

Kontextbasierte Bewegungsplanung automatisierter Fahrzeuge an Kreuzungen mit vernetzten Lichtsignalanlagen

Johannes Müller*, Jan Strohbeck*, Max Mertens* und Michael Buchholz†

Zusammenfassung: Die Vielzahl an Situationen, welche im urbanen Straßenverkehr vorkommen, stellt aktuelle Bewegungsplanungsverfahren in automatisierten Fahrzeugen immer noch vor große Herausforderungen. Während die Modellierung zusätzlicher Szenarien für klassische Verfahren oft sehr mühsam ist, erleichtert die kontextbasierte Bewegungsplanung diese Erweiterung. Um dies zu demonstrieren, wird in diesem Beitrag ein bestehendes kontextbasiertes Verfahren um das Überqueren einer Kreuzung mit vernetzter Lichtsignalanlage erweitert. Diese stellt auch prädiktive Informationen zur Verfügung, welche durch die Bewegungsplanung im Fahrzeug gewinnbringend verwendet werden. Das vorgestellte Verfahren wird simulativ und im realen Verkehr evaluiert. Gegenüber einer rein reaktiven Planung zeigen sich dabei deutliche Vorteile.

Schlüsselwörter: Bewegungsplanung, Lichtsignalanlage, vernetztes automatisiertes Fahren

1 Einleitung

Vernetzte automatisierte Fahrzeuge müssen im urbanen Raum eine Vielzahl verschiedener Szenarien beherrschen. Dabei sollen alle Spezifika des einzelnen Szenarios berücksichtigt werden, gleichzeitig muss der Planungsalgorithmus aber möglichst generell mit allen Szenarien umgehen können. Diese konkurrierenden Anforderungen stellen heutige Bewegungsplanungsverfahren immer noch vor große Herausforderungen. Klassische Ansätze teilen die Bewegungsplanung in Handlungs- und Trajektorienplanung auf [1]. Die Handlungsplanung muss also für alle antizipierten Szenarien immer eine adäquate Verhaltensentscheidung treffen, für welche die Trajektorienplanung dann eine gültige Trajektorie berechnen muss. In den dabei üblicherweise verwendeten Zustandsautomaten erfolgt die Modellierung neuer Szenarien indirekt: Für die neue Situation muss zunächst ein adäquates Verhalten modelliert werden. Zu diesem müssen Entscheidungskriterien definiert werden, welche einerseits die Situation beschreiben und andererseits die Auswahl der vorgesehenen Verhaltensentscheidung ermöglichen. Dabei müssen die Kreuzabhängigkeiten der jeweiligen Kriterien bedacht werden. Entsprechend sind viele existierende Verfahren zum

*J. Müller, J. Strohbeck und M. Mertens sind Akademische Mitarbeiter am Institut für Mess-, Regel- und Mikrotechnik – Universität Ulm, Albert-Einstein-Allee 41, 89081 Ulm (E-Mail: {johanneschristian.mueller, jan.strohbeck, max.mertens}@uni-ulm.de).

†Michael Buchholz ist Akademischer Oberrat am Institut für Mess-, Regel- und Mikrotechnik – Universität Ulm, Albert-Einstein-Allee 41, 89081 Ulm (E-Mail: michael.buchholz@uni-ulm.de).

Lösen von Kreuzungsszenarien mit vernetzter Lichtsignalanlage, z.B. [2, 3], nicht einfach auf andere Szenarien wie das Einfädeln in eine Vorfahrt-Achten-Kreuzung übertragbar.

Modernere Verfahren, z.B. Methoden auf Basis von Markov-Entscheidungsprozessen [4], selbstbestärkendem Lernen [5, 6] oder Ende-zu-Ende-Lernverfahren benötigen zwar keine explizit modellierten Kriterien mehr, dafür aber einen großen Trainingsdatensatz, der die zu lösende Situation beschreibt [7].

