

# Aktualitätsverifikation semantischer HD-Karten für das urbane automatisierte Fahren

Jan-Hendrik Pauls\* und Christoph Stiller†

**Zusammenfassung:** In diesem Beitrag wird ein Gesamtsystem zur Aktualitätsverifikation hochauflösender, semantischer, aber dennoch kompakter Karten vorgestellt. Es basiert auf einer geeigneten semantisch-parametrischen Kartendarstellung, die automatisiert erstellt und aktualisiert werden kann. Durch die Kombination semantischer Detektionen und Lidar-Tiefenmessungen kann nicht nur eine hochgenaue 6D-Lokalisierung realisiert werden, die robust gegenüber Änderungen ist. Es wird hiermit auch eine evidenzbasierte, ternäre Aktualitätsverifikation ermöglicht, die aus den Messdaten eines einzelnen Fahrzeugs Änderungen detektieren oder Karteninhalte freigeben kann. Schließlich wird erläutert, wie man Verifikationsergebnisse von physischen Elementen, wie Verkehrsschildern, auf abstrakte Karteninhalte, wie Tempolimits, übertragen kann.

**Schlüsselwörter:** Aktualitätsverifikation, Semantische HD-Karten, Lokalisierung

## 1 Einleitung

Komfortables und sicheres Fahren erfordert ein umfassendes Verständnis der Umgebung. Automatisierte Fahrfunktionen müssen dieses entweder zur Laufzeit aus Sensordaten herleiten oder auf in Karten gespeicherte Informationen zurückgreifen. Da eine Inferenz zur Laufzeit mit aktuellen Methoden und Sensoren nicht mit hinreichender Qualität möglich ist, werden hochauflösende, semantische Karten auf absehbare Zeit unabdingbar sein.

Die Verwendung von Karten bringt dafür ein anderes Problem mit sich: Die Aktualitätsverifikation der Karteninhalte. So könnte sich beispielsweise ein in der Karte annotiertes Tempolimit seit der Erstellung oder letzten Aktualisierung der Karte geändert haben. Um also Karteninhalte sicher nutzen zu können, muss ihre Aktualität mithilfe der aktuellen Sensordaten geprüft und dies an die Fahrfunktionen weitergegeben werden. Durch Verdeckungen sind aber nicht immer alle Karteninhalte sichtbar, was in der Verifikation berücksichtigt werden muss.

Dieser Beitrag stellt ein Gesamtsystem vor, das eine passende, automatisiert erzeugbare Kartendarstellung umfasst, die Grundlage einer robusten Lokalisierung sowie einer evidenztheoretischen Verifikation der Karteninhalte ist. Schließlich wird vorgeschlagen, wie mithilfe einer relationalen Annotation Änderungen der physischen Kartenelemente auf abstraktere Karteninhalte übertragen werden können.

---

\*Jan-Hendrik Pauls leitet die Forschungsgruppe *Kartierung und Lokalisierung* am Institut für Mess- und Regelungstechnik (MRT) des Karlsruher Instituts für Technologie (KIT), pauls@kit.edu.

†Prof. Dr.-Ing. Christoph Stiller leitet das Institut für Mess- und Regelungstechnik (MRT) des Karlsruher Instituts für Technologie (KIT), stiller@kit.edu.

## 2 Verwandte Arbeiten

Verwandte Arbeiten lassen sich anhand der einzelnen Teile des Gesamtsystems gliedern, der hochauflösenden Kartierung, der robusten Lokalisierung und der Aktualitätsverifikation. Für die Verarbeitung der erkannten Änderungen innerhalb einer Karte sind den Autoren keine verwandten wissenschaftlichen Publikationen bekannt.

### 2.1 Hochauflösende, semantische Kartierung

Hochauflösende Karten beschränkten sich anfangs auf sensorspezifische Kartenmerkmale [1, 2]. Die Extraktion vektorieller semantischer Merkmale, die sowohl kompakt speicherbar als auch sensorübergreifend wahrnehmbar sind, war lange Zeit nur mit manuellem Aufwand möglich.

