

Zuverlässige und integrale Landmarken-basierte Lokalisierungsmethoden zum automatisierten Fahren

Isabell Hofstetter^{*}, Florian Ries[†], Frank Schuster[‡], Martin Haueis[§]

Zusammenfassung: Nachweisbare Zuverlässigkeit Landmarken-basierter Lokalisierungsverfahren bleibt bis heute eine der größten Herausforderungen auf dem Gebiet des automatisierten Fahrens. Wesentliches Fehlerpotential steckt dabei vor allem in der Assoziation von detektierten Landmarken mit Kartenelementen. Periodische Muster und uneindeutige Lokalisierungsmerkmale stellen Fehlerquellen für eine korrekte Datenassoziation dar und gefährden damit eine integrale Lokalisierung.

Diese Arbeit beschäftigt sich damit, Integrität von Lokalisierungsverfahren sicherzustellen. Durch eine Vorprozessierung des Kartenmaterials werden zunächst mehrdeutige Landmarkenmuster identifiziert, die mögliche Fehlerquellen darstellen. Zusätzlich wird eine neue Datenassoziationsmethode basierend auf Geometric Hashing eingeführt, welche keinerlei Informationen über die vorhergehende Position des Fahrzeugs benötigt und somit das Risiko der Fehlerfortpflanzung ausschließt. Abschließend wird die Identifikation eindeutiger Landmarkenkonstellationen zur integralen Fahrzeuglokalisierung beschrieben.

Schlüsselwörter: Fahrzeuglokalisierung, Datenassoziation, Geometric Hashing, Integrität

1 Einleitung

Landmarken-basierte Lokalisierungsmethoden zum automatisierten Fahren wurden in der Vergangenheit ausgiebig erforscht und deren großes Potential verdeutlicht. Diese Verfahren nutzen eine zuvor generierte Karte, die Merkmale aus der Umgebung des Fahrzeugs enthält. Während der Lokalisierungsfahrt werden die detektierten Merkmale mit den Kartenelementen in Verbindung gebracht und daraus die Fahrzeugpose berechnet.

Die Herausforderung besteht somit vor allem darin, die korrekten Assoziationen zwischen kartierten Landmarken und Detektionen zu finden. Um Integrität sicherzustellen, sollte außerdem nachgewiesen werden können, dass die Wahrscheinlichkeit einer Falschassoziation hinreichend gering ist [1].

Lokalisierungsverfahren, die nur spärliche Landmarken mit schwachen Deskriptoren verwenden, bieten viele Vorteile, wie zum Beispiel eine reduzierte Kartengröße oder die Wiederverwendbarkeit der Merkmale für andere Aufgaben [4], [5], [6]. Allerdings geht mit

^{*}Isabell Hofstetter ist Doktorandin bei der Mercedes-Benz AG, isabell.hofstetter@daimler.com.

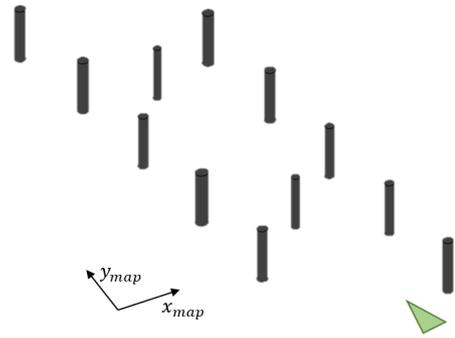
[†]Florian Ries ist Entwicklungsingenieur bei der Mercedes-Benz AG, florian.ries@daimler.com.

[‡]Frank Schuster ist Entwicklungsingenieur bei der Mercedes-Benz AG, frank.fs.schuster@daimler.com.

[§]Martin Haueis ist Leiter des Teams Fahrzeuglokalisierung bei der Mercedes-Benz AG, martin.haueis@daimler.com.



(a) Kamerabild einer städtischen Straße in Karlsruhe.



(b) Zugehöriger Kartenabschnitt mit zylindrischen Lokalisierungsmerkmalen.

Abb. 1: Beispiel einer städtischen Straße mit zugehörigen Lokalisierungsmerkmalen in der Karte.

der Extraktion solcher Lokalisierungsmerkmale auch ein großer Informationsverlust einher, und die Eindeutigkeit einer lokalen Umgebung wird in der Karte nicht immer widerspiegelt. Dies führt zu Mehrdeutigkeiten in der Assoziation von detektierten Merkmalen mit der Karte. Eine Garantie, dass Falschassoziationen ausgeschlossen werden, ist somit nicht mehr unbedingt gegeben.

