

Verifikation von HD-Karten mittels räumlich und semantisch separierbarer 1D-Signale

Jan-Hendrik Pauls*, Tobias Strauß†, Carsten Hasberg†
Martin Lauer* und Christoph Stiller*

Zusammenfassung: Für automatisierte Fahrfunktionen haben sich Karten sowohl als perfekte Ergänzung als auch als Rückfallebene für Sensordaten erwiesen. Gerade hochaufgelöste Karten können jedoch sehr schnell veralten.

In teilweise geänderten Umgebungen ist eine Lösung des Lokalisierungsproblems schwierig oder uneindeutig – insbesondere wenn diese strukturiert oder periodisch sind. Um dennoch die Aktualität einer Karte sicherstellen zu können, werden in diesem Beitrag 1D-Signale vorgestellt, die sich nur selten oder geringfügig entlang einer Straße ändern, aber signifikante Änderungen aufweisen, sobald sich die kartierte Umgebung gegenüber der Karte geändert hat.

Drei beispielhafte Signale werden durch die Kombination zweier Verfahren – einer räumlich-semantischen Gruppierung und einer ordnungsinduzierenden Projektion – sowohl aus punkt- als auch aus linienförmigen Landmarken hergeleitet.

Schlüsselwörter: Aktualitätsverifikation, Automatisiertes Fahren, HD-Karten, Kartenverifikation

1 Einleitung

In den vergangenen Jahren gab es sowohl im Bereich der Sensorik als auch bei den Algorithmen, die Sensordaten verarbeiten, große Fortschritte. Dennoch scheinen hochaufgelöste Karten (HD-Karten) bislang unerlässlich für (hoch-)automatisierte Fahrfunktionen [1]. Gegenüber Sensorik zeichnen sich Karten durch eine unbegrenzte Reichweite, eine quasi beliebige Auflösung, eine völlige Unabhängigkeit von möglichen Verdeckungen sowie durch eine vorab verifizierbare Korrektheit der Repräsentation [2] aus. Im Gegensatz zu Sensoren, die ein geringfügig verzögertes Bild der Umgebung liefern, enthalten Karten mitunter Jahre altes Kartenmaterial. Hierdurch ergibt sich der Fehlerfall von Karten: Sie veralten.

Insbesondere HD-Karten, also Karten, die nicht nur den Straßenverlauf, sondern auch detailliertere Merkmale wie Fahrbahnmarkierungen, Ampeln, Verkehrsschilder oder gar spezifische Verkehrsregeln enthalten, veralten sehr schnell. Je mehr Details eine Karte enthält, desto größer die Wahrscheinlichkeit, dass sich auch nur ein Merkmal ändert.

Während die oben beschriebenen, komplementären Eigenschaften HD-Karten zur perfekten Ergänzung sowie einer möglichen Rückfallebene für Sensordaten machen, muss

*Institut für Mess- und Regelungstechnik am Karlsruher Institut für Technologie (KIT), 76131 Karlsruhe (e-mail: {pauls,martin.lauer,stillr}@kit.edu).

†Robert Bosch GmbH, 74232 Abstatt. (e-mail: {tobias.strauss, carsten.hasberg}@de.bosch.com)

damit auch die Korrektheit, d. h. die Aktualität, der verwendeten Karte sichergestellt werden. In vorhergehenden Veröffentlichungen [3] haben wir zwischen Kartvalidierung, also der anwendungsspezifischen Absicherung einer Karte, und Kartenverifikation, also einem merkmalsbasierten Abgleich von Karte und kartierter Umgebung, unterschieden. Dieser Beitrag befasst sich mit der Verifikation einer HD-Karte auf der Detailebene von semantischen Merkmalen bzw. Merkmalsgruppen.

Voraussetzung für einen Abgleich zwischen Kartendaten und der durch Sensorik wahrgenommenen Umgebung ist eine korrekte Lokalisierung. Für den Fall einer eindeutigen und hochgenauen Lokalisierung wurde bereits ein Verfahren zur Kartenverifikation vorgestellt [4]. Schnellstraßen und Autobahnen sind sehr strukturierte Umgebungen, in denen Merkmale oft periodisch oder in sich wiederholenden Mustern auftreten. Dadurch ist eine solche eindeutige Lokalisierung vor allem entlang der Fahrtrichtung nicht immer gegeben – insbesondere, wenn Teile der Karte veraltet sind. In lateraler Richtung kann hingegen eine Lokalisierung bis hin zum korrekten Fahrstreifen angenommen werden [5]. Dies wirft die Frage auf, wie man unter diesen speziellen Voraussetzungen dennoch die Aktualität einer HD-Karte sicherstellen kann.

