\bar{X}_j|$ Beobachtungen des Kontextaspektes x_j , sowie
- $con^{x_j} : \mathbb{N}^+ \times [0; 1] \rightarrow \mathbb{R}^+$ eine aspektsspezifische Konsolidierung der Varianz auf Basis der Anzahl der Beobachtungen, sowie der maximalen konsolidierten Aussagekraft der Beobachtungen. Typischerweise weist eine derartige Konsolidierung die Form $con^{x_j}(|\bar{X}_j|, inf_{\bar{X}_j}^{max}) = \frac{a}{|\bar{X}_j|} \cdot \left(\frac{b}{inf_{\bar{X}_j}^{max}} - b \right)$ auf. Die Parameter a und b charakterisieren dabei die aspektsspezifische asymptotische Näherung in Abhängigkeit der Anzahl an Beobachtungen (a) sowie der maximalen konsolidierten Aussagekraft (b). Abbildung 3 zeigt einen exemplarischen Kurvenverlauf der Varianzkonsolidierung. Da die Anzahl der Beobachtungen ganzzahlig ist, ergibt sich in dieser Dimension implizit ein diskreter Charakter. Unter der Annahme einer weiteren angemessenen Diskretisierung der zweiten Dimension kann die Funktion im Hinblick auf die Ressourcenbeschränkung eingebetteter Fahrzeugsysteme über einfache Tabellenabgleiche erfolgen. Die Zahl der Tabellen entspricht dabei der maximal zu erwartenden bzw. maximal hilfreichen Zahl der Beobachtungen.




Fig. 3: Aspektsspezifische Konsolidierung der Varianz auf Basis der Anzahl der Beobachtungen, sowie der maximalen konsolidierten Aussagekraft der Beobachtungen

Dann gilt:

$$\sigma_{\bar{X}_j}^2 = con^{x_j}(|\bar{X}_j|, inf_{\bar{X}_j}^{max}) \cdot \left(\sum_{\bar{x}_j^i \in \bar{X}_j} (\hat{x}_j^i - \hat{x}_j)^2 \cdot inf(\bar{x}_j^i) \right)$$

Unter der Annahme einer Normalverteilung fehlerhafter Beobachtungen ergibt sich auf Basis der Beobachtungsvarianz schließlich ein Maß für die Eintrittswahrscheinlichkeit der gemittelten erwarteten Ausprägung des Kontextaspektes. Damit ergibt sich für die Wahrscheinlichkeit $p_{\Delta\delta}^{\hat{x}_j}$ des gewichteten Mittelwerts \hat{x}_j :

$$p_{\Delta\delta}^{\hat{x}_j} = \int_{\hat{x}_j - \Delta\delta}^{\hat{x}_j + \Delta\delta} N(\hat{x}_j, \sigma_{\bar{X}_j}^2) =$$

$$\int_{\hat{x}_j - \Delta\delta}^{\hat{x}_j + \Delta\delta} \frac{1}{\sqrt{2\pi \cdot \sigma_{\hat{X}_j}^2}} \cdot e^{-\frac{1}{2} \cdot \left(\frac{x - \hat{x}_j}{\sigma_{\hat{X}_j}}\right)^2} dx$$

Je größer die Varianz der Beobachtungen ist, desto größer ist bei gleicher Wahrscheinlichkeit das Konfidenzintervall $2 \cdot \Delta\delta$ und desto geringer ist in Folge auch die resultierende Aussagekraft des gewichteten Mittelwerts. Die Eintrittswahrscheinlichkeit gilt in gleicher Weise auch für Kontextaspekte mit diskretem oder binären Wertebereich. Unter der Annahme einer linearen Ordnung der diskreten Zustandswerte und einer bijektiven Abbildung in eine finite Teilmenge der natürlichen Zahlen gilt, dass die Eintrittswahrscheinlichkeit eines Zustands dem Integral über dem Intervall zwischen zwei Zuständen entspricht, d.h. $\Delta\delta = 0,5$. An den Intervallgrenzen des Wertebereiches der bijektiven Abbildung gilt das Integral von $-\infty$ bzw. bis ∞ . Abbildung 4 zeigt diesen Sachverhalt exemplarisch am Beispiel einer vierstufigen Diskretisierung der Regenintensität (0=kein Regen, 1=wenig Regen, 2=mittelstarker Regen, 3=starker Regen).

