

Lidarbasierte Fahrstreifen- und Randbebauungserkennung mit Occupancy Grids für Spurhalte- und Spurwechselfunktionen

Florian Homm, Alexander Duda, Nico Kaempchen, Peter Waldmann, Michael Ardel
BMW Group Forschung und Technik
D-80788 Munich, Germany
Email: {Florian.Homm, Nico.Kaempchen, Peter.Wa.Waldmann, Michael.Ardelt}@bmw.de

Zusammenfassung—In diesem Beitrag wird ein Verfahren zur robusten Fahrstreifen- und Randbebauungserkennung in Occupancy Grids vorgestellt. Zur Generierung eines konsistenten Straßenmodells wurde ein neuartiges iteratives Verfahren zur histogrammbasierten Merkmalsextraktion entwickelt. Dieses auf dem Down-Hill Simplex basierende Optimierungsverfahren ermöglicht es, mehrere Fahrstreifen und Randbebauungen simultan in Echtzeit zu erfassen und, im Gegensatz zu anderen Verfahren, gekrümmte Fahrbahnverläufe abzubilden. Das entwickelte Verfahren ist robust gegen Messrauschen und die erreichte Genauigkeit entspricht der eines videobasierten Systems zur Fahrstreifenenerkennung.

I. EINFÜHRUNG

Für die Realisierung von hochautomatisierten Fahrfunktionen, wie zum Beispiel den von der BMW Forschung und Technik GmbH entwickelten Nothalteassistenten [1], muss das Fahrumfeld zu jedem Zeitpunkt zuverlässig wahrgenommen werden. Hierzu zählt die Erkennung anderer Verkehrsteilnehmer, die Erkennung freier befahrbarer Bereiche sowie Informationen über die eigene Position und den Straßenverlauf. Insbesondere der genauen Positionsbestimmung in Bezug auf die Fahrbahn kommt eine enorme Bedeutung zu, um Fahrstrategien sicher ableiten zu können und eine robuste Längs- und Querführung des Fahrzeugs zu gewährleisten. Eine der größten Herausforderungen sind automatisierte Fahrstreifenwechsel. Um diese sicher durchführen zu können, muss sowohl die Position auf dem eigenen Fahrstreifen als auch die Anzahl und Positionen der benachbarten Fahrstreifen verfügbar sein. Eine Möglichkeit zur Lokalisation besteht in der Verwendung einer videobasierten Fahrstreifenenerkennung, die die Querablage des Fahrzeuges im Fahrstreifen sowie die Fahrbahnkrümmung anhand eines Videobildes bestimmt. Ein Vorteil von Lidar-Sensorik gegenüber der Bildverarbeitung besteht in ihrem wesentlich größeren horizontalen Sichtbereich zur simultanen Erfassung benachbarter Fahrstreifen und der Unempfindlichkeit bei Lichtschwankungen. Zusätzlich ist es möglich, relevante Fahrbahnbegrenzungen, wie zum Beispiel Leitplanken und Tunnelwände, zuverlässig zu detektieren und als Landmarken zur Eigenlokalisierung zu verwenden.

In diesem Beitrag wird ein Verfahren zur robusten Fahrstreifen- und Randbebauungserkennung in Occupancy Grids vorgestellt. Zur Generierung eines konsistenten Straßenmodells wird ein neuartiges iteratives Verfahren zur histogrammbasierten Merkmalsextraktion vorgestellt. Dieses auf dem Down-Hill Simplex basierende Optimierungsverfahren ermöglicht es, mehrerer Fahrstreifen und Randbebauungen

simultan in Echtzeit zu erfassen und, im Gegensatz zu anderen Verfahren, gekrümmte Fahrbahnverläufe abzubilden. Das entwickelte Verfahren ist robust gegen Messrauschen und die erreichte Genauigkeit entspricht der eines videobasierten Systems zur Fahrstreifenenerkennung.

II. EINFÜHRUNG IN DIE GRIDBASIERTE FAHRUMFELDERFASSUNG : OCCUPANCY GRIDS

Abstrakte und vereinfachte Modelle des Fahrumfeldes bilden die Grundlage für eine Vielzahl von Verarbeitungsschritten in der Umgebungswahrnehmung mit umfelderfassender Sensorik. Nach [2] kann grundlegend zwischen zwei Repräsentationen unterschieden werden: *feature-based* (merkmalsbasiert) und *location-based* (ortsbezogen). Bei der merkmalsbasierten Repräsentation werden die Messwerte definierten Objekten zugewiesen. Die Indizierung erfolgt über eine Objekt-ID. Die merkmalsbasierte Repräsentation eignet sich insbesondere dann, wenn die Form und Ausprägung der Objekte leicht durch geometrische Primitive (Geraden, Kreise) approximiert werden kann. Für die Beschreibung beliebiger statischer Objekte ist sie jedoch eher ungeeignet, da deren Form und Ausprägung äußerst komplex sein kann. Im Kontrast hierzu steht die gridbasierte Repräsentation, die zur Klasse der ortsbezogenen Modelle zählt. Bei der gridbasierten Repräsentation des Fahrumfeldes werden keine Annahmen über die strukturellen Zusammenhänge der einzelnen Messwerte getroffen. Jeder Messwert eines Messzyklus wird ausschließlich entsprechend seiner gemessenen räumlichen Position gespeichert. Zu den bekanntesten gridbasierten Repräsentationen gehört das von Elfes [3] vorgestellte Occupancy Grid Framework zur Modellierung von zeitlich aufeinanderfolgenden unsicheren Messungen. Dazu wird unter Berücksichtigung der Eigenbewegung und der aktuellen Sensormessungen über die Zeit die Belegungswahrscheinlichkeit der einzelnen Zellen eines $n \times m$ großen Grids berechnet. Occupancy Grids eignen sich deshalb besonders zur Modellierung von räumlich komplexen Objekten, die über der Zeit keine Positionsveränderung erfahren (statische Objekte) [2]. Im Gegensatz zu klassischen Objektverfolgungsansätzen, enthalten sie nicht nur Informationen über die Anwesenheit von Objekten, sondern auch über die Abwesenheit (Freiraum).

