



Bachelorarbeit am Institut für Informatik der Freien Universität Berlin,  
Arbeitsgruppe Künstliche Intelligenz

## Fahrspurerkennung in LIDAR-Punktwolken

Knut Zeißler  
Matrikelnummer: 4295518  
[knut.zeissler@fu-berlin.de](mailto:knut.zeissler@fu-berlin.de)

Betreuer: Professor Dr. Raúl Rojas

Berlin, 7.3.2013

## **Zusammenfassung**

Für den Erfolg autonomer Fahrzeuge ist die Bestimmung der eigenen Position in einer virtuellen Umgebungskarte essentiell. Da das häufig eingesetzte GPS-System nicht die benötigte Präzision und Verfügbarkeit garantiert, ist es nötig, die eigene Position anhand weiterer Merkmale zu bestimmen. Dafür soll ein Spurerkennungssystem dienen, das neben der eigenen Fahrspur auch die Markierungen der umliegenden Fahrspuren erkennt. Diese Arbeit untersucht, inwieweit die Messungen des Velodyne LIDAR HDL-64e für eine Erkennung von Spurmarkierungen ausreichend sind. Das entwickelte Spurerkennungssystem besteht aus der Erkennung von Hindernissen, der Extraktion der Straßenoberfläche, der Korrektur der Intensitätsinformationen, der Selektion der Messungen, die Spurmarkierungen enthalten, sowie der Anpassung eines Spurmodells an die gefundenen Markierungspunkte. Bei der Auswertung des Systems wird deutlich, dass der Kontrast zwischen Fahrbahnmarkierungen und Asphalt in den LIDAR-Intensitäten deutlich geringer ausfällt als in Kamerabildern. Dadurch ist das System nur auf gut gepflegten Straßenabschnitten in der Lage, die eigene Fahrspur und Nachbarspuren zuverlässig zu erkennen.

### **Eidesstattliche Erklärung**

Ich versichere hiermit an Eides Statt, dass diese Arbeit von niemand anderem als meiner Person verfasst worden ist. Alle verwendeten Hilfsmittel wie Berichte, Bücher, Internetseiten oder ähnliches sind im Literaturverzeichnis angegeben, Zitate aus fremden Arbeiten sind als solche kenntlich gemacht. Die Arbeit wurde bisher in gleicher oder ähnlicher Form keiner anderen Prüfungskommission vorgelegt und auch nicht veröffentlicht.

7. März 2013

# Inhaltsverzeichnis

<b>1</b>	<b>Einleitung</b>	<b>1</b>
1.1	Motivation . . . . .	1
1.1.1	Fahrspurerkennung . . . . .	1
1.1.2	Autonome Fahrzeuge . . . . .	1
1.1.3	Probleme kamerabasierter Fahrspurerkennungssysteme . . . . .	1
1.1.4	LIDAR-Fahrspurerkennung . . . . .	1
1.2	Aufgabenstellung . . . . .	2
1.3	Struktur dieser Arbeit . . . . .	2
1.4	Projektbeschreibung . . . . .	2
1.4.1	Versuchsfahrzeug - MadeInGermany . . . . .	2
1.5	Velodyne HDL-64e LIDAR . . . . .	4
1.5.1	Funktionsprinzip . . . . .	4
1.5.2	Tiefeninformationen . . . . .	5
1.5.3	Intensität . . . . .	6
1.6	Global Positioning System (GPS) . . . . .	7
1.6.1	Applanix Inertial Navigation System . . . . .	8
<b>2</b>	<b>Related Work</b>	<b>9</b>
2.1	Verwandte Arbeiten . . . . .	9
2.1.1	T. Ogawa et al.: Lane recognition using on-vehicle LIDAR, 2006 [13] . . . . .	9
2.1.2	S. Kammel, B. Pitzer: Lidar-based lane marker detection and mapping, 2008 [14] . . . . .	9
2.1.3	Chen et al.: Next Generation Map Making: Geo-Referenced Ground-Level LIDAR Point Clouds for Automatic Retro-Reflective Road Feature Extraction, 2009 [16] . . . . .	10
2.1.4	Lindner et al.: Multi-channel lidar processing for lane detection and estimation, 2009 [17] . . . . .	10
2.2	Hough Transformation . . . . .	11
2.2.1	Geradenerkennung . . . . .	11
2.2.2	Überführung in den Dualraum . . . . .	12
2.3	Radon Transformation . . . . .	13
2.4	RANSAC . . . . .	15
2.5	Kalman Filter . . . . .	16
<b>3</b>	<b>Straßenerkennung</b>	<b>20</b>
3.1	Höhenniveaus . . . . .	20
3.2	Repräsentation der Messdaten . . . . .	20
3.2.1	Gitternetz . . . . .	21
3.2.2	Polares Gitternetz . . . . .	21
3.2.3	Sensorbild . . . . .	22
3.3	Bordstein- und Hinderniserkennung . . . . .	23

