

Semantische Netze als Wissensbasis automatisierter Fahrzeuge

Stephan Lapoehn, Paulin Pekezou Fouopi, Christian Löper, Sascha Knake-Langhorst, Tobias Hesse

Deutsches Zentrum für Luft- und Raumfahrt e.V., Institut für Verkehrssystemtechnik, Braunschweig

Kurzfassung

Situationsverständnis ist eine Grundvoraussetzung, um im Straßenverkehr kollisionsfreie, komfortable und regelkonforme Fahrmanöver durchführen zu können. Ein Fahrer interpretiert permanent, wie die wahrgenommenen Objekte im aktuellen Geschehen zusammenwirken, welche Eigenschaften und Handlungsspielräume diese haben und in naher Zukunft haben werden. Die Interpretation ist dabei maßgeblich vom Vorwissen des Fahrers abhängig. Auf Basis der Situationsinterpretation und seinen aktuellen Zielen trifft der Fahrer Entscheidungen über das folgende Fahrmanöver. Um das Fahren in höheren Automatisierungsgraden ermöglichen zu können, müssen Automationssysteme ebenfalls, analog dem menschlichen Vorbild, vorrausschauend fahren können und situationsabhängig relevantes Vorwissen in die Entscheidungsfindung einbeziehen. In dieser Arbeit wird ein Konzept vorgestellt, in dem das nötige Vorwissen zur Interpretation einer Situation, zur Manöverplanung und der Ansteuerung des Mensch-Maschine Interface in einer Wissensbasis in Form einer Ontologie modelliert und das Funktionsverhalten über prädikatenlogische Regeln gesteuert wird. Zur Abbildung von unsicherem Wissen werden die Konzepte der Ontologie mit *Markov Logic Networks* verknüpft. Die Umsetzung des Konzepts wurde in einer Simulation einer urbanen Verkehrssituation, in der Vorwissen über das Verhalten von Passanten notwendig ist, evaluiert.

1. Einleitung

Im städtischen Umfeld gestaltet sich die Implementierung höherer Automationsstufen schwierig und bleibt auch in der kommenden Dekade ein Forschungsschwerpunkt, da nicht nur eine komplexe Objekterkennung (Fußgänger, Radfahrer, Gegenverkehr, etc.) notwendig ist, sondern auch Wissen über Zusammenhänge zwischen den Einzelobjekten in einer Verkehrssituation und den daraus abzuleitenden Entscheidungen für die Manöverauswahl. In der in Abbildung 1 gezeigten Situation kann ein menschlicher Fahrer anhand seiner Erfahrung antizipieren, dass eine Person aus der Sichtverdeckung auf die Straße treten könnte

und würde daher besonders langsam fahren. Dieser vorsichtige Ansatz des menschlichen Fahrers reduziert den notwendigen Bremsweg falls kurz vor Erreichen der Sichtverdeckung eine Person auf die Straße tritt und erhöht somit die Wahrscheinlichkeit, dass das Fahrzeug in diesem Fall rechtzeitig zum Stehen kommt. Durch fehlendes a priori-Wissen würde ein reaktiver Softwareagent in dieser Situation lediglich die Kollisionswahrscheinlichkeit mit dem Ball berechnen und, falls notwendig, seine Geschwindigkeit anpassen, sodass eine Kollision mit dem Ball vermieden wird. Tritt dann plötzlich eine Person auf die Straße würde der Softwareagent auch erst in diesem Moment eine Notbremsung auslösen, durch die ggf. eine Kollision mit der Person nicht mehr vermieden werden kann.



Abbildung 1: Nutzung von Vorwissen (auf Ball folgt Kind) im Straßenverkehr

Um das a priori-Wissen für solche Situationen abbilden zu können wird in dem hier gezeigten Ansatz eine Ontologie erstellt und mit logischen Regeln sowie *Markov Logic Networks (MLN)* verknüpft. Auf Grundlage der MLN-basierten Situationsinterpretation entscheidet ein Manöverplaner über das auszuführende Manöver. Es wird darüber hinaus gezeigt wie dieser Ansatz zur situations- und automationsangepassten Ansteuerung des Mensch-Maschine Interface (MMI) im Fahrzeug verwendet werden kann. Durch diesen Ansatz soll die Komplexität der Systeme reduziert werden, sodass eine Adaption durch die Erweiterung der Regelbasis möglich ist und nicht den Eingriff in die Prozeduren der Systemmodule bedingt.

Im folgenden Kapitel werden zunächst die technologischen Grundlagen eingeführt. Das dritte Kapitel umfasst den Stand der Technik. Im vierten Kapitel folgt die Beschreibung der Simulation. Kapitel fünf zeigt das Konzept der Arbeit. Darauf folgen die Auswertung sowie ein Ausblick auf künftige Themen.

2. Technologische Grundlagen

Um Begriffe innerhalb einer Domäne (bspw. dem Straßenverkehr), strukturiert zu beschreiben kann eine Faktenbasis in Form einer Ontologie erstellt werden. In einer Ontologie, als Unterart eines semantischen Netzes, wird über eine Taxonomie und partonomische Relationen ein Repräsentationsvokabular erstellt, welches zur Kommunikation zwischen Automaten und/oder Menschen genutzt werden kann [1]. Dieses Vokabular stellt das Expertenwissen über die Domäne dar und soll somit bei der langfristigen Entwicklung von Technologien als Referenz dienen. Ontologien haben in den letzten Jahrzehnten in diversen Bereichen Anwendung gefunden, beispielsweise in der Medizin (SNOMED CT [2]) oder in der Raumfahrt (SWEET [3]). Die zur Situationserfassung, Manöverplanung und MMI-Ansteuerung notwendigen Konzepte werden in dieser Arbeit in einer Ontologie definiert und den Funktionsmodulen als einheitliches Vokabular zur Verfügung gestellt. Dabei werden zwei Regelsysteme verwendet. Für die Situationserfassung werden Regeln über *Markov Logic Networks* ausgewertet da hier über unsicheres Wissen geschlossen werden muss. Für die Manöverplanung und MMI-Ansteuerung werden Regeln in Form der *Semantic Web Rule Language* (SWRL) genutzt. Eine Übersicht über diese Technologien bietet dieses Kapitel.