Sei m ein planares Occupancy Grid. Eine einzelne Zelle wird als $m_{x,y}$ und die Messwerte aller Messzyklen bis zum Zeitpunkt t werden als $z_{1:t}$ bezeichnet. Jede Zelle enthält einen Wert von $0 \dots 1$, der die Belegungswahrscheinlichkeit

der Zelle angibt. Die Notation $p(m_{x,y})$ bedeutet, dass eine Zelle *belegt* ist. Ziel ist es, die Belegungswahrscheinlichkeiten des Occupancy Grids zum Zeitpunkt t in Abhängigkeit aller vergangener Messwerte zu bestimmen:

$$p(m|z_1, \dots, z_t) \quad (1)$$

Da diese *a-posteriori* Wahrscheinlichkeit für m in annehmbarer Zeit nicht berechnet werden kann, wird zur Vereinfachung angenommen, dass die einzelnen Zellen eines Grids unabhängig voneinander sind:

$$p(m_{x,y}|z_{1:t}) \quad (2)$$

Nach der Umformung von Gleichung 2 in die so genannte *odds form*,

$$p(m_{x,y}|z_{1:t}) = \frac{p(m_{x,y}|z_{1:t})}{1 - p(m_{x,y}|z_{1:t})} \quad (3)$$

der Anwendung des Satz von Bayes und weiteren Umformungen ergibt sich als *a-posteriori* Belegung für eine Zelle $m_{x,y}$:

$$\frac{p(m_{x,y}|z_{1:t})}{1 - p(m_{x,y}|z_{1:t})} = \frac{p(m_{x,y}|z_t)}{1 - p(m_{x,y}|z_t)} \cdot \frac{p(m_{x,y}|z_{1:t-1})}{1 - p(m_{x,y}|z_{1:t-1})} \quad (4)$$

Die *a-posteriori* Wahrscheinlichkeit $p(m_{x,y})$ für die Belegung einer Zelle ergibt sich somit aus der Multiplikation der a-priori Wahrscheinlichkeit $p(m_{x,y}|z_{1:t-1})$ mit der Wahrscheinlichkeit für die Belegung in Abhängigkeit der aktuellen Messung $p(m_{x,y}|z_t)$. Für eine vollständige Herleitung sei der Leser auf [4] verwiesen. Das in dieser Arbeit verwendete Occupancy Grid basiert wie das unter [5] vorgestellte Verfahren auf einem ortsfesten Occupancy Grid. Die einzelnen Distanzmessungen des Laserscanners werden mit einem *inversen* Sensormodell [2] in einem temporären Grid m_t akkumuliert und anschließend unter Verwendung des binären Bayes Filters (Gleichung 4) mit $m_{1:t-1}$ zu m fusioniert.

Eine Besonderheit des hier verwendeten für automotiv Applikationen entwickelten mehrzeiligen Laserscanners ist die Fähigkeit, in einem Vorverarbeitungsschritt eine Klassifikation zwischen sogenannten *Objekt-* und *Bodenpunkten* durchzuführen. Jeder einzelne Messwert kann somit einer dieser beiden Klassen zugeordnet werden, wobei die Objektklasse mit großer Wahrscheinlichkeit Punkte von erhabenen Objekten und die Bodenklasse Punkte von Objekten enthält, die direkt zu der Bodenebene zu zählen sind oder dieser sehr nahe sind. Als Beispiel für die Bodenebene zu nennen sind: Asphalt (mit Straßenmarkierungen) und Gras. Eine Sonderstellung hierbei nehmen Abgrenzungen wie zum Beispiel Bordsteine ein, die Aufgrund ihrer erhabenen Ausprägung auch der Klasse Objekt zugeordnet werden könnten, jedoch durch ihre Materialeigenschaften und damit verbundenen Reflektivität in einem Klassifikationsschritt eher der Bodenebene zugeordnet sind. Im Folgenden wird eine Trennung der beiden Objektklassen auf zwei unterschiedliche Occupancy Grids vorgenommen, die als Basis für die in den Abschnitten III und IV vorgestellten

Algorithmen zur Parameterextraktion dienen. Das Occupancy Grid mit Messwerten aus der Objektklasse wird im nachfolgenden als mO , das Occupancy Grid mit Messwerten aus der Bodenklasse als mG bezeichnet. Abbildung 1(a) zeigt als Beispiel ein OccupancyGrid mO mit akkumulierten Messwerten der Objektklasse. Abbildung 1(b) zeigt das OccupancyGrid mG mit akkumulierten Punkten der Bodenklasse.

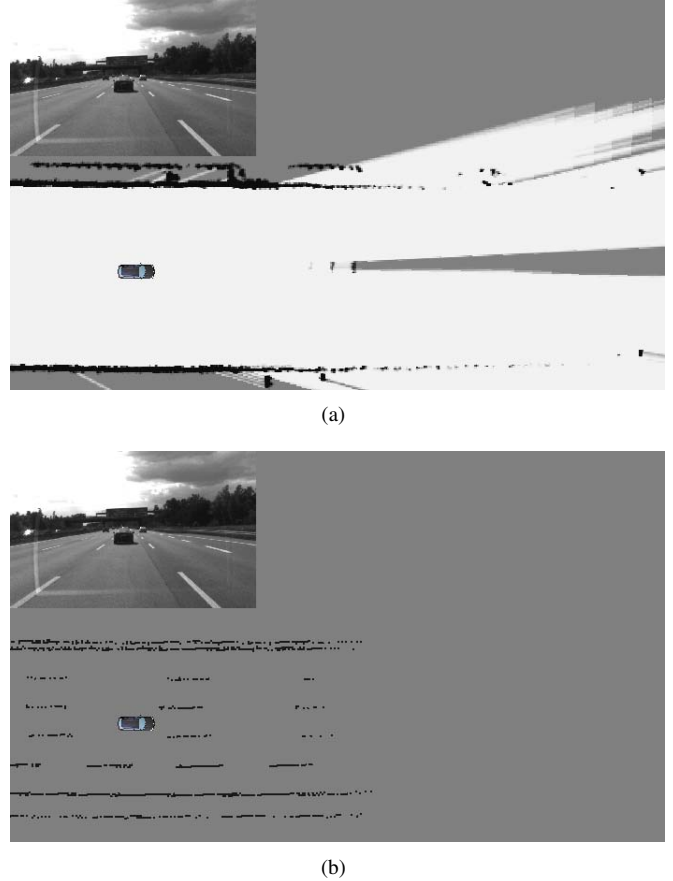


Abbildung 1. In Bild (a), ein Beispiel für ein Occupancy Grid in einem Autobahnszenario. In Bild (b), das korrespondierende Occupancy Grid mG .

