

Probabilistische Methoden in der Umfeldwahrnehmung Kognitiver Automobile

Probabilistic Methods for Environment Perception of Cognitive Automobiles

Christoph Stiller, Sören Kammel, Irina Lulcheva und Julius Ziegler

Durch sensorielle Wahrnehmung und Interpretation von Video- und Lidardaten erstellen sich Kognitive Automobile ein Lagebild ihrer Umgebung, welches die Grundlage für die Entscheidung und Ausführung situationsangepassten Fahrverhaltens bildet. Probabilistische Modelle erlauben dabei die konsistente Repräsentation der Sensorinformation einschließlich ihrer Unsicherheit. Symbolisches Wissen über die Verkehrsszene kann in diesem Kontext durch Markov-Logik-Netze probabilistisch formuliert und inferiert werden. Anstelle von fertigkeit- oder regelbasiertem Verhalten geben wissensbasierte Methoden Werte und Ziele vor, sodass die Verhaltensentscheidung durch Auswahl des Verhaltens erfolgt, das den größtmöglichen Zielerreichungsgrad erwarten lässt. Erste Ergebnisse umfassen neben dem Fahrzeugaufbau bereits autonome Manöver sowie die Finalteilnahme im Urban Challenge Wettbewerb.

Cognitive automobiles acquire an internal representation of the driving environment through perception and interpretation of video- and lidar-data. This knowledge serves as a basis for decision and control of driving behavior that is appropriate in the perceived driving situation. Probabilistic models enable a consistent representation of the acquired sensor information and its uncertainty. In this context, symbolic knowledge on the traffic situation may be formulated probabilistically and inferred using Markov Logic Networks. Beyond skill- and rule-based behavior the concept of knowledge-based methods allow to specify values and goals. The task of behavior decision then reduces to the selection of the behavior alternative that fulfils the preset goals to the highest expected degree. Preliminary results include an experimental vehicle that conducts first autonomous maneuvers and that has entered the finals of the Urban Challenge competition.

Schlagwörter: Kognitive Automobile, autonome Fahrzeugführung, maschinelles Sehen, Stereosehen, diversitäre Wahrnehmung, probabilistische Inferenz, Markov-Logik-Netze, Bahnplanung

Keywords: Cognitive automobiles, autonomous vehicles, machine vision, stereo vision, diversitary perception, probabilistic inference, Markov Logic Network, trajectory planning

1 Einleitung

Bereits im Kognitivismus haben sich Philosophen wie Aristoteles mit der Frage befasst, warum uns die Welt so erscheint, wie sie uns erscheint. Das wichtige Konzept der Kognition wurde anhand der Betrachtung von Einzel-

wesen zur Theorie der Erkenntnis verallgemeinert – eine Fähigkeit, die zumindest bislang ausschließlich höheren Lebewesen zugeordnet wird.

Kognition beinhaltet Wahrnehmung, Denken und Erkenntnis und bildet damit die Grundlage zielgerichteten Verhaltens. Die Übertragung kognitiver Fähigkeiten auf Maschi-

nen eröffnet neuartige Perspektiven für ein Zusammenwirken von Maschinen untereinander und mit dem Menschen. Kognitive Automobile sind in der Lage, sich selbst und ihre Umgebung wahrzunehmen sowie Wissen selbstständig anzusammeln und zu strukturieren. Sie werden damit langfristig befähigt, selbst in komplexen Verkehrssituationen sinnvolle Verhaltensentscheidungen zu treffen, indem sie auf eine realistische Vorstellung von sich selbst und der Umgebung sowie auf einen ständig sich erweiternden Wissenshintergrund zurückgreifen. Insbesondere die Fähigkeit der Kooperation erschließt Fahrzeugen ein hohes langfristiges Nutzenpotenzial hinsichtlich verkehrlicher Sicherheit und Effizienz.

Das Automobil bietet ein ideales Anwendungsfeld für die Forschung in diesem Bereich. Wissenschaftliche Erkenntnisse lassen sich hier unmittelbar in – im wahrsten Wortsinne – *erfahrbares* Verhalten umsetzen und dadurch demonstrieren und bewerten. Gleichzeitig ist der Automobilbau ein maßgeblicher Innovationstreiber der Wissenschaft und eines der bedeutenden Standbeine der Industrie. Nicht zuletzt ist die Verbesserung der Verkehrssicherheit ein wichtiges Anliegen unserer Gesellschaft. Aufgrund ihrer kognitiven Fähigkeiten werden Automobile der Zukunft bei der Fahrzeugführung mitdenken und in kritischen Situationen automatisch und zielgerichtet in Bremse und Lenkung eingreifen. Ein großer Teil heutiger Unfälle könnte vermieden bzw. die Unfallschwere maßgeblich gemindert werden, wenn es dadurch gelänge, geeignete Notmanöver rund eine Sekunde früher einzuleiten. Die Erhöhung der Sicherheit und der Effizienz des Straßenverkehrs stellt eine interdisziplinäre Herausforderung dar, deren erfolgreiche Bewältigung nicht nur aus wissenschaftlicher und ökonomischer Motivation wichtig, sondern gleichzeitig gesellschaftlich relevant ist.

Seit nunmehr einem Jahrzehnt verfügen erste Serienfahrzeuge über Sensoren zur Wahrnehmung und Beschreibung von Verkehrssituationen auf hoch strukturierten Straßen – wie etwa auf Autobahnen. Dort lassen sich erste Funktionen wie Fahrbahnverlassenswarnung oder Abstandsrege-

lung bereits durch Messung weniger Parameter realisieren, die etwa die Fahrbahngeometrie sowie die Position und Geschwindigkeit anderer Fahrzeuge beschreiben. Allgemeine Verkehrsszenen erfordern aufgrund der Vielschichtigkeit relevanter Information hingegen mächtigere Ansätze zur Wissensrepräsentation. Darin sind Interpretationen des Verhaltens und des mutmaßlich künftigen Verhaltens anderer Verkehrsteilnehmer, sowie die Bedeutung bestimmter Objektklassen, Markierungen, Verkehrszeichen und -signale etc. geeignet zu berücksichtigen. Entsprechend sind bislang kaum Ansätze, geschweige denn realisierte Fahrerassistenzfunktionen zur Handhabung der gerade in städtischer Umgebung möglichen Komplexität von Verkehrsszenen bekannt.

Die Betrachtung des in Bild 1 dargestellten, an [11] angelehnten Verhaltensmodells menschlicher Fahrer gibt erste Hinweise auf eine mögliche Weiterentwicklung künftiger Fahrerassistenzfunktionen [16]. In dieser Terminologie sind heutige Fahrerassistenzsysteme weitestgehend zur Umsetzung *fertigkeitsbasierten Verhaltens* fähig. Dabei werden durch Filterung einfacher Merkmale Reiz-/Reaktionsmechanismen zur Stabilisierung des Fahrzeugs aktiviert. In diese Verhaltenskategorie fällt beispielsweise das laufende Spurhalten.

In geringerem Maße ist *regelbasiertes Verhalten* bereits technisch realisiert. Hierbei werden Charakteristika der aktuellen Situation erkannt und dadurch mit einer vorher gespeicherten Situation assoziiert, um ein bekanntes für diese Situation zielführendes Verhaltensmuster zu initiieren. Ein aktuelles Beispiel für derartiges Verhalten von Fahrzeugen besteht in der Anwendung einfacher Vorfahrtsregeln, die im Urban Challenge Wettbewerb autonomer Fahrzeuge fast ausschließlich durch endliche Automaten umgesetzt wurden. Aufgrund der Erfahrungen in diesem Bereich erscheint es mittelfristig fraglich, wie weit sich das Regelwerk mit diesen Methoden beherrschbar erweitern lässt.