In diesem Beitrag werden zur Lösung dieses Problems 1D-Signale vorgeschlagen, die sowohl aus stückweise quasi-konstanten Umgebungsmerkmalen, wie der Asphaltelligkeit, aber insbesondere – wie in diesem Beitrag – auch aus stückweise quasi-konstant periodischen Landmarken wie (gestrichelten) Fahrbahnmarkierungen oder den Aufhängepfosten von Schutzplanken abgeleitet werden können. Allgemeiner können all solche Signale gewählt werden, die sich entlang der Fahrtrichtung nur langsam oder selten ändern, bei Änderungen der kartierten Umgebung gegenüber der Karte jedoch signifikante Änderungen aufweisen.

2 Stand der Technik

Der Stand der Technik unterscheidet sich nach der Art der zu verifizierenden Karte. Dudek u. a. [6] beschäftigten sich erstmals mit der Verifikation einer Karte, die durch einen Graphen repräsentiert wurde. Wenngleich die Arbeit nicht ansatzweise den Umfang von HD-Karten abdeckt, so kann sie doch auf den oft in HD-Karten hinterlegten Routing-Graphen angewandt werden.

Spätere Arbeiten befassten sich mit Karten, wie sie für Navigations-, Komfort- und Fahrerassistanzanwendungen üblich sind. Zinoune u. a. [7, 8, 9] verifizierten eine Navigationskarte mit Befahrungen durch ein Fahrzeug, um beispielsweise neu gebaute Kreisverkehre einzufügen. Diese Anwendung ist sehr ähnlich zur Arbeit von Raaijmakers und Bouzouraa [10], die mittels Lidar und einer Karte neu gebaute Kreisverkehre detektierten und schätzten. In seiner Dissertation stellte Raaijmakers darüber hinaus das erste uns bekannte probabilistische Modell zur Verifikation von Karten vor [11]. Hartmann u. a. [12] fusionierten verschiedene Sensordaten mit abgetasteten Geometrieinformationen einer Karte in einem neuronalen Netz, um die Aktualität der Karte zu verifizieren.

Karten in der mobilen Robotik enthalten oft nur Landmarken, die eine globale Lokalisierung erlauben. Für unstrukturiert verteilte Landmarken beschäftigten sich Stübler u. a. mit einem Konsistenzmaß [13] sowie der Anwendung dessen für langzeitstabile Karten [14]. Ebenfalls im Bereich der Robotik ist außerdem das Forschungsfeld langzeitstabiler Karten und zugehöriger Lokalisierungsverfahren zu verorten. Hier wird das Problem der Karten-

verifikation allerdings nicht explizit gelöst.

Die einzigen bemerkenswerten Ausnahmen sind die Ansätze von Jo u. a. [4] sowie von Pannen u. a. [15]. Pannen u. a. schlugen einen bzw. zwei Partikelfilter zur Lokalisierung vor, aufgrund deren Partikel ein Klassifizierer die Aktualität der Karte beurteilt. Hiervon unterscheidet sich der in diesem Beitrag vorgestellte Ansatz, da verifizierte Teile der Karte weiterhin verfügbar sind.

Jo u. a. erweiterten das klassische Problem der gleichzeitigen Lokalisierung und Kartierung (SLAM) um eine auf der Dempster-Shafer-Theorie basierende Update-Komponente. Dies setzt aber immer noch eine eindeutige, hochgenaue Lokalisierung voraus, da eine punktweise Assoziation zwischen Karten- und detektierten Elementen notwendig ist. Diese ist unter der in strukturierten Umgebungen nicht unbegründeten Annahme einer Fehllokalisierung nicht mehr gangbar, da die Assoziationskomplexität mit zunehmender Unsicherheit explodiert.

3 Räumlich-semantische Merkmalsgruppierung

Wie anfangs erwähnt können aus bereits stückweise quasi-konstanten Umgebungsmerkmalen direkt passende Signale abgeleitet werden. Typischerweise sind solche Umgebungsmerkmale aber nicht Teil aktueller Karten oder Datensätze. Daher wird in diesem und den folgenden Kapiteln gezeigt, wie aus beispielhaften Landmarken dennoch passende Signale generiert werden können.