Die meisten Ansätze verlassen sich bei der Datenassoziation auf die prädierte Pose des Fahrzeugs aus früheren Schätzwerten [2], was jedoch das Risiko der Fehlerfortpflanzung mit sich bringt. Andere Methoden greifen auf verschiedene Arten von Pattern Matching zurück [4], [7] um gewisse Mehrdeutigkeiten in der Zuordnung der Lokalisierungsmerkmale auszuschließen. Doch auch bei der Berechnung lokaler Deskriptoren aus Merkmalsmustern in [8], [9] fällt auf, dass solche Muster mehrdeutig sein können.

In dieser Arbeit wird auf ein Lokalisierungsverfahren aufgebaut, welches zylindrische Landmarken als Lokalisierungsmerkmale verwendet [4]. In Abbildung 1 ist die Art der Lokalisierungsmerkmale visualisiert: Zu einem Kamerabild in Abbildung 1a ist der passende Kartenabschnitt in Abbildung 1b zu sehen. Die zylindrischen Objekte, die hier in der Karte abgespeichert sind, repräsentieren in diesem Beispiel Bäume und Straßenlaternen. Im Folgenden werden diese Zylinder durch ihren Mittelpunkt auf der Bodenebene als zwei-dimensionale Punkte im Kartenkoordinatensystem dargestellt.

Um auch mittels solcher Lokalisierungsmerkmale eine integrale Fahrzeuglokalisierung sicherstellen zu können, werden im Folgenden drei neue Ansätze beleuchtet: Kapitel 2 beschäftigt sich mit der Identifikation möglicher Fehlerquellen durch die a priori Detektion von Mehrdeutigkeiten im Kartenmaterial. Dazu wird eine Methode basierend auf Geometric Hashing genutzt, die in Kapitel 3 ebenfalls zur zuverlässigen Datenassoziation ohne Risiken durch Fehlerfortpflanzung vorgeschlagen wird. Abschließend wird in Kapitel 4 die Nutzung ausgewählter Landmarken zur integren und zuverlässigen Fahrzeuglokalisierung vorgeschlagen. Dazu wird die Identifikation eindeutiger Landmarkenmuster in der Karte erläutert.

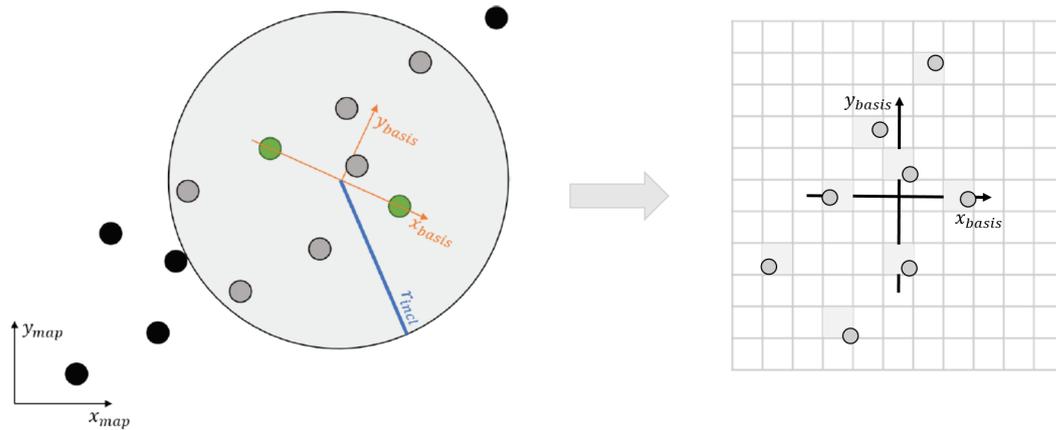


Abb. 2: Visualisierung der Hashing Parameter: Landmarken im Kartenkoordinatensystem (schwarz), ein Basispaar (grün), die zugehörige geometrische Basis (orange), Landmarken I_k (grau) im Umkreis r_{incl} (blau).

2 Vorprozessierung von Kartenmaterial zur Identifikation von Fehlerpotential

Mehrdeutigkeiten in den Kartendaten führen zu einem nicht eindeutig lösbaeren Problem der Datenassoziation. Solche Mehrdeutigkeiten entstehen durch uneindeutige Lokalisierungsmerkmale, ähnliche Landmarkenkonstellationen und periodische Muster von Lokalisierungsmerkmalen.

In diesem Kapitel wird eine Methode basierend auf Geometric Hashing vorgeschlagen, um strukturiert und effizient nach mehrdeutigen Mustern in Karten zu suchen. Das Wissen über die Existenz und räumliche Verteilung solcher Mehrdeutigkeiten erlaubt eine a priori Abschätzung von möglichen Assoziationsfehlern während der Lokalisierung und kann zu einer integren Lokalisierung beitragen.

Geometric Hashing wurde ursprünglich von Lamdan et al. im Gebiet des Bildverstehens zur Objekterkennung entwickelt [3], [10]. Inzwischen ist es eine bekannte Methode zur Assoziation von geometrischen Merkmalen, die einer Transformation unterzogen wurden.