In dem folgenden Abschnitt III, wird zuerst auf die Extraktion der Fahrstreifen aus der Bodenkarte mG eingegangen. In Abschnitt IV erfolgt die Erweiterung des entwickelten Verfahrens auf das Occupancy Grid mit Messwerten aus der Objektebene mO zur Erkennung von Fahrbahnbegrenzungen.

III. LIDAR BASIERTE FAHRSTREIFENERKENNUNG

Die automatische Erkennung von longitudinalen Fahrbahnmarkierungen bildet die Grundlage für eine Vielzahl von aktuellen und zukünftigen Fahrerassistenzsystemen. Bei der Bestimmung der Fahrzeugposition mit Bezug auf die Fahrbahn kommt ihnen eine entscheidende Rolle zu. Sie enthalten Informationen über den Fahrbahnverlauf, befahrbare Flächen und bilden im Zusammenhang die überaus wichtige Information über die sogenannten Fahrstreifen. Sie eignen sich daher insbesondere, um Informationen über die Position

und Fahrzeugausrichtung innerhalb der Fahrstreifen und deren Anzahl abzuleiten.

Dementsprechend zahlreich sind die bekannten Arbeiten, die sich mit ihrer Erkennung beschäftigen. Der am häufigsten verwendete Sensor zu Detektion von Fahrbahnmarkierungen ist die Videokamera. Ein kurzer Überblick kann in [6] gefunden werden. Erste Systeme befinden sich bereits im Serieneinsatz.

Im Gegensatz zur videobasierten Detektion, die auf dem Kontrastunterschied zwischen Fahrbahnbelag und Fahrbahnmarkierung im sichtbaren Spektrum basiert, machen sich Laserscanner basierte Ansätze die retroreflektiven Eigenschaften von Fahrbahnmarkierungen zu nutzen. Um die Sichtbarkeit von Fahrbahnmarkierungen bei Nacht zu verbessern, werden die für Straßenmarkierungen verwendeten Materialien mit Zusätzen versehen, die die Retroreflektivität von einfallendem Scheinwerferlicht erhöhen. Bei permanenten Fahrbahnmarkierungen wird dies durch die Einbettung von sogenannten Glasperlen erreicht, die in Kombination mit der Farbe der Markierungen einen Spiegel bilden (Abbildung 2). Analog




Abbildung 2. Retroreflektion durch Einbettung von Glasperlen. E einfallendes Licht, R retroreflektiertes Licht, F Lichteintrittsfenster. [7]

gilt dieses Prinzip für das Laserlicht, welches im Vergleich zu gewöhnlichem Straßenbelag mit einer größeren Intensität zurückgestrahlt wird. Betrachtet man den Fahrbahnbelag als Störsignal und die Fahrbahnmarkierungen als Nutzsinal, entsteht ein SNR (Signal-zu-Rausch-Verhältnis) welches von modernen Laserscannern detektiert werden kann. Als relevante Arbeiten zur Fahrstreifenenerkennung mit Laserscannern zu nennen sind [8], [9], [10], [11]. Keines dieser Verfahren ermöglicht es jedoch, simultan mehrere Fahrstreifen mit Krümmung zu erfassen. Anders als in [10], [9], ist bei dem hier vorgestellten Verfahren keine direkte Modifikation des Laserscanners zur Erkennung von Fahrbahnmarkierungen notwendig. Zur Detektion der Markierungen wird lediglich die unterste Mess-Ebene des Scanners verwendet. Durch die ausgenutzte Mehrzielfähigkeit des Scanners entstehen so in einer Entfernung von 24-28 m die abgetasteten Bodenmessungen für das Occupancy Grid mG .

Im folgenden Teilabschnitt III-A wird zuerst das zur Beschreibung der Straße und Fahrstreifen verwendete Straßenmodell vorgestellt. Anschließend erfolgt in Teilabschnitt III-B die histogrammbasierte Extraktion der unter III-A spezifizierten Parameter aus der Bodenkarte mG . Teilabschnitt III-C beschäftigt sich mit der Klassifikation der einzelnen Fahrbahn-

markierungen und der Erzeugung eines konsistenten Straßenmodells.

A. Straßenmodell

Die Aufgabe des Straßenmodells ist es, die in einem Fahrumfeld vorhandenen Fahrstreifen mit einem parametrischen Modell eindeutig zu beschreiben. Die Komplexität dieses Modells und die Anzahl der Parameter kann sich je nach Anforderung erheblich unterscheiden und es ist in der Regel notwendig, einen geeigneten Kompromiss zwischen der Anzahl der Parameter und den Modellierungsfehlern der gewählten Repräsentation zu finden. Eine Übersicht über geeignete Straßenmodelle ist in [12] zu finden.

Das in dieser Arbeit verwendete Modell basiert auf dem in [9] vorgestellten Fahrstreifenmodell. In diesem Modell wird jeder Fahrstreifen durch einen Kreisbogen approximiert und durch den Zustandsvektor (Gleichung 5) mit den vier Parametern Krümmung c , Fahrstreifenbreite b , laterale Ablage y und Ausrichtung γ relativ zum Fahrzeug beschrieben. Die Modellierungsfehler des Straßenverlaufs bei konstanten Krümmungsänderungen (Klothoiden Segmente) als Kreisbogen können vernachlässigt werden, da dieser in der für die Bodenerkennung relevanten Distanz unterhalb des Messrauschens liegt. Die einzelnen modellierten Fahrstreifen (Gleichung 5) einer Straße bilden anschließend zusammen das Straßenmodell (Gleichung 6).

$$f_i = [c_i \ \gamma_i \ y_i \ b_i]^T \quad (5)$$

$$S = \{f_1, \dots, f_m\} \quad (6)$$

B. Histogrammbasierte Parameterextraktion

Ziel der Parameterextraktion ist es, alle in einem Occupancy Grid enthaltenen Fahrstreifen f_i zu bestimmen und ein konsistentes Straßenmodell S zu erzeugen. Sei

$$\mathbb{P}_S = \{f_0, \dots, f_i, \dots, f_n\} \quad (7)$$

die Menge aller möglicher Kombinationen von Fahrstreifen, dann existiert eine Teilmenge $S \subset \mathbb{P}_S$ die alle in einem Occupancy Grid mG vorhandenen Fahrstreifen enthält. Das bestimmen der Teilmenge S ist keinesfalls trivial und um den Suchraum einzugrenzen, wird zuerst die Annahme getroffen, dass die Krümmung und Ausrichtung aller in mG enthaltener Fahrstreifen identisch ist.