2.1 Web Ontology Language

Die *Web Ontology Language* (OWL) 2 ist eine formale Beschreibungssprache für Ontologien die 2009 vom *World Wide Web Consortium* (W3C) veröffentlicht wurde [4]. OWL 2 lässt sich auf die Beschreibungslogik *SROIQ* abbilden, welche ein entscheidbares Fragment der Prädikatenlogik erster Ordnung ist¹. In einer Beschreibungslogik wird das Wissen über eine Domäne in die TBox, das terminologische Wissen, und in die ABox, das assertionale Wissen, unterteilt². In der TBox werden Konzepte über die Taxonomie und Partonomie definiert. Beispielsweise kann in der TBox definiert werden, dass eine Lichtsignalanlage ein Infrastrukturelement ist welches genau drei Lichtsignale ausgeben kann, deren Farben ausschließlich rot, gelb und grün sind und für mindestens einen Fahrstreifen gelten (vgl. Formel 1).

¹ Der Sprachumfang einer Beschreibungslogik wird über die Buchstaben im Namen definiert. So steht das *I* in *SROIQ* für die Möglichkeit inverse Rollen zu definieren (*fasterThan* = *slowerThan*⁻)

² Gelegentlich wird die RBox in der Literatur genannt und dient der weiteren Unterteilung der Axiome, um Rollen und deren Eigenschaften zu beschreiben.

$$\begin{aligned}
& \text{TrafficLight} \sqsubseteq \text{Infrastructure} \sqcap \leq 3 \text{hasLight.T} \sqcap \geq 3 \text{hasLight.T} \sqcap \\
& \forall \text{hasLight. (red or yellow or green)} \sqcap \exists \text{isReferringToLane.Lane} \sqcap \\
& \exists \text{hasStatus. (red or yellow or green)}
\end{aligned} \tag{1}$$

Die ABox enthält Individuen, die in der TBox beschriebenen Konzepte. Beispielsweise wären alle an einer bestimmten Kreuzung vorhandenen Lichtsignalanlagen Individuen des Konzepts der Lichtsignalanlage, die jeweils unterschiedliche Ausprägungen ihrer Rollen besitzen (aktuelle Signalfarbe, Bezugsfahrbahnen, etc.).

2.2 Semantic Web Rule Language

Für die Umsetzung eines „intelligent“ agierenden Systems wird zusätzlich die Fähigkeit benötigt aus dem vorhandenen Wissen und logischen Regeln auf neues Wissen deduktiv zu schließen. SWRL bietet eine Horn-Klausel ähnliche Syntax und kann mit OWL kombiniert werden [5]. Ein einfaches Beispiel für die Syntax findet sich in der Formel 2. Dabei ist linkerhand des Implikationssymbols (\rightarrow) die Prämisse, rechts die Konklusion zu finden.

$$\begin{aligned}
& \text{Vehicle}(?v) \wedge \text{Lane}(?ln) \wedge \text{TrafficLight}(?tl) \wedge \text{isOnLane}(?v, ?ln) \wedge \\
& \text{isReferringToLane}(?tl, ?ln) \wedge \text{hasStatus}(?tl, \text{"red"}) \rightarrow \text{stopInFrontOf}(?v, ?tl)
\end{aligned} \tag{2}$$

2.3 Markov Logic Networks

Markov Logic Networks (MLN), in [6] eingeführt, sind eine Kombination von graphischen Modellen und Konzepten der Wahrscheinlichkeitstheorie. Knoten werden durch Zufallsvariablen repräsentiert. Kanten beschreiben probabilistische Abhängigkeiten zwischen diesen Zufallsvariablen. Damit sind diese Modelle zur Modellierung von Vorwissen mit Unsicherheiten gut geeignet. MLN kombinieren Regeln in Form der Prädikatenlogik erster Ordnung mit Wahrscheinlichkeiten. Die Prädikate in den Regeln können aus den Konzepten einer Ontologie generiert werden.

Ein MLN ist durch die endliche Tupelmenge $L = \{(F_i, w_i)\}, i = 1, \dots, n; n \in \mathbb{N}$ definiert, wobei F_i eine Formel in der Form prädikatenlogischer Aussagen und $w_i \in \mathbb{R}$ die Gewichtung dieser Formel ist. Je größer die Gewichtung einer Formel ist, desto wahrscheinlicher bzw. sicherer ist die Erfüllung dieser Formel. Formeln mit unendlichen Gewichtungen werden deshalb sichere Formeln genannt. Die Gewichtungen werden anhand von Trainingsdaten gelernt. Werden alle Variablen in L durch die endliche Menge logischer Konstanten $C = \{C_i\}, i = 1, \dots, m; m \in \mathbb{N}$ ersetzt, wird das Markov-Netz $M_{L,C}$ wie folgt definiert [6]:

1. $M_{L,C}$ enthält einen binären Knoten für jedes Grundatom aus der endlichen Grundatommenge $X = \{X_i\}, i = 1, \dots, m; X_i \in \{0,1\}$ aller Prädikate von L . Das Grundatom X_i ist eine binäre Zufallsvariable mit dem Wertebereich $\{0,1\}$. $X_i = 0$ bedeutet, dass das Grundatom X_i falsch ist. $X_i = 1$ bedeutet, dass das Grundatom X_i wahr ist.
2. $M_{L,C}$ enthält ein binäres Feature für jede Grundinstanz aus der endlichen Grundinstanzmenge $G = \{G_i = f_i(x)\}, i = 1, \dots, p; x \in X, f_i(x) \in \{0,1\}, p \in \mathbb{N}$ aller Formeln F von L . Das Feature $f_i(x)$ nimmt den Wert 0 an, wenn die Grundinstanz G_i für das gegebene $x \in X$ falsch ist und 1 sonst. Die Gewichtung w_i des Feature f_i ist die Gewichtung der entsprechenden Formel F_i .
3. $M_{L,C}$ enthält eine Kante zwischen zwei Knoten, wenn die entsprechenden Grundatome in mindestens einer Grundinstanz vorhanden sind.

Ein MLN kann als ein Template betrachtet werden, womit ein Grund-Markov-Netz für gegebene logische Konstanten aufgebaut wird. Die Wahrscheinlichkeit einer möglichen Welt der Grundatome ist durch Gleichung 3) gegeben, wobei Z der Normalisierungsfaktor ist. Diese Wahrscheinlichkeit sowie den Zustand der Grundatome (Knoten) können anhand von Inferenzalgorithmen für probabilistische graphische Modelle (z.B. „Belief Propagation“ oder „Simulated annealing“) geschätzt werden [6].

$$P(X = x) = \frac{1}{Z} \exp\left(\sum_{i=1}^p w_i f_i(x)\right) \quad (3)$$

3. Stand der Technik

In diesem Kapitel wird der Stand der Technik zur wissensbasierten Situationserfassung und Manöverplanung im Hinblick auf das Gesamtsystem gesondert betrachtet, da sich der Fokus dieser Systemaspekte technologisch unterscheidet.

3.1 Situationserfassung

Wissensbasierte Verfahren zur Situationserfassung verwenden Kontextinformationen über Objekte und Situationen wie z.B. die Existenzwahrscheinlichkeit, die Position und Objektgröße um die Situation holistisch zu modellieren und zu interpretieren [7]. Die Modellierung dieser Kontextinformationen zur Objektklassifikation in einer Ontologie wurde in [8, 9] vorgeschlagen und mit logischen Regeln ergänzt. MLN wurden anhand dieser Regeln gelernt und verwendet, um gegebene Bildregionen zu klassifizieren. In [10, 11] wurden semantische Beziehungen zwischen Objekten wie z.B. die Fahrstreifenzugehörigkeit, die relative Position und die Verkehrsregeln mit einer Ontologie und logischen Regeln modelliert, um die Situati-

on an einer Kreuzung zu analysieren. Die Konzepte aus diesen Arbeiten wurden für die hier vorgestellte Anwendung adaptiert und vereinfacht, um eine echtzeitfähige Situationsinterpretation zu ermöglichen.

3.2 Manöverplanung

Die Modellierung von Manövern in Ontologien fand in der Literatur bisher wenig Beachtung. Manöverbeschreibungen außerhalb von Ontologien lassen sich jedoch bereits unter anderem in [12, 13] finden. Diese wurden großteilig nachmodelliert. In [14] wurde das Fahrer-Modell mit dem Kontext-Modell in einer Ontologie zusammengeführt, um eine erweiterte Datenbasis für intelligente Systeme und adaptive Mensch-Maschine Interfaces im Fahrzeug zur Verfügung zu stellen. Konzepte aus diesem Ansatz (Manöver, Fahrzeug- und Event-Beschreibungen) wurden für den Automationskontext adaptiert und in die Fahrzeugautomation eingebunden.

4. Simulation



Abbildung 3: Betrachtete Verkehrssituation in der Simulation



Abbildung 2: Links – Information über Bremsung; Rechts - Notbremsung bei Detektion des Kindes

Das in Kapitel 1 beschriebene Szenario wurde in die Simulation überführt, um das Gesamtsystem zu evaluieren. Abbildung 3 zeigt drei Schlüsselszenen der Simulation. Die Automation muss bei der Erkennung des Balls abbremesen, um in der letzten Szene eine Notbremsung einleiten zu können, die das Fahrzeug vor dem Passanten zum Stillstand bringt. Die Objektdaten wurden aus der Simulation heraus generiert, wobei die Sichtverdeckung durch

das am Seitenrand parkende Fahrzeug über ein Raytracing-Verfahren berücksichtigt wurde. Das MMI bestand aus einer digitalen Nachbildung des Fahrzeugkombiinstrument, das parallel zur Simulation auf einem zweiten Bildschirm ausgegeben wurde (siehe Abbildung 2). Die Anzeige links zeigt eine Information über eine mögliche Kollision als Auslöser für eine Geschwindigkeitsreduktion. Die rechte Anzeige zeigt die Notbremsung.

5. Konzept

Abbildung 4 zeigt eine Übersicht des aufgebauten Systems. Zur Modellierung der Wissensbasis wurde eine Ontologie in der Beschreibungssprache OWL 2, eine Regelbasis in SWRL und ein trainiertes *Markov Logic Network* verwendet.