Im Folgenden wird Geometric Hashing mit Hinblick auf die Verwendung der Methode zur Detektion von Mehrdeutigkeiten in Kartendaten hergeleitet. Das Vorgehen beinhaltet im ersten Schritt die Hash Table Generierung für einen Kartenabschnitt (siehe Abschnitt 2.1) und eine anschließende Suche nach Mehrdeutigkeiten mit Hilfe dieses Hash Tables (siehe Abschnitt 2.2).

2.1 Hash Table Generierung

In einem offline Schritt werden alle Merkmale in einer Karte $M = \{f_1, f_2, \dots, f_n\}$ in einer Vielzahl von Koordinatensystemen dargestellt und in einem schnell durchsuchbaren, tabularen Format, dem *Hash Table*, gespeichert. Dafür werden Koordinatensysteme wie folgt definiert: Jede Kombination von zwei Landmarken $k = (f_i, f_j)$ mit $f_i, f_j \in M$ für $i, j \in \{1, \dots, n\}$, $i \neq j$, auch *Basispaar* genannt, definiert eine *geometrische Basis*. Den Ursprung dieser Basis stellt der Mittelpunkt zwischen f_i und f_j dar und die x -Achse ist

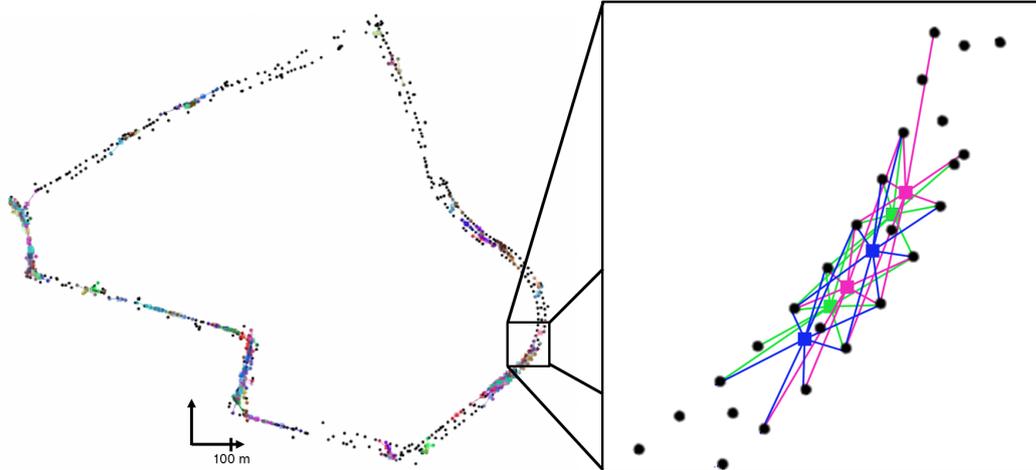


Abb. 3: Kartenausschnitt mit mehreren kongruenten Landmarkenkonstellationen: Kongruente Muster sind in der gleichen Farbe dargestellt und deren zugehörige Landmarken durch Kanten mit ihrem Schwerpunkt (als Quadrat dargestellt) verbunden.

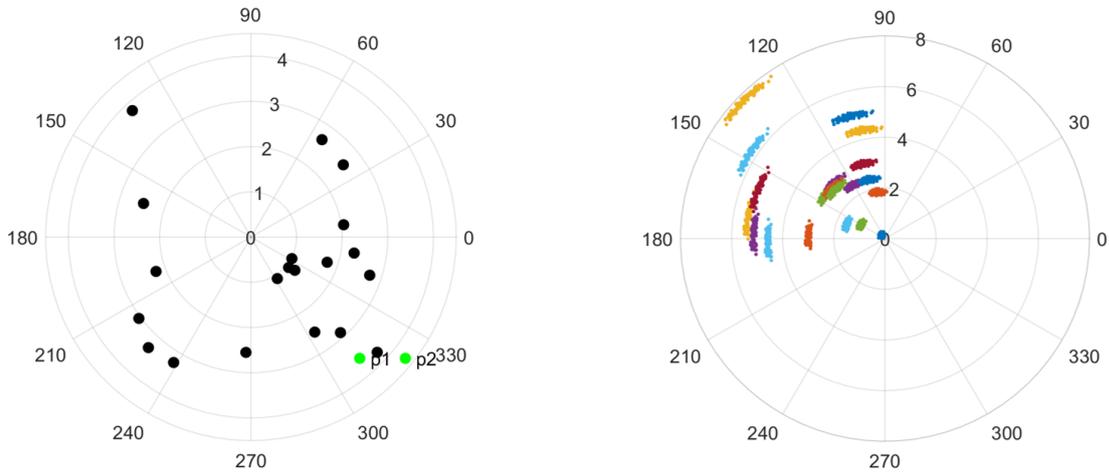
definiert als die Gerade, die durch die Punkte f_i und f_j geht. Um die Anzahl der dadurch entstehenden Koordinatensysteme einzuschränken, werden nur Basispaare verwendet für die gilt, dass $\|f_i - f_j\| < d_{basis}$ für ein maximales Basispaar-Limit d_{basis} .