Arbeiten zur Automatisierung konzentrierten sich zuerst auf Straßenmarkierungen [3] sowie die Extraktion semantischer Merkmale mittels ungelerner Verfahren [4]. Erst das Aufkommen leistungsstarker maschineller Lernverfahren, insbesondere tiefer neuronaler Netze, und die kostengünstigere Verfügbarkeit hochauflösender Lidar-Sensoren erlaubt die Detektion diverser Merkmale in hoher Genauigkeit.

Viele Arbeiten, die semantische Objekte kartieren, nutzen eine möglichst generische, d.h. klassenübergreifende Darstellung der Objekte, wie Quadriken [5]. Während man hierdurch keinerlei Modellwissen aufträgt, verliert man gleichzeitig an Genauigkeit. Im Gegensatz dazu nutzt das in diesem Beitrag vorgestellte Verfahren, wie bereits in [6] gezeigt, die semantische Klassifikation, um eine an die Klasse angepasste, kompakte, parametrische Darstellungsform zu bestimmen, deren Parameter aus Bild- und Lidarinformationen geschätzt werden. Dies erlaubt die automatische Kartierung mit einer Genauigkeit in derselben Größenordnung wie bislang nur manuelle Annotationsverfahren.

### 2.2 Robuste Lokalisierung

Wie auch bei der Kartierung waren robuste Lösungen für das Lokalisierungsproblem lange Zeit sensorspezifisch: Nur innerhalb derselben Sensordomäne konnten so dicht eindeutige Merkmale bestimmt werden, dass auch noch unter Änderungen der Umgebungsbedingungen oder bei veralteten Karteninformationen eine Lokalisierung möglich war [2].

Weniger eindeutige Merkmale erforderten Verfahren, die mehrere Hypothesen parallel verfolgen und auswerten können [7, 8]. Eine Alternative ist die Überprüfung der Eindeutigkeit von Karteninformation bei der Kartenerstellung [9].

In diesem Beitrag wird ein auf der hochgenauen semantischen Kartendarstellung aufbauendes Verfahren vorgestellt, das eine selbsteinschätzende Lokalisierung zur Laufzeit ermöglicht. Die Eindeutigkeit kann hierbei über die sehr hohe Genauigkeit der Messungen und deren intelligente Auswertung erreicht werden. Im Gegensatz zu rekursiven Filtern [8] umgeht das Verfahren durch die Verwendung nur einer (zeitlich begrenzten) Messung die Gefahr, bei überlappenden, aber teilkonsistenten Kartenänderungen zu einer falschen Lösung zu “driften”.

## 2.3 Aktualitätsverifikation

Das Problem der Aktualitätsverifikation ist eng mit dem Problem der Lokalisierung verbunden. Meist kann ein Abgleich zwischen Karten- und Sensordaten nur erfolgen, wenn die Pose relativ zur zu verifizierenden Karte bekannt ist. Eine Ausnahme ist ein unter anderem von den Autoren vorgestellter Ansatz, der eine Merkmalsreduktion durchführt, die robust gegenüber Lokalisierungsfehlern ist [10].

Um die starke Kopplung zu reduzieren, kann man Änderungen mittels Flottendaten detektieren [11]. Zeitvariante Lokalisierungsfehler können sich so ausgleichen. Um nicht nur allmählich Änderungen zu detektieren, sondern Karteninhalte instantan zu verifizieren, ist man aber allein auf die Sensordaten des Ego-Fahrzeugs beschränkt.

Eine andere Lösungsmöglichkeit ist, Lokalisierung und Änderungsdetektion gekoppelt zu lösen [8, 12]. Angelehnt an diese Idee wird in diesem Beitrag vorgeschlagen, die Aktualitätsverifikation basierend auf einer der Lokalisierung ähnlichen Datenassoziation durchzuführen. Hierbei ist aber nicht die Pose, sondern die Wahrscheinlichkeit, ein Kartenmerkmal beobachtet zu haben, das Ergebnis.