Im Gegensatz dazu kann das kontextbasierte Bewegungsplanungsverfahren [8] einfach auf neue Szenarien erweitert werden. Die Kernidee dieses Verfahrens besteht darin, die einzelnen Situationen durch die jeweils geltenden Randbedingungen, Modellannahmen und Heuristiken zur Bestimmung möglicher Trajektorienkandidaten zu beschreiben. Diese Beschreibung wird *Situationskontext* genannt und vereinfacht die Modellierung erheblich. Die Handlungs- und Trajektorienplanung wird in einem Schritt mit Hilfe eines Sampling-Verfahrens gelöst, welches über alle verfügbaren Handlungsoptionen eines Situationskontexts iteriert und die dazu berechnete Trajektorie auswählt, die alle Randbedingungen erfüllt und insgesamt die geringsten Kosten aufweist. Durch die explizite Beschreibung von Randbedingungen und Modellannahmen kann das Planungsverfahren auf mengenbasierte Ansätze zur Behandlung von Unsicherheiten zurückgreifen, welche dem Verfahren Sicherheitsgarantien verleihen.

In diesem Beitrag wird ein Situationskontext für Kreuzungen mit vernetzten Lichtsignalanlagen modelliert. Damit wird das kontextbasierte Bewegungsplanungsverfahren [8], welches bisher an Vorfahrt-Achten-Kreuzungen mit Infrastrukturunterstützung zur Auflösung von Verdeckungen evaluiert wurde, für die Anwendung an Kreuzungen mit vernetzten Lichtsignalanlagen erweitert. Es dient der Umsetzung des Anwendungsfalls „Überqueren einer Kreuzung mit vernetzter Infrastruktur“ aus dem EU-Projekt ICT4CART (www.ict4cart.eu). Vernetzte Lichtsignalanlagen können dem vernetzten Fahrzeug hierbei nicht nur den aktuellen Signalstatus pro Spur übertragen, sondern auch eine Schätzung für den Umschaltzeitpunkt in den nächsten Signalzustand. Dazu kommt die standardisierte Nachricht SPATEM (Signal Phase and Timing Extended Message) des Europäischen Instituts für Telekommunikationsnormen (ETSI) zum Einsatz. Die vorgestellte Modellierung berücksichtigt dabei sowohl Unsicherheiten in dieser Schätzung als auch Unsicherheiten in den präzidierten Trajektorien weiterer Verkehrsteilnehmer. Das erweiterte Verfahren wird simulativ evaluiert und experimentell an einer Kreuzung mit vernetzter Lichtsignalanlage verifiziert. Dabei zeigt das erweiterte Verfahren an der untersuchten Kreuzung gegenüber einer rein reaktiven Planung deutliche Vorteile.

2 Situationskontext für Kreuzungen mit vernetzten Lichtsignalanlagen

Der Situationskontext für Vorfahrt-Achten-Kreuzungen mit vernetzter Infrastruktur zur Auflösung von Verdeckungen wird in [8] näher beschrieben. Die Modellierung des Situationskontexts für Kreuzungen mit vernetzten Lichtsignalanlagen bleibt strukturell nahezu gleich, lediglich das Risikomodell muss neu erstellt werden. Daher wird dieses im Abschnitt 2.2 genauer vorgestellt. Zuvor wird im Abschnitt 2.1 der sich insgesamt ergebende Situationskontext für die Kreuzung mit Lichtsignalanlage beschrieben.

2.1 Resultierender Situationskontext

Gemäß [8] wird der Situationskontext allgemein durch

$$\mathcal{C}_{[s_j, s_{j+1})} = (\mathcal{S}_C, \mathcal{S}_{RA}, \mathcal{L}_B) \quad (1)$$

mathematisch beschrieben und enthält vier Teile: ein Gültigkeitsintervall $[s_j, s_{j+1})$, welches durch die 1D-Positionen s_j und s_{j+1} entlang der geplanten Route charakterisiert ist, eine Menge von Randbedingungen \mathcal{S}_C , eine Menge von regularisierenden Annahmen \mathcal{S}_{RA} und einer Liste von Verhaltensoptionen \mathcal{L}_B . Randbedingungen sind beispielsweise die Verkehrsregeln oder die Straßengeometrie, welche die sichere Kurvengeschwindigkeit begrenzt. Diese müssen von der Planung stets eingehalten werden. Regularisierende Annahmen, wie z.B. die Einhaltung der Verkehrsregeln durch andere Verkehrsteilnehmer, sind dagegen deutlich schwächere Modellannahmen, die in manchen Situationen verletzt werden können. Weitere Beispiele für regularisierende Annahmen sind die Verteilungsannahmen im Risikomodell oder Heuristiken, mit denen die Liste der Verhaltensoptionen bestimmt wird. Die Liste der Verhaltensoptionen enthält alle in der aktuellen Situation sinnvollen Möglichkeiten, wie sich das Fahrzeug verhalten kann. Diese sind gemäß

$$\mathcal{B} : (\mathcal{P}, \langle (\mathbf{x}_f, t_f) \rangle_i, I) \quad (2)$$

durch drei Komponenten charakterisiert: den Referenzpfad \mathcal{P} , die Zielsequenz $\langle (\mathbf{x}_f, t_f) \rangle_i$, entlang der die Längsplanung die Trajektorie generiert, und die Priorität I . Die Priorität I wird anhand der Heuristiken in \mathcal{S}_{RA} festgelegt und bestimmt, wie stark präferiert die zu der Handlungsoption korrespondierende Handlungsentscheidung ist.