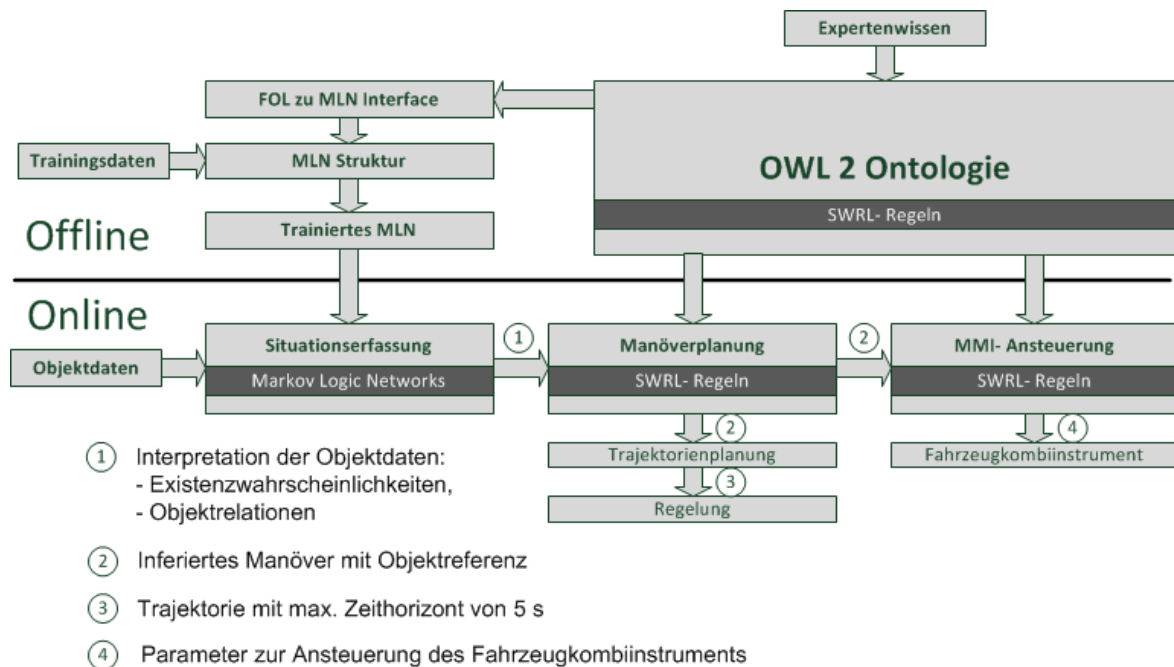


Abbildung 4: Zusammenspiel der Einzelkomponenten in der wissensbasierten Fahrzeugautomation

Die **Ontologie** umfasst die Beschreibung der drei Domänen Situationserfassung, Manöverplanung und MMI. Die Ontologie wurde anhand von **Expertenwissen** erstellt. Regeln ohne Unsicherheiten, die für die Manöverplanung und MMI-Ansteuerung genutzt wurden, konnten mit SWRL direkt in der Ontologie hinterlegt werden. Für das Lernen der MLN-Struktur wurde ein **First Order Logic (FOL) zu MLN – Interface** entwickelt, welches die Erstellung der Regeln aus den Konzepten und Rollen der Ontologie unterstützt. Die aus den Regeln resultierende MLN-Struktur wurde mit **Trainingsdaten** kombiniert, um die Gewichtungen zu lernen. Die Modellierung der Ontologie, der Regelbasis sowie das Lernen der MLN erfolgten offline. Zur Laufzeit wurden im Situationserfassungsmodul die Wahrscheinlichkeiten der Regeln die

eine Situation beschreiben, abhängig von den eingehenden **Objektdaten**, inferiert. Die resultierende Interpretation wird von dem **Manöverplaner** zur Laufzeit in die Ontologie eingespeist. Über die SWRL Regeln und in der Ontologie definierten Konzept- und Rollen-Definitionen wird das auszuführende Manöver inferiert (2). Auf Basis der Manöverwahl wird die passende **Trajektorie** berechnet (3) und von dem **Regler** umgesetzt. Das Modul zur **MMI-Ansteuerung** inferiert parallel auf Basis des Manövers, wie das **Fahrzeugkombi-instrument** angesteuert werden muss (4).

5.1 Ontologie Design

In Anlehnung an die Arbeit von Bohlken sind alle Konzepte der Ontologie Hyponyme *konzeptueller* oder *physikalischer Objekte* [15]. *Konzeptuelle Objekte* beschreiben domänenabhängige Konzepte die keiner physikalischen Repräsentation in der realen Welt entsprechen (Events, Definitionen). *Physikalische Objekte* beschreiben Objekte, die in einer realen Szene auftreten können (bspw. Infrastrukturkomponenten und Personen). Diese Konzepte sind allgemeingültig und domänenunabhängig (Auszug siehe Abbildung 5). Konzepte der drei Domänen Situationserfassung, MMI und Automation wurden in die *physikalischen* und *konzeptuellen Objekte* eingegliedert.