Die Eingangsdaten für das vorgestellte Verfahren sind somit semantisch klassifizierte punkt- oder linienförmige Landmarken, beispielsweise Schutzplankenpfosten (SPF) oder Fahrbahnmarkierungen (FBM) sowie eine lateral fahrstreifengenaue, longitudinal aber unsichere Lokalisierung. Weiterhin wird die Fahrstreifentopologie als unverändert oder rekonstruiert angenommen. Dies kann mit dem Stand der Technik detektiert und sogar kompensiert werden [16]. Eine Einschränkung ist bisher noch, dass die eingehenden Landmarken als perfekt kartiert bzw. detektiert angenommen wurden, d. h. es gibt weder Messfehler noch Fehldetektionen.

Basierend auf diesen Landmarkendaten und der geschätzten Fahrzeugposition können nun Trenngrenzen (sog. Separatoren) eingeführt werden, die die semantisch bereits klassifizierten Landmarken auch räumlich gruppieren. Hierbei können durchgezogene FBM sowie SPF auf den meisten Autobahnabschnitten durch nur einen Separator in der Fahrbahnmitte gruppiert werden. Gestrichelte FBM sind jeweils zwischen zwei Fahrstreifen zu finden, sodass hier je Fahrstreifen ein Separator in der Fahrstreifenmitte eingebracht werden kann. Das Verfahren ist in Abb. 1 dargestellt und hat semantisch greifbare Merkmalsgruppen wie „rechte gestrichelte Fahrbahnmarkierungen“ als Ergebnis.

4 Ordnungsinduzierende Dimensionalitätsreduktion

Wenngleich aufgearbeitete Kartendaten bereits eine Ordnung besitzen können, sind insbesondere Merkmalspunkte aus Sensordaten im Allgemeinen noch ungeordnet. Um wohldefinierte 1D-Signale auf den Merkmalen definieren zu können, ist aber eine Ordnungsrelation notwendig. Diese lässt sich durch Projektion auf eine Referenzlinie, besser noch auf einen durch Referenzpunkte gelegten Referenzspline, induzieren. Als Referenzpunkte eignen sich

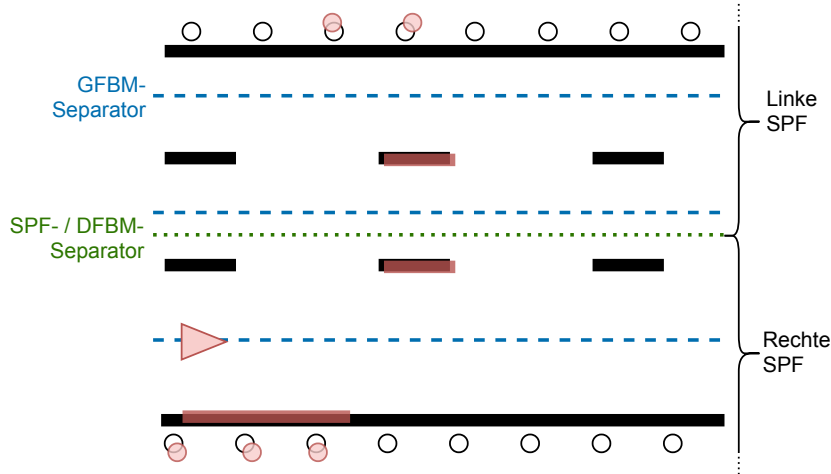


Abbildung 1: Illustration der räumlichen Gruppierung semantischer Merkmalsgruppen. Dargestellt ist die Kartenrepräsentation (schwarz), die aktuelle Pose mit zugehörigen Sensordaten (rot) sowie Separatoren für gestrichelte FBM (GFBM; blau) und SPF bzw. durchgezogene FBM (DFBM; grün). Rechts sind zwei der sich dadurch ergebenden Merkmalsgruppen angedeutet.

sowohl in der Karte verortete Geometrien wie Punkte auf der linken durchgezogenen FBM als auch dynamisch eingeführte Punkte, die beispielsweise durch die Egopositionen definiert sein können.