Analog zum Situationskontext für Vorfahrt-Achten-Kreuzungen enthält \mathcal{S}_C auch für den Kontext „Kreuzung mit vernetzter Lichtsignalanlage“ ein Tempolimitprofil $v_{\max}(s, t)$. Dieses passt sich an vorausfahrende Fahrzeuge an und stellt dadurch sicher, dass das Ego-Fahrzeug in einer Folgefahrt nicht näher als den Sicherheitsabstand auf das vorausfahrende Fahrzeug auffährt. Weiterhin sind auch die minimale und maximale Beschleunigung sowie das maximal zulässige Restrisiko in beiden Kontexten in \mathcal{S}_C enthalten. Auf Grund des Überholverbots im Kreuzungsbereich sind die Verhaltensoptionen auf einen Referenzpfad entlang der Fahrspur begrenzt. Für beide Szenarien enthält der Kontext die regularisierende Annahme, dass sich die anderen Verkehrsteilnehmer an die Verkehrsregeln halten. Außerdem haben beide Kontexte das Anhalten mit konstanter Verzögerung an der Haltelinie bzw. hinter einem bremsenden Vorausfahrer als Fail-Safe-Strategie in \mathcal{S}_{RA} hinterlegt. Für komfortables Anhalten werden jeweils Zielsequenzen mit variierender Endzeit t_f , aber mit identischem Zielzustand $\mathbf{x}_f = [s_{\text{stop}}, v = 0, a = 0]^T$ generiert, wobei v die Geschwindigkeit und a die Beschleunigung bezeichnen.

Unterschiedlich ist jedoch das Risikomodell, das im folgenden Abschnitt 2.2 beschrieben wird. Zudem werden anstatt einer Liste von durch Infrastruktursensorik detektierten Objekten die Zustände einer Lichtsignalanlage und deren Prädiktion übertragen.

Schließlich beinhaltet \mathcal{L}_B die Liste der Verhaltensoptionen, welche durch die entsprechenden Heuristiken generiert wurden. Wie für die Vorfahrt-Achten-Kreuzung wird auch hier das Überqueren der Kreuzung höher priorisiert als das Anhalten an der Kreuzung. Dadurch überquert das Fahrzeug die Kreuzung, wann immer es dafür eine gültige Trajektorie gibt.

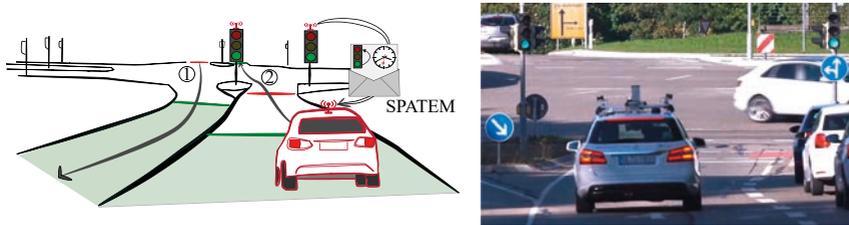


Abbildung 1: Die Skizze links zeigt eine Kreuzung mit vernetzter Lichtsignalanlage, die Haltelinie (rot) sowie PNR und PGA (grün) für ein Überqueren der Kreuzung. Im Foto rechts ist der automatisierte Versuchsträger zu sehen, der von der vorgestellten Bewegungsplanung gesteuert wird. Das Fahrzeug bremst bereits komfortabel während der grünen Ampelphase, da durch die von der Lichtsignalanlage bereitgestellten Informationen klar ist, dass ein Überqueren nicht mehr möglich sein wird.