Anschließend werden alle Merkmale von Interesse I_k , d.h. diejenigen, die in einem gegebenen Umkreis r_{incl} um den Koordinatenursprung liegen, in das neue Koordinatensystem transformiert und diskretisiert. Schließlich werden für die Koordinaten der Lokalisierungsmerkmale I_k relativ zur geometrischen Basis Hashwerte berechnet, welche in einem Hash Table zusammen mit Informationen über das Basispaar abgespeichert werden. Abbildung 2 veranschaulicht den Hashing-Prozess und seine wichtigsten Parameter.

2.2 Detektion von Mehrdeutigkeiten

Der in Kapitel 2.1 generierte Hash Table enthält nun Informationen über lokale Umgebungen in der Karte, die in unterschiedlichsten Koordinatensystemen dargestellt und durch die Landmarken selbst definiert sind. Nun kann dieser Hash Table zur effizienten und strukturierten Suche nach kongruenten Landmarkenmuster in einer Karte genutzt werden. Dazu werden alle Koordinatensysteme oder *Layer* des Hash Tables nach ihren Basispaaren sortiert. Alle Layer mit übereinstimmenden Basispaaren werden anschließend nach weiteren Gemeinsamkeiten durchsucht. Diese Gemeinsamkeiten stellen ein kongruentes Landmarkenmuster dar, welches mindestens zweimal im Kartenkoordinatensystem vorkommt. Die Menge dieser Lokalisierungsmerkmale wird anschließend extrahiert und als mehrdeutige Konstellation abgespeichert. Ebenso wird jede mögliche Teilkonstellation in die Liste mit aufgenommen. Jede dieser Konstellationen wird mit Informationen über ihren Gegenpart und die Transformation zwischen den beiden abgespeichert. Dies ermöglicht die offline Abschätzung von möglichen Fehlern bei einer Falschassoziation von kongruenten Konstellationen.

Ein Kartenausschnitt mit detektierten kongruenten Konstellationen aus sieben Landmarken ist in Abbildung 3 dargestellt. Im hervorgehobenen Bereich ist deutlich sichtbar,



(a) Landmarken (schwarz) und zufällig gewähltes Basispaar p_1 und p_2 (grün) in Polarkoordinaten dargestellt.

(b) Simulierte Messungen der Landmarken, welche in das verrauschte Basis-Koordinatensystem transformiert wurden.

Abb. 4: Rauschverstärkung durch Geometric Hashing mit starren Transformationen.

dass kongruente Konstellationen im Kartenkoordinatensystem leicht verschoben zueinander auftreten können. Für weitere Details und Ergebnisse verweisen die Autoren auf [11].

3 Integre und effiziente Datenassoziation ohne Annahmen über vorhergehende Fahrzeugposen

Um den in Kapitel 2.1 generierten Hash Table nicht nur zur Detektion von Mehrdeutigkeiten sondern auch online zur effizienten und zuverlässigen Datenassoziation zu nutzen, muss er um ein Modell für das Messrauschen erweitert werden. Dies wird in 3.1 näher beschrieben. Anschließend wird die Datenassoziation mit Hilfe des Hash Tables in 3.2 hergeleitet. Das vorgeschlagene Verfahren ermöglicht die Datenassoziation ohne Prädiktion der Fahrzeugpose anhand von früheren Schätzwerten. Dies birgt viel Potential, da das Risiko der Fehlerfortpflanzung ausgeschlossen werden kann und somit eine sichere Lokalisierung ermöglicht wird.

3.1 Rauschmodellierung für Geometric Hashing mittels starrer Transformationen

Während der Generierung des Hash Tables wird eine Monte Carlo Simulation durchgeführt, um das Messrauschen zu beschreiben, welches durch die Transformation in die verrauschte geometrische Basis verstärkt wird. Abhängig von der Wahl des Basispaars, sowie der Lage der restlichen Landmarken in der geometrischen Basis, muss eine Verteilung im Basis-Koordinatensystem geschätzt werden. Bei nah beieinander liegenden Basis-Landmarken wird das Messrauschen in der Winkelkomponente deutlich verstärkt,