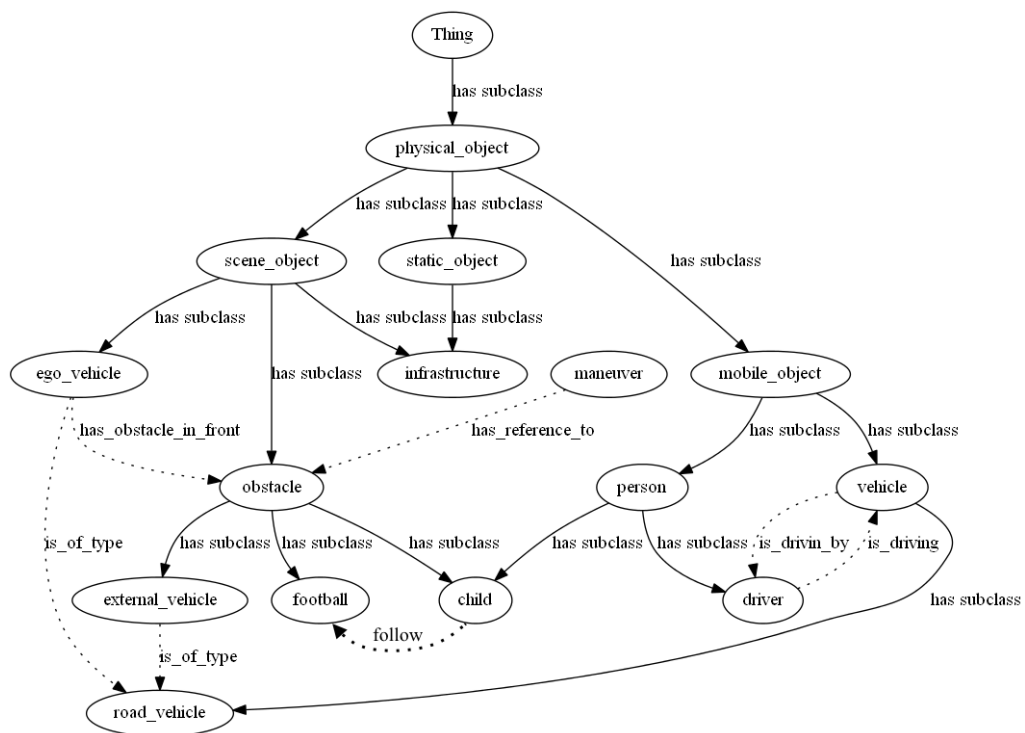


Abbildung 5: Auszug aus der Beschreibung der physikalischen Objekte.

5.2 Situationserfassung

Die Verhaltensprädiktion hat in dieser Arbeit die Aufgabe zu erkennen, dass ein Kind sehr wahrscheinlich einem Ball folgen wird (hier „Kind folgt Ball“ genannt). Dafür wurden die in [8, 9] beschriebenen wissensbasierten Ansätze übernommen und die Wissensbasis vereinfacht, um die Echtzeitanforderungen zu erfüllen. *Physikalische Objekte*, die für die o.g. Verhaltensprädiktion benötigt wurden, sind in Abbildung 5 in dem Knoten *scene_object* enthalten. Die Relationen zwischen den für die Verhaltensprädiktion relevanten Objekten $C = \{\text{football}, \text{child}, \text{hallucinated_object}\}$ wird durch das zweistellige Prädikat $\text{follow}(c_1, c_2), c_1 \in C, c_2 \in C$ beschrieben, wobei das Prädikat wahr ist, wenn das Objekt c_1 dem Objekt c_2 folgt. *hallucinated_object* ist ein *konzeptuelles Objekt* und findet sich somit nicht unter *scene_object*. Da die Verhaltensprädiktion Unsicherheiten beinhaltet, wurden die Regeln unter Anwendung der Konzepte der Ontologie erstellt und die Wahrscheinlichkeiten gelernt. Die Regeln in Tabelle 1 modellieren die Situation, dass ein Kind einem Ball folgt.

Tabelle 1: Ausschnitt des MLN zur Prädiktion der Situation "Kind folgt Ball".

Gewichtung	Regeln
2,04051	$\forall x_1 \forall x_2 (\text{football}(x_1) \wedge \text{hallucinated_object}(x_2) \rightarrow \text{child}(x_2))$
3,0512	$\forall y_1 \forall y_2 (\text{child}(y_1) \wedge \text{football}(y_2) \rightarrow \text{follow}(y_1, y_2))$

In boolescher Logik würde ein Kind entweder immer oder nie dem Ball folgen. Deshalb wurden die Formeln mit Trainingsdaten kombiniert, um die Gewichtungen zu lernen. Die Gewichtungen haben die Bedeutung, dass die Existenz eines Kindes halluziniert werden soll, sobald ein Ball sichtbar ist (vgl. Tabelle 1). Darüber hinaus wird das (halluzinierte) Kind sehr wahrscheinlich dem Ball folgen. Das zu dieser Tabelle passende Grund-Markov-Netz stellt die Abbildung 6 dar. Zur Laufzeit wurden die klassifizierten Objekte (football, child) dem gelernten MLN zur Verhaltensprädiktion übergeben. Wurde ein Ball erkannt, wurde über die Existenz eines Kindes halluziniert, das dem Ball folgen wird. Wurde zu dem Ball auch ein Kind erkannt, wurde mit einer hohen Wahrscheinlichkeit inferiert, dass das Kind dem Ball folgen würde.




Abbildung 6: Grund-Markov-Netz des MLN aus der Tabelle 1 für die Konstanten $\{o_1, o_2\}$

5.3 Manöverplanung

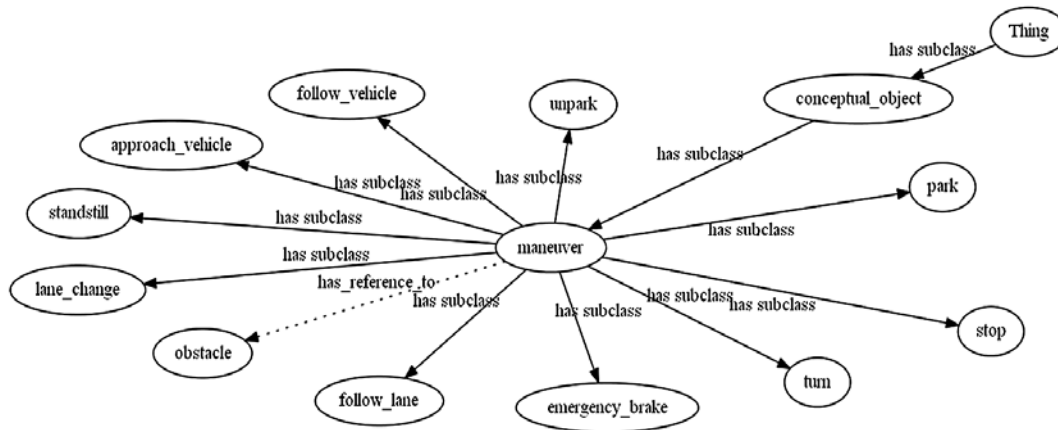


Abbildung 7: Taxonomie der konzeptuellen Objekte für die Domäne Manöverplanung.