2.2 Risikomodell

Mit dem Risikomodell wird die Wahrscheinlichkeit berechnet, dass das Ego-Fahrzeug in einen Zustand kommt, für den die Bewegungsplanung nicht mehr garantiert eine gültige Lösung findet [8]. Die Eingangsdaten des Risikomodells bestehen primär aus einer Objektliste, welche der Bewegungsplanung von der Fahrzeugperzeption zur Verfügung gestellt wird, dem Zustand des Ego-Fahrzeugs, welcher von der Lokalisierung bereitgestellt wird, und Zustandsprädiktionen für die Lichtsignalanlage, welche per Vehicle-to-anything-Kommunikation (V2X-Kommunikation) übermittelt werden.

Auf Basis dieser Eingangsdaten wird zunächst mit Hilfe von mengenbasierten Verfahren nach [9] eine invariabel sichere Zustandsmenge (ISZ) bestimmt, welche sich dadurch auszeichnet, dass jeder enthaltene Zustand garantiert Startpunkt einer gültigen Trajektorie ist. Im Idealfall lässt sich eine Trajektorie finden, welche vollständig in der ISZ liegt, sodass deren Sicherheit formal garantiert werden kann [9]. Im Allgemeinen wird jedoch nur per Randbedingung erzwungen, dass das Ende der Trajektorie in der ISZ liegt. Entsprechend kann es vorkommen, dass Trajektorienkandidaten zeitweise außerhalb der ISZ liegen und später (wieder) in diese eintreten. Der Austrittspunkt aus einer ISZ heißt dann Point of No Return (PNR) und der Wiedereintrittspunkt Point of Guaranteed Arrival (PGA) [9], siehe Abbildung 1. Beide Punkte können mit mengenbasierten Verfahren bestimmt werden. Für ein Kreuzungsszenario ist der PNR anschaulich der Punkt, an dem das Ego-Fahrzeug gerade noch vor der Haltelinie der Kreuzung bzw. hinter einem vorausfahrenden Fahrzeug anhalten kann. Der PGA hingegen markiert den Punkt, ab dem die Kreuzungssituation sicher erfolgreich gelöst wurde, beispielsweise durch Einfädeln in eine Lücke auf der Zielspur oder durch erfolgreiches Überqueren der Kreuzung.

Das Restrisiko einer Trajektorie setzt sich nun aus zwei Teilen zusammen: Einerseits besteht das Risiko, dass mindestens eine der zur Konstruktion der ISZ verwendeten regularisierenden Annahmen in der aktuellen Situation unzutreffend ist. Andererseits besteht ein Risiko, dass das Fahrzeug zwischen PNR und PGA in einen Zustand gerät, für den die Sicherheit nicht mehr gewährleistet werden kann. Im Allgemeinen lässt sich das Risi-

komodell also durch die Gleichung

$$p_{\text{risk}}(\mathcal{T}_{ii}) = (1 - p_{\text{RA}}) + p_{\text{RA}} \int_{t_{\text{PNR}}}^{t_{\text{PGA}}} \int_{s_i(t) - s^-(t)}^{s_i(t) + s^+(t)} f(s, t) ds dt \quad (3)$$

beschreiben, wobei p_{RA} die Wahrscheinlichkeit angibt, dass die regularisierenden Annahmen korrekt sind. Weiterhin sind s^- und s^+ die Sicherheitsabstände zu anderen Verkehrsteilnehmern, t_{PNR} und t_{PGA} die Zeiten, an denen das Ego-Fahrzeug den PNR bzw. den PGA erreicht, und $s_i(t)$ die 1D-Position auf der Trajektorie. Die Funktion $f(s, t)$ gibt die Wahrscheinlichkeit an, dass das Ego-Fahrzeug einen bestimmten 1D-Ort entlang des Referenzpfads zur Zeit t nicht überfahren darf. Für den konkreten Situationskontext gibt es dafür zwei Gründe: Entweder sperrt die Lichtsignalanlage zu einem Zeitpunkt t die Kreuzung, d.h. alle Orte zwischen Haltelinie und PGA, oder ein Ort s wird voraussichtlich zum Zeitpunkt t von einem Verkehrsteilnehmer mit Vorrang belegt. Um die Wahrscheinlichkeit einer Belegung durch andere Verkehrsteilnehmer zu bestimmen, werden für jedes Objekt der Objektliste mehrere mögliche zukünftige Trajektorien mit dem neuronalen Netz aus [10] prädiziert. Aus den Prädiktionen werden die Trajektorien aussortiert, die entweder die eigenen Trajektorienkandidaten sicher nicht schneiden, oder Verkehrsregeln verletzen und damit unplausibel sind. Dies ergibt die Liste relevanter prädizierter Trajektorien \mathcal{L}_{RPT} . Diese werden auf den Trajektorienkandidat projiziert, mit Hilfe eines Kalman-Filters zeitlich interpoliert und das Risikointegral über den Trajektorienkandidaten integriert. Damit berechnet sich das Risiko durch andere Verkehrsteilnehmer zu