## 3 Semantisch-parametrische Kartendarstellung

Grundlage der Aktualitätsverifikation ist eine passende Kartendarstellung. Automatisierte Fahrfunktionen erfordern in der Regel semantisch-relationale, physische Merkmale wie Straßen- und Fahrstreifenberandungen, (Verkehrs-)schilder, Ampeln<sup>1</sup> und die hierdurch ableitbaren, abstrakten Inhalte wie Fahrstreifen, Verkehrsregeln sowie einen topologischen Zusammenhang zur Routenplanung. Beispielhaft sei hier eine Lanelet2-Karte [13]. Karteninhalte müssen kompakt gespeichert werden, um Aktualisierungen über mobile Datenübertragungswege zu ermöglichen. Während Lanelet2 dies nicht explizit erfordert, wird dieser Beitrag schließlich zeigen, dass eine parametrische 3D-Darstellung aller Schilder und Ampeln für verifizierbare Karten hilfreich ist und ebenbürtig zu parametrischen Fahrstreifenberandungen zum Standard werden sollte.

Da Schilder, Ampeln und Masten mit üblicher Sensorik aus wesentlich größerer Entfernung detektiert werden können als Straßenmarkierungen, eignen sie sich auch besser zur hochgenauen Lokalisierung, die notwendige Voraussetzung der Aktualitätsverifikation ist. Daher konzentriert sich dieser Beitrag im Folgenden beispielhaft auf diese drei Klassen.

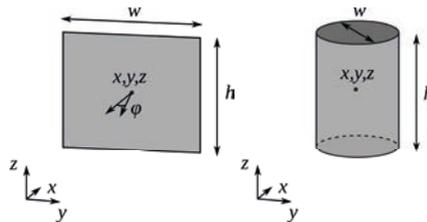


Abbildung 1: Visualisierung der parametrischen Darstellungen für Schilder (links) sowie Ampeln und Masten (rechts) wie bereits in [6] veröffentlicht.

<sup>1</sup>Im Folgenden wird der geläufigere Begriff *Ampel* für den Fachterminus *Signalgeber* verwendet.

Eine fast vollständig automatisierte Erstellung einer solch semantisch-parametrischen 3D-Karte wurde bereits vorgestellt [6]. Kurz umrissen können semantische Detektionen in Kamerabildern mit Tiefeninformationen aus Lidar-Sensoren kombiniert werden. Eine Kernidee ist hierbei, dass die semantische Klasse der Detektion hierbei über die parametrische Darstellung der Karteninhalte entscheidet: Schilder werden als um die Hochachse rotierte Rechtecke repräsentiert während Ampeln und Masten durch Zylinder dargestellt werden (siehe Abbildung 1). Die Darstellungen sind hierbei kompakte parametrische Annäherungen, die gleichzeitig eine treffende Rückprojektion in ein Kamerabild, eine gute Datenassoziation und eine zuverlässige Schätzung der Darstellung ermöglichen.

Das Messmodell entnimmt den Sichtstrahl zum Mittelpunkt sowie Höhe und Breite der Repräsentation aus den Bounding Boxen der Detektionen. Durch Projektion der Lidar-Punktwolke ins Kamerabild können durch die Detektionsmaske relevante Punkte ausgewählt werden. Diese ergeben die Tiefe des Mittelpunkts sowie, im Fall von Schildern, den Rotationswinkel. Wie in [6] gezeigt erreicht die so automatisierte Kartierung hierbei – abgesehen von Fehldetektionen des neuronalen Netzes – mit ca.  $1^\circ$  Orientierungs- bzw. weniger als 10 cm Translationsfehler annähernd menschliche Annotationsqualität. Ein typisches Kartierungsergebnis ist in Abbildung 2 veranschaulicht.



Abbildung 2: Beispielhaftes Kartierungsergebnis an einer urbanen Kreuzung in Karlsruhe. Masten sind in Hellblau, Ampeln in Grün und Schilder in Gelb gezeigt.

## 4 Änderungsrobuste Lokalisierung

Neben einer passenden Karte benötigt die Verifikation eine hochgenaue Lokalisierung, die gegenüber Änderungen der Karte robust sein muss. Genau genommen ist die Lokalisierung, d.h. die Bestimmung der Ego-pose im Koordinatensystem der Karte, für die Verifikation ebenso wichtig wie die Assoziation von Detektionen zu Karteninhalten. Gleichzeitig erlauben hinreichend viele assoziierte Detektionen die Berechnung einer hochgenauen 6D-Pose. In diesem Beitrag wird das Lokalisierungsproblem daher durch das Finden geeigneter Assoziationen gelöst.