Am geringsten ausgeprägt ist die Fähigkeit, *wissensbasiertes Verhalten* maschinell umzusetzen, bei dem Situationen verstanden und die jeweiligen Auswirkungen der verschie-

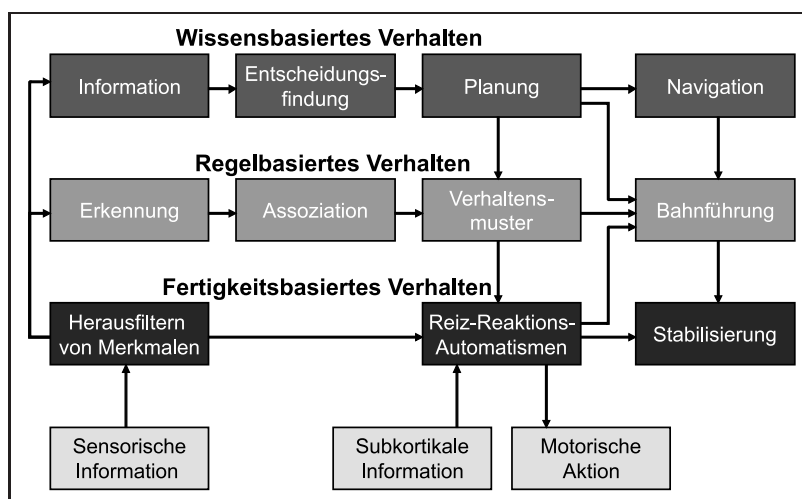


Bild 1: Verhaltensmodell der menschlichen Fahrzeugführung (vgl. [11]).

denen möglichen Verhaltensalternativen abgeschätzt und anhand vorgegebener Maßstäbe bewertet werden, sodass ein Verhaltensplan für das bestmögliche Verhalten und dessen Auswirkung entsteht. Der Übergang auf wissensbasiertes Verhalten erfordert nicht bloß eine quantitative, sondern vielmehr einen qualitativen Fortschritt. Weder zur formalen Festlegung der im Allgemeinen multikriteriellen Werte und Ziele noch zur Vorhersage der Auswirkungen unterschiedlicher Verhaltensalternativen stehen einfache Lösungen bereit. Auch diese Überlegungen motivieren Forschungsaktivitäten zur Kognition von Automobilen. In Abschnitt 6 wird ein einfaches Beispiel für automatisches wissensbasiertes Verhalten vorgestellt.

Die folgenden Abschnitte sind wie folgt gegliedert: Der folgende Abschnitt skizziert den SFB/Tr. Kognitive Automobile und die dort verwendete Architektur. Abschnitt 3 und 4 geben einen Überblick über aktives Sehen bzw. Lidardatenanalyse. Die zur probabilistischen Inferenz symbolischer Information verwendeten Markov-Logik-Netzwerke werden in Abschnitt 5 vorgestellt. Abschnitt 6 zeigt die Trajektorienplanung als ein Beispiel wissensbasierten Verhaltens auf. Experimentelle Ergebnisse werden in Abschnitt 7 beschrieben.




Bild 2: Die Kombination von Fahrumgebungswahrnehmung und Fahrzeug-Fahrzeug-Kommunikation eröffnet Kognitiven Automobilen das Potenzial kooperativer Wahrnehmung und kooperativen Verhaltens.

2 Kognitive Automobile

In 2006 wurde von der Deutschen Forschungsgemeinschaft der Sonderforschungsbereich (SFB) Transregio *Kognitive Automobile* gegründet, der Wissenschaftler der Universität, des Forschungszentrums und des Fraunhofer IITB in Karlsruhe sowie der Technischen Universität und der Universität der Bundeswehr in München miteinander vernetzt.

Übergeordnete Themenstellungen sind die systematische und interdisziplinäre Erforschung der maschinellen Kognition mobiler Systeme als Grundlage maschinellen Handelns und die Entwicklung einer wissenschaftlichen Theorie maschineller Kognition. Deren Tragfähigkeit wird exemplarisch dadurch aufgezeigt, dass das Verhalten von Automobilen im Straßenverkehr erfasst, verstanden und sogar automatisch generiert wird. Das Kognitive Automobil soll dabei sowohl zu individuellem als auch zu kooperativem Wahrnehmen und Handeln fähig sein.

Wie exemplarisch in Bild 2 illustriert, bietet Kooperativität zwischen Fahrzeugen ein hohes Nutzenpotenzial für den Straßenverkehr. So können Kognitive Automobile durch Kommunikation ihren Sichthorizont erheblich erweitern und dadurch Information über ansonsten uneinsehbare Bereiche erhalten. Auf der Grundlage einer gleichartigen Wahrnehmung der aktuellen Verkehrssituation lässt sich ein kooperatives Fahrverhalten zwischen Automobilen abstimmen [5; 10; 15].

Basierend auf theoretisch abgeleiteten Methoden und simulativer Verifikation werden die im SFB Transregio gewonnenen Erkenntnisse durch Erprobungsfahrzeuge experimentell abgesichert. Anhand des in Bild 3 skizzierten Aufbaus eines Erprobungsfahrzeugs und des in Bild 4 dargestellten Strukturbildes kann die grundsätzliche Funktionsweise des Kognitiven Automobils nachvollzogen werden. Dabei sind in Bild 3 naturgemäß überwiegend Komponenten der unteren physischen Ebene des Strukturbildes sichtbar, während die oberen Ebenen algorithmisch auf der Rechenhardware des Erprobungsfahrzeugs implementiert sind [6]. Verschiedene Video-, Radar- und Lidarsensoren erzielen eine diversitäre Rundumsicht. Wie beim menschlichen Vor-

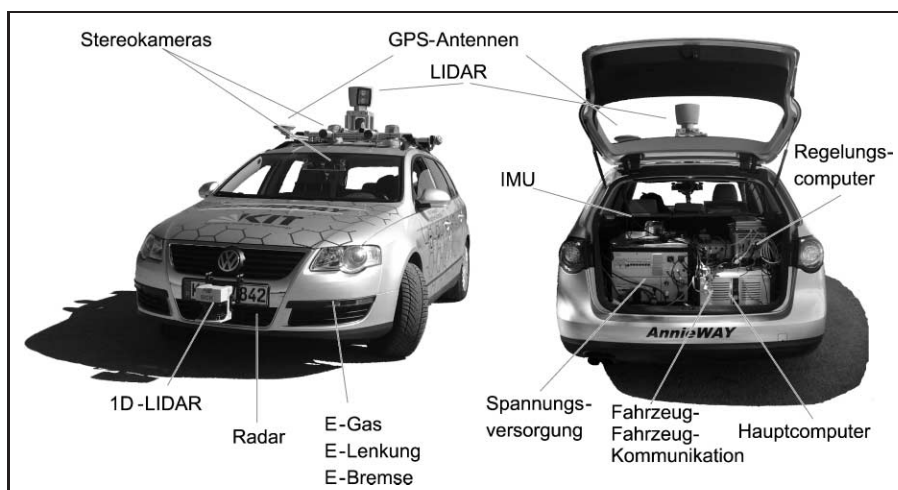


Bild 3: Erprobungsfahrzeug für Kognitive Automobile.