$$p_{\text{RPT}} = \sum_{s_{\mathcal{T}} \in \mathcal{L}_{\text{RPT}}} \int_{t_{\text{PNR}}}^{t_{\text{PGA}}} \Phi \left(\frac{s_{\mathcal{T}}(t) - s^+(t) - s_{ii}(t)}{\sigma_{\mathcal{T}}} \right) - \Phi \left(\frac{s_{\mathcal{T}}(t) + s^-(t) - s_{ii}(t)}{\sigma_{\mathcal{T}}} \right) dt, \quad (4)$$

wobei $\Phi(\cdot)$ die Stammfunktion der aus der Kalman-Filterung der projizierten Trajektorien $s_{\mathcal{T}}$ stammenden Normalverteilung mit Varianz $\sigma_{\mathcal{T}}^2$ bezeichnet. In der praktischen Implementierung wurde das Integral durch die in [8] gegebene Iteration approximiert, um Rechenzeit zu sparen.

Die Wahrscheinlichkeit p_{TL} , dass die Lichtsignalanlage die Durchfahrt sperrt, bevor das Ego-Fahrzeug in die Kreuzung eingefahren ist, wird in Abhängigkeit des aktuellen Zustands sowie t_{min} , t_{erw} und t_{max} , also dem frühesten, dem erwarteten und dem spätesten Umschaltzeitpunkt, modelliert. Diese Umschaltzeitpunkte sowie die Konfidenz für t_{erw} werden von der Lichtsignalanlage per SPATEM übertragen, wobei aus der Konfidenz die Varianz σ_{TL}^2 berechnet wird. Dazu wird der Umschaltzeitpunkt als normalverteilt mit Mittelwert t_{erw} und Varianz σ_{TL}^2 angenommen, die Verteilung aber bei t_{min} und t_{max} hart zu Null bzw. Eins abgeschnitten. Dies führt auf

$$p_{\text{TL}} = \begin{cases} 1, & \text{falls grün und } t_{\text{stop}} \geq t_{\text{max}} \text{ oder rot und } t_{\text{stop}} \leq t_{\text{min}}, \\ 0, & \text{falls grün und } t_{\text{stop}} \leq t_{\text{min}} \text{ oder rot und } t_{\text{stop}} \geq t_{\text{max}}, \\ \Phi \left(\frac{t_{\text{stop}} - t_{\text{erw}}}{\sigma_{\text{TL}}} \right), & \text{falls grün und } t_{\text{min}} < t_{\text{stop}} < t_{\text{max}}, \\ 1 - \Phi \left(\frac{t_{\text{stop}} - t_{\text{erw}}}{\sigma_{\text{TL}}} \right), & \text{falls rot und } t_{\text{min}} < t_{\text{stop}} < t_{\text{max}}, \end{cases} \quad (5)$$

wobei t_{stop} die Zeit angibt, zu dem das Fahrzeug die Haltelinie erreicht. Für die praktischen Tests wurde für ein konservativeres Verhalten $t_{\text{stop}} = t_{\text{PGA}}$ gesetzt. Um zusätzlich die Gelbphasen mit zu berücksichtigen, werden t_{min} , t_{erw} und t_{max} entsprechend korrigiert.

Falls die Lichtsignalanlage keine Schätzung für den Umschaltzeitpunkt überträgt (oder der Ampelzustand nur aus einem Kamerabild extrahiert wurde), wird als Risiko $p_{TL} = 0$ bei grünem Ampelzustand und sonst $p_{TL} = 1$ angenommen. Dies entspricht der rein reaktiven Planung. Die Berechnung von (3) erfolgt für eine Kreuzung mit Lichtsignalanlage insgesamt also durch

$$p_{\text{risk}} = (1 - p_{\text{RA}}) + p_{\text{RA}}(p_{\text{TL}} + (1 - p_{\text{TL}})p_{\text{RPT}}). \quad (6)$$

3 Evaluation

Die Evaluation des vorgestellten Verfahrens erfolgt in zwei Schritten: Zunächst demonstrieren wir anhand von Simulationen den Effizienzgewinn, der sich durch Ausnutzen der von vernetzten Lichtsignalanlagen übermittelten Informationen ergibt. Dann validieren wir anhand von Tests an einer Pilotanlage das Verhalten des Verfahrens im realen Straßenverkehr.