Die Lokalisierung in einer möglicherweise veränderten Karte ist hierbei besonders herausfordernd, da die sonst oft geltende Annahme, dass die Kartenmerkmale als gegeben anzunehmen sind, nicht mehr gilt. Diese Herausforderung kann dennoch gemeistert werden, da die zuvor vorgestellte Kartenrepräsentation durch die Kombination der semantisch-

parametrischen und der geometrischen Dimensionen Detektionen sehr eindeutig werden lässt. Anders gesagt passen Fehldetektionen nur sehr selten gut zu Kartenelementen.

Um mögliche Assoziationshypothesen zu finden kann man nun einen Assoziationsgraphen  $\mathcal{A} = (\mathcal{G}, \mathcal{E})$  aufspannen. Knoten dieses Graphen sind hypothetische Paarungen  $(l, d)$  eines Kartenelements  $l \in L$  mit einer Detektion  $d \in D$ . Von allen möglichen Paarungen können durch semantisch-parametrische Kompatibilität bereits viele Kombinationen ausgeschlossen werden, beispielsweise weil die Höhe und Breite eines Schilds zu verschieden ist. Anschließend werden alle verbleibenden Paarungen auf paarweise geometrische Kompatibilität geprüft. Dies bedeutet, dass zwei Paarungen  $(l_{i_1}, d_{j_1}), (l_{i_2}, d_{j_2})$  in  $\mathcal{A}$  genau dann verbunden werden, wenn  $\|l_{i_1} - l_{i_2}\| - \|d_{j_1} - d_{j_2}\| < \tau$ , wobei  $\tau$  ein Schwellwert ist.

Eine passende Assoziationshypothese ist damit eine Menge von individuell semantisch-parametrisch und paarweise geometrisch kompatiblen Paarungen von Karteninhalten und Detektionen. Mögliche Assoziationshypothesen  $\theta$  können durch Umformung der Wahrscheinlichkeit einer Mehrzielmessung verglichen werden [15, S. 423], wobei wir der in [15] eingeführten Notation folgen.

$$f(\theta|D, L) = e^\lambda \prod_{i:\theta(i)=0} (1 - p_D(l_i)) \prod_{i:\theta(i)>0} f(d_{\theta(i)}|l_i) p_D(l_i) \prod_{j:\theta^{-1}(j)=0} \lambda c(d_j) \quad (1)$$

Hierbei bezeichnet  $p_D(l_i)$  die Detektionswahrscheinlichkeit eines Kartenelements und  $f(d_{\theta(i)}|l_i)$  die Ähnlichkeit der zugeordneten Paarung. Die Parameter  $\lambda$  und  $c(d_j)$  charakterisieren Fehldetektionen. Typische Werte zeigen, dass die Wahrscheinlichkeit einer Assoziationshypothese mit jeder Paarung um einen Faktor von ca.  $10^3$  wächst. Die wahrscheinlichsten Hypothesen sind also jene, die die meisten Paarungen umfassen. Dies wird auch als *Maximum Consensus*-Datenassoziation bezeichnet.

In  $\mathcal{A}$  sind Assoziationshypothesen Cliques im Sinne der Graphentheorie. Es gilt somit, die größten Cliques in  $\mathcal{A}$  zu finden. Während die Bestimmung der größten Clique in einem Graph ein bekanntes Problem der Informatik ist, sind wir an allen Cliques  $\Theta^p(\hat{\theta}) \subseteq \Theta$  interessiert, die um höchstens  $p$  kleiner sind als die größte Clique  $\hat{\theta}$ . Eine Anpassung des Bron-Kerbosch-Algorithmus [14] ermöglicht eine sehr effiziente Suche nach  $\Theta^p(\hat{\theta})$ .