Nun können die Merkmale \tilde{f}_k jeder Merkmalsgruppe \tilde{F}_k durch Projektion auf den Referenzspline geordnet werden. Hierbei ist zu beachten, dass sich ein generisches Optimierungsverfahren [17] numerisch stabiler zeigte als die vermeintlich optimale Lösung für dieses Problem [18]. Die Projektion erfolgt somit durch Minimierung des Gütefunktional $J(t_i, i) = \|\tilde{f}_i - \mathcal{S}(t_i)\|$, das den Abstand zwischen dem kartesischen Merkmalspunkt $\tilde{f}_i = (x_i, y_i) \in \tilde{F}_k$ und dem entsprechenden Projektionsaufpunkt $\mathcal{S}(t_i)$ minimiert. Dies überführt jeden Merkmalspunkt in ein Frenet-Koordinatensystem definiert durch die Splinekoordinate t_i sowie den orientierten Abstand u_i : $f_i = (t_i, u_i)$.

Dies wiederum induziert nun die Ordnungsrelation $<_t$, sodass man die Merkmalspunkte in $\tilde{f}_i \in \tilde{F}_k$ nun als wohlgeordnete Menge \mathcal{F}_k auffassen kann.

5 1D-Signale

Nachdem aus ungruppierten und ungeordneten Merkmalspunkten nun geordnete Merkmalsmengen hergeleitet wurden, können in diesem Kapitel 1D-Signale definiert werden, die die Eigenschaft haben, dass sie sich bei Fehlern in der longitudinalen Lokalisierung kaum, bei Änderungen der Umgebung jedoch signifikant ändern. Hierbei sind die vorgestellten Signale nur beispielhaft. Weitere Beispiele werden in Kapitel 5.4 eingeführt.

Die bisher angedachten Signale lassen sich in drei Kategorien ordnen: *Existenz* ist ein notwendiges Meta-Signal, ohne das alle weiteren Signale nicht mehr wohldefiniert sind. Sogenannte *intrinsische* Signale sind innerhalb nur einer Merkmalsgruppe definiert. Beispiele sind der Abstand zweier gestrichelter FBM oder deren Länge. *Extrinsische* Signale hingegen setzen zwei verschiedene Merkmalsgruppen zueinander in Beziehung.

5.1 Existenz

Grundlage aller Signale ist die sogenannte *Existenz* \exists . In unserer Implementierung ist die Existenz als binäres Signal über ein Fenster w in Spline-Koordinaten für eine geordnete Merkmalsmenge \mathcal{F}_k und eine Spline-Koordinate t definiert:

$$\exists(\mathcal{F}_k, t, w) := \begin{cases} 1 & \left(\sum_{\{f_i \in \mathcal{F}_k : t_i \in [t-w, t+w]\}} 1 \right) \geq T_{\exists} \\ 0 & \text{sonst} \end{cases} \quad (1)$$

Hierbei gilt für perfekte Eingangsdaten $T_{\exists} = 1$, während für mit Fehldetektionen behaftete Daten ein größerer Schwellwert zu wählen ist.

5.2 Intrinsische Signale

In diesem Beitrag werden zwei intrinsische Signale vorgestellt. Das erste ist der longitudinale Abstand $\mathcal{D}_{\text{long}}$ zweier aufeinanderfolgender Merkmalspunkte:

$$\begin{aligned} \mathcal{D}_{\text{long}}(\mathcal{F}_k, t) &:= t_j - t_i \\ \text{u.d.N.}^1 \quad i &= \arg \max_{l \in \mathcal{F}_k : t_l \leq t} (t_l) \\ j &= \arg \min_{l \in \mathcal{F}_k : t_l > t} (t_l). \end{aligned} \quad (2)$$

Für punktförmige Merkmale wie SPF ist diese Definition trivial. Für linienförmige oder anderweitig ausgedehnte Merkmale muss ein konsistenter Referenzpunkt gefunden werden. Bei gestrichelten FBM kann dies beispielsweise der Anfangspunkt oder der Endpunkt der jeweiligen Markierung sein.