3.1 Simulationsbeispiele zum Nutzen der Zustandsprädiktion

Die Simulationen wurden mit Hilfe unseres Simulationsframeworks DeepSIL [11] durchgeführt. Dieses wurde dafür um ein Modell für Lichtsignalanlagen erweitert. Jedes Simulationsszenario wird hierfür zweimal durchlaufen. Das eine Mal wird dem Planungsverfahren der prädizierte t_{erw} , sowie der früheste t_{min} und späteste t_{max} Umschaltzeitpunkt bereitgestellt. Das andere Mal hingegen kennt das Fahrzeug nur den aktuellen Zustand der Lichtsignalanlage und kann daher sein Verhalten nur reaktiv anpassen. Beide Male schaltet die Lichtsignalanlage tatsächlich zur Zeit $t = 0$ s. Die Simulationsszenarien sind dabei so gewählt, dass das Fahrzeug kurz vor dem Umschalten an der Lichtsignalanlage ankommt. Abbildung 2 zeigt die Trajektorien des Ego-Fahrzeugs mit und ohne Prädiktion beim Umschalten der Lichtsignalanlage von grün auf rot (links) und von rot nach grün (rechts) im Vergleich. Es zeigt sich, dass das Ego-Fahrzeug die Prädiktionsinformation beim Umschalten von grün nach rot effektiv dafür nutzen kann, früher und damit sanfter zu bremsen. Beim Umschalten von rot nach grün adaptiert das Ego-Fahrzeug seine Geschwindigkeit frühzeitig, sodass es weniger bremsen und früh wieder moderat beschleunigen kann. Dadurch wird das Überqueren der Kreuzung energie- und zeiteffizienter als das rein reaktive Fahren.

3.2 Fahrversuche im realen Straßenverkehr

Im nächsten Schritt wird im realen Straßenverkehr validiert, dass das vorgestellte Verfahren angemessenes Verhalten für das Ego-Fahrzeug generiert. Dazu wird die Kreuzung bei der Halle Nord am Berliner Ring in Ulm betrachtet. Die Lichtsignalanlage wurde von Partnern im Projekt ICT4CART so umgerüstet, dass sie ihren frühesten, erwarteten und spätesten Umschaltzeitpunkt per hybrider Kommunikation [12] sowohl über ETSI ITS-G5 als auch über LTE/5G an das Ego-Fahrzeug überträgt. Abbildung 3 zeigt 35 Trajektorien von Versuchsfahrten an der Pilotkreuzung aus zwei verschiedenen Richtungen, wobei die Lichtsignalanlage bei Ankunft an der Kreuzung in 15 Szenarien grün und in 20 Szenarien rot zeigte. Aufgetragen ist die Position s über der Zeit t und die Geschwindigkeit v über

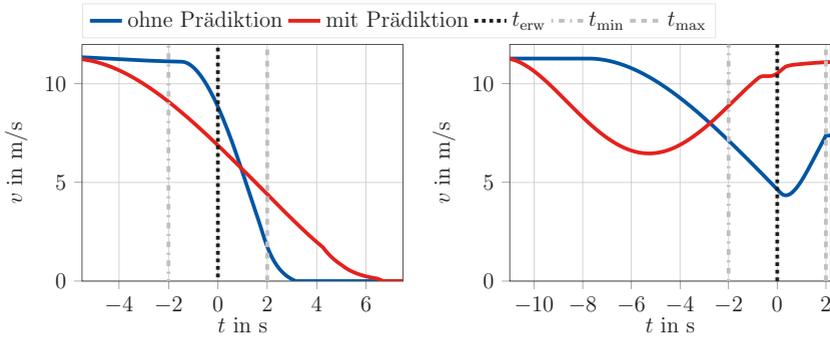


Abbildung 2: Simulierte Geschwindigkeitsverläufe $v(t)$ beim Umschalten der Lichtsignalanlage von grün über gelb nach rot (links) und von rot über rot-gelb nach grün (rechts).