In urbanen Szenarien ergeben sich hierbei häufig Cliques, die größtenteils übereinstimmen, aber in wenigen Paarungen voneinander abweichen. Für eine reine Lokalisierung wäre das Ergebnis, d.h. die resultierende Pose, quasi identisch. Für eine Änderungsdetektion ist jedoch jede individuelle Paarung  $(l_i, d_j)$  interessant, da potentiell  $d_j$  die Existenz von  $l_i$  bestätigt. Die Wahrscheinlichkeit jeder Paarung ergibt sich durch Summierung über alle relevanten Assoziationshypothesen:

$$f((l_i, d_j)|D, L) = \sum_{\theta \in \Theta:\theta(i)=j} f(\theta|D, L) \approx \sum_{\theta \in \Theta^p(\hat{\theta}):\theta(i)=j} f(\theta|D, L) \quad (2)$$

Somit können nicht nur ausschließlich hinreichend sichere Paarungen für die Posen-schätzung verwendet werden. Es können auch Situationen mit mehrdeutigen Lokalisierungslösungen aktiv erkannt werden, wodurch eine Fehllokalisierung vermieden werden kann. Hierbei ist anzumerken, dass Systeme, die eine möglicherweise ausbleibende Kartenfreigabe erfordern, ebenso eine fehlende Lokalisierung tolerieren können sollten.

Neben einer hochgenauen und robusten 6D-Pose  $\mathcal{P}$  erhält man also auch für jede Landmarke eine Wahrscheinlichkeit, dass diese durch eine Detektion bestätigt werden konnte. Beide Ergebnisse werden im folgenden Abschnitt für die Sichtbarkeitsprüfung bzw. für die Aktualitätsbestätigung der Landmarken benötigt.

## 5 Ternäre, evidenzbasierte Verifikation

Die Verifikation von Karten, wie sie in diesem Beitrag vorgestellt wird, unterscheidet sich in zwei Details von vorherigen Arbeiten [8, 12]. Sie setzt nicht auf Flottendaten [11], sondern allein auf die Beobachtungen eines einzelnen Fahrzeugs. Außerdem konzentriert sie sich auf mehrschichtige, semantische HD-Karten. Während reine Lokalisierungskarten allmählich aktualisiert werden können, da im Regelfall trotz einer Änderung hinreichend viele unveränderte Merkmale zur hochgenauen Lokalisierung existieren, erfordern semantische HD-Karten eine unmittelbare Verifikation.

Um ein Tempolimit, das nur mit einem Schild signalisiert wird, zu verifizieren, muss man genau dieses Schild lokalisieren und auf Existenz prüfen. Da nur die Messdaten eines einzigen Fahrzeugs zur Verfügung stehen, kann es aber auch zu Verdeckungen kommen. Dies motiviert eine ternäre Verifikation: Jedes physische Kartenelement kann entweder *aktuell*, *veraltet* oder *nicht beobachtbar* sein.

### 5.1 Evidenzbasierte Messmodelle

Für jedes Kartenelement  $l_i$  können aber nur für die beiden Hypothesen *aktuell* und *veraltet* Evidenzen gesammelt werden. Hierfür werden zwei beispielhafte Evidenzquellen vorgeschlagen, die Datenassoziation und eine Sichtbarkeitsprüfung. Die verbleibende Evidenzmasse entspricht dann der Nicht-Beobachtbarkeit als dritte Hypothese.

Wenn  $l_i$  in der Datenassoziation verwendet wurde, dient dies als Evidenz, dass ein solches Kartenelement in geometrischer, semantischer und parametrischer Form sehr ähnlich beobachtet wurde. Die Formeln für die Evidenzmassen aus der Datenassoziation (DA) lauten daher

$$\begin{aligned} m^{DA}(l_i \text{ veraltet}) &= 0 \\ m^{DA}(l_i \text{ aktuell}) &= \lambda \sim f((l_i, d_j)|D, L) \\ m^{DA}(\Omega) &= 1 - \lambda. \end{aligned}$$

Hierbei ist  $f((l_i, d_j)|D, L)$  die bereits eingeführte Assoziationswahrscheinlichkeit und  $\Omega$  die Gesamtheit der Hypothesen. Bei einer Verdeckung kann  $l_i$  nicht in der Datenassoziation auftauchen. Gleichzeitig ist dies aber keine Evidenz für eine Veränderung.