Für ausgedehnte Merkmale ergeben sich dafür weitere mögliche Signale. Eines davon ist die kontinuierliche Länge \mathcal{L} einer gestrichelten FBM-Gruppe, trivial definiert durch die Längen ℓ_i der einzelnen Markierungen. Diese kann entweder entlang dem Referenzspline linear interpoliert werden oder stückweise konstant sein:

$$\begin{aligned} \mathcal{L}(\mathcal{F}_k, t) &:= \|\ell_i\| \\ \text{u.d.N.} \quad i &= \arg \max_{l \in \mathcal{F}_k : t_l \leq t} (t_l). \end{aligned} \quad (3)$$

5.3 Extrinsische Signale

Extrinsische Signale setzen zwei Merkmalsgruppen zueinander in Beziehung. Ein Beispiel hierfür ist die laterale Distanz \mathcal{D}_{lat} , die für zwei geordnete Merkmalsmengen \mathcal{F}_k und \mathcal{F}_l an jeder Koordinate t definiert ist:

$$\begin{aligned} \mathcal{D}_{\text{lat}}(\mathcal{F}_k, \mathcal{F}_l, t) &:= \|u_j - u_i\| \\ \text{u.d.N.} \quad i &= \arg \min_{m \in \mathcal{F}_k} (\|t_m - t\|) \\ j &= \arg \min_{m \in \mathcal{F}_l} (\|t_m - t\|). \end{aligned} \quad (4)$$

Hierbei ist u_i bzw. u_j die zum Referenzspline orthogonale Koordinate.

¹unter den Nebenbedingungen

5.4 Generalisierung

Neben den bereits vorgestellten 1D-Signalen sind zahlreiche weitere denkbar. Neben den vorgestellten Signalen für periodische Umgebungen sind hierbei insbesondere Signale denkbar, die bereits stückweise quasi-konstant bzw. nur sehr langsam veränderlich als kontinuierliche Größen vorkommen. Beispiele hierfür sind Asphaltelligkeiten, Breiten von Markierungen und Bordsteinen, aber auch Höhen von Bordsteinen oder Schutzplanken.

6 Kartenverifikation und Änderungsdetektion

Schließlich können nun durch einen direkten Vergleich der Karten- mit den Messdatensignalen Änderungen in der Umgebung detektiert werden. Hierfür wird, wie in Abb. 2 dargestellt, ein dreistufiger Ansatz verfolgt. In einem ersten Schritt wird die Existenz derselben Merkmalsgruppe in Karte und Sensordaten geprüft. Ist diese für keine der beiden gegeben, so ist die Karte trivialerweise verifiziert. Stimmt die Existenz nicht überein, so kann eine Änderung detektiert werden. Existiert eine Merkmalsgruppe sowohl in der Karte als auch in den Sensordaten, so wird zur zweiten Stufe übergegangen. Hier werden die intrinsischen Signale auf Übereinstimmung geprüft. Dies geschieht mit einem Schwellwertverfahren auf der Differenz der Signale. Wurde weiterhin keine Änderung detektiert, so kommt die Merkmalsgruppe in die dritte Stufe. Hier werden nun potentiell noch valide Merkmalsgruppen auf ihre extrinsischen Signale geprüft. Dies geschieht ebenfalls durch ein Schwellwertverfahren.

Nach drei Schritten können so einige Merkmalsgruppen als bereits geändert angesehen werden. Für andere ist dies noch nicht klar, da eine konsistente Verschiebung in Fahrtrichtung prinzipbedingt nicht festgestellt werden kann, ohne sich mit einer punktweisen Assoziation longitudinal zu lokalisieren. Es kann aber für einen anschließenden punktweisen Abgleich die Menge der auszuwertenden Merkmale teils erheblich eingeschränkt werden, da alle bereits als geändert bekannten Merkmalsgruppen ausgeschlossen werden können.

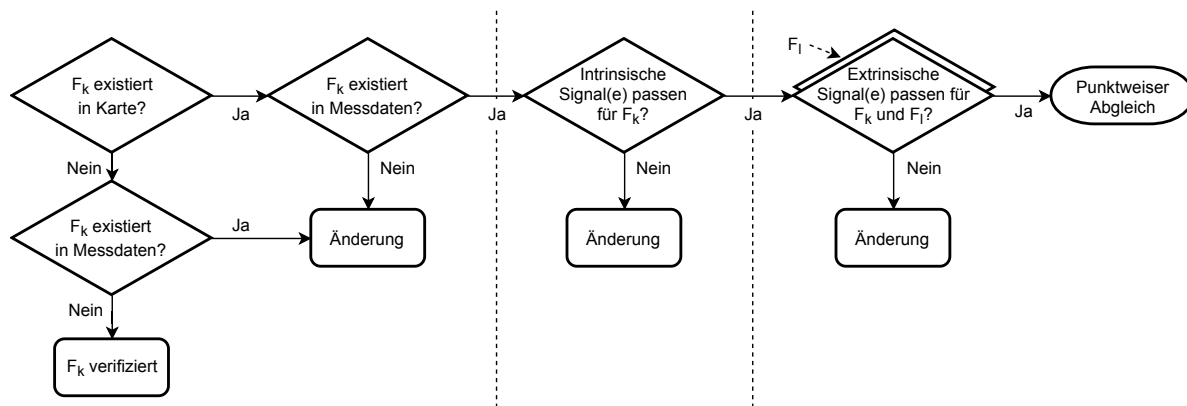


Abbildung 2: Schema zur Änderungsdetektion. Gestrichelte Linien markieren die Abtrennung der drei Detektionsstufen Existenz, intrinsische Signale und extrinsische Signale.