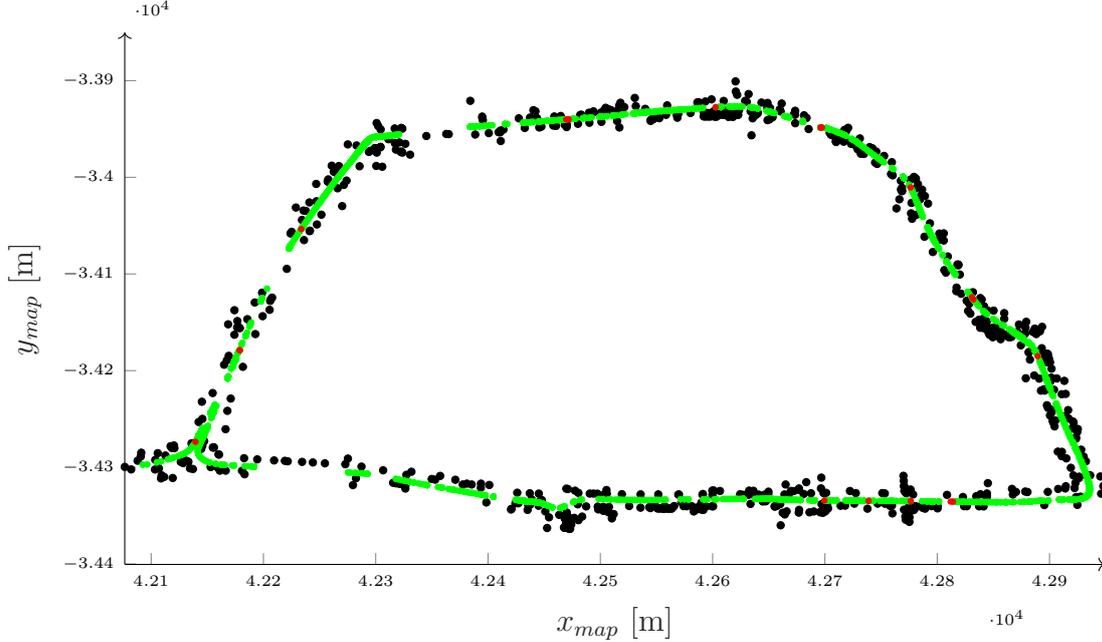


Abb. 5: Karte mit 738 zylindrischen Lokalisierungsmerkmalen (schwarz) und Positionen an denen eine sichere Assoziation möglich war (grün).

während das Rauschen in radialer Richtung konstant bleibt. Deswegen empfehlen die Autoren, die resultierende Verteilung in Polarkoordinaten zu betrachten (siehe Abb. 4).

Simulativ werden Messungen mit gegebenem Messrauschen σ erzeugt, welche dann in die Transformation mit einfließen. Für jede geometrische Basis des Hash Tables und jede darin repräsentierte Landmarke werden aus diesen Messungen Standardabweichungen in radiale Richtung σ_r und in der Winkelkomponente σ_θ berechnet. Diese Standardabweichungen werden dann im Hash Table gespeichert.

3.2 Datenassoziation basierend auf Geometric Hashing

Gegeben sei eine Menge von detektierten Lokalisierungsmerkmalen D und ein Hash Table H zu einer zugehörigen Karte M .

Um Assoziationen zwischen den Detektionen D und Kartenelementen in M zu finden, müssen die detektierten Landmarken zunächst passend zum Hash Table verschlüsselt werden. Dazu wird ein zufälliges Paar an Merkmalen ausgewählt, welches eine geometrische Basis definiert. Alle verbleibenden Merkmale werden anschließend in dieses Koordinatensystem transformiert und entsprechend ihrer Koordinaten verschlüsselt. Für jeden berechneten Hashwert wird der zugehörige Eintrag im Hash Table gesucht und jede dort vorhandene geometrische Basis bekommt eine Stimme. Im folgenden Schritt werden die Basen, die eine gewisse Anzahl an Stimmen bekommen haben, extrahiert. Diese sind Kandidaten für mögliche Assoziationen. Abschließend wird eine Validierung durchgeführt, mit der entschieden wird, welche der Kandidaten die richtige Assoziation darstellt. Um weitere Sicherheit zu bekommen, können zusätzliche lokale geometrische Basen generiert und der Prozess wiederholt werden.