3.3.1	Umsetzung . . . . .	25
3.3.2	Vertikale Hinderniserkennung . . . . .	25
3.3.3	Horizontale Hinderniserkennung . . . . .	25
3.3.4	Kombination der Klassifikationen . . . . .	26
3.3.5	Kalibrierung durch Rückkopplung . . . . .	26
<b>4</b>	<b>Fahrspurerkennung</b>	<b>28</b>
4.1	Aufgabenstellung . . . . .	28
4.2	Probleme der Sensorbilder . . . . .	28
4.3	Schwellwert-Ansatz . . . . .	29
4.3.1	Angleichung der Intensitätsniveaus . . . . .	29
4.3.2	Statischer Schwellwert . . . . .	30
4.3.3	Adaptive Schwellwertverfahren . . . . .	30
4.3.4	Statistischer Schwellwert . . . . .	30
4.4	Koordinaten-Transformation . . . . .	31
4.5	Polynomanpassung . . . . .	32
4.5.1	Lineare Regression . . . . .	32
4.5.2	Anwendung von RANSAC zur Polynomanpassung . . . . .	33
4.5.3	Regionale Aufteilung . . . . .	34
<b>5</b>	<b>Ergebnisse</b>	<b>36</b>
5.1	Hinderniserkennung . . . . .	36
5.2	Spurerkennung . . . . .	36
5.3	Vergleich . . . . .	37
<b>6</b>	<b>Fazit</b>	<b>37</b>
6.1	Zusammenfassung . . . . .	37
6.2	Ausblick . . . . .	38

# 1 Einleitung

## 1.1 Motivation

### 1.1.1 Fahrspurerkennung

Bei der Entwicklung von Personenwagen werden seit jeher Komfort und Sicherheit als Ziele verfolgt. Seit 20 Jahren werden dazu nicht nur klassische mechanische Komponenten am Auto verbaut, sondern auch umfangreiche elektronische Systeme, wie das elektronische Stabilitätsprogramm (ESP) oder intelligente Geschwindigkeitsregelsysteme. Seit 2001 bieten immer mehr Hersteller auch Fahrspurerkennungssysteme an, die auf Bilddaten einer Kamera basieren [1]. Durch diese Systeme können nach Schätzungen 10-25% der Unfälle verhindert werden, die durch Sekundenschlaf, Unaufmerksamkeit oder Ablenkung verursacht werden [2].

### 1.1.2 Autonome Fahrzeuge

Autonome Fahrzeuge haben bei der DARPA Urban Challenge 2007 eindrucksvoll gezeigt, wie fortgeschritten die Entwicklung elektronischer Programme und Sensorik für Kraftfahrzeuge ist. Die meisten autonomen Fahrzeuge verlassen sich auf GPS-Systeme, um die eigene Position in einer virtuellen Umgebungskarte zu bestimmen. Da aufgrund dieser Positionsmessung weitere Aktionen des Fahrzeugs geplant werden, ist eine möglichst präzise Ortung wichtig. Leider funktionieren GPS-Systeme nicht immer mit der geforderten Genauigkeit oder sind in bestimmten Situationen gar nicht verfügbar. Daher ist es sinnvoll, die Position des Fahrzeugs auch durch andere Umgebungsmerkmale, wie Fahrbahnmarkierungen, zu bestimmen [3].

### 1.1.3 Probleme kamerabasierter Fahrspurerkennungssysteme

Kamerabasierte Fahrspurerkennungssysteme arbeiten in Situationen zuverlässig, in denen Kameras ein klares Bild der Straßenoberfläche aufnehmen können. Problematisch sind Faktoren wie Dunkelheit oder direkte Einstrahlung der Sonne in die Kameralinse. In solchen Fällen werden teilweise gar keine Fahrspuren erkannt. Es sind aber auch Fälle problematisch, in denen Spurmarkierungen abseits der Straße erkannt werden. Dieses Fehlverhalten ist auch darauf zurückzuführen, dass Kameras zweidimensionale Bilder generieren, aus denen die Struktur der Umgebung rekonstruiert werden muss.