Donges [16] unterteilt in dem 3-Ebenen-Modell die Fahraufgabe in die Ebenen Navigation, Führung und Stabilisierung. Dieses Modell wurde in der Arbeit von Löper et. al [17] weiter modularisiert und die Führungsebene in die Manöver- und die Trajektorienplanungsebene unterteilt. Manöver beschreiben auf natursprachlicher Ebene zeitlich und räumlich zusammenhängende Gruppen von Fahrzeugbewegungen im Kontext einer Verkehrssituation („Überholen“, „Stoppen“, „Notbremsung“, etc.). Innerhalb der *konzeptuellen Objekte* finden sich die Manöverdefinitionen (Abbildung 7). Manöver können mit Referenzen auf Hindernisse versehen werden (Bsp.: Manöver „Fahrzeug folgen“ benötigt ein Fahrzeug als Referenz). Für die Manöverauswahl wurden SWRL-Regeln definiert. Formel 4 zeigt eine Regel für das Stop-Manöver (Komfortables Abbremsen vor einem Objekt bis in den Stillstand). In der Prämisse beschreibt o das Hindernis, cp die Kollisionswahrscheinlichkeit, ep die Existenzwahrscheinlichkeit des verdeckten Kindes und caa die Negativbeschleunigung die notwendig wäre, um vor dem Kind zu halten. In der Konklusion steht m für zu klassifizierende Manöver und v für das Fahrzeug. Die Regel für die Notbremsung unterscheidet sich von Formel 4 ausschließlich in den numerischen Werten in der Prämisse und dem Nothaltekonzept in der Konklusion. Da die Wahrscheinlichkeiten mit Sichtung des Kindes steigt, wird erst das Stop-Manöver ausgeführt und, falls nötig, bei Sichtung die Notbremsung eingeleitet.

$$\begin{aligned}
 & has_collision_probability(? o, ? cp) \wedge greaterThan(? cp, 0.5) \wedge \\
 & has_existence_probability(? o, ? ep) \wedge greaterThan(? ep, 0.5) \wedge \\
 & has_collision_avoidance_acceleration(? o, ? caa) \wedge is_between(? caa, -1, -6) \rightarrow \quad (4) \\
 & stop(? m) \wedge is_driving_maneuver(? v, ? m) \wedge has_reference_to(? m, ? o)
 \end{aligned}$$

5.1 Mensch-Maschine Interface (MMI)

Unter den *konzeptuellen Objekten* wurden in der Ontologie *vehicle_events* eingeführt. Als *vehicle_events* wurden drei Nachrichtentypen klassifiziert (*alert*, *warning* und *indication*). Die Definition der *alert*-Nachricht wird durch das folgende Axiom beschrieben:

$$\begin{aligned} alert \sqsubseteq VehicleEvent \sqcap \exists hasEventTopic.T \\ \sqcap \forall hasDisplayPriority.1 \sqcap \exists isFeedbackRequired.T \end{aligned} \quad (5)$$

Über die Priorität kann gesteuert werden, wann und wo welche Nachricht angezeigt wird. Wolf et al. [18] zeigten, dass die Priorisierung, das Timing und der Informationskanal bei der Übermittlung von sicherheitsrelevanten Nachrichten an den Fahrer berücksichtigt werden müssen, da der Mensch nur 5 – 9 Informationseinheiten gleichzeitig aufnehmen kann und ein Großteil bereits mit Umfeldfaktoren belegt ist. Die Vergabe der Priorität in Formel 5 zeigt wie solche MMI-Anforderungen prinzipiell über wissensbasierte Verfahren abgebildet werden können. Die SWRL-Regeln zur Steuerung des MMI nutzen als Eingabe das aktuell von der Manöverplanung gewählte Fahrmanöver und bilden dieses auf eines der *vehicle_events* ab:

$$\begin{aligned} vehicle_event(?e) \wedge emergency_brake(?m) \rightarrow \\ alert(?e) \wedge has_event_topic(?e, "Notbremsung!") \wedge \\ is_feedback_required(?e, true) \end{aligned} \quad (6)$$

6. Resümee




Abbildung 11: Beispielergebnisse der Verhaltensprädiktion für zwei unterschiedliche Szenen.