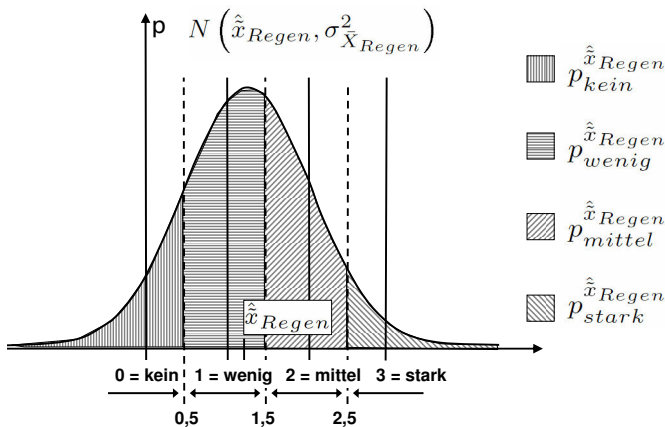


Fig. 4: Eintrittswahrscheinlichkeit von Regen auf Basis einer vierstufigen Diskretisierung der Regenintensität

Die Repräsentation als sogenanntes *Wahrscheinlichkeitsgebirge* bietet im Hinblick auf die inhärente Situationsdynamik den Vorteil, dass sie sich automatisch und nahtlos an beobachtete Veränderungen anpassen kann. Erhält ein Fahrzeug neue Beobachtungen, so wird ein neuer *Stützpunkt* des Wahrscheinlichkeitsgebirges eingefügt. Stützpunkte können entsprechend auch wieder entfernt werden, wenn beispielsweise aufgrund des Alters kein oder ein nur sehr geringes Vertrauen in die Richtigkeit der Beobachtung existiert. Existieren viele, räumlich nahe gelegene, ähnliche und sich daher verstärkende Beobachtungen zu einem Kontextaspekt, so können diese zusammengefasst werden, um die Rechenkomplexität weiter zu reduzieren. Das Resultat der Zusammenfassung entspricht dabei dem Durchschnitt an Intensität, Wahrscheinlichkeit und Vertrauen in die Beobachtung. Um eine Untergewichtung der Menge von Beobachtungen bei der gewichteten Interpolation zu vermeiden, muss jedoch hierbei die Anzahl der zusammengefassten Beobachtungen bei der Summenbildung mit berücksichtigt werden. Die Größe des Gebietes, in dem

ähnliche Beobachtungen zusammengefasst werden können, kann dabei wiederum mit zunehmender Distanz zur aktuellen Fahrzeugposition vergrößert werden. Die durchschnittsbildende Zusammenfassung vermindert jedoch die Genauigkeit des Interpolationsergebnisses. Es gilt andererseits, dass mit zunehmender Entfernung zur Fahrzeugposition die notwendige Genauigkeit der Situationsinferenz abnimmt.

C. Wechselwirkungen von Kontextaspekten

Für jeden Kontextaspekt (zu dem in der Vergangenheit bereits Beobachtungen von anderen Fahrzeugen bekannt sind) existiert ein solches Wahrscheinlichkeitsgebirge. Die bisherigen Betrachtungen beschränkten sich dabei auf einen bestimmten Kontextaspekt. Genau genommen spannt sich jedoch je ein Wahrscheinlichkeitsgebirge pro relevantem Kontextaspekt über dem Modellraum auf. Zudem existiert eine Reihe von Wechselwirkungen und kausalen Abhängigkeiten auch zwischen den einzelnen Kontextaspekten. Beispielsweise ist das Auftreten einer Aquaplaningefahr wie beschrieben dann wahrscheinlicher, wenn zuvor eine große Niederschlagsmenge aufgetreten ist.

Die Qualität der Vorhersage kann verbessert werden, wenn auch die kausalen Abhängigkeiten anderer Kontextaspekte mit berücksichtigt werden. Eine derartige Quervalidierung kann dadurch realisiert werden, dass sich der eben beschriebenen interpolierten Abschätzung der einzelnen Kontextaspekte eine kausale Konsolidierung auf Basis der bekannten Abhängigkeiten zwischen den Kontextaspekten anschließt. Auf diese Weise können auch sich widersprechende Vorhersagen aufgedeckt werden, was letztlich jedoch zu einer Reduzierung der Eintrittswahrscheinlichkeit der sich widersprechenden Aspekte führt. Die Hypothesen werden in diesem Fall also (wie gefordert) weniger aussagekräftig.