$$c_i = c_k = \dots = \bar{c} \quad (8)$$

$$\gamma_i = \gamma_k = \dots = \bar{\gamma} \quad (9)$$

Diese Annahme setzt implizit parallel überlappungsfreie Fahrstreifen voraus und entspricht einer autobahnähnlichen Straße ohne die Berücksichtigung von Abzweigungen (Abbildung 3). Die für S zu bestimmenden Parameter reduzieren sich somit auf die allgemeine Krümmung der Straße \bar{c} , die relative Fahrzeugausrichtung $\bar{\gamma}$, die jeweilige Ablage y_i und die Breite für jeden Fahrstreifen b_i (Gleichung 10 und 11).

$$\bar{f}_i = [\bar{c} \ \bar{\gamma} \ y_i \ b_i]^T \quad (10)$$

$$S = \{\bar{f}_1, \dots, \bar{f}_n\} \quad (11)$$




Abbildung 3. Beispiel für ein Straßenmodell mit zwei Fahrstreifen, Ausrichtung γ , Krümmung c , Ablagen y_{off1}, y_{off2} und Breite der Fahrstreifen b_1, b_2 .

Um nun die gesuchten Parameter aus mG zu extrahieren, wird S in eine Histogrammdarstellung überführt, bei der jede mögliche Variation von \bar{c} und $\bar{\gamma}$ genau ein einzelnes Histogramm H_i definiert. Jeder Klasse $k(b, c, \alpha)$ eines Histogramms H_i , sind dabei alle Wahrscheinlichkeiten $p(x, y)$ aus mG zugeordnet, die sich auf einem Kreisbogen K_r mit der Krümmung c befinden, der eine Gerade $g(\alpha, x, x_0, y_0)$ senkrecht in einem Abstand b zur Fahrzeugposition schneidet (Abbildung 4). Die Gerade g beschreibt dabei eine Gerade in mG unter Berücksichtigung der Eigenfahrzeugposition (x_0 und y_0) mit der Steigung $\alpha = \gamma + \frac{\pi}{2}$.

$$k(b, c, \alpha) = \sum_{x=-j}^l f(b, x, c, \alpha) \quad (12)$$

Als Beispiel, gilt $\bar{c} = \bar{\gamma} = 0$, entspricht dies einer zeilen- oder spaltenweisen Histogrammbildung. Ein Histogramm H_i wird nun als *optimales* Histogramm H_{opt} bezeichnet, wenn keine weitere Parameterkombination von \bar{c} und $\bar{\gamma}$ existiert, die eine bessere Approximation der in mG enthaltenen Krümmung und Ausrichtung darstellt. Abbildung 5(a) zeigt als Beispiel das zur Bodenkarte aus Abbildung 4 korrespondierende Histogramm H_{opt} . In diesem Beispiel wird \bar{c} und $\bar{\gamma}$ als bekannt vorausgesetzt. Da diese Parameter jedoch nicht bekannt sind, ist eine direkte Bestimmung von H_{opt} nicht möglich. Werden die Parameter des optimalen Histogramms nun variiert, degeneriert das Histogramm mit zunehmender Abweichung hin zu einer Gleichverteilung. Abbildung 5(b) und 5(c) zeigen als Beispiel die Auswirkung auf H_{opt} bei einer Abweichung von der optimalen Krümmung. Analog gilt dieses für eine Abweichung in der Ausrichtung $\bar{\gamma}$. Der Grund für diese Degeneration ist, dass bei einer Straße alle




Abbildung 4. Bodenkarte mit einem Beispiel für einen Kreisbogen K_r (gelb) senkrecht zu der Geraden g (weiß). Die zugehörige Klasse im Histogramm k_i ist eindeutig durch den Abstand b bestimmt.




Abbildung 5. In (a), das optimale Histogramm H_{opt} mit $c = -0.00076$ m. In (b), ein additiver Fehler von 0.002 m. In (c), 0.006 m.

Fahrbahnmarkierungen in Richtung der Fahrbahn ausgerichtet sind und bei einem Fehler in der Krümmung oder Ausrichtung die Wahrscheinlichkeiten $p(x, y)$ auf mehrere Klassen verteilt werden. Dies kann ausgenutzt werden, um eine Gütefunktion $q(H_i)$ zu definieren. Beim einem optimalen Histogramm sind definitionsgemäß die Wahrscheinlichkeiten der Fahrbahnmarkierungen möglichst wenigen Klassen zugewiesen. Daher ist es möglich, die Gütefunktion $q(H_i)$ durch die Summe der Quadrate der Klassen k zu beschreiben (Gleichung 13). Ein Histogramm wird besonderes gut bewertet, wenn sich die Wahrscheinlichkeiten aus mG auf möglichst wenige Klassen in H_i verteilen.

$$q(H_i) = \sum_{b=-d}^d k(b, c_i, \alpha_i)^2 \quad (13)$$

Abbildung 6 zeigt die exemplarische Auswertung der Kostenfunktion $q(H_i)$ für verschiedene Kombinationen von Krümmungen und Ausrichtungen. Es ist deutlich ersichtlich, dass ein eindeutiges Maximum $q(H_{opt})$ existiert. Durch die Gütefunktion $q(H_i)$ ist es nun möglich, die einzelnen Histogramme relativ zueinander zu bewerten. Dabei besitzt das




Abbildung 6. Ergebnis für die Auswertung von $q(H_i)$ für $\gamma = -4^\circ \dots 4^\circ$ und $c = -0.0001 \dots 0.0001m$.

optimale Histogramm das größte Gütemaß und alle anderen entsprechend ihrer Parameter geringere Werte. Ziel ist es, das Maximum dieser Zielfunktion zu bestimmen, ohne alle Histogramme beziehungsweise deren zugehöriges Gütemaß berechnen zu müssen. Eine Besonderheit ist, dass sich die Lage des Maximums in der Zielfunktion kontinuierlich über der Zeit verändert, da die Lage des Maximums durch den Winkel α und die Krümmung c der Straße vorgegeben wird, auf der die Messung durchgeführt wird. Da diese beiden Parameter sich bei einer autobahnähnlichen Straße kontinuierlich über den Weg und damit auch die Zeit verändern, ist die Positionsveränderung des Maximums in der Funktion kontinuierlich.