der Position s jeweils bis zum Stopp des Fahrzeugs (bei rot) oder bis zum Erreichen des PGA (bei grün). Es zeigt sich, dass das Fahrzeug vorschriftsmäßig bei rot an der Kreuzung anhält (in rot gezeichnete Kurven) und bei grün über die Kreuzung fährt (in grün gezeichnete Kurven). Außerdem ist klar erkennbar, dass das Fahrzeug auch auf vorausfahrende Fahrzeuge reagiert und deshalb in den in magenta markierten Kurven deutlich vor der Stopp-Linie (Position $s = 0$) anhält. Die in blau dargestellte Trajektorie korrespondiert zu einem Szenario, in dem die Lichtsignalanlage während der Anfahrt auf grün umschaltet. In dem Szenario fährt zudem ein weiteres Fahrzeug vor dem Ego-Fahrzeug, auf welches das Ego-Fahrzeug Rücksicht nehmen muss. Die entsprechende Verhaltensadaption ist im Geschwindigkeitsverlauf des Ego-Fahrzeugs deutlich zu erkennen. Außerdem ist zu erkennen, dass das Ego-Fahrzeug auf Basis der Prädiktion schon frühzeitig abbremst, um noch mit Fahrt an der Kreuzung anzukommen, wenn die Lichtsignalanlage auf grün umschaltet. So kann das Fahrzeug ohne anzuhalten über die Kreuzung fahren und erreicht, wie in der Simulation dargestellt, eine höhere Zeiteffizienz.

4 Zusammenfassung und Ausblick

In dieser Arbeit wurde ein bestehendes kontextbasiertes Planungsverfahren auf einen neuen Use-Case, das Überqueren von Kreuzungen mit vernetzten Lichtsignalanlagen, erweitert. Es zeigte sich, dass dies aufgrund des kontextbasierten Verfahrens nur einer Modellerweiterung bedurfte und dadurch deutlich weniger mühsam ist als bei verhaltensbasierten Verfahren. In Simulationen wurde gezeigt, dass das Verfahren deutliche Effizienzvorteile bringt, wenn die prädizierten Umschaltzeitpunkte der Lichtsignalanlage zur Verfügung stehen. Schließlich wurde im Straßenverkehr evaluiert, dass die mit dem Verfahren generierten Trajektorien auch unter realen Einsatzbedingungen ein angemessenes Verhalten des Ego-Fahrzeugs widerspiegeln.

Zukünftig bietet es sich an, das kontextbasierte Planungsverfahren auf weitere Use-Cases, wie zum Beispiel Kreisverkehre, Fahrbahnverengungen oder Baustellen, zu erweitern. Außerdem könnte das vorgestellte Verfahren von Heuristiken profitieren, die z.B.

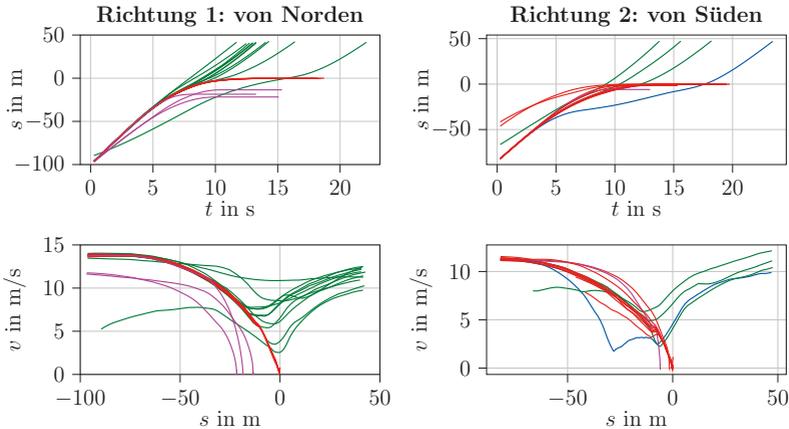


Abbildung 3: Experimentelle Verifikation im realen Straßenverkehr. Die Kreuzung mit vernetzter Lichtsignalanlage wird aus zwei verschiedenen Richtungen her angefahren. Zu sehen sind 16 Anfahrten bei rot ohne Fahrzeug voraus (rot), 4 Anfahrten bei rot mit Fahrzeug voraus (magenta), 14 Anfahrten bei grün und eine Anfahrt (blau), bei der die Lichtsignalanlage auf grün umschaltet. Die Trajektorien enden beim Stopp bzw. beim Erreichen des PGA.

mit Reinforcement-Learning-Verfahren gelernt wurden.