Links- Szene 1; rechts- Szene 2

Die Komplexität des MLN, wird durch die Anzahl der Prädikate und Formeln beschrieben. Das MLN wies eine geringe Komplexität auf. Insgesamt wurden 4 Prädikate und 6 Formeln zur Verhaltensprädiktion des (halluzinierten) Kindes verwendet. Prinzipiell sollten kleine MLN für unterschiedliche Aspekte einer Situation erstellt werden, um die Prozessierungsdauer möglichst gering zu halten. Die Objektklassen wurden in dieser Arbeit von der Simulation generiert. Die Ergebnisse der Verhaltensprädiktion für 2 unterschiedliche Szenen ist in Tabelle 2 dargestellt. Die zugehörigen Objektmarkierungen finden sich in Abbildung 11. In Szene 1 war lediglich der Ball sichtbar (linkes Bild). Die Existenz eines Kindes wurde aufgrund der Existenz des Balls mit einer Wahrscheinlich von 0,76 inferiert, obwohl das Kind noch

nicht sichtbar war. Darüber hinaus wurde mit einer Wahrscheinlichkeit von 0,752 inferiert, dass das halluzinierte Kind dem Ball folgen wird. Wurde nach der Halluzination in der Szene 1 kein Kind sichtbar, wurde das halluzinierte Kind aus der Objektliste entfernt nachdem das Ego-Fahrzeug die Bahn des Balls überquert hatte. In der Szene#2 wurde zu dem Ball auch das Kind sichtbar (rechtes Bild).

Tabelle 2: Inferenzergebnisse und -Laufzeit des MLN zur Verhaltensprädiktion

Szene	Inputprädikat		Inferenzergebnis		Laufzeit
	Bezeichnung	Werte	Bezeichnung	Werte	
Szene 1: Ball sichtbar	hallucinated_object (o ₂)	1	child(o ₂)	0,76	42 ms
	football(o ₁)	1	follow(o ₂ , o ₁)	0,752	
Szene 2: Ball & Kind sichtbar	child(o ₂)	1	follow(o ₂ , o ₁)	0,897	31 ms
	football(o ₁)	1			

Die Halluzination über die Existenz des Kindes wurde aufgrund des sichtbaren Kindes validiert. Die Tatsache, dass das Kind den Ball folgen wird, wurde mit einer Wahrscheinlichkeit von 0,897 inferiert. Dieser Wahrscheinlichkeit war deutlich höher als die aus der Szene#1. Die Inferenzzeiten für die Szene#1 und #2 lagen bei 42ms und 31ms. Die Simulation wurde auf einem Notebook mit durchschnittlichen Leistungskennwerten betrieben (Prozessor: i7-5600U, 8 GB DDR3 RAM, Intel HD Graphics 5500).

Tabelle 3: Metrik zur Gesamtontologie (Umfelderfassung, Manöverplanung, MMI)

Axiome	Axiomanzahl
Konzept	183
Subklassen	190
Äquivalente Klassen	17
Disjunkte Klassen	30
Objekt-Rollen	26
Inverse	6
Funktionale	1
Asymmetrische	1
Domain-Angaben	19
Range-Angaben	17
Datentyp-Rollen	30
Funktionale	14
Domain-Angaben	28
Range-Angaben	28
Individuen \emptyset	6

Klassenzuweisungen	6
Objektrollen-Zuweisungen	4
Datenrollen-Zuweisungen	3
Gesamt	609

Die Prozessierungsdauer für die Manöverplanung und MMI-Ansteuerung mit dem Regler auf Basis der SWRL, betrug im Durchschnitt 182 ms (Inferenzmaschine: Pellet [19]). Die Inferenzzeit ist abhängig von der Komplexität der Ontologie (Anzahl Konzepte, Rollen, Rolleneigenschaften, etc.). Tabelle 3 führt die entsprechende Metrik auf. Die Ontologie umfasste vergleichsweise wenige Axiome (vgl. SNOMED CT: ca. 292.000 Konzepte und 62 Rollendefinition [20]). Das Fahrzeug war in der Lage vor dem Kind zum Stehen zu kommen, da bereits bei der Detektion des Balls eine graduelle Reduzierung der Geschwindigkeit durchgeführt wurde. Dennoch ist eine maximal Latenz von 50ms auch für komplexe Situationen, die Zugriff auf viele Axiome einer Wissensbasis benötigen, angestrebt.

Ein offensichtlicher Vorteil des Systems ist die einfache Änderbarkeit und Erweiterbarkeit des Systemverhaltens, indem die Regeln angepasst oder ersetzt werden. Für die Bearbeitung von Ontologien stehen ausgereifte Tools, Inferenzmaschinen und Programmierschnittstellen zur Verfügung. Für regelbasierte Logiksysteme ohne Unsicherheiten ist mit der Verknüpfung von OWL und SWRL eine effiziente Umsetzung gegeben. SWRL ermöglicht die Zeichenkettenverarbeitung innerhalb von Regeln und den Vergleich numerischer Datentypen, Datums- und Zeitangaben. Nachteilig ist, dass weder die logische Negation von Rollen noch die Disjunktion in SWRL Regeln unterstützt wird (Verletzung der Monotonie). Dies führt zu teilweise komplexen oder teil-redundanten Regeln. Ein weiterer Nachteil ist, dass nur Individuen, die in der Prämisse einer Regel vorhanden sind auch in der Konklusion verwendet werden können (DL-Safe Rules). Daraus resultiert, dass das Faktum über das neue Informationen erschlossen werden soll bereits vor der Regelausführung bekannt sein muss (vgl. Formel 6).

7. Zusammenfassung

In dieser Arbeit wurde ein wissensbasiertes System im Kontext des automatisierten Fahrens vorgeschlagen. Die Wissensbasis, bestehend aus einer Ontologie, einer Regelbasis und einem trainierten MLN, wurde offline erstellt. Zur Laufzeit wurde anhand der Wissensbasis und Evidenzen die Situation interpretiert, sowie die Manöverauswahl und MMI-Ansteuerung inferiert. Die Verhaltensprädiktion war in der Lage die Intention eines Kindes, aus einer Sichtverdeckung heraus einem Ball zu folgen, zu antizipieren und zu validieren. Das prädizierte Verhalten wurde der Manöverplanung bereitgestellt, so dass potentielle Kollisionen frühzeitig erkannt und durch Stop- und Notbremsmanöver verhindert werden konnten. Über

prädikatenlogische Regeln konnte der Manöverplaner und die MMI-Ansteuerung einfach parametrisiert werden, wodurch eine schnelle Adaption des Systems außerhalb der prozeduralen Verarbeitungslogik ermöglicht wurde. Die Evaluation erfolgte in einer Simulation.