1) *Down-Hill-Simplex Optimierung von Krümmung und Ausrichtung:* Für die Suche nach dem Maximum der Funktion q wird das iterative Down-Hill-Simplex Verfahren verwendet. Das Verfahren verwendet für einen n dimensional Parameterraum ein Simplex mit $n + 1$ Ecken, um über geschickte Transformationen von diesem Simplex das Maximum zu finden. Es gehört zu den ableitungsfreien Methoden zur Optimierung nichtlinearer Funktionen von mehreren Parametern und eignet sich deshalb und wegen seiner Robustheit gegenüber kleinen lokalen Maxima, um die durch die Gütefunktion (Gleichung 13) berechnete nichtlineare Zielfunktion zu maximieren. Dabei ist es von großem Vorteil, dass die Ableitung der Zielfunktion, die nur sehr aufwendig über den Differentialquotienten berechnet werden kann, nicht benötigt wird. Bei der Suche nach dem optimalen Histogramm besteht der Parameterraum aus den zwei Parametern \bar{c} und $\bar{\gamma}$. Das Simplex beschreibt somit ein Dreieck, dessen Ecken jeweils für ein berechnetes Gütemaß eines Histogramms stehen. Es existieren zahlreiche Varianten des Down-Hill-Simplex Verfahrens, die je nach zu lösendem Problem unterschiedliche Ausprägungen der einzelnen Berechnungsschritte aufweisen.

Das verwendete Optimierungsverfahren basiert im grundlegenden auf dem in [13] vorgestellten Nelder-Mead Algorithmus. Zu Beginn werden für die Krümmung und die Ausrichtung geeignete Startparameter festgelegt und anschließend die benötigte Anzahl an Simplex-Iterationen ausgeführt,

bis ein Abbruchkriterium erfüllt ist. Um die Laufzeit des Algorithmus zu verbessern und die vorher definierten Kriterien über die konstante Änderung von Krümmung und Ausrichtung in Betracht zu ziehen, werden nach der Initialisierungsphase lediglich so viele Iterationen ausgeführt, bis die maximale zu erwartende Änderung der Krümmung und Ausrichtung berücksichtigt wurde. Die relativ aufwendige Berechnung der einzelnen Histogramme H_i , kann so auf ein Minimum reduziert werden.

2) *Extraktion möglicher Fahrbahnmarkierungen:* Aus dem optimalen Histogramm H_{opt} , dessen Parameter mit Hilfe der Down-Hill-Simplex Verfahrens gefunden wurden, ist es nun möglich, diejenigen Stellen im Histogramm zu identifizieren, an denen prinzipiell eine Fahrbahnmarkierung vorliegen kann. Eine Auswertung über einen festen Schwellwert über die Klassen k ist hierbei aufgrund von möglichen Störeinflüsse in mG nicht ausreichend (Abbildung 7). Eine Möglichkeit besteht




Abbildung 7. Beispiel für eine Bodenkarte mG mit 3 Fahrstreifen und additiven Störgrößen auf dem linken Fahrstreifen.

in der Verwendung des Signal-Rausch-Verhältnisses, um jede Klasse k_i unter Betrachtung der lokalen Nachbarschaft in H_i zu bewerten. Für die Berechnung des SNR wird sowohl die Nutz- als auch die Rauschleistung benötigt, welche als Quadrat der Klasse $k_i(b_i, c_n, \alpha_n)$, für den das SNR bestimmt werden soll, und als Quadrat des minimalen Wertes einer Klasse $k_j(b_j, c_n, \alpha_n)$ in einer Umgebung u um $k_i(b_i, c_n, \alpha_n)$ definiert werden können. Die Bestimmung des SNR entspricht einer dynamische Schwellwertanpassung auf die verschiedenen Bereiche des Histogramms und kompensiert das innerhalb von mG unterschiedlich starke Auftreten von Störgrößen. Jede Klasse $k_i(b_i, c_n, \alpha_n)$, dessen Signal Rausch Verhältnis einen festen Schwellwert übersteigt, wird anschließend als mögliche Position einer Fahrbahnmarkierung angesehen und dessen Index im Histogramm ausgewählt. In Abbildung 8 sind diese Positionen exemplarisch mit einem maximalen Abstand von ± 10 m zur Eigenposition des Fahrzeuges im Histogramm gelb dargestellt. Ein weiterer Vorteil des histogrammbasierten Signal-Rausch-Verhältnisses ist, dass einzelne Fahrstreifen bezüglich ihrer Güte direkt bewertet werden können. Dies ist insbesondere dann von Nutzen, wenn zuverlässige Informationen über das Vertrauen in die Fahrstreifenenerkennung benötigt werden.




Abbildung 8. Korrespondierendes Histogramm zur Bodenkarte aus Abbildung 7. In gelb, mögliche Positionen von Fahrbahnmarkierungen bis zu einem lateralen Abstand von ± 10 m zum Eigenfahrzeug.

3) *Subpixelauflösung*: Die markierten Positionen in H_{opt} , und die damit verbundenen Ablagen y , besitzen in erster Näherung eine Genauigkeit entsprechend der Zellgröße des Occupancy Grids mG . Die hier beispielhaft verwendete Auflösung entspricht 0.25 m für eine Zelle. Eine feinere Zellauflösung würde zwar die Genauigkeit von y erhöhen, jedoch auch den Berechnungsaufwand zur Histogrammbildung unnötig vergrößern. Unter der Annahme, dass die akkumulierten Messungen in mG einem lokalen Messrauschen unterliegen, das durch eine Gaußverteilung beschrieben ist, kann die Genauigkeit der Ablage y durch Interpolation zwischen k_i , k_{i-1} und k_{i+1} deutlich verbessert werden. Dies folgt der direkten Annahme, dass auch H_i als Histogrammdarstellung von mG einer Gaußverteilung unterliegt. Als geeignete Approximation der Gaußverteilung bietet sich die Interpolation mit einem Polynom zweiten Grades an, welche es ermöglicht, die Auflösung der Ablage um den Faktor 2-3 im Vergleich zur direkten Zellengröße zu verbessern.