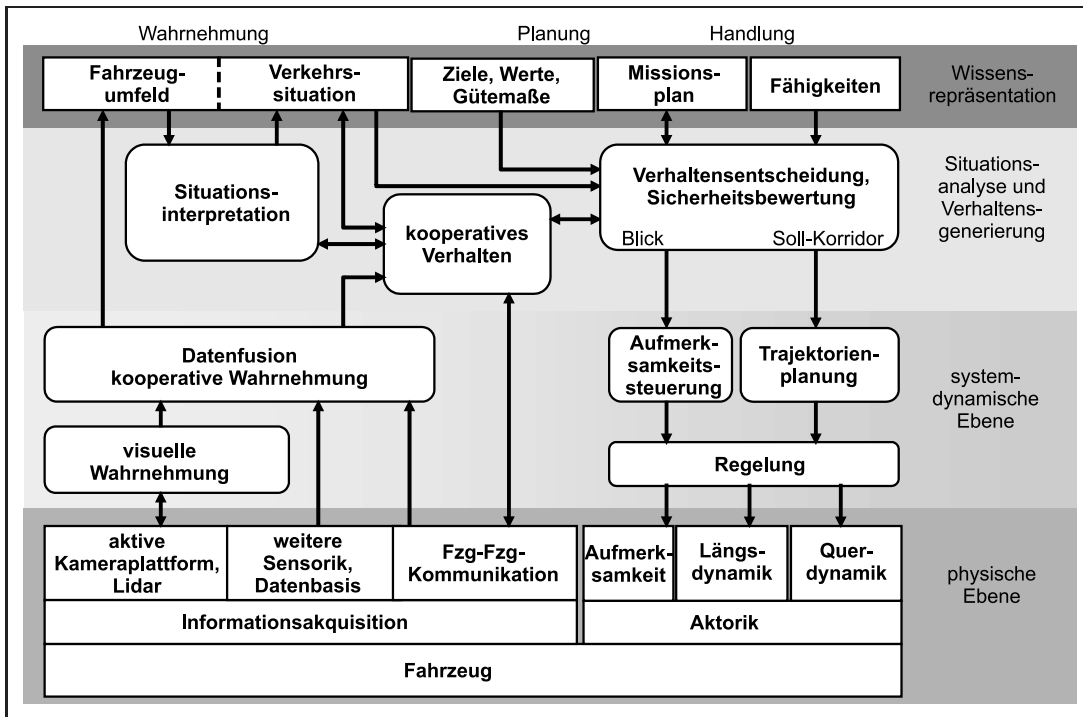


Bild 4: Strukturdiagramm eines kognitiven Automobils mit der Fähigkeit zur Kooperation.

Die dominante Rolle in der Umgebungserfassung wird von optischen Sensoren übernommen. Verfahren zur Datenanalyse bestimmen aus diesen Sensordaten für die Fahrzeugführung relevante Informationen, wie den Verlauf der Fahrbahn, die 3D-Geometrie der statischen Umgebung und die Bewegung anderer Verkehrsteilnehmer [3; 4].

Als weitere Sensorik ist ein GPS-Empfänger eingebaut, der durch die Fusion mit der Information von Inertialsensoren die Position des Fahrzeugs mit Genauigkeiten im Zentimeterbereich bestimmt. Als Datenbasis ist eine digitale Straßenkarte vorhanden. Schließlich nimmt das Fahrzeug durch Kommunikation mit seiner Außenwelt Informationen auf bzw. gibt gezielt Informationen nach außen. Durch die Datenfusion wird diese Informationsfülle ganzheitlich analysiert und zunächst ein mentales dreidimensionales geometrisches Modell der Fahrumgebung erstellt. Dieses Modell wird laufend in einer Wissensdatenbank aktualisiert. Neben dieser metrischen Fahrumgebungsinformation ist eine Interpretation der Fahrumgebung und der Verkehrssituation erforderlich. Die so entstehende Wissensrepräsentation umfasst neben metrischer Information auch durch Schlussfolgerungen gewonnene begriffliche Informationen, wie z. B. „Das Fahrzeug rechts vor mir möchte auf meine Spur einscheren“ [2; 14; 19].

Aus der aktuellen Verkehrssituation wird schließlich ein geeignetes Fahrverhalten in Form eines räumlich-zeitlichen Soll-Korridors abgeleitet, in dem das Fahrzeug fahren soll. Die Verhaltensentscheidung orientiert sich dabei an explizit vorgegebenen Zielen, Werten (einschließlich Verkehrsregeln) und Gütemaßen sowie am Missionsplan, den eigenen dynamischen Fähigkeiten des Fahrzeugs und der durch das jeweilige Verhalten erwarteten Sicherheit [1]. Auf der systemdynamischen Ebene werden eine exakte räumlich-

zeitliche Fahrtrajektorie geplant und entsprechende Stellbefehle an die elektrisch ansteuerbare Aktorik (Lenkung, Bremse und Gas) gegeben.

3 Visuelle Wahrnehmung

Den überwiegenden Anteil der für die Fahrzeugführung benötigten Informationen nehmen menschliche Fahrer visuell




Bild 5: a) Aktive Kamera-Plattform im Erprobungsfahrzeug. b) Konzeptskizze der aktiven Kamera-Plattform (C1, C2: Stereokameras, C3: Telekamera, M: Spiegel).

auf. Das in Bild 5 dargestellte für den SFB entwickelte multifokale aktive Kamerasystem zeigt attraktive Parallelen zum menschlichen Sehsystem auf. Die Plattform umfasst zwei Kameras mit einem horizontalen Blickwinkel von 46° und eine Telekamera. Die Blickrichtungen der Kameras sind kontinuierlich und sakkadisch steuerbar. Durch fortlaufende Analyse der Disparitäten und Verschiebungen ist eine Selbstkalibrierung [3], d. h. eine 3D-Geometrieermittlung des Umfeldes in einem Blickbereich von bis nahezu 180° möglich. Der wichtigste Beitrag für das hohe Leistungspotenzial von Kamerasystemen für die Fahrumgebungswahrnehmung liegt in der reichhaltigen Information von Bildsequenzen begründet. Bereits aus einzelnen Bildern lassen sich relevante Objekte aufgrund charakteristischer Erscheinungsmerkmale detektieren. In der Literatur sind beispielsweise Methoden zur Detektion von Fahrzeugen oder Fußgängern aufgrund ihrer Textur, Form, Farbe, Symmetrie oder Schatten bekannt [7; 13; 20]. Zusätzlich lassen sich durch Korrespondenzanalyse, d. h. der Bestimmung der stereoskopischen Disparität bzw. des optischen Flusses die 3D-Geometrie der Umgebung rekonstruieren und somit

ebenfalls Objekte detektieren. Durch ein probabilistisches – z. B. Bayes'sches [22] – Modell lassen sich die verschiedenen visuellen Merkmale integrativ auswerten, sodass eine diversitäre Wahrnehmung entsteht.

4 Laserdatenanalyse

Während Videosensoren die Rekonstruktion der 3D-Geometrie indirekt über den Umweg der Korrespondenzanalyse vornehmen, bestimmen Laserscanner die 3D-Geometrie unmittelbar über die Messung der Lichtlaufzeit. Gleichzeitig bieten Laserscanner in der Regel große Erfassungswinkel. Der in Bild 6(a) dargestellte Laserscanner misst gleichzeitig die Laufzeit von 64 übereinander angeordneten Laserstrahlen. Damit wird ein Bereich von 360° (horizontal) und $26,5^\circ$ (vertikal) bis zu einer Reichweite von über 100 m erfasst und 10 mal pro Sekunde aktualisiert. In Bild 6(b) ist beispielhaft ein solcher Datensatz visualisiert. Die große Datenmenge des Laserscanners wird in eine diskrete 2D-Karte (Belegungsgitter, siehe [17; 18]) projiziert, in der jede Zelle Informationen über die an dieser Stelle vorherrschende Elevation enthält. Die Elevation der Zellen ergibt sich dabei aus der Höhendifferenz der über der Zelle auftreffenden Laserstrahlen, siehe Bild 7(a). Die in Bild 7(b) dargestellte Luftaufnahme sowie ein Detailphoto des Randsteins verdeutlicht die erreichbare Sicherheit der Kartierung auch niedriger Objekte.