7 Evaluierung

Da in diesem Beitrag stets perfekte Karten- und Sensordaten angenommen werden, konnte die Evaluierung direkt auf einem bereits publizierten Datensatz [3] erfolgen. Da das Label-Rauschen im Datensatz in lateraler Richtung in derselben Größenordnung wie die zu beobachteten Änderungen liegt, wurden jedoch nur die ersten beiden Stufen der in Kapitel 6 beschriebenen Änderungsdetektion ausgewertet. Dies wäre bei automatisierter Erfassung der Merkmale nicht zu erwarten.

Als Metriken dienen die Richtig-Positiv-Rate und die Falsch-Positiv-Rate auf den vermeintlich² perfekten Daten. Abb. 3 zeigt beide über einen simulierten, zeitlich konstanten Lokalisierungsfehler. Wie anfangs beschrieben ist dieser Lokalisierungsfehler rein longitudinal, d. h. entlang der Fahrtrichtung.

Hierbei konnten stets 49 % bis 98 % aller Änderungen erkannt werden. Gleichzeitig blieb die Falsch-Positiv-Rate meist bei unter 15 %. Bei Lokalisierungsfehlern von 20 m wären die allermeisten punktweise arbeitenden Verfahren längst funktionsunfähig.




Abbildung 3: Evaluierung auf drei Autobahnabschnitten. Abgebildet sind Richtig- (\times) und Falsch-Positiv-Rate (\circ) der linken/rechten SPF (blau/rot) sowie der linken/rechten gestrichelten FBM (gelb/lila) über ansteigendem simuliertem Lokalisierungsfehler.

Gerade bei den SPF kann bereits aufgrund dem Meta-Signal *Existenz* ein Großteil der Änderungen erkannt werden, da diese zwischen den Fahrbahnen mehr und mehr durch Betonrückhaltesysteme ersetzt werden.

Falsch-positive Änderungsdetektionen treten typischerweise an den Übergängen auf, in denen die lokale Konstanz der Signale nicht mehr gegeben ist. Dies ist dem Ansatz geschuldet und wurde entsprechend erwartet.

Die fehlenden richtig-positiven Änderungsdetektionen stammen von longitudinalen Verschiebungen der Merkmale. Diese sind mit dem vorgestellten Ansatz nicht zu beobachten, sondern erfordern – ob nun direkt oder indirekt – eine punktweise Assoziation, die stets einer Lokalisierung gleichkommt. Diese sollte im Anschluss an das vorgestellte Verfahren auf den potentiell noch korrekten Signalen/Merkmalen erfolgen.

8 Fazit und Ausblick

In diesem Beitrag wurde ein Ansatz vorgestellt, der eine Aktualitätsverifikation von HD-Karten erlaubt, obwohl teils erhebliche Lokalisierungsfehler – wie beim aktuellen Stand

²Falsch-Positiv-Detektionen aufgrund von Label-Fehlern wurden ignoriert und die Falsch-Positiv-Raten entsprechend kompensiert.

der Technik auf Autobahnen und Schnellstraßen zu erwarten – vorliegen. Der Ansatz nutzt stückweise quasi-konstante 1D-Signale, die sich longitudinal kaum, im Falle von Änderungen der kartierten Umwelt aber signifikant ändern. Neben bereits in dieser Form vorliegenden Signalen wurde in diesem Beitrag darüber hinaus vorgestellt, wie strukturiert oder periodisch auftretende Landmarken wie Schutzplankenpfosten oder Fahrbahnmarkierungen in eine solche Signalform gebracht werden können.