In Abbildung 5 ist eine Karte mit 738 Lokalisierungsmerkmalen zu sehen. Grüne Punkte stellen Positionen dar, an denen zuverlässige Assoziationen ohne Annahmen über ei-

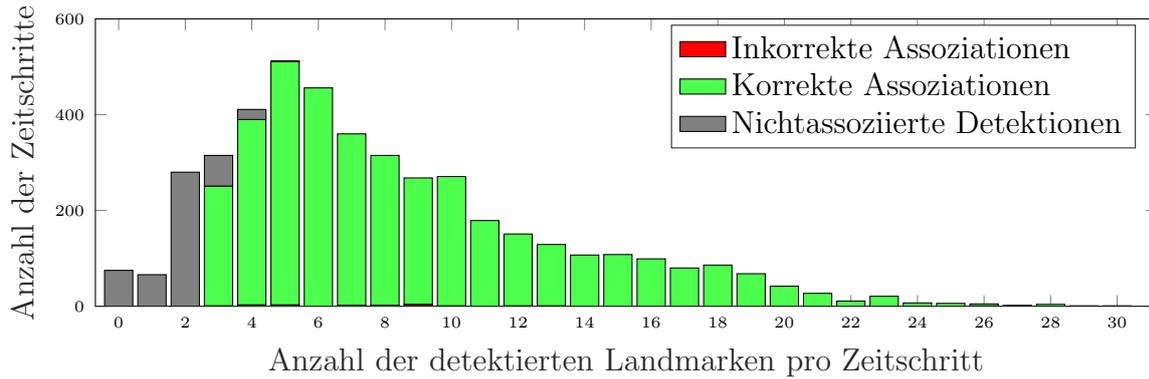


Abb. 6: Häufigkeit von verschiedensten Anzahlen von detektierten Landmarken und entsprechenden Assoziationen.

ne vorhergehende Position des Fahrzeugs gefunden werden konnten. Rote Punkte stellen Fahrzeugposen dar, an denen mehrdeutige Konstellationen detektiert wurden und eine zuverlässige Assoziation somit nicht garantiert werden konnte. Die Häufigkeit von Landmarkendetektionen pro Zeitschritt und die zugehörigen korrekten bzw. inkorrekten Assoziationen sind mit Hilfe eines Balkendiagramms in Abbildung 6 dargestellt.

4 Ermittlung von Landmarkenkonstellationen zur integren Lokalisierung

Eine sichere Lokalisierung ist genau dann möglich, wenn keine Mehrdeutigkeiten in der Assoziation von Kartendaten und Detektionen vorhanden sind oder diese mit einer sehr hohen Wahrscheinlichkeit ausgeschlossen werden können.

In diesem Kapitel wird vorgeschlagen nur ausgewählte Landmarkenmuster zur Lokalisierung zu verwenden, die eine lokale Umgebung in der Karte eindeutig zuordenbar machen. Sobald ein solches Merkmalsmuster während der Fahrt detektiert wird, können Falschassoziationen dank der Eindeutigkeit der Konstellation unter gewissen Annahmen an Sensorfehler ausgeschlossen werden.

Im Folgenden wird zunächst definiert, was unter einer eindeutigen Landmarkenkonstellation zu verstehen ist. Anschließend wird beschrieben, wie solche Muster aus der Karte extrahiert werden können. Experimentelle Ergebnisse für einen Kartenabschnitt von ca. 4 km werden abschließend demonstriert.

4.1 Definition von eindeutigen Landmarkenmustern

Landmarkenmuster, die hier von Interesse sind, sollen in einem vorgegebenen Kartenabschnitt eindeutig sein. Dies gelte selbst dann, wenn die detektierten Landmarken mit einem Messrauschen σ belegt sind. Mit anderen Worten: Es gibt für ein eindeutiges Landmarkenmuster kein zweites approximatives Matching [12], [13] in der Karte. Ebenso sollen für eine eindeutige Konstellation auch alle Teilmengen der Merkmale wiederum eindeutig sein um auch bei teilweisen Verdeckungen noch eine eindeutige Assoziation zu ermöglichen.

Um diese Voraussetzung mathematisch beschreiben zu können, sei der Abstand d

zwischen einzelnen Landmarken $x \in \mathbb{R}^2$ und Landmarkengruppen K , wobei $K \subset \mathbb{R}^2$, definiert als

$$d(x, K) := \min\{\|x - k\|_2 \mid k \in K\}.$$

Der minimale Abstand D zwischen zwei Landmarkengruppen K und L sei dann gegeben durch

$$D(K, L) := \min\{d(k, L) \mid k \in K\}.$$

Sei nun \mathcal{T} die Menge aller euklidischen Transformationen, d.h. alle Kombinationen aus Rotationen und Translationen. Dann ist ein Landmarkenmuster $M_1 = \{f_1, \dots, f_N\}$ mit $N > 2$ genau dann eindeutig in einem Kartenabschnitt M , wenn gilt

$$\forall T \in \mathcal{T} \exists F \subset M_1 \text{ mit } |F| = |M_1| - 2 : D(M_{sub,|F|}, T(F)) > \epsilon \quad (1)$$

für alle Teilmengen der Kartenmerkmale $M_{sub,|F|} \subset M \setminus M_1$ mit $|M_{sub,|F|}| = |F|$ und einem Mindestabstand ϵ .