Bild 6: Laserscanner und exemplarischer Datensatz.

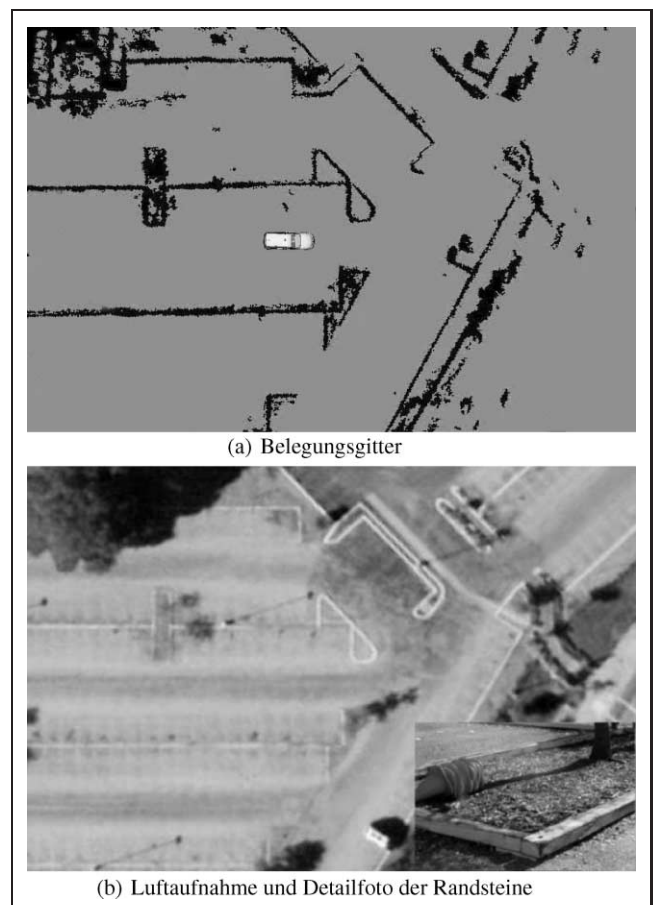


Bild 7: Laserscanner und Laserdatenkartierung.

5 Probabilistische Inferenz

Neben metrischer Information erfordert die Fahrzeugführung symbolisches Wissen über die Fahrumgebung. Markov-Logik-Netze zeichnen sich für dessen Inferenz dadurch aus, dass Regeln nicht nur explizit vorgebar sind, sodass Entscheidungen später nachvollziehbar werden, sondern deren Gültigkeit darüber hinaus statistisch validiert und erlernt werden kann. Das Konzept wird nachfolgend vorgestellt und an einem einfachen Beispiel der Fahrumgebungserfassung illustriert.

5.1 Markov-Logik-Netze (MLN)

Ein Markov-Logik-Netz (MLN) ist eine probabilistische Repräsentation, welche Prädikatenlogik erster Stufe und Markov-Netze, auch Markov-Zufallsfelder genannt, miteinander verknüpft [12]. Gegeben seien eine Menge prädikatenlogischer Formeln $F = \{F_1, \dots, F_n\}$, die einen bestimmten Diskursbereich beschreiben, und eine Menge von zugeordneten Gewichten $w_1, \dots, w_n \in \mathbb{R}$. Sie definieren ein MLN L mit:

$$L = \{(w_1, F_1), \dots, (w_n, F_n)\}.$$

Jedes Gewicht wird anhand von Trainingsdaten gelernt und beschreibt den Wahrheitsgehalt der durch die entsprechende Formel ausgedrückten Behauptung. Je größer das Gewicht, desto größer wird die Wahrscheinlichkeit für das Zutreffen der entsprechenden prädikatenlogischen Formel modelliert. Eine Welt, in der die Formel erfüllt ist, wird bei großem Gewicht entsprechend als wesentlich wahrscheinlicher eingestuft als eine alternative Welt, in der die Formel verletzt wird (bei Festhalten aller anderen Werte). Durch die Gewichte wird das Zutrauen in die jeweilige Formel quantifiziert. Im Sonderfall eines unendlich großen Gewichtes wird die zugehörige Formel als sicher angesehen; ein MLN mit ausschließlich unendlichen Gewichten ist äquivalent zu einer klassischen deterministischen prädikatenlogischen Wissensbasis.

Tabelle 1: Beispiel-MLN L_1 .

w_i	F_i
0,6	$\forall o \forall r \quad on(o, r) \wedge road(r) \wedge hasSpeed(o, Low) \Rightarrow car(o)$
1,4	$\forall o \quad hasDirection(o, Same) \Rightarrow car(o)$

Gegeben seien das MLN L und eine endliche Menge logischer Konstanten $C = \{c_1, \dots, c_m\}$. Durch Einsetzen der Konstanten für die Variablen der prädikatenlogischen Formeln in L werden alle möglichen Grundatome $X = (X_1, \dots, X_q)$ und daraus alle möglichen Grundinstanzen aller Formeln $G = (G_1, \dots, G_p)$ aus L gebildet. Dabei bekommt jedes Element aus G das Gewicht der zu Grunde liegenden Formel aus L zugeordnet.

Alle Elemente X_i können auf einen Wahrheitswert x_i mit

$$(X_1 = x_1, \dots, X_q = x_q), \quad x_i \in \{0, 1\}, \quad i = 1, \dots, q$$

und alle Elemente G_k auf ein Feature $f_k(x)$ mit

$$(G_1 = f_1(x), \dots, G_p = f_p(x)), \quad f_k(x) \in \{0, 1\}, \\ k = 1, \dots, p$$

abgebildet werden.

Wird die Menge der Grundatome X als eine Menge binärer Zufallsvariablen betrachtet, kann ein Markov-Netz $M(L, C)$ konstruiert werden. Dabei besitzt das Netz $M(L, C)$ einen binären Knoten für jedes mögliche Grundatom aus X . Der Wert eines Knotens x_i ist genau dann 1, wenn das zu Grunde liegende Grundatom wahr ist. Es existiert eine ungerichtete Kante zwischen zwei Knoten aus $M(L, C)$, genau wenn beide Grundatome mindestens in einer Formel aus G gemeinsam vorkommen. Somit bilden die Grundatome jeder Grundinstanz einer Formel eine Clique von $M(L, C)$. Die Variablenbelegung der k -ten Clique wird durch das Feature $f_k(x)$ der entsprechenden Grundinstanz der Formel aus G und durch das ihr zugeordnete Gewicht w_k bewertet. Ein Feature $f_k(x)$ ist genau dann 1, wenn x eine mögliche Welt für G_k darstellt, d.h. wenn die Aussage von G_k über den Diskursbereich wahr ist. Folglich ist das k -te Feature $f_k(x)$ ausschließlich durch die Variablenbelegung der k -ten Clique aus der Welt x bestimmt. Die Verbundwahrscheinlichkeit möglicher Welten x , die das resultierende Markov-Netz beschreibt, ist gegeben durch:

$$P(X = x) = \frac{1}{Z} \exp \left(\sum_k w_k f_k(x) \right), \quad (1)$$

wobei der skalare Faktor Z die Gesamtwahrscheinlichkeit aller möglichen Realisationen auf 1 normiert. $w_k f_k(x)$ wird als Cliquenpotenzial bezeichnet.