Durch die gewichteten Interpolationen lässt sich für jeden beliebigen Ort für jeden Kontextaspekt jeweils eine Eintrittswahrscheinlichkeit für die wahrscheinlichste Ausprägung ableiten. Darauf aufbauend lässt sich für einen spezifischen Ort beispielsweise mit Hilfe Bayesscher Netze eine kausale Konsolidierung durchführen (siehe Abbildung 5). Falls vorhanden, können dabei neben den Abschätzungen der aktuellen Ausprägung zudem weitere Hypothesen hinsichtlich des existenten Wissens mit berücksichtigt werden, die es beispielsweise erlauben, den wahrscheinlichen Verlauf eines Aspekts über einen längeren Zeitraum mit zu berücksichtigen. So steigt wie beschrieben die Aquaplaningefahr an einem Ort beispielsweise auch dann, wenn aktuell dort sicher kein Niederschlag mehr auftritt, es jedoch in letzter Zeit stark geregnet hat. Dieser kausale Zusammenhang lässt sich durch eine zusätzlich eingeführte Hypothese in gleicher Weise mit berücksichtigen, wobei die konkrete Hypotheseninstanziierung offensichtlich eine vorangestellte Berechnung erfordert. Es lassen sich auf die gleiche Weise auch räumliche kausale Einflüsse abbilden, die zwischen unterschiedlichen Kontextaspekten existieren. So steigern beispielsweise auffällige und atypische Fahrmanöver mehrerer Fahrzeuge an und vor einer bestimmten Position die Wahrscheinlichkeit dafür, dass dort möglicherweise ein




Fig. 5: Kausale Konsolidierung interpolierter Kontextaspekte für einen spezifischen Ort

Hindernis auf der Fahrbahn existiert (für eine ausführlichere Diskussion der Möglichkeit einer Hinderniserkennung auf Basis fahrdynamischer Sensorik sei an dieser Stelle auf [6] verwiesen).

III. BEWERTUNG

Die in diesem Kapitel beschriebene Vorgehensweise zur kooperativen Prädiktion des Fahrkontextes wurde simulativ ausgewertet. Hierzu wurden 100 Fahrzeuge mit einer maximalen Kommunikationsreichweite von 400m in einem $8km^2$ großen Innenstadtszenario simuliert, über das zufällig einzelne Regengebiete hinwegziehen. Überlagerungen dieser Gebiete führen zu einer additiven Intensivierung der angenommenen Regenintensität. Bei mindestens drei überlagerten Regengebieten wird starker Regen angenommen.

Abbildung 6 stellt dabei die vorgestellte zweistufige Prädiktion (Interpolation und Quervalidierung) und die tatsächliche simulierte Ausprägung des Kontextaspekts Regen (zwischen 0 und 100) an einer entfernten Position gegenüber. Die Prädiktion basiert dabei wie in Abbildung 4 dargestellt auf einer vierstufigen gleichverteilten Diskretisierung der Regenintensität und entspricht der wahrscheinlichsten Hypothese. In weiteren Simulationen wurde die Anzahl der verfügbaren Sensoren in den Fahrzeugen schrittweise reduziert und so die möglichen individuellen Beobachtungen und daraus resultierend auch das Vertrauen in die individuelle Inferenz verringert. Eine hinreichend große Zahl an partizipierenden Fahrzeugen vorausgesetzt, bleibt davon die Qualität der Vorhersage jedoch nahezu unberührt. Dies lässt sich darauf zurückführen, dass das Vertrauen in die individuellen Hypothesen bei der interpolierten Vorhersage entsprechend berücksichtigt wird.

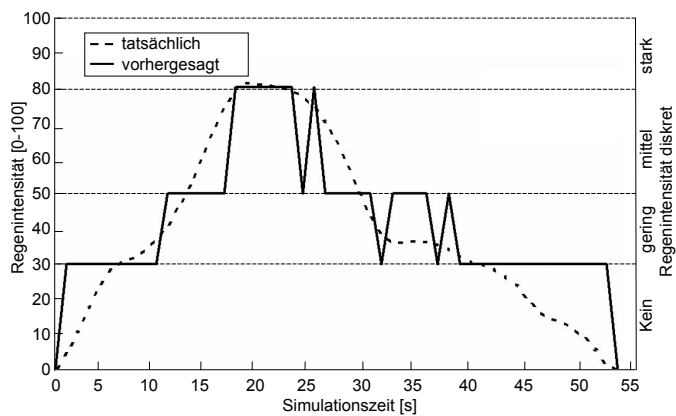


Fig. 6: Vergleich zwischen Prädiktion und tatsächlicher Ausprägung des Kontextaspekts Regen an einer entfernten Position

Als Konsequenz gehen Beobachtungen von besser ausgestatteten Fahrzeugen mit höherem Gewicht in die Prädiktion ein und ermöglichen weiterhin eine gute Vorhersagequalität. Die nachgelagerte Quervalidierung stützt zudem die Qualität der Vorhersage. So konnte des Weiteren simulativ gezeigt werden, dass auch dann eine richtige Vorhersage hinsichtlich einer Aquaplaninggefahr möglich ist, wenn keine direkten Aquaplaningvidenzen, sondern lediglich Starkregenevidenzen vorliegen.