Um Evidenz für Änderungen zuzuweisen, schlagen wir daher eine Sichtbarkeitsprüfung (SP) vor, die die zuvor bestimmte, hochgenaue 6D-Pose  $\mathcal{P}$  verwendet. Durch die Transformation ins Sensorkoordinatensystem kann mittels Lidar gemessen werden, wie viele Strahlen  $R_\odot$  durch  $l$  gingen, und dies in Verhältnis zu allen auf  $l_i$  fallenden Strahlen  $R$  gesetzt werden. Die Evidenzmassen ergeben sich somit durch

$$\begin{aligned} m^{SP}(l_i \text{ veraltet}) &= \sigma \sim \frac{|R_\odot|}{|R|} \\ m^{SP}(l_i \text{ aktuell}) &= 0 \\ m^{SP}(\Omega) &= 1 - \sigma. \end{aligned}$$

Im Gegensatz zu vorherigen Arbeiten kann somit nicht nur eine Veränderung detektiert, sondern sowohl aktiv die Aktualität gemessen als auch das Ausbleiben von Informationen für beide Hypothesen modelliert werden.

## 5.2 Aggregation und Ergebnisse

Mit den soeben vorgestellten Messmodellen kann nun in jedem Zeitschritt Evidenz gesammelt und über die Zeit aggregiert werden. Die Übersetzung der Evidenzen in eine passende Ausgabe ist ein Klassifikationsproblem, das im einfachsten Fall die Hypothese mit der größten Evidenzmasse ausgibt.

Für die Evaluation wurden reale Karteninhalte zufällig verändert. Durch diese simulierte Änderung ist somit das Sollergebnis bekannt. Erste Ergebnisse zeigen eine Änderungsdetektionsrate (Recall) von ca. 95% sowie eine Genauigkeit (Precision) von 98%.

## 6 Verarbeitung der Änderungsergebnisse

Wie im vorhergehenden Abschnitt beschrieben können für jedes physische Kartenelement  $l$  Evidenzen ermittelt und aggregiert werden. Für viele Fahrfunktionen ist aber nicht die physische Kartenschicht, sondern abstraktere Merkmale, wie Tempolimits, Ampelzuordnungen oder Abbiegevorschriften interessant und müssen daher ebenfalls verifiziert werden.

Eine direkte Verifikation dieser Merkmale, beispielsweise durch das Verhalten anderer Verkehrsteilnehmer, ist durchaus denkbar, erfordert aber entsprechende Befahrungsstatistiken oder Flottendaten. Damit ein einzelnes Fahrzeug dennoch diese abstrakten Merkmale verifizieren kann, wurde im Kartenformat Lanelet2 [13] neben einer direkten Annotation solcher abstrakter Inhalte auch die Möglichkeit vorgesehen, die abstrakte Eigenschaft mit den Elementen der physischen Kartenschicht in Beziehung zu setzen.

Eine solche Relation ist in Abbildung 3 abgebildet. Wird nun also festgestellt, dass das Verkehrsschild, das das Tempolimit anordnet, nicht als aktuell bestätigt werden kann, kann dieses Ergebnis direkt auf abstraktere, abgeleitete bzw. betroffene Karteninhalte propagiert werden. Fahrfunktionen erhalten somit für alle Schichten und Merkmale einer semantischen HD-Karte eine Aktualitätsinformation.

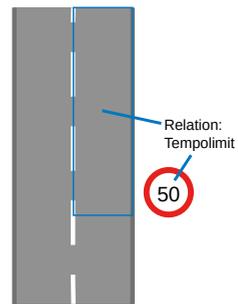


Abbildung 3: Beispielhafte Tempolimit-Relation, die das anordnende Verkehrsschild mit dem betroffenen Lanelet in Verbindung setzt.

## 7 Fazit

In diesem Beitrag wurde ein Gesamtsystem vorgestellt, das basierend auf einer passenden, automatisiert erzeugbaren Kartendarstellung eine hochgenaue und dennoch gegenüber Änderungen robuste Lokalisierung erlaubt. Die Lokalisierung ermöglicht hierbei Rückschlüsse auf die detektierten und assoziierten Karteninhalte. Zusammen mit einer Sichtbarkeitsprüfung können diese für eine ternäre Aktualitätsverifikation der Karteninhalte verwendet werden. Durch relationale Annotation von abgeleiteten Karteninhalten, wie Tempolimits, kann das Verifikationsergebnis von der physischen auf höhere Kartenebenen propagiert werden.