Das resultierende Markov-Netz wird als *belegtes* Markov-Netz bezeichnet. Tabelle 1 zeigt einen Auszug aus dem in 5.2 beschriebenen MLN. Für dieses aus zwei Formeln

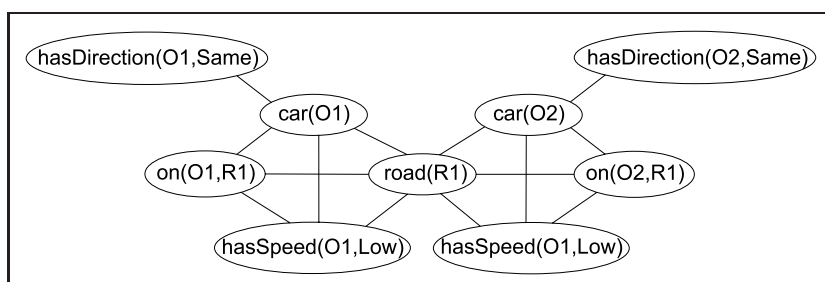


Bild 8: Belegtes Markov-Netz $M(L_1, C_1)$ für das MLN L_1 und die Konstantenmenge C_1 , siehe Text.

bestehendes MLN $L1$ kann bei gegebener Konstantenmenge, z. B. $C1 = \{O1, O2, R1\}$, das entsprechende belegte Markov-Netz $M(L1, C1)$ konstruiert werden, welches in Bild 8 veranschaulicht ist. Für unterschiedliche Mengen von logischen Konstanten werden entsprechend unterschiedlich große belegte Netze konstruiert, die jedoch gewisse strukturelle Gemeinsamkeiten aufgrund der gleichen logischen Struktur des MLN aufweisen. Gl. (1) bewirkt, dass eine mögliche Welt, in der eine oder mehrere der Grundinstanzen der Formeln falsch sind, weniger wahrscheinlich, aber nicht unmöglich wird. Auf diese Weise gelingt es, die harten Einschränkungen auf die Menge der möglichen Interpretationen aus der klassischen deterministischen Prädikatenlogik zu schwächen. Insbesondere führen vereinzelte Verletzungen der prädikatenlogischen Formeln nicht zu einer Inkonsistenz.

Auf ein belegtes Markov-Netz können gewöhnliche probabilistische Inferenzalgorithmen angewendet werden.

5.2 Anwendung zur Klassifikation von Objekten der Verkehrsszene

In einem ersten Experiment wurde ein MLN zur Klassifikation von Objekten der Verkehrsszene erstellt. Die Klassifizierung eines Objekts erfolgt dabei nicht nur aufgrund objektspezifischer Merkmale (z. B. Geschwindigkeit), sondern auch aufgrund der Relation zu anderen Objekten (z. B. „Das betrachtete Objekt befindet sich auf einer Straße“). Dabei wurde das in Bild 9 gezeigte Vokabular verwendet, um Wissen über die Objekte, deren Merkmale sowie ihre Beziehungen zu anderen Objekten durch eine Menge prädikatenlogischer Formeln auszudrücken. Die Objekt- und

Merkmalsklassen sind in taxonomischen Strukturen organisiert. Innerhalb einer Spezialisierungsebene sind die Konzepte als paarweise disjunkt und in ihrer Vereinigung erschöpfend modelliert. Die Relationen repräsentieren Beziehungen zwischen Objekten (z. B. $on(O1, Road1)$) oder zu Objektmerkmalen (z. B. $hasHeight(O1, Average)$). Die Wertebereiche der Merkmale – wie Form, relative räumliche Position oder Bewegung – werden zweckmäßig in eine Menge diskreter, symbolischer Ausprägungen unterteilt. Zu jeder logischen Formel wird in einer Trainingsphase anhand von manuell segmentierten Szenenobjekten ein zugehöriges Gewicht gelernt. Das Gewicht spiegelt die relative Häufigkeit wider, mit der die Formel in den Trainingsdaten erfüllt wurde.

Als Eingangsdaten für den so gebauten Klassifikator dienen die symbolischen Merkmalsausprägungen für alle Ontologie-Merkmale, die aus den vorhandenen quantitativen Sensorinformationen über ein konkretes Objekt abstrahiert werden. Diese dienen zur Erstellung einer Menge von wahren Grundatomen, die als Evidenzdaten bezeichnet werden.

Das MLN zur Klassifikation, gemeinsam mit den Evidenzdaten, wird automatisiert in ein belegtes Markov-Netz übersetzt. Für Anfragen nach einer oder mehrerer Objektklassen (z. B. car) werden mittels Inferenz anhand des belegten Markov-Netzes bedingte Wahrscheinlichkeiten für alle Grundatome der angefragten Objektklassen geschätzt (z. B. $P(car(O1))$, $P(car(O2))$), gegeben die Konstantenmenge $\{O1, O2\}$. Diese Wahrscheinlichkeiten liefern den Wahrheitsgrad der Aussage, die durch das jeweilige Grundatom gemacht wird (z. B. die Wahrscheinlichkeit, mit der

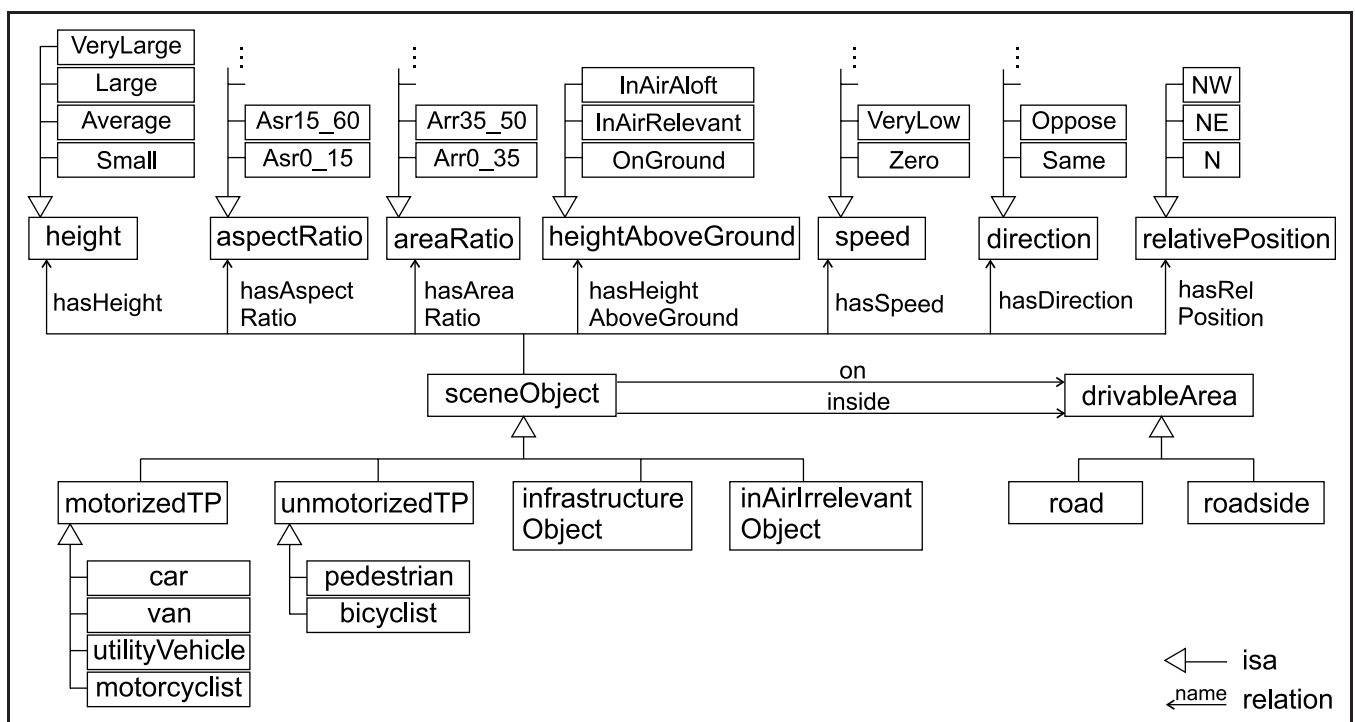


Bild 9: Ontologie für Objekte einer Verkehrsszene. Aus Platzgründen wurde für einige Merkmale nur ein Auszug aus der Menge der möglichen Ausprägungen aufgelistet.