8. Ausblick

Künftige Ansätze der Autoren werden sich mit der Segmentierung von Domänenwissen auf Basis der in den Regeln genutzten Konzepte für die Funktionsimplementierung beschäftigen. Dazu sollen die in den Regeln referenzierten Konzepte zur Übersetzungszeit aus der Ontologie automatisiert extrahiert werden können, um diese den Fahrzeugfunktionen zur Laufzeit zur Verfügung stellen zu können. Ein weiterer Schwerpunkt liegt in der Modellierung der Manöver, beispielsweise über die Einführung von Manöverphasen, Start- und Abbruchbedingungen und den zugehörigen Regeln. Mit Fuzzy-Controllern sollen künftig auch vage Konzepte in die Modelle einfließen. Darüber hinaus müssen Methoden zur systematischen Handhabung von Inkonsistenzen, etwa wenn sich die Wissensbasis und die Realität widersprechen, entwickelt werden. Die Erprobung im realen Stadtverkehr steht ebenfalls noch aus.

Literaturverzeichnis

- [1] N. Noy and D. L. McGuinness, "Ontology development 101: A guide to creating your first," *Technical Report SMI-2001-0880, Stanford Medical Informatics*, 2001.
- [2] R. Cornet and N. de Keizer, "Forty years of SNOMED: a literature review.," *BMC medical informatics and decision making* 8, 2008.
- [3] R. G. Raskin and M. J. Pan, "Knowledge representation in the semantic web for Earth and environmental terminology (SWEET).," *Computers & geosciences* 31.9, 2005.
- [4] B. Motik, P. F. Patel-Schneider, B. Parsia, C. Bock, A. Fokoue, P. Haase and M. Smith, "OWL 2 web ontology language: Structural specification and functional-style syntax," *W3C recommendation 27.65*, 2009.
- [5] I. Horrocks, P. F. Patel-Schneider, H. Boley, S. Tabet, B. Grosz and M. Dean, "SWRL: A Semantic Web Rule Language Combining OWL and RuleML," *W3C Member submission 21*, 2004.
- [6] M. Richardson and P. Domingos, "Markov Logic Networks," *Machine Learning*, vol. 62, no. 1-2, p. 107–136, 2006.
- [7] C. Galleguillos and S. Belongie, "Context Based Object Categorization: A Critical Survey," *Comput. Vis. Image Underst.*, vol. 114, no. 6, p. 712–722, 2010.

- [8] I. Hensel, "Probabilistisch-logische Inferenz relationaler Situationsbeschreibungen aus Verkehrsbildfolgen," 2013.
- [9] C. Stiller, S. Kammel, I. Lulcheva and J. Ziegler, "Probabilistische Methoden in der Umfeldwahrnehmung Kognitiver Automobile," *Automatisierungstechnik Methoden und Anwendungen der Steuerungs-, Regelungs- und Informationstechnik*, vol. 56, no. 11, p. 563–574, 2008.
- [10] M. Hülsen, J. M. Zöllner and C. Weiss, "Traffic intersection situation description ontology for advanced driver assistance," 2011.
- [11] B. Hummel, "Description Logic for Scene Understanding at the Example of Urban Road Intersections," Univ, Karlsruhe.
- [12] P. Levi, "Verteilte Aktionsplanung für autonome mobile Agenten," *KI Informatik Fachberichte 181*, 2013.
- [13] H.-H. Nagel, "A vision of 'vision and language' comprises action: An example from road traffic," *Artificial Intelligence Review 8.2-3*, 1994.
- [14] M. Feld and C. Müller, "The automotive ontology: managing knowledge inside the vehicle and sharing it between cars.," *Proceedings of the 3rd International Conference on Automotive User Interfaces and Interactive Vehicular Applications. ACM*, 2011.
- [15] W. Bohlken, Realzeit-Szeneninterpretation mit ontologiebasierten Regeln, Universität Hamburg, 2012.
- [16] E. Donges, "Fahrerverhaltensmodelle," in *Handbuch Fahrerassistenzsysteme*, Springer Fachmedien Wiesbaden, 2015.
- [17] C. Löper, C. Brunken, G. Thomaidis, S. Lapoehn, P. P. Fouopi, H. Mosebach and F. Köster, "Automated Valet Parking as Part of an Integrated Travel Assistance," *16th International IEEE Conference on Intelligent Transportation Systems*, 2013.
- [18] H. Wolf, R. Zöllner and H. Bubb, "Ergonomischer Lösungsansatz für die gleichzeitige Rückmeldung mehrerer Fahrerassistenzsysteme an den Fahrer," in *2. Tagung Aktive Sicherheit durch Fahrerassistenz*, Munich, 2006.
- [19] E. Sirin, B. Parsia, B. C. Grau, A. Kalyanpur and Y. Katz, "Pellet: A practical owl-dl reasoner," *Web Semantics: science, services and agents on the World Wide Web 5.2*, 2007.
- [20] K. Dentler, R. Cornet, A. Ten Teije and N. De Keizer, "Comparison of reasoners for large ontologies in the OWL 2 EL profile," *emantic Web*, 2(2), 71-87, 2011.