Die Qualität der Vorhersage vermindert sich jedoch, wie erwartet, mit zunehmender Situationsdynamik und geringerer Fahrzeugdichte. Dieser Effekt wird insbesondere durch die gezielte Verbreitung falscher Vorhersagen verstärkt. Eine weiterführende Analyse gezielter Angriffe und den Auswirkungen verschiedener Mehrheitsentscheidungen auf die Qualität der Vorhersage ist in [7], [8] beschrieben.

IV. ZUSAMMENFASSUNG UND AUSBLICK

Es wurde ein zweistufiges Inferenzverfahren vorgestellt, das die räumlichen und zeitlichen Wirkeinflüsse mittels funktional gewichteter Interpolation für beliebige Straßenpositionen abbilden kann. Eine Quervalidierung auf Basis der existenten kausalen Abhängigkeiten zwischen den einzelnen Kontextaspekten ermöglicht schließlich eine nachgelagerte Verfeinerung der Ergebnisqualität. Detaillierte mikroskopische Simulationen unter Variation der zugrunde liegenden Einflussparameter zeigten, dass selbst bei wenigen teilnehmenden Fahrzeugen auf Basis des vorgestellten Verfahrens eine stabile und belastbare Vorhersage der Fahrsituation erzielt wird.

Zudem wurde aufgezeigt, wie die resultierende Rechenkomplexität im Hinblick auf die begrenzten Ressourcen eingebetteter Systeme im Fahrzeug durch Minimierung der Auswertezyklen signifikant reduziert werden kann.

Die konkrete Leistungsfähigkeit des Prädiktionsverfahrens hängt dabei jedoch in entscheidendem Maße an der optimalen Konfiguration der einzelnen Parameter, insbesondere der statistischen kausalen Abhängigkeiten und der räumlich-zeitlichen Veränderlichkeit der betrachteten Aspekte. Eine entsprechende Parametrisierung kann auf Basis üblicher Opti-

mierungsalgorithmen automatisch erzeugt werden, jedoch setzt dies aufgrund der großen Zahl der Parameter eine sehr große Datenbasis voraus.

REFERENCES

- [1] T. Kosch, "Situationsadaptive kommunikation in automobilen ad-hoc netzen," Ph.D. dissertation, Technische Universität München, Fakultät für Informatik, 2005.
- [2] D. Neumerkel, P. Rammelt, D. Reichardt, W. Stolzmann, and A. Vogler, "Fahrermodelle - ein schlüssel für unfallfreies fahren?" *KI*, vol. 16(3), pp. Seiten 34–36, 2002.
- [3] P. Magiera, "Reputationssysteme in großen, hoch-mobilen ad-hoc-netzen," Master's thesis, Technische Universität Darmstadt, Fachbereich Informatik, 2004.
- [4] R. L. Keeney and R. F. Meyer, *Decisions with Multiple Objectives*, H. Raiffa, Ed. Cambridge University Press; New Ed edition, 2002.
- [5] C. Kray, "Situating interaction on spatial topics," Ph.D. dissertation, Naturwissenschaftlich-Technischen Fakultät I der Universität des Saarlandes, 2003.
- [6] M. Straßberger and R. Lasowski, "A new approach for obstacle detection based on dynamic vehicle behaviour," in *10th International Forum on Advanced Microsystems for Automotive Applications*, Berlin, Germany, April 2006.
- [7] B. Ostermaier, "Analysis and improvement of inter-vehicle communication security by simulation of attacks," Master's thesis, Technische Universität München, Institut für Informatik, Munich, Germany, 2005.
- [8] B. Ostermaier, F. Dötzer, and M. Strassberger, "Enhancing the security of local danger warnings in vanets - a simulative analysis of voting schemes," in *Proceedings of the Second International Conference on Availability, Reliability and Security (ARES 2007)*, 10-13 April, Wien, Österreich, 2007.