Bild 10: Klassifikationsergebnisse für manuell segmentierte Objekte einer innerstädtischen Verkehrsszene.

die Konstante $O1$ zu der Objektklasse *car* gehört). Dadurch wird eine Wahrscheinlichkeit für die Klassenzugehörigkeit jedes konkreten Objekts aus den Evidenzdaten bestimmt.

Bild 10 stellt die Klassifikationsergebnisse für eine manuell segmentierte innerstädtische Verkehrsszene dar. Zur Inferenz wird der MC-SAT Algorithmus der frei verfügbaren Software *Alchemy* verwendet, welcher den MCMC-Algorithmus (Markov chain Monte Carlo) mit einem SAT-Solver kombiniert.

6 Trajektorienplanung

Dieser Abschnitt stellt Ansätze vor, um auf übergeordneter Ebene getroffene Verhaltensentscheidungen in fahrbare Trajektorien umzusetzen. Das Fahrzeug soll eine gestellte Aufgabe sicher lösen, beispielsweise ein Überholmanöver durchführen oder eine Kreuzung durchfahren. Im Gegensatz zu reaktiven oder regelbasierten Verhalten erlauben wissensbasierte Methoden die explizite Vorgabe von Werten und Zielen, wie beispielsweise dem sicheren Abstandhalten gegenüber anderen Verkehrsteilnehmern. Die zu ermittelnde und an die nachgeschaltete Regelung zu übergebende Trajektorie maximiert dann den Grad der erwarteten Zielerreichung.

Obwohl die Bahnplanung für den Menschen in der Regel eine leicht lösbare Aufgabe darstellt, gilt sie als eine Herausforderung innerhalb der Robotik und Informatik ([8; 9]). Im Fall des Kognitiven Automobils stellt sie besonders hohe Anforderungen an Modellierung und Algorithmik, da neben der nichtholonomen Kinematik des Automobils noch Zwangsbedingungen einzuhalten sind, die sich etwa aus den Verkehrsregeln und dem Verhalten anderer Verkehrsteilnehmer ergeben.

Eine der Grundtechniken in der künstlichen Intelligenz ist die Repräsentation eines Problems als Entscheidungsbaum oder -graph. Anschließend können dann Algorithmen der Graphentheorie verwendet werden, um diesen Graphen zu

durchlaufen und einen Pfad zu finden, der das gestellte Problem löst. Abschnitt 6.1 beschreibt den geometrischen Graphen, der dem Bahnplanungssystem des Kognitiven Automobils zugrunde liegt. Abschnitt 6.2 erläutert, wie dieser durchlaufen werden kann, um eine situationsangepasste Trajektorie zu erhalten.

6.1 Konfigurationsgraph

Zur Betrachtung der Bahnplanung in graphentheoretischem Kontext wird ein Graph zu Grunde gelegt, der sowohl die kinematischen und dynamischen Zwangsbedingungen des Fahrzeuges als auch das aktuelle Lagebild widerspiegelt: Ein Knoten des Graphen entspricht einer möglichen Konfiguration des Fahrzeuges, und eine (gerichtete) Kante zwischen zwei Knoten existiert genau dann, wenn ein Übergang zur Konfiguration des Nachfolgerknotens fahrdynamisch möglich ist. Jeder solchen Kante hinterliegt eine geometrische Repräsentation der Trajektorie, die beide Konfigurationen miteinander verbindet.

Die Wahl des Konfigurationsraumes hängt von den Anforderungen an die zu generierenden Bahnen ab. Für ein zügiges Durchfahren ohne Anhalten muss die Krümmung der Bahn stetig verlaufen. Eine Konfiguration entspricht dann einem möglichen Zustand eines kinematischen Fahrzeugmodells, und der Konfigurationsraum wird von der Position \vec{x} , der Orientierung θ und der Bahnkrümmung κ , die unmittelbar aus dem Lenkwinkel des Fahrzeuges abgeleitet werden kann, aufgespannt. Zur Planung hochdynamischer Fahrmanöver, zum Beispiel von Überholvorgängen oder Ausweichmanövern, lässt sich dieses kinematische Modell durch zusätzliche dynamische Zustandsgrößen entsprechend erweitern, z. B. um Geschwindigkeit, Beschleunigung und Schräglaufwinkel.

Die Bilder 11 und 12 veranschaulichen für den kinematischen Fall, wie ein solcher Graph aufgespannt werden kann. Der Konfigurationsraum wurde in allen Dimensionen gitterartig diskretisiert. Der Übersichtlichkeit halber wurde in Bild 11 eine sehr grobe Diskretisierung verwendet. Bild 12 zeigt, bei feinerer Diskretisierung von θ und κ ,




Bild 11: Konfigurationsgraph. Ein möglicher Pfad ist eingezeichnet. Alle Pfade haben einen stetigen Krümmungsverlauf.




Bild 12: Mögliche Nachfolger eines Knotens des Konfigurationsgraphen bei feinerer Diskretisierung. Die Krümmung κ wurde auf 5 Werte, die Orientierung θ auf 16 Werte diskretisiert.

welche Nachfolger von einem Knoten aus erreichbar sind. Eine strenge Diskretisierung führt zu einem azyklischen Graphen mit hohem Eingangsgrad pro Knoten, dies ist im Sinne eines effizienten Durchlaufens des Graphen wünschenswert.

6.2 Kostengesteuertes Durchlaufen des Graphen

Die Kanten des Graphen werden derart mit Kosten gewichtet, dass ein kürzester Pfad eine Lösung des Bahnplanungsproblems darstellt. Die Kostenfunktion orientiert sich an den vorgegebenen Zielen und kann situationsabhängig angepasst werden, sinnvollerweise minimiert man beispielsweise für ein Einparkmanöver die Bogenlänge des Pfades, während in hochdynamischen Situationen Energiefunktionale mit einfließen, welche Stellamplituden, Beschleunigungen oder den Ruck berücksichtigen. Kosten können auch aus Verkehrsregeln abgeleitet werden, zum Beispiel werden solche Kanten, die die Gegenfahrspur schneiden, mit hohen Kosten versehen. Kanten, die zur Kollision mit Hindernissen oder anderen Verkehrsteilnehmern führen, werden mit unendlich hohen Kosten bestraft.

Die Berechnung eines kürzesten Pfades in einem kantengewichteten Graphen ist ein Standardproblem der Gra-




Bild 13: Geplante Bahn für ein Ausweichmanöver mit Krümmungsverlauf (unten).

phentheorie, für dessen Lösung einige optimal effiziente Algorithmen bekannt sind. Der bekannteste ist der von Dijkstra, der vom Startknoten aus einen aufspannenden Baum aus kürzesten Pfaden berechnet. Der Algorithmus kann durch eine Abschätzfunktion zum A*-Algorithmus erweitert werden, durch die die Lösung unter Beibehaltung der Optimalität beschleunigt wird (vgl. [23]).