Das bedeutet, unter jeder beliebigen starren Transformation T gibt es höchstens zwei Merkmale $f_i, f_j \in M_1$, $i \neq j$, deren Abstand zu den Kartenelementen in $M \setminus M_1$ kleiner als ϵ ist. Somit gibt es nur eine eindeutige Transformation, welche ein approximatives Matching der vollständigen Konstellation ermöglicht. Gleiches gilt auch für alle Teilkonstellationen F der Größen $|F| = [3, |M_1| - 1]$.

4.2 Identifikation eindeutiger Landmarkenmuster in der Karte

Um die Detektion vollständiger Landmarkenkonstellationen zu ermöglichen, ist zusätzlich zur Eindeutigkeit der Landmarkenmuster eine möglichst geringe Ausdehnung des Musters im Kartenkoordinatensystem wünschenswert, d.h.

$$d(f_i, f_j) < L \quad \forall f_i, f_j \in M_1, i \neq j, \quad (2)$$

mit gegebener maximaler Ausdehnung L .

Um Landmarkenkonstellationen mit Eigenschaften (1) und (2) aus den Kartendaten zu extrahieren, wird ein Clustering-Verfahren angewendet, welches die Informationen über Mehrdeutigkeiten gemäß der in Kapitel 2 beschriebenen Methoden nutzt.

Dazu werden zufällige Cluster von Lokalisierungsmerkmalen gebildet und mit der Liste der mehrdeutigen Konstellationen abgeglichen. Cluster, die die oben genannten Anforderungen (1) und (2) erfüllen, werden als eindeutige Landmarkenkonstellationen extrahiert. Die restlichen Cluster werden wiederholt zufällig aufgeteilt bis hier ebenfalls eindeutige Konstellationen gefunden werden.

In Abbildung 7 ist eine Karte zu sehen, in der Landmarkenmuster durch Farbe und verbindende Kanten gekennzeichnet sind. Diese Cluster stellen jeweils in der gesamten Karte eindeutige Konstellationen aus jeweils fünf Landmarken dar. Periodische Muster werden in verschiedene Konstellationen zerlegt, wie ebenfalls in Abbildung 7 zu sehen ist. Während der Lokalisierungsfahrt kann nun im Fall der Detektion einer solchen Konstellation unter gewissen Annahmen garantiert werden, dass keine Falschassoziation vorliegt.

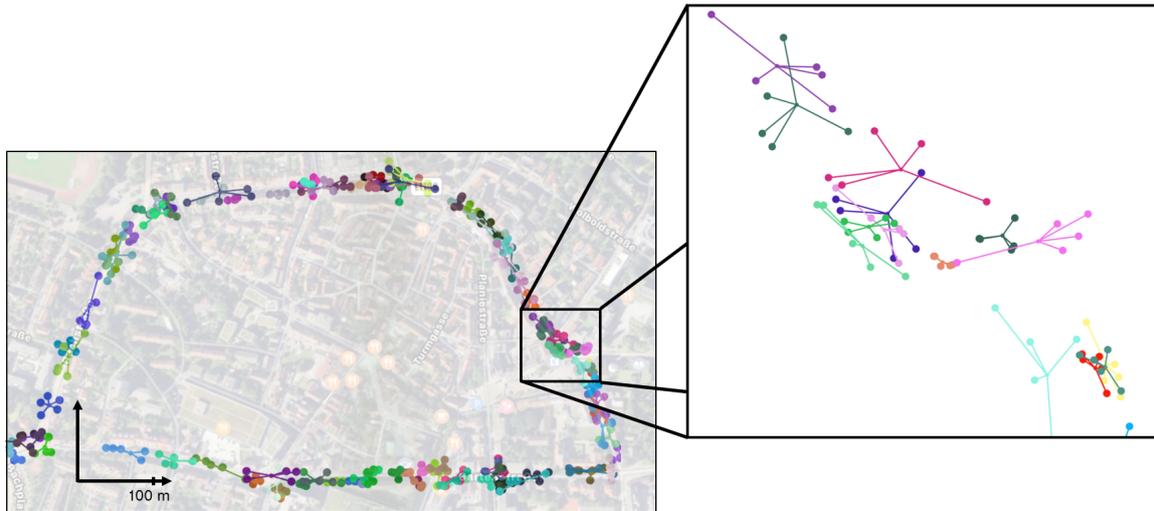


Abb. 7: Eindeutige Konstellationen von Lokalisierungsmerkmalen. Jede eindeutige Konstellation ist eindeutig farblich gekennzeichnet. Lokalisierungsmerkmale, die zu einem eindeutigen Merkmalsmuster gehören, sind durch Kanten mit dem Schwerpunkt der Konstellation verbunden.