Danksagung

Teile dieser Arbeit wurden im Rahmen des Projekts ICT4CART durchgeführt, welches durch das Forschungs- und Innovationsprogramm Horizon 2020 der Europäischen Union unter der Fördernummer 768953 finanziert wird. Weitere Teile dieser Arbeit wurden finanziell vom Bundesministerium für Wirtschaft und Klimaschutz im Rahmen des Programms „Hoch- und vollautomatisiertes Fahren in anspruchsvollen Fahrsituationen“ (Projekt LUKAS, FKZ 19A16010I) unterstützt.

Literatur

- [1] B. Paden, M. Čáp, S. Z. Yong, D. Yershov, and E. Frazzoli, “A survey of motion planning and control techniques for self-driving urban vehicles,” *IEEE Trans. Intell. Veh.*, vol. 1, no. 1, pp. 33–55, Mar. 2016.
- [2] C. Sun, J. Guanetti, F. Borrelli, and S. J. Moura, “Optimal eco-driving control of connected and autonomous vehicles through signalized intersections,” *IEEE Internet of Things Journal*, vol. 7, no. 5, pp. 3759–3773, 2020.
- [3] G. Mahler and A. Vahidi, “An optimal velocity-planning scheme for vehicle energy efficiency through probabilistic prediction of traffic-signal timing,” *Trans. Intell. Transp. Sys.*, vol. 15, no. 6, pp. 2516–2523, 2014.

-
- [4] C. Hubmann, J. Schulz, G. Xu, D. Althoff, and C. Stiller, “A belief state planner for interactive merge maneuvers in congested traffic,” in *Proc. IEEE Int. Conf. Intell. Transp. Syst. (ITSC)*, Maui, HI, USA, Nov. 2018, pp. 1617–1624.
 - [5] F. Gritschneider, P. Hatzelmann, M. Thom, F. Kunz, and K. Dietmayer, “Adaptive learning based on guided exploration for decision making at roundabouts,” in *Proc. IEEE Intell. Vehicles Symp. (IV)*, Gothenburg, Sweden, Nov. 2016, pp. 433–440.
 - [6] M. Meghjani, Y. Luo, Q. H. Ho, P. Cai, S. Verma, D. Rus, and D. Hsu, “Context and intention aware planning for urban driving,” in *Proc. IEEE/RSJ Int. Conf. Intell. Robots Syst. (IROS)*, Macau, China, Nov. 2019, pp. 2891–2898.
 - [7] E. Yurtsever, J. Lambert, A. Carballo, and K. Takeda, “A survey of autonomous driving: Common practices and emerging technologies,” *IEEE Access*, vol. 8, pp. 58 443–58 469, Mar. 2020.
 - [8] J. Müller, M. Herrmann, J. Strohbeck, and M. Buchholz, “Motion planning for connected automated vehicles at occluded intersections with infrastructure sensors,” accepted for publication in *IEEE Trans. Intell. Transp. Syst.*, <https://arxiv.org/pdf/2110.11246.pdf>, Nov. 2021.
 - [9] C. Pek, M. Koschi, M. Werling, and M. Althoff, “Enhancing motion safety by identifying safety-critical passageways,” in *Proc. IEEE Annu. Conf. Decis. Control (CDC)*, Melbourne, VIC, Australia, Dec. 2017, pp. 320–326.
 - [10] J. Strohbeck, V. Belagiannis, J. Müller, M. Schreiber, M. Herrmann, and M. Buchholz, “Multiple trajectory prediction with deep temporal and spatial convolutional neural networks,” in *Proc. IEEE/RSJ Int. Conf. Intell. Robots Syst. (IROS)*, Virtual, Nov. 2020.
 - [11] J. Strohbeck, J. Müller, A. Holzbock, and M. Buchholz, “DeepSIL: A software-in-the-loop framework for evaluating motion planning schemes using multiple trajectory prediction networks,” in *Proc. IEEE/RSJ Int. Conf. Intell. Robots Syst. (IROS)*, Prague, Czech Republic, Sep. 2021, pp. 7075–7081.
 - [12] M. Buchholz, J. Strohbeck, A.-M. Adaktylos, F. Vogl, G. Allmer, S. C. Barros, Y. Lassoued, M. Wimmer, B. Hättü, G. Massot *et al.*, “Enabling automated driving by ict infrastructure: A reference architecture,” 8th Transp. Res. Arena TRA 2020 (conf. cancelled), 2020.