Bild 13 zeigt einen für die Umfahrung eines großen Hindernisses errechneten Pfad, bei dem eine Kostenfunktion verwendet wurde, die Spurtreue und Lenkbewegung berücksichtigt. Die Kostenterme

$$C_1 = \int_0^L \left(\frac{d\kappa}{dl} \right)^2 dl \quad (2)$$

$$C_2 = \int_0^L s^2 dl \quad (3)$$

$$C_{ges} = w_1 C_1 + w_2 C_2 \quad (4)$$

beinhalten Integrale über die gesamte Bogenlänge L der Bahn und bestrafen durch Gl. (2) hohe Krümmungsänderungen, also heftige Lenkbewegungen, und durch Gl. (3) großen Abstand s von einer Sollspur, die beispielsweise aus einer digitalen Karte oder dem Wahrnehmungsmodul stammt. Die Sollspur ist in Bild 13 hell eingezeichnet. Die Bahn in Bild 13 besteht aus den in Bild 12 skizzierten Segmenten, die dem rein kinematischen Fahrzeugmodell entstammen. Das nachgeschaltete Reglermodul aus [21] kann der geplanten Bahn dennoch bereits bei Geschwindigkeiten von 50 km/h bis auf 20 cm Abweichung folgen.

7 Experimentelle Ergebnisse in der Urban Challenge

Die *DARPA Urban Challenge 2007* war ein Wettbewerb, der den Fortschritt und die Leistungsfähigkeit autonomer Fahrzeuge öffentlich darstellen und beschleunigen sollte. Das Finale dieses Wettbewerbs fand am 3. November 2007 in Victorville (Kalifornien) statt. Ebenso wie bei ihren Vorgängerveranstaltungen, den Grand Challenges 2004 und 2005, mussten die teilnehmenden Fahrzeuge vollständig autonom und unbemannt vorgegebene Missionen ausführen, ohne den Teams eine Möglichkeit zum Eingreifen zu geben. Im Unterschied zu den früheren Veranstaltungen war bei der Urban Challenge jedoch das Fahren in vorstadtähnlichen Verkehrsszenarien gefordert, wobei der Verkehr durch die anderen teilnehmenden autonomen Fahrzeuge sowie Fahrzeuge des Veranstalters erzeugt wurde. Die große Herausforderung bei diesem Wettbewerb bestand darin, kollisionsfrei und in Einklang mit den kalifornischen Verkehrsregeln (z. B. Vorfahrt an Kreuzungen) zu fahren und dabei kurz vor dem Start bekanntgegebene Missionen zu erfüllen, die Fahrmanöver wie Überholen, 3-Punkt-Wende, Einfädeln in den fließenden Verkehr und Einparken beinhalten konnten. Zudem mussten Strategien für Situation




Bild 14: Gebiet des Urban Challenge Finales.




Bild 15: Pfadplanung in stark belegter Zone mit Daten des Belegungs-gitters (Eingabe) in schwarz und den abgetasteten Wegpunkten als Ausgabe für die Regelung (grau).

demonstriert werden, die nicht vollständig durch die Verkehrsregeln abgedeckt sind, wie beispielsweise verstopfte Kreuzungen befahren oder gesperrte Straßen umgehen. Bild 14 zeigt die Strecke des Finales in Victorville.

Der Wettbewerb hat sowohl die Forschung auf dem Gebiet des autonomen Fahrens erheblich beschleunigt als auch das öffentliche Interesse an diesem Thema geweckt. Von ursprünglich 89 angetretenen Teams erreichten nur 11 das Finale des Urban Challenge. Darunter konnte sich das Team AnnieWAY behaupten, das überwiegend von Partnern des SFB Transregio gebildet wurde. Dabei stellt sich die Frage, ob sich der Erfolg dieser 11 Teams auf besondere Schlüsseltechnologien zurückführen lässt. Eine Gemeinsamkeit war sicher die vorwiegende Verwendung von Laserscannern – gleich sieben Finalisten nutzten den oben vorgestellten Prototyp. Die Verwendung eines Zustandsautomaten sowie eine A*-basierte Routenplanung zählten ebenfalls zu den Standardalgorithmen, waren aber kein Garant für Erfolg. Letztendlich haben Dauertests, Erfahrung und vielleicht auch ein bisschen Glück eine nicht zu vernachlässigende Rolle gespielt. Nachdem der einfache Zustandsautomat zur Bewertung der Verkehrssituation und Generierung eines angemessenen Verhaltens im Wesentlichen aus Zeitgründen gewählt wurde, richtet sich die aktuelle Forschung jedoch verstärkt auf probabilistische Inferenzsysteme wie das zuvor beschriebene MLN, welche langfristig eine weit höhere Flexibilität und Stabilität versprechen [15]. Ein dem vorgestellten ähnlicher Ansatz zur Bahnplanung auf Parkplätzen und in anderen unstrukturierten Bereichen erwies sich als so robust, das er auch als Rettungssystem verwendet wurde, um beispielsweise auf verstopften Kreuzungen und abseits der vorgegebenen Strecke sicher wieder auf Kurs zu kommen.

Bild 15 illustriert einen Test auf einem Parkplatz in der Nähe des Geländes der Urban Challenge. Anders als die geforderten Navigationsfähigkeiten während des Rennens beinhaltete das gewählte Testszenario deutlich mehr




Bild 16: Zwei Fahrbeispiele für AnnieWAYs Fahrt im Finale des Urban Challenge.

schwierige Hindernisse wie z. B. Autos und Randsteine und konnte erfolgreich bewältigt werden.

Bild 16 zeigt abschließend zwei Beispiele von Team AnnieWAY, welche durch Überlagerung von Luftaufnahmen mit dem gefahrenen Pfad im Finale erzeugt wurde.

8 Zusammenfassung und Ausblick

Kognition erschließt Automobilen neuartige Fähigkeiten und wird zu einer qualitativen Verbesserung der Fahrzeugsicherheit und der Effizienz des Straßenverkehrs führen. Der SFB Transregio Kognitive Automobile widmet sich langfristig ausgerichteter Methodenerforschung für die Situationswahrnehmung, Verhaltensentscheidung und -ausführung. Dabei werden Wahrnehmung und Verhaltensgenerierung kooperativ mit anderen Verkehrsteilnehmern abgestimmt. Zur sensorischen Erfassung der Fahrumgebung wurde eine selbstkalibrierende Kameraplattform vorgestellt, die interessante Parallelen zum Aufbau des menschlichen Sehapparats aufweist. Laserscanner erzielen durch direkte Messung die 3D-Geometrie der Szene mit hohem Erfassungswinkel. Diversitäre Methoden der Wahrnehmung verknüpfen die unterschiedlichen Informationen zu einer konsistenten Umgebungsrepräsentation. Diese lässt sich unter Berücksichtigung erlernter Regeln in Markov-Logik-Netzen um symbolisches Wissen erweitern. Ein so entstehendes Lagebild stellt die Grundlage für die Entscheidung und Ausführung situationsangepassten Fahrverhaltens dar. Wissensbasierte Methoden zur Verhaltensentscheidung geben explizit Werte und Ziele vor. Gemeinsam mit einer expliziten diskretisierten Formulierung der kinematischen und dynamischen Fähigkeiten des Kognitiven Automobils wird die Verhaltensentscheidung so in eine Graphensuche überführt, d. h. in die Suche nach dem Pfad in einem Graph, der den größtmöglichen Zielerreichungsgrad erwarten lässt.