An einem Verfahren zur Rekonstruktion periodischer Signale auch aus verrauschten bzw. mit Fehldetektionen behafteten Sensordaten wird aktuell geforscht. Darüber hinaus ergibt sich fast schon natürlich die Frage, ob direkt im Signalraum das SLAM-Problem gelöst werden kann. Dies geht auch damit einher, dass die unveränderten Teile der Karte zur Lokalisierung genutzt werden, um die geänderten Teile zu aktualisieren. Damit stellt sich schließlich die Frage, wie man geänderte Teile der Karte – ob nun als Landmarken oder als Signale – probabilistisch aktualisieren kann.

Literatur

- [1] F. Poggenhans u. a. „Lanelet2: A high-definition map framework for the future of automated driving”. In: *21st Int. Conf. Intell. Transp. Syst. (ITSC)*, Nov. 2018, S. 1672–1679.
- [2] F. Poggenhans *Generierung hochdetaillierter Karten für das automatisierte Fahren*, Dissertation, Karlsruher Institut für Technologie (KIT), 2019.
- [3] J. Pauls u. a. „Can We Trust Our Maps? An Evaluation of Road Changes and a Dataset for Map Validation”. In: *21st Int. Conf. Intell. Transp. Syst. (ITSC)*, Nov. 2018, S. 2639–2644.
- [4] K. Jo u. a. „Simultaneous Localization and Map Change Update for the High Definition Map-Based Autonomous Driving Car”. In: *Sensors*, Vol. 18, No. 9, S. 3145, Sep. 2018.
- [5] M. Harr u. a. „Robust Localization on Highways Using Low-Cost GNSS, Front/Rear Mono Camera and Digital Maps”. In: *AME 2018 - Automotive meets Electronics; 9th GMM-Symposium*, Mär. 2018, S. 1–7.
- [6] G. Dudek u. a. „Map validation and self-location in a graph-like world”. In: *Int. Joint Conf. Artificial Intell.*, Aug. 1993, S. 1648–1653.
- [7] C. Zinoune u. a. „Detection of missing roundabouts in maps for Driving Assistance Systems”. In: *2012 IEEE Intelligent Vehicles Symposium*, Jun. 2012, S. 123–128.
- [8] C. Zinoune u. a. „A sequential test for autonomous localisation of map errors for driving assistance systems”. In: *15th Int. Conf. Intell. Transp. Syst. (ITSC)*, Sept. 2012, S. 1377–1382.
- [9] C. Zinoune u. a. „Sequential FDIA for Autonomous Integrity Monitoring of Navigation Maps on Board Vehicles”. In: *IEEE Trans. Intell. Transp. Syst.*, Jan. 2016, S. 143–155.
- [10] M. Raaijmakers und M. E. Bouzouraa „In-vehicle Roundabout Perception Supported by A Priori Map Data”. In: *18th Int. Conf. Intell. Transp. Syst. (ITSC)*, Sep. 2015, S. 437–443.

- [11] M. Raaijmakers *Towards environment perception for highly automated driving: with a case study on roundabouts*, Dissertation/Prüfsschrift, TU Eindhoven, 2017.
- [12] O. Hartmann u. a. „Robust and real-time multi-cue map verification for the road ahead”. In: *17th Int. Conf. Intell. Transp. Syst. (ITSC)*, Okt. 2014, S. 894–899.
- [13] M. Stübler u. a. „Consistency of feature-based random-set Monte-Carlo localization”. In: *2017 Eur. Conf. on Mobile Robots*, Sep. 2017, S. 1–6.
- [14] M. Stübler u. a. „A continuously learning feature-based map using a bernoulli filtering approach”. In: *2017 Sensor Data Fusion: Trends, Solutions, Applications (SDF)*, Okt. 2017, S. 1–6.
- [15] D. Pannen u. a. „HD Map Change Detection with a Boosted Particle Filter”. In: *2019 Int. Conf. Robot. Autom. (ICRA)*, Mai 2019, S. 2561–2567.
- [16] F. Dierkes u. a. „Towards a Multi-Hypothesis Road Representation for Automated Driving”. In: *18th Int. Conf. Intell. Transp. Syst. (ITSC)*, Sep. 2015, S. 2497–2504.
- [17] J. Lagarias u. a. „Convergence Properties of the Nelder–Mead Simplex Method in Low Dimensions”. In: *SIAM Journal on Optimization*, Band 9, Jan. 1998, S. 112 – 147.
- [18] H. Wang u. a. „Robust and efficient computation of the closest point on a spline curve”. In: *5th Int. Conf. Curves and Surfaces*, 2002, S. 397–406.