C. Fahrstreifenklassifikation

Nachdem in Teilabschnitt III-B die Krümmung der Straße, die relative Ablage der Straße zum Fahrzeug und die Positionen aller möglicher Fahrbahnmarkierungen bestimmt wurde, ist es möglich, ein konsistentes Straßenmodell zu erzeugen. Hierfür ist es zuerst notwendig, alle Indices von k_i zu bestimmen, die eine gültige Fahrbahnmarkierung repräsentieren. Sind diese identifiziert, ist es möglich, aus ihnen die einzelnen Fahrstreifen abzuleiten. Da Fahrstreifen gewissen baulichen Anforderungen unterliegen, wie zum Beispiel der Anforderung an eine minimale oder maximale Fahrstreifenbreite, kann die Menge gültiger Kombinationen von Fahrbahnmarkierungen zu Fahrstreifen erheblich eingeschränkt werden. Zusätzlich lässt sich ausnutzen, dass befahrbare Bereiche der Straße anhand von durchgezogenen Fahrbahnmarkierungen von nicht befahrbaren Bereichen abgegrenzt werden müssen. Diese Konvention wird ausgenutzt, um die detektierten Fahrstreifen zu plausibilisieren und eine Straße zu generieren. Für diese Plausibilisierung wird eine Klassifizierung der Fahrstreifenmarkierungen in „gestrichelt“, beziehungsweise „durchgezogen“, vorgenommen. Die Wahrscheinlichkeiten $p(x, y)$, die der Klasse

$k_i(b_i, c_n, \alpha_n)$ zugeordnet wurden, werden dazu als Funktion über ihrer Position auf dem Kreisbogen K_r in mG interpretiert. Diese Funktion entspricht einem diskreten, krümmungsfreien und ausrichtungsneutralen Signal S der in k_i abgebildeten Fahrbahnmarkierung. Das so erhaltene Signal S stimmt im idealen Fall mit dem einer Rechteckfunktion überein, wobei die Periode bei einer „gestrichelten“ Fahrbahnmarkierung in etwa der doppelten Markierungslänge entspricht und bei einer „durchgezogenen“ Fahrbahnmarkierung den Wert unendlich annimmt. Durch die Autokorrelation des Signals mit sich selbst, kann diese Periode berechnet und eine Klassifikation durchgeführt werden. Da diese Berechnung jedoch aufwendiger ist, als die Berechnung des Autoleistungsspektrums, wird anstelle der Autokorrelation das Autoleistungsspektrum verwendet, welches sich aus dem Quadrat des Betrages der Fourierspektren ergibt (Gleichung 15). Anhand der Analyse der vorkommenden Frequenzanteile kann entschieden werden, welcher Typ von Fahrbahnmarkierung vorliegt.

$$F(\omega_n) = \sum_{k=1}^N e^{-i\omega_n t_k} f(t_k) \quad (14)$$

$$S_{xx}(\omega_n) = |F(\omega_n)|^2 \quad (15)$$

Mit dem vorliegenden Klassifikationsergebnis für die einzelnen Fahrbahnmarkierungen und den vorher getroffenen Annahmen über gültige Fahrstreifen, kann die Ablage zu jeder gültigen Fahrbahnmarkierung und die Anzahl an Fahrstreifen bestimmt werden. Abbildung 9 zeigt als Beispiel ein aus einer Bodenkarte abgeleitetes Straßenmodell mit drei gültigen Fahrstreifen.




Abbildung 9. Aus der Bodenkarte abgeleitetes Straßenmodell mit drei gültigen Fahrstreifen. Jeweils zwei Fahrbahnmarkierungen wurden als „gestrichelt“, beziehungsweise „durchgezogen“ klassifiziert.

D. Evaluierung

In diesem Abschnitt wird die vorgestellte histogrammbasierte Erkennung von Fahrstreifen betreffend der benötigten Rechenzeit und die erzielte Genauigkeit im Vergleich zu einem kommerziellen System zu videobasierten Fahrstreifenenerkennung untersucht.

1) *Laufzeit*: Das in der Evaluierung verwendete Occupancy Grid mG besitzt eine Größe von 256×256 mit einer Zellauflösung von 0.25 m. Die benötigte Zeit zum Erstellen der Histogramme, die iterativen Optimierung der Parameter für Krümmung und Ausrichtung, die Extraktion und

Klassifikation der einzelnen Fahrbahnmarkierungen aus dem Histogramm H_{opt} beträgt 5-8 ms auf einem Testsystem mit einem Intel®Core2™ Quad Prozessor mit 2.5 Ghz. Eine Parallelisierung bei der Berechnung der einzelnen Histogramme H_i wurde nicht vorgenommen.

2) *Vergleich videobasierte Fahrstreifenenerkennung*: Im Folgenden wird die Genauigkeit der lidarbasierten Fahrstreifenenerkennung im Vergleich zu einem kommerziellen System zur videobasierten Fahrstreifenenerkennung untersucht. Da dieses System lediglich die Parameter Krümmung, Ablage und Fahrstreifenbreite für den eigenen Fahrstreifen berechnet, wird auf die Bewertung angrenzender benachbarter Fahrstreifen verzichtet.

In den Abbildungen 10 - 12 sind die Ergebnisse dargestellt, die während eines dynamischen Fahrmanövers innerhalb des eigenen Fahrstreifens bei einer konstanten Geschwindigkeit von $v = 70\text{km/h}$ und einer Sinusfrequenz von $f = 0.37\text{Hz}$ ermittelt wurden. Abbildung 10 zeigt die ermittelte Ausrichtung γ im Vergleich zu dem videobasierten System. Zusätzlich wurde die Ausrichtung mit einem hochgenauen Inertialsystem bestimmt, welches als Referenz dient. Abbildung 11 zeigt die ermittelte Fahrstreifenbreite im Vergleich zur videobasierten Fahrstreifenenerkennung. Es ist zu erkennen, dass sowohl das videobasierte als auch das lidarbasierte Verfahren von der eigentlichen Fahrstreifenbreite abweicht. Dieses liegt daran, dass bei dem videobasierten System der Übergang zwischen Fahrbahnmarkierung und Fahrbahnbelag als Referenzpunkt dient. Das lidarbasierte Verfahren verwendet, bedingt durch die histogrammbasierte Parameterextraktion, die Mitte der Fahrbahnmarkierungen. Abbildung 12 zeigt die ermittelte Krümmung c im Vergleich zu dem videobasierten System.