Mit der Ausrichtung mehrerer Challenges hat die US Darpa erfolgreich universitäre Ressourcen und industrielles Sponsoring auf automatisches Fahren gelenkt und die Selektion ausgereifter Verfahren vorangetrieben. Dabei gelang mehreren Teams das unbemannte Befahren vorstädtischer Straßennetze im gemischten Verkehr.

Danksagung

Teile der berichteten Arbeiten werden durch die Deutsche Forschungsgemeinschaft, DFG unterstützt. Unser Dank gilt der DFG sowie den beteiligten Partnern des Sonderforschungsbereichs Transregio 28 Kognitive Automobile und allen Mitgliedern des Urban Challenge Teams AnnieWAY für die fruchtbare Zusammenarbeit.

Literatur

- [1] M. Althoff, O. Stursberg, and M. Buss. Online verification of cognitive car decisions. In *Proc. IEEE Intelligent Vehicles Symposium*, pages 728–733, Istanbul, Turkey, June 2007.
- [2] M. Arens and H.-H. Nagel. Quantitative movement prediction based on qualitative knowledge about behavior. *KI Künstliche Intelligenz*, (2/05):5–11, 2005.
- [3] T. Dang, C. Hoffmann, and C. Stiller. Self-calibration for active automotive stereo vision. In *Proc. IEEE Intelligent Vehicles Symposium*, pages 364–369, Tokyo, Japan, June 2006.
- [4] C. Duchow and B. Körtner. Aggregating lane markings into lanes for intersection assistance. In *Proc. IEEE Intelligent Vehicles Symposium*, pages 722–727, Istanbul, Turkey, June 2007.
- [5] C. Frese, J. Beyerer, and P. Zimmer. Cooperation of cars and formation of cooperative groups. In *Proc. IEEE Intelligent Vehicles Symposium*, pages 227–232, Istanbul, Turkey, June 2007.
- [6] M. Goebel and G. Färber. A real-time-capable hard- and software architecture for joint image and knowledge processing in cognitive automobiles. In *Proc. IEEE Intelligent Vehicles Symposium*, pages 734–739, Istanbul, Turkey, June 2007.
- [7] C. Hoffmann, T. Dang, and C. Stiller. Vehicle detection fusing 2D visual features. In *Proc. IEEE Intelligent Vehicles Symp.*, pages 280–285, Parma, Italy, June 2004.
- [8] Y. K. Hwang and N. Ahuja. Gross motion planning – a survey. *ACM Computing Surveys*, 24(3):219–291, 1992.
- [9] S. M. LaValle. *Planning Algorithms*. Cambridge University Press, Cambridge, U.K., 2006.
- [10] R. Nagel, S. Eichler, and J. Eberspächer. Intelligent wireless communication for future autonomous and cognitive automobiles. In *Proc. IEEE Intelligent Vehicles Symposium*, pages 716–721, Istanbul, Turkey, June 2007.
- [11] J. Rasmussen. Skills, rules, and knowledge; signals, signs, and symbols, and other distinctions in human performance models. *IEEE Trans. Systems, Man, and Cybernetics*, SMC-13(3):257–266, Mai/Juni 1983.
- [12] M. Richardson and P. Domingos. Markov logic networks. *Machine Learning*, 62(1-2):107–136, 2006.
- [13] H. Schneidermann and T. Kanade. A statistical method for 3D object detection applied to faces and cars. In *Proc. IEEE Conf. Computer Vision Pattern Recognition*, 2000.
- [14] J. Schröder, M. Hoffmann, M. Zöllner, and R. Dillmann. Behavior decision and path planning for cognitive vehicles using behavior networks. In *Proc. IEEE Intelligent Vehicles Symposium*, pages 710–715, Istanbul, Turkey, June 2007.
- [15] C. Stiller, G. Färber, and S. Kammel. Cooperative cognitive automobiles. In *Proc. IEEE Intelligent Vehicles Symposium*, pages 215–220, Istanbul, Turkey, June 2007.
- [16] C. Stiller and S. Kammel. Zur Interpretation der Verkehrsszenen für städtische Fahrzeugführung. In *Proc. 9. Braunschweig. Symp. Automatisierungs-, Assistenzsysteme und eingebettete Systeme für Transportmittel*, pages 151–164, Braunschweig, February 2008.
- [17] S. Thrun. Learning occupancy grid maps with forward sensor models. *Auton. Robots*, 15(2):111–127, 2003.
- [18] S. Thrun. Robotic mapping: A survey. In G. Lakemeyer and B. Nebel, editors, *Exploring Artificial Intelligence in the New Millennium*. Morgan Kaufmann, 2002.
- [19] S. Vacek, R. Nagel, T. Batz, F. Moosmann, and R. Dillmann. An integrated simulation framework for cognitive automobiles. In *Proc. IEEE Intelligent Vehicles Symposium*, pages 221–226, Istanbul, Turkey, June 2007.
- [20] P. Viola and M. Jones. Rapid object detection using a boosted cascade of simple features. In *Proc. IEEE Conf. Computer Vision Pattern Recognition*, pages 511–518, Kauai, HI, USA, Dezember 2001.
- [21] M. Werling and L. Gröll. Low-level controllers realizing high-level decisions in an autonomous vehicle. In *Proceedings of the IEEE Intelligent Vehicles Symposium*, Eindhoven, Die Niederlande, 2008.
- [22] Ü. Özgüner, C. Stiller, and K. Redmill. Systems for safety and autonomous behavior in cars: The DARPA Grand



Challenge experience. *IEEE Proceedings*, 95(2):1–16, February 2007.

- [23] J. Ziegler, M. Werling, and J. Schröder. Navigating car-like vehicles in unstructured environment. In *Proceedings of the IEEE Intelligent Vehicles Symposium*, Eindhoven, Die Niederlande, 2008.

Manuskripteingang: 9. Juni 2008.

Prof. Dr.-Ing. Christoph Stiller ist Ordinarius und Leiter des Instituts für Mess- und Regelungstechnik an der Fakultät Maschinenbau der Universität Karlsruhe. Forschungsschwerpunkte: Maschinelles Sehen, Kognitive technische Systeme, Fahrerassistenzsysteme, Bahnortungssysteme, Sichtprüfungssysteme.

Adresse: Institut für Mess- und Regelungstechnik, Universität Karlsruhe, 76131 Karlsruhe, E-Mail: stiller@mrt.uka.de

Dr.-Ing. Sören Kammel ist Gruppenleiter am Institut für Mess- und Regelungstechnik und Teamleiter des Karlsruher Grand Challenge Teams. Arbeitsgebiet: Sichtprüfungssysteme, Maschinelles Sehen, Kognitive technische Systeme, 3D-Szenenverstehen.

Adresse: wie oben,
E-Mail: kammel@mrt.uka.de

Dipl.-Ing. Irina Lulcheva ist wissenschaftliche Mitarbeiterin am Institut für Mess- und Regelungstechnik. Arbeitsgebiet: Probabilistische Inferenz für die Fahrumgebungswahrnehmung.

Adresse: wie oben,
E-Mail: lulcheva@mrt.uka.de

Dipl.-Inform. Julius Ziegler ist wissenschaftlicher Mitarbeiter am Institut für Mess- und Regelungstechnik. Arbeitsgebiet: Bahnplanung für Fahrzeuge.

Adresse: wie oben,
E-Mail: ziegler@mrt.uka.de