5 Zusammenfassung und Ausblick

Die vorliegende Arbeit bietet einen Überblick zu drei neuen Ansätzen zur Sicherstellung integrier Landmarken-basierter Lokalisierung. Im ersten Teil wird die offline Vorprozessierung von Kartenmaterial vorgeschlagen, um mögliche Fehlerquellen schon a priori zu identifizieren. Dazu werden alle vorhandenen Mehrdeutigkeiten in der Geometrie der Landmarkenverteilung extrahiert und analysiert.

In einem zweiten Schritt wird eine neue Datenassoziationsmethode basierend auf Geometric Hashing vorgeschlagen. Dieses Verfahren benötigt keinerlei Information über vorhergehende Fahrzeugposen und ermöglicht eine effiziente und sichere Datenassoziation, welche allein auf der Geometrie der Lokalisierungsmerkmale beruht. Da somit die Prädiktion der Fahrzeugpose anhand früherer Schätzwerte in der Datenassoziation vernachlässigt werden kann, ist eine Fehlerfortpflanzung ausgeschlossen und eine integrale Lokalisierung möglich.

Abschließend wird die Ermittlung von eindeutigen Landmarkenkonstellationen in Karten beschrieben. Mit Hilfe der Informationen über Mehrdeutigkeiten wird bestimmt, welche Landmarkenmuster eine lokale Umgebung eindeutig zuordenbar machen. Dies sind wertvolle Informationen um online Aussagen zur Wahrscheinlichkeit einer Falschassoziation zu treffen, welche in die Berechnung eines Integritätsmaßes einfließen können.

Zukünftige Arbeiten werden sich mit der online Nutzung der bereitgestellten Informationen und einer darauf basierenden Validierung von Landmarkenassoziationen beschäftigen.

Literatur

- [1] PETOVELLO, MARK, S PULLEN, J SYRJARINNE und L WIROLA: *Quantifying the performance of navigation systems and standards for assisted-GNSS*. Inside GNSS, Seiten 20–24, 2008.

- [2] JOERGER, MATHIEU und BORIS PERVAN: *Quantifying Safety of Laser-Based Navigation*. IEEE Transactions on Aerospace and Electronic Systems, 2018.
- [3] LAMDAN, YEHEZKEL und HAIM J WOLFSON: *Geometric hashing: A general and efficient model-based recognition scheme*. 1988.
- [4] KÜMMERLE, J, M SONS, F POGGENHANS, M LAUER und C STILLER: *Accurate and Efficient Self-Localization on Roads using Basic Geometric Primitives*. In: *2019 International Conference on Robotics and Automation (ICRA)*, Seiten 5965–5971. IEEE, 2019.
- [5] SCHREIBER, MARKUS, CARSTEN KNÖPPEL und UWE FRANKE: *Laneloc: Lane marking based localization using highly accurate maps*. In: *IEEE Intelligent Vehicles Symposium (IV)*, Seiten 449–454, 2013.
- [6] POGGENHANS, FABIAN, NIELS OLE SALSCHIEDER und CHRISTOPH STILLER: *Precise Localization in High-Definition Road Maps for Urban Regions*. In: *2018 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS)*, Seiten 2167–2174, 2018.
- [7] ASCANI, ANDREA, EMANUELE FRONTONI, ADRIANO MANCINI und PRIMO ZINGARETTI: *Feature group matching for appearance-based localization*. In: *2008 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS)*, Seiten 3933–3938, 2008.
- [8] SCHLICHTING, ALEXANDER und CLAUS BRENNER: *Localization using automotive laser scanners and local pattern matching*. In: *2014 IEEE Intelligent Vehicles Symposium Proceedings*, Seiten 414–419. IEEE, 2014.
- [9] BRENNER, CLAUS: *Global localization of vehicles using local pole patterns*. In: *Joint Pattern Recognition Symposium*, Seiten 61–70. Springer, 2009.
- [10] RIGOUTSOS, ISIDORE: *Massively parallel Bayesian object recognition*. Technischer Bericht, New York University, Department of Computer Science, 1992.
- [11] HOFSTETTER, ISABELL, MICHAEL SPRUNK, FRANK SCHUSTER, FLORIAN RIES und MARTIN HAUEIS: *On Ambiguities in Feature-Based Vehicle Localization and their A Priori Detection in Maps*. In: *2019 IEEE Intelligent Vehicles Symposium (IV)*, Seiten 1192–1198. IEEE, 2019.
- [12] GOSHTASBY, A ARDESHIR: *Image registration: Principles, tools and methods*. Springer Science & Business Media, 2012.
- [13] GOODRICH, MICHAEL T, JOSEPH SB MITCHELL und MARK W ORLETSKY: *Approximate geometric pattern matching under rigid motions*. IEEE Transactions on Pattern Analysis and Machine Intelligence, 21(4):371–379, 1999.