Die in 10 - 12 ermittelte Güte der Parameter entspricht der des videobasierten Systems zur Fahrstreifenenerkennung. Das vorgestellte Verfahren eignet sich daher insbesondere um eine videobasierte Positionierung auf der Fahrbahn sinnvoll zu ergänzen und eine Redundanz zu schaffen.

IV. HISTOGRAMMBASIERTE ERKENNUNG VON RANDBEBAUUNGEN

Ein weiteres zu detektierendes Merkmal, das Informationen über den Verlauf der Straße und die relative Position des eigenen Fahrzeugs beinhaltet, sind kontinuierliche Fahrbahnbegrenzungen wie zum Beispiel Betonabweiser, Leiplanken und Tunnelwände. Im Gegensatz zu Fahrbahnmarkierungen, lassen sich aus ihnen jedoch keine direkten Informationen über die relative Position des Fahrzeuges mit Bezug zu den einzelnen Fahrstreifen ableiten, da weder die Breite der Fahrstreifen noch deren Abstand zur Randbebauung als gegeben vorausgesetzt werden kann. Kann jedoch ihre Ablage zu den einzelnen Fahrstreifen, durch zum Beispiel Beobachtung, geschätzt werden, oder kann sie als gegeben vorausgesetzt werden [14], ist ihre Erkennung durchaus sinnvoll.

Im Folgenden wird kurz auf die Erweiterung der histogrammbasierten Merkmalsextraktion zur Erkennung von Randbebauungen eingegangen, die im Wesentlichen auf denen in III vorgestellten Algorithmen basiert.

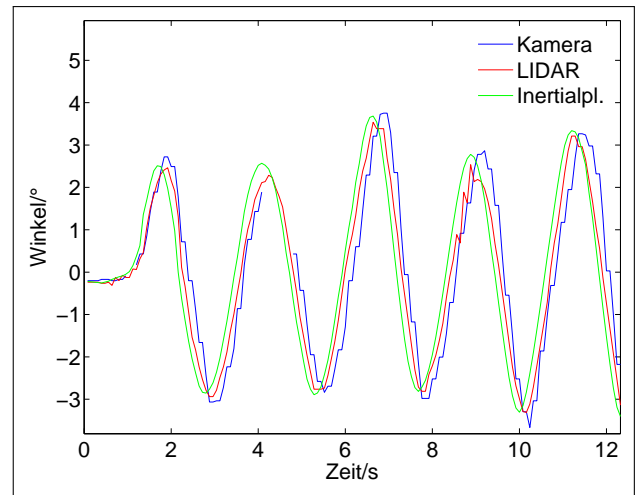


Abbildung 10. Ausrichtung des Fahrzeugs innerhalb des eigenen Fahrstreifens. In dem Diagramm ist die durch die lidar- und videobasierte Fahrstreifenenerkennung gemessene Ausrichtung $\gamma_{\alpha_{mL}}$ und α_{mV} über die Zeit dargestellt. Zusätzlich ist die Ausrichtung β_{mI} , die mit einer hochgenauen Inertialplattform ermittelt wurde, eingezeichnet.

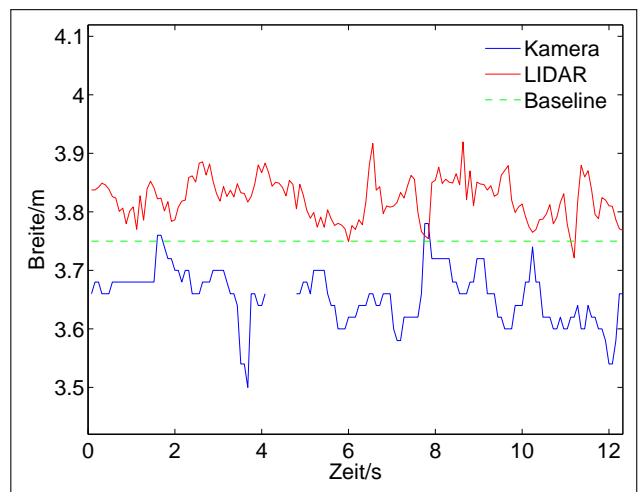


Abbildung 11. Das Diagramm zeigt die durch die lidar- und videobasierte Fahrstreifenenerkennung gemessenen Fahrstreifenbreiten b_{mL} und b_{mV} . Zusätzlich ist die korrekte Fahrstreifenbreite als Baseline in grün eingezeichnet.

Zur geeigneten Beschreibung von Randbebauungen wird das Modell aus III-A erweitert, da die unter Gleichung 8 getroffenen Annahmen über eine einheitliche Krümmung und Ausrichtung der Straße für die Randbebauungen nur begrenzte Gültigkeit besitzen. Im Folgenden wird angenommen, dass sich die Krümmung und relative Ausrichtung der Randbebauungen zum Fahrzeug unterscheiden können.

$$\bar{r}_i = [\bar{c} \quad \bar{\gamma} \quad y_i \quad b_i]^T \quad (16)$$

$$\tilde{r}_j = [\tilde{c} \quad \tilde{\gamma} \quad y_j \quad b_j]^T \quad (17)$$

Die für die Randbebauung zu bestimmenden Parameter werden auf zwei Krümmungen \bar{c} und \tilde{c} und zwei relative Fahrzeugausrichtungen $\bar{\gamma}$ beziehungsweise $\tilde{\gamma}$ erweitert. Dies folgt der Annahme, dass sich die Krümmung und Ausrichtung der Randbebauungen je nach Position zum Eigenfahrzeug (*links*