Das System zeigt erstmals, wie eine hochgenaue und dennoch robuste Lokalisierung in einer kompakten, semantischen HD-Karte funktionieren kann. Darüber hinaus erlaubt das System erstmals die Aktualitätsverifikation mit den Sensordaten einer einzigen Befahrung und kann so Karteninhalte für die Verwendung durch automatisierte Fahrfunktionen freigeben bzw. die Karte absichern. Dies gilt hierbei nicht nur für physische Elemente, sondern für alle Ebenen einer Karte.

## Literatur

- [1] J. Levinson und S. Thrun, *Robust vehicle localization in urban environments using probabilistic maps*, 2010 International Conference on Robotics and Automation (ICRA), IEEE, S. 4372–4378, 2010.
- [2] H. Lategahn und C. Stiller, *Vision-only localization*, IEEE Transactions on Intelligent Transportation Systems, IEEE, 15. Jg., Nr. 3, S. 1246–1257, 2014.
- [3] M. Schreiber, F. Poggenhans und C. Stiller, *Detecting symbols on road surface for mapping and localization using OCR*, 17th International Conference on Intelligent Transportation Systems (ITSC), IEEE, S. 597–602, 2014.
- [4] M. Sefati, M. Daum, B. Sondermann, K. D. Kreisköther und A. Kampker, *Improving vehicle localization using semantic and pole-like landmarks*, 2017 Intelligent Vehicles Symposium (IV), IEEE, S. 13-19, 2017.
- [5] L. Nicholson, M. Milford und N. Sünderhauf, *QuadricSLAM: Dual Quadrics From Object Detections as Landmarks in Object-Oriented SLAM*, IEEE Robotics and Automation Letters, IEEE, 4. Jg., Nr. 1, S. 1–8, 2018.
- [6] J.-H. Pauls, B. Schmidt und C. Stiller, *Automatic Mapping of Tailored Landmark Representations for Automated Driving and Map Learning*, 2021 International Conference on Robotics and Automation (ICRA), IEEE, S. 6725–6731, 2021.
- [7] N. Sünderhauf und P. Protzel, *Switchable constraints vs. max-mixture models vs. RRR—a comparison of three approaches to robust pose graph SLAM*, 2013 International Conference on Robotics and Automation (ICRA), IEEE, S. 5198–5203, 2013.
- [8] M. Stübler, *Self-assessing localization and long-term mapping using random finite sets*. Dissertation, Fakultät für Ingenieurwissenschaften, Informatik und Psychologie, Universität Ulm, Ulm, 2018.
- [9] I. Hofstetter, M. Sprunk, F. Schuster, F. Ries und M. Hauéis, *On ambiguities in feature-based vehicle localization and their a priori detection in maps*, 2019 Intelligent Vehicles Symposium (IV), IEEE, S. 1192–1198, 2019.
- [10] J.-H. Pauls, T. Strauß, C. Hasberg, M. Lauer und C. Stiller, *HD Map Verification Without Accurate Localization Prior Using Spatio-Semantic 1D Signals*, IEEE, 2020 Intelligent Vehicles Symposium (IV), S. 680–686, 2020.

- [11] D. Pannen, M. Liebner und W. Burgard, *HD Map Change Detection with a Boosted Particle Filter*, 2019 International Conference on Robotics and Automation (ICRA), IEEE, S. 2561–2567, 2019.
- [12] K. Jo, C. Kim und M. Sunwoo, *Simultaneous Localization and Map Change Update for the High Definition Map-Based Autonomous Driving Car*, Sensors 18, No. 9, S. 3145, 2018.
- [13] F. Poggenhans, J.-H. Pauls, J. Janosovits, S. Orf, M. Naumann, F. Kuhnt und M. Mayr, *Lanelet2: A high-definition map framework for the future of automated driving*, 2018 21st International Conference on Intelligent Transportation Systems (IT-SC), IEEE, S. 1672–1679, 2018.
- [14] C. Bron und J. Kerbosch, *Algorithm 457: finding all cliques of an undirected graph*. Commun. ACM 16, 9 (Sept. 1973), S. 575–577, 1973.
- [15] R. Mahler, *Statistical Multisource-Multitarget Information Fusion*, Norwood, MA, USA: Artech House, 2007.