### 1.1.4 LIDAR-Fahrspurerkennung

Die durch LIDAR gewonnene, dreidimensionale Wahrnehmung der Fahrzeugumgebung sollte eine robustere Erkennung von Straßenbegrenzungen wie Bordsteinen ermöglichen. Da LIDAR-Systeme mit einem eigenen Licht arbeiten, sind ihre Messungen unabhängiger von äußeren Beleuchtungsquellen

als Kamerabilder und können auch nachts eingesetzt werden. Bei dem auf dem Versuchsfahrzeug verbauten Velodyne-LIDAR wird außerdem das Erkennen von Nachbarspuren ermöglicht, da die Messung in allen Himmelsrichtungen und nicht nur in dem Bereich vor dem Fahrzeug erfolgt. Allerdings liefern LIDAR-Systeme keine Farb- oder Helligkeitswerte der Umgebung, sondern messen die Intensität der reflektierten Strahlung, auf die am Ende dieses Kapitels eingegangen wird.

## 1.2 Aufgabenstellung

Ziel der Arbeit ist es, eine Software zu entwickeln, die Fahrspuren im Umfeld des Fahrzeugs anhand von Fahrbahnmarkierungen erkennt. Dazu erhält das System bei jeder vollständigen Umdrehung des Velodyne HDL-64e eine Menge von Punkten und deren Intensitätswerte sowie die Position und Ausrichtung des Fahrzeugs. Die Ausgabe des Systems ist eine Menge von Spurmarkierungen, von denen jede durch ein Polynom charakterisiert ist. Die Implementierung des Systems soll die Daten des Sensors echtzeitfähig verarbeiten können, insofern, als dass die Verarbeitung der Daten kürzer dauert als die Messung selbst.

## 1.3 Struktur dieser Arbeit

Bis zu diesem Punkt wurde erklärt, warum ein neues Spurerkennungssystem gebraucht wird und welche Vorteile davon erwartet werden. Den Abschluss dieses Kapitels bildet die Projektbeschreibung, in der das Versuchsfahrzeug und die Funktionsweise der verwendeten Sensoren vorgestellt wird. Im zweiten Kapitel wird eine Übersicht über Arbeiten, die eine ähnliche Zielsetzung haben, gegeben und deren Vor- und Nachteile zusammengefasst. Es werden außerdem Techniken vorgestellt, die sowohl in den bestehenden Veröffentlichungen als auch in dieser Arbeit verwendet werden. Der darauffolgende Hauptteil der Arbeit ist in zwei Abschnitte unterteilt: Im ersten Teil wird erklärt, wie die Straßenoberfläche aus den Sensordaten extrahiert werden kann. Im zweiten Teil geht es darum, die Spurmarkierungen auf der Straßenoberfläche zu finden. Das letzte Kapitel der Arbeit überprüft, inwieweit das Ergebnis der Arbeit den formulierten Anforderungen genügt und zieht einen Vergleich zu kamerabasierten Referenzsystemen.

## 1.4 Projektbeschreibung

### 1.4.1 Versuchsfahrzeug - MadeInGermany

Nachdem die Arbeitsgruppe bereits mit dem Fahrzeug *Spirit of Berlin* erfolgreich an der DARPA Urban Challenge 2007 teilgenommen hat, wechselte sie 2010 auf ein Fahrzeug vom Typ VW Passat Variant B6. Der Vorteil des Fahrzeugs sind die bereits verbaute Sensorik sowie die stärkere elektronische

Vernetzung der Komponenten. Die ebenfalls verbaute *Drive-by-Wire* Technology, die es ermöglicht das Fahrzeug durch elektrische Signale zu steuern, macht zusätzliche Aktoren für Lenkung und Pedalerie überflüssig und eliminiert somit eine potenzielle Fehlerquelle.




Abbildung 1: Das autonome Fahrzeug *MadeInGermany* mit Sensorik [4]

**Das Fahrzeug verfügt über die folgenden Sensoren:**

**Kamera im Rückspiegel (Serie)** In Serienfahrzeugen dient diese Kamera dem Spurhalteassistenten und der Lichtautomatik [5].

**Hella Aglaia INKA** Zwei Stereokameras um den Innenspiegel montiert dienen der Fußgänger-, Ampel-, Verkehrszeichen- und Spurerkennung.

**Lux Laser Stoßstangenbereich** An Front und Heck des Fahrzeugs sind jeweils drei Einheiten verbaut, die zur Erkennung von Hindernissen dienen.

**Smart Microwave Sensors GmH Radar** Montiert an der Stoßstange dient es der Geschwindigkeitsermittlung vorausfahrender Fahrzeuge. Der Öffnungswinkel des Radar beträgt 100 Grad.

**Vier TRW Radare** Drei Radare an der Front des Fahrzeugs dienen der Abstandsregelautomatik. In der Serie wird lediglich eine Einheit im Bereich des Kühlergrills verbaut. Die Reichweite des Sensors beträgt 150m bei einem Öffnungswinkel von 25 Grad.

**GPS-Antenne (Applanix POS/LV System)** Dient der Positionsbestimmung per Satellit unter Einrechnung von Korrekturfaktoren. Eine genauere Beschreibung folgt in Abschnitt 1.6.1.

**Velodyne HDL-64e** Dieser LIDAR rotiert um seine vertikale Achse und deckt somit das gesamte Umfeld des Autos mit einem vertikalen Öffnungswinkel von 27 Grad ab. Er wird zur Hinderniserkennung und in dieser Arbeit zur Spurerkennung verwendet. Eine genauere Beschreibung folgt im nächsten Abschnitt.

**Odometer (Applanix POS/LV System)** Misst die Umdrehungen eines Rads zur Bestimmung der zurückgelegten Distanz, da die Messungen des Fahrzeugtacho zu unpräzise sind.

## 1.5 Velodyne HDL-64e LIDAR




Abbildung 2: Velodyne HDL-64e [6]

### 1.5.1 Funktionsprinzip

Die ersten LIDAR wurden kurz nach dem zweiten Weltkrieg gebaut, nachdem das Geheimnis um die RADAR-Technologie gelüftet wurde. Der Begriff LIDAR wurde erstmals von Middleton & Spilhaus 1953 verwendet, allerdings ohne die Bedeutung des Akronyms zu erklären. Die Konstruktion des LASER (Light Amplification by Stimulated Emission of Radiation) durch Maiman 1960 stellte eine enorme Verbesserung für LIDAR dar, da

LASER im Gegensatz zu anderen Lichtquellen ein sehr enges Frequenzband aussenden[7].

LIDAR (LIght Detection and Ranging) bestehen aus einem Sender (in der Regel ein LASER), einem Empfänger und verarbeitender Elektronik. Nach dem Senden eines Lichtimpulses werden die reflektierten Strahlen gemessen und daraus Rückschlüsse auf Hindernisse oder Beschaffenheit der Atmosphäre gezogen.




Abbildung 3: Strahlung - Absorption und Reflektanz (nach [8])

Aus der Zeitdifferenz zwischen Senden und Empfangen lässt sich die Entfernung  $d$  bestimmen, in der die Reflektierende Oberfläche liegt:

$$d(t) = t * \frac{c}{2}$$

wobei  $t$  die Zeitdifferenz, und  $c$  die Lichtgeschwindigkeit ist.

Neben Oberflächen reflektieren auch Bestandteile der Atmosphäre, sodass zur Entfernungsmessung die reflektierte Strahlung der Oberfläche gefunden werden muss. Die Intensität bildet üblicherweise ein globales Maximum aller Reflektionen. Die anderen Reflektionen können vielfältige Informationen liefern, beispielsweise über Aerosolpartikel oder Moleküle in der Atmosphäre.

### 1.5.2 Tiefeninformationen

Indem nur die Reflektion mit der maximalen Intensität betrachtet wird, kann mit der obigen Formel die Entfernung zwischen LIDAR und Hindernis bestimmt werden. Wenn zusätzlich die Position und die Ausrichtung des LIDAR bekannt sind, können die Koordinaten des reflektierenden Punktes berechnet werden. Die Menge solcher Punkte nennt sich Punktwolke(siehe Abb. 4).

Der Velodyne HDL-64e ist konzipiert worden, um schnell eine Punktwolke der direkten Umgebung zu erstellen. Dazu besitzt er einen rotierenden Kopf, auf dem Sender und Empfänger untergebracht sind(siehe Abb. 2). Der Kopf besteht aus einem oberen und unteren Block, die jeweils 32 Laser und einen




Abbildung 4: Punktwolke mit farbiger Hervorhebung der Höhenunterschiede [9]

Empfänger beherbergen. Es werden ungefähr 1.3 Millionen Punkte pro Sekunde gemessen[6]. Durch die Rotation um die vertikale Achse beträgt das horizontale Sichtfeld  $360^\circ$ . Der vertikale Öffnungswinkel beträgt lediglich  $27^\circ$ , sodass die direkte Umgebung unter dem LIDAR und besonders hoch liegende Hindernisse (beispielsweise Straßenlaternen) nicht gemessen werden.

### 1.5.3 Intensität

Zum Finden von Spurmarkierungen ist es notwendig, die reflektierte Strahlung von Asphalt und Spurmarkierungen unterscheiden zu können.

Die gemessene Intensität  $P$  der reflektierten Strahlung als Funktion vom Abstand  $R$  und der Wellenlänge  $\lambda$ [8]:

$$P(\lambda, R) = CWn_b(R)\sigma_b \frac{dR}{R^2} \exp\left(-2 \int_0^R \sigma(\alpha)N(r) + K_{ext}(r)dr\right)$$

$C$  ist eine System-Konstante,  $W$  ist die gesendete Impulsenergie und  $n_b(R)$  ist die Teilchendichte von streuenden Objekten mit Rückstreuoeffizient  $\sigma_b$ . Es wird zweifach über die Entfernung integriert, da die Strahlung in diesem Bereich auf dem Hin- und Rückweg gedämpft wird. Die Dämpfung ist abhängig von der Wellenlänge  $\lambda$ , Konzentration der Atome  $N(r)$ , dem Absorptionsquerschnitt  $\sigma(\lambda)$ . Die Zahl  $K_{ext}$  steht für die Dämpfung von Partikeln, die nicht oder kaum von der Wellenlänge abhängen (siehe Abb. 5).




Abbildung 5: Unterschiedliche Reflektivität je nach Wellenlänge[10]

Die Betrachtung der Dämpfung auf dem Weg zwischen LIDAR und Oberfläche ist für die Erkennung von Oberflächen zunächst zu vernachlässigen, allerdings kann die Intensität der Oberfläche durch Abgasemissionen anderer Verkehrsteilnehmer beeinflusst werden.

Für diese Arbeit ist es wichtig, dass die Rückstreukoeffizienten  $\sigma_b$  von Spurmarkierungen und Asphalt unterscheidbar sind. Nur dann ist die Intensität eine ausreichende Information für die Unterscheidung der Materialien.

Da die verwendete Wellenlänge von 905nm auch von der Sonne ausgestrahlt wird, kann es zur Blendung des LIDAR kommen. Aufgrund der Ausrichtung der Empfängereinheiten sollte dies jedoch nur zu Zeiten der Dämmerung passieren. Selbst bei optimalen externen Bedingungen müssen mindestens die folgenden Faktoren berücksichtigt werden:

- die Intensität nimmt mit der Distanz quadratisch ab
- der Rückstrahlkoeffizient kann für verschiedene Auftreffwinkel unterschiedlich groß sein
- die gleiche Messung kann aufgrund von baulichen Unterschieden mit verschiedenen Lasern unterschiedliche Ergebnisse liefern

## 1.6 Global Positioning System (GPS)

Das Global Positioning System wurde 1994 vom amerikanischen Verteidigungsministerium in Betrieb genommen und dient der globalen Positionsbestimmung in longitudinaler und lateraler Richtung. Wichtigster Bestandteil des Systems sind 24 Satelliten, die sich auf Umlaufbahnen der Erde befinden. Die Abdeckung erlaubt dabei an freien Orten auf der Erde eine Erreichbarkeit von mindestens 6 Satelliten. Die Satelliten senden permanent Signale,

die den Zeitpunkt des Sendens und die Position des Satelliten zu diesem Zeitpunkt beinhalten. Ein GPS Empfänger misst die Entfernungen zu den Satelliten aus dem Zeitunterschied zwischen Senden und Empfangen der Signale. Der Empfang von mindestens 4 Satellitensignalen ermöglicht eine präzise Lokalisation. Die Verfügbarkeit und Präzision der GPS-Lokalisierung werden aufgrund der geringen Feldstärke der Satellitensignale jedoch häufig durch Witterungsumstände oder die Umgebung des Empfängers einschränkt.

### 1.6.1 Applanix Inertial Navigation System

Da das GPS Signal vorübergehend eingeschränkt oder nicht verfügbar sein kann, verfügt das verwendete Applanix POS LV-System neben einer GPS-Einheit über eine *Inertial Measurement Unit* (IMU). Mithilfe der IMU werden Änderungen der Fahrzeugausrichtung gemessen und mithilfe des Odometers die zurückgelegte Strecke. Aus diesen Daten kann das *Inertial Navigation System* (INS) die Position des Fahrzeugs schätzen und den Verlust des GPS-Signals vorübergehend kompensieren. Da die Schätzungen mit der Dauer, in der das GPS-Signal fehlt, immer weiter von der tatsächlichen Position des Fahrzeugs abweichen, kommt es bei der Wiederherstellung des GPS-Signals zu einem Sprung zwischen geschätzter und tatsächlicher Position. Diese abrupten Änderungen sind für autonome Fahrzeuge kritisch, da alle Aktionen von der eigenen Position abhängen und davon abhängig geplant wurden. Ein solcher Positionssprung kann in der virtuellen Umgebungskarte des Fahrzeugs eine Versetzung in eine benachbarte Fahrspur bewirken, woraufhin ein Fahrspurwechsel geplant wird oder ungewollte Lenkbewegungen initiiert werden. Mithilfe einer Fahrspurerkennung, die neben der eigenen Spur auch die Nachbarspuren erkennt, kann dieser Fall abgefangen werden und die Lokalisation robuster gemacht werden.

## 2 Related Work

### 2.1 Verwandte Arbeiten

Der erste Schritt einer Spurerkennung ist die Extraktion der Fahrbahnoberfläche, die oft durch Hindernisse wie Bordsteine, Leitplanken oder Pfosten markiert wird. LIDAR sind aufgrund der gemessenen Tiefeninformationen prädestiniert für die Erkennung von Hindernissen. Erste Ansätze den Straßenverlauf durch diese Merkmale zu erkennen wurden 1998 von A. Kirchner und Th. Heinrich in [11] beschrieben. Die Erkennung von Spurmarkierungen unter Ausnutzung der gemessenen Intensitäten wurde bisher ebenfalls untersucht, allerdings werden LIDAR oft lediglich als Ergänzung für kamerabasierte Spurerkennungssysteme genutzt, um sog. Falsche-Positive Spurmarkierungen, die abseits der Straße liegen, zu verwerfen (siehe [12]).

#### 2.1.1 T. Ogawa et al.: Lane recognition using on-vehicle LIDAR, 2006 [13]

In der ersten Arbeit, in der versucht wurde, Spurmarkierungen mit einem LIDAR zu finden, wird ein modifizierter LIDAR der Firma DENSO verwendet, der auf der Frontstoßstange des Versuchsfahrzeugs montiert ist. Daraus ergibt sich auch der Nachteil des Systems, dass aufgrund des eingeschränkten Sichtfelds ausschließlich die Markierungen der eigenen Fahrspur erkannt werden. Das Hauptprinzip zur Erkennung der Fahrspuren bildet ein Schwellwert-Verfahren mit anschließender mehrdimensionaler Hough-Transformation (siehe Abschnitt 2.2), in der alle denkbaren Spuren überprüft werden. Die Spuren werden dabei durch ein Polynom 2. Ordnung beschrieben. Am Ende der Arbeit findet ein Vergleich mit einem kamerabasierten Spurerkennungssystem statt, der den LIDAR-Ergebnissen eine bessere Stabilität bescheinigt. Der Vergleich findet allerdings auf einem Autobahnabschnitt statt, dessen Markierungen eine besonders hohe Reflektivität für das LIDAR-Licht aufweisen.

#### 2.1.2 S. Kammel, B. Pitzer: Lidar-based lane marker detection and mapping, 2008 [14]

Das Team AnnieWAY nahm mit ihrem Fahrzeug an der DARPA Urban Challenge 2007 teil und entwickelte hierfür eine Spurerkennung, die primär zur Verbesserung der Selbstlokalisierung in einer digitalen Umgebungskarte (Road Network Definition File) dient. Das System wurde später auch zur Kartenerstellung genutzt, da neben der eigenen Spur auch die Nachbarspuren erkannt werden können. Die Erkennung von Hindernissen und somit auch Begrenzungen der Fahrbahnen basiert auf dem als *Occupancy Grid Mapping* (siehe [15]) bekannten Verfahren. Da dieses Verfahren ursprünglich nur in statischen Umgebungen funktioniert, wurde es um eine

Zeitkomponente erweitert, die zeitlich zurückliegende Messungen vernachlässigt. Außerdem verfügt das System über eine gesonderte Erkennung und Verfolgung von beweglichen Hindernissen. Zur Erkennung von Spurmarkierungen werden sowohl Markierungen als auch Bordsteine gleichberechtigt behandelt. Mithilfe der Radon-Transformation (siehe Abschnitt 2.3) wird berechnet, welche Spurmarkierungen vorliegen. Das System scheint auch im Stadtverkehr gute Ergebnisse zu liefern.

### 2.1.3 Chen et al.: Next Generation Map Making: Geo-Referenced Ground-Level LIDAR Point Clouds for Automatic Retro-Reflective Road Feature Extraction, 2009 [16]

Chen et al. beschreiben einen Aufbau, in dem die gesammelten Daten zur Kartenerstellung genutzt werden. Dazu wird in den Punktwolken eines Velodyne HDL-64E nach Spurmarkierungen sowie Straßenschildern gesucht. Der Velodyne-LIDAR ist im Gegensatz zu unserem Fahrzeug jedoch schräg am Fahrzeugheck angebracht, sodass lediglich der Bereich der Straße direkt hinter dem Fahrzeug erfasst wird. Der Vorteil ist hierbei, dass die gemessenen Punkte deutlich dichter beieinander liegen, für eine vorausschauende Fahrspurerkennung ist die Position jedoch nicht geeignet. Um die Straßenoberfläche aus den Punktwolken zu extrahieren, wird bei jeder Umdrehung des LIDAR nach einer Erhöhung links und rechts vom Fahrzeug gesucht. Dies funktioniert auf Autobahnen gut, allerdings gibt es Probleme, wenn vorbeifahrende Fahrzeuge die Fahrbahnoberfläche verdecken, oder die Straße durch einen Grasstreifen oder Graben beschränkt wird. Bei der Suche nach Spurmarkierungen werden die Intensitäten parallel zur Fahrtrichtung in mehreren Streifen aufsummiert und durch adaptive Schwellwertverfahren wird bestimmt, in welchen dieser Streifen Spurmarkierungen liegen. Weitere Kriterien sind der Abstand zwischen den Spuren, sowie die Orientierung der Spur im Vergleich zur Fahrtrichtung. Wahrscheinlich erkennt das System im Stadtverkehr Fahrspuren nicht verlässlich, da im Schlussteil sowohl andere Verkehrsteilnehmer, als auch schlechte Farbqualität als problematisch dargestellt werden.

### 2.1.4 Lindner et al.: Multi-channel lidar processing for lane detection and estimation, 2009 [17]

Die Arbeit entstand in Zusammenarbeit mit der Firma DENSO, weshalb die Wahl des Sensors, wie in [13], auf einen Sensor dieser Firma fiel. Eine Weiterentwicklung des Sensors besteht darin, durch die Messung mehrerer Echos die Qualität der Messungen bei schlechtem Wetter zu verbessern. Das entwickelte System geht davon aus, dass die Remissionsstrahlung weit entfernter Spurmarkierungen gemessen werden kann, während die des Asphalts nicht mehr messbar ist. Diese Annahme löst das Problem, dass die Intensitätswerte

weit entfernter Spurmarkierungen zu schwach sind, um eine Unterscheidung zwischen Asphalt und Markierung zu treffen. Bei der Auswertung des Systems werden verschiedene Straßenbeläge und Farben, sowie Umwelteinflüsse in Betracht gezogen. Dabei wird deutlich, dass neben der Qualität der Markierung vor allem das Material der Straßenoberfläche, entweder Asphalt oder Beton, für die Erkennung entscheidend ist. Außerdem wird festgestellt, dass auf deutschen Autobahnen verschiedene Farben zum Einsatz kommen, von denen eine eine Erhöhung von 2mm aufweist und dadurch erhöhte Intensitäten reflektiert. Falls die Spurmarkierungen aus dieser Farbe bestehen, liefert das System auch bei starkem Regen gute Ergebnisse. Bei Blendung durch direkte Sonneneinstrahlung sind allerdings keine brauchbaren Ergebnisse zu erreichen.

## 2.2 Hough Transformation

Das als *Hough Transformation* bezeichnete Verfahren wurde 1962 von dem Physiker Paul Hough erfunden, als er versuchte Muster in einer Blaskammer zu finden [18]. Seit den siebziger Jahren wurde das Verfahren immer wieder von Informatikern aufgegriffen und zur Erkennung von Geraden, Kreisen, Kurven und letztlich auch beliebigen Formen eingesetzt.

Die Basis des Verfahrens bildet eine Transformation vom Ursprungsraum in einen Dualraum. Den Ursprungsraum bildet üblicherweise ein binäres digitales Bild nach Durchführung einer Kantenerkennung. Der Dualraum wird durch eine geeignete Parametrisierung der zu suchenden Objekte festgelegt. Im Dualraum sollten alle möglichen Ausprägungen der gesuchten Form dargestellt werden können.

### 2.2.1 Geradenerkennung

Die älteste Anwendung der Hough Transformation ist die Erkennung von Geraden. Um den Dualraum zu definieren, ist es notwendig, eine geeignete Parametrisierung von Geraden zu finden. Jeder Punkt im Dualraum soll durch seine Koordinaten eine Gerade eindeutig beschreiben. In den Arbeiten von Paul Hough wurden die Geraden durch die Gleichung

$$y = xm + c$$

beschrieben. Dabei ergibt sich allerdings das Problem, dass sich vertikale Geraden nicht darstellen lassen, da dann die Steigung  $m$  gegen unendlich strebt. Für beliebige Geraden wurde daher seit 1972 meist folgende Parametrisierung gewählt (siehe [19]):

$$r = x \cos \phi + y \sin \phi$$

Der Parameter  $r$  beschreibt den minimalen Abstand der Geraden zum Koordinatenursprung. Der Winkel  $\phi$  wird von der x-Achse und der Abstandsgeraden eingeschlossen. Der Dualraum ist hier der  $\mathbb{R}^2$ , wobei eine Koordinate den

$\phi$ -Wert der Geraden und die andere Koordinate den Abstand  $r$  der Geraden zum Nullpunkt darstellt (siehe Abb. 6).




Abbildung 6: Parametrisierung einer Geraden durch Abstand  $r$  und Winkel  $\phi$

### 2.2.2 Überführung in den Dualraum

Um aus dem Bildraum den Dualraum zu errechnen, werden alle Pixel einzeln betrachtet. Dabei gibt jeder helle Pixel eine Stimme für alle Geraden ab, auf denen er liegt. Dazu werden nacheinander alle Pixel des Bildes überprüft und für helle Pixel die folgende Prozedur ausgeführt: Die Koordinaten  $(x, y)$  des Pixels werden in die Formel  $r = x \cos \phi + y \sin \phi$  eingesetzt. Für unterschiedliche Werte  $\phi$  erhält man dadurch jeweils einen Wert  $r$ , sodass mit  $(r, \phi)$  ein Punkt im Dualraum bestimmt ist. Schritt für Schritt wird  $\phi$  inkrementiert und die errechneten Punkte  $(r(\phi), \phi)$  im Dualraum jeweils um Eins erhöht. Die Wertepaare  $(r, \phi)$  ergeben im Dualraum eine Kurve, die der Sinusfunktion ähnelt (Abb. 7).




Abbildung 7: Ein Punkt im Ursprungsraum liegt auf mehreren Geraden, die im Dualraum eine Sinuskurve bilden

Wenn zwei Pixel im Ursprungsraum auf einer gemeinsamen Gerade liegen, ist für beide Punkte der Wert  $r(\phi)$  gleich. Somit ergibt sich im Dualraum der Schnittpunkt  $(r(\phi), r)$  der beiden Sinusoidale (siehe Abb. 8).

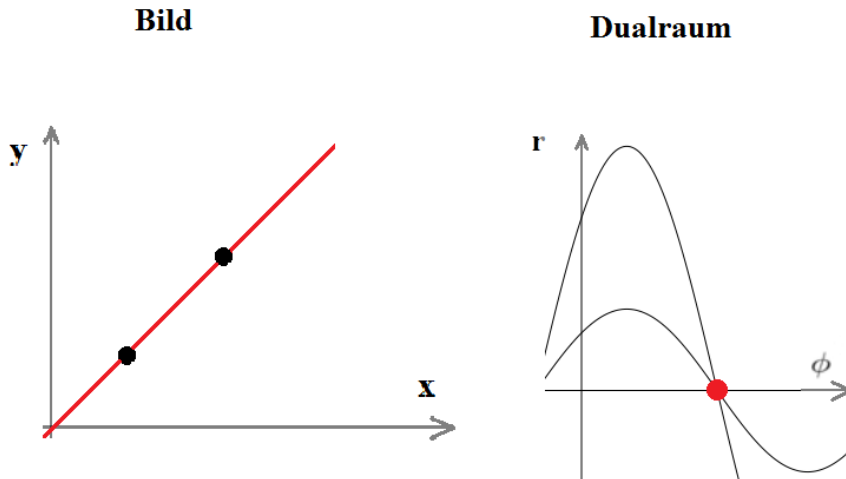


Abbildung 8: Eine durch zwei Punkte definierte Gerade im Ursprungsraum entspricht dem Schnittpunkt der beiden Sinuskurven im Dualraum

Der Wert  $(r, \phi)$  im Dualraum ist umso größer, je mehr helle Pixel auf der Geraden liegen, die durch  $r$  und  $\phi$  beschrieben wird. Nach der Hough-Transformation des Bildes muss der Dualraum auf Maxima untersucht werden, um die Geraden mit den meisten Pixeln zu ermitteln.

Die Laufzeit der Hough Transformation beträgt ohne Optimierungen  $O(\#Pixel * \#Winkel)$ , wobei  $\#Winkel$  die Anzahl der untersuchten Winkel und  $\#Pixel$  die Anzahl der hellen Pixel im Ursprungsbild darstellt. Die