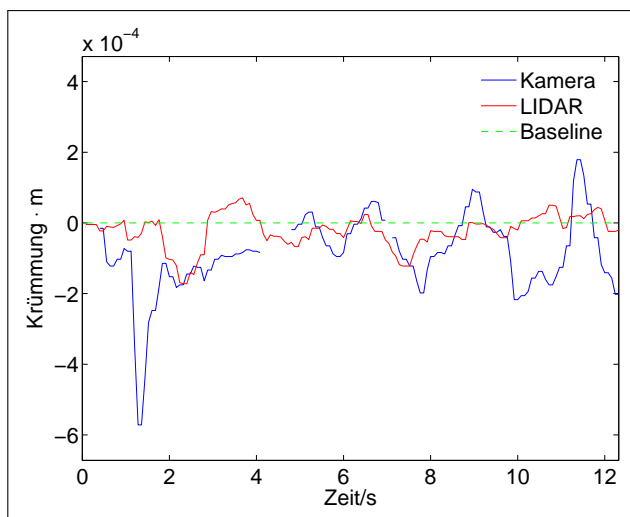


Abbildung 12. In dem Diagramm ist die durch die lidar- und videobasierte Fahrstreifenerkennung gemessene Fahrbahnkrümmung c_{mL} und c_{mV} über die Zeit dargestellt. Zusätzlich ist die korrekte Krümmung als Baseline in grün eingezeichnet.

und rechts) unterscheiden können, jedoch Randbebauungen auf derselben Seite eine identische Krümmung und Ausrichtung besitzen. Die eigentliche Erkennung erfolgt analog zu Teilabschnitt III-B, mit dem Unterschied, dass für jeden Parametersatz ein eigenes Histogramm H_i beziehungsweise H_j über mO optimiert wird. Ein großen Vorteil der histogrammbasierten Erkennung im Vergleich zu anderen Verfahren bietet die Möglichkeit, ein Güte- oder Qualitätskriterium für jede Randbebauung aus dem Histogramm H_{opt} abzuleiten. Dies ist insbesondere dann von Nutzen, wenn zwischen der Qualität der Randbebauungen für eine mögliche Eigenlokalisierung wie zum Beispiel zwischen Büschen oder Leitplanken unterschieden werden muss. Abbildung 13 zeigt als Beispiel die Erkennung der linken und rechten Randbebauung in einem Baustellenszenario.



Abbildung 13. Beispiel für die Erkennung von zwei Randbebauungen (rot) aus dem Occupancy Grid mO in einem Baustellenszenario.

V. ZUSAMMENFASSUNG UND AUSBLICK

In diesem Beitrag wurde ein neuartiges Verfahren zur histogrammbasierten Extraktion von Fahrstreifen und Randbebauungen aus Occupancy Grids vorgestellt. Das Verfahren ist äußerst robust gegen Fehldetektionen und Messrauschen und

reduziert den Berechnungsaufwand durch die effiziente iterative Berechnung der benötigten Histogramme auf ein Minimum. Es eignet sich daher hervorragend für Anwendungen im Automotive-Bereich mit hohen Anforderungen an die Robustheit und Echtzeitfähigkeit, wie zum Beispiel Querführungsfunktionen. Um die Genauigkeit des vorgestellten Verfahrens zur Fahrstreifendetektion zu evaluieren, erfolgte der Vergleich mit einem videobasierten System. Die erzielten Ergebnisse bezüglich der Güte der ermittelten Parameter entsprechen dem eines videobasierten Systems zur Fahrstreifenenerkennung.

In diesem Beitrag wurde lediglich ein Vergleich des laserscanner- und videobasierten Systems zur Fahrstreifenenerkennung vorgenommen. Es ist jedoch durchaus sinnvoll, beide Systeme miteinander zu kombinieren um die Verfügbarkeit von Fahrstreifeninformationen für Assistenzsysteme zu erhöhen. Darüber hinaus, ist die Fusion von Randbauungsinformationen mit denen einer Fahrstreifenenerkennung zur Plausibilisierung und Überbrückung kurzzeitiger Ausfälle von Fahrbahnmarkierungen denkbar.

LITERATUR

- [1] M. Ardel F. Homm P. Waldmann, N. Kaempchen. The emergency stop assistant: secured stop in case of abrupt health related loss of control by the driver. In 3. *Deutscher AAL Kongress*, 2010. 1
- [2] Sebastian Thrun, Wolfram Burgard, and Dieter Fox. *Probabilistic Robotics*. MIT Press, 2005. 1, 2
- [3] A. Elfes. *Occupancy Grids: a probabilistic framework for robot perception and navigation*. PhD thesis, Carnegie Mellon University, 1989. 1
- [4] Sebastian Thrun. Learning occupancy grid maps with forward sensor models. *Auton. Robots*, 15(2):111–127, 2003. 2
- [5] T. Weiss, B. Schiele, and K. Dietmayer. Robust driving path detection in urban and highway scenarios using a laser scanner and online occupancy grids. In *Proc. IEEE Intelligent Vehicles Symposium*, pages 184–189, 2007. 2
- [6] J.C. McCall and M.M. Trivedi. Video-based lane estimation and tracking for driver assistance: Survey, system, and evaluation. volume 7, pages 20–37, March 2006. 3
- [7] Dsgs-jahrbuch fahrbahnmarkierung 2006/2007. Technical report, Die Deutsche Studiengesellschaft für Straßenmarkierungen e.V. (DSGS), 2007. 3
- [8] S. Kammel and B. Pitzer. Lidar-based lane marker detection and mapping. In *Intelligent Vehicles Symposium, 2008 IEEE*, pages 1137–1142, June 2008. 3
- [9] A. Reyher. *Lidarbasierte Fahrstreifenzuordnung von Objekten für eine Abstandsregelung im Stop&Go-Verkehr*. PhD thesis, Technischen Universität Darmstadt, 2006. 3
- [10] Kay Fürstenberg Jörg Kibbel, Winfried Justus. Lane estimation and departure warning using multilayer laserscanner. In *Proceedings of the 8th International IEEE Conference on Intelligent Transportation Systems*, 2005. 3
- [11] T. Ogawa and K. Takagi. Lane recognition using on-vehicle lidar. In *Intelligent Vehicles Symposium, 2006 IEEE*, pages 540–545, 0-0 2006. 3
- [12] Heiko Kramer. *Modelle zur multisensoriellen Erfassung des Fahrzeugumfeldes mit Hilfe von Schätzverfahren*. PhD thesis, Technische Universität Chemnitz, 2005. 3
- [13] J. A. Nelder and R. Mead. A simplex method for function minimization. *The Computer Journal*, 7(4):308–313, 1965. 5
- [14] Kaempchen N. Homm F. Waldmann P. Ardel M. Umfelderkennung für den nothalteassistenten - ein system zum automatischen anhalten bei plötzlich reduzierter fahrfähigkeit des fahrers. In 11. *Braunschweiger Symposium, AAET 2010*, 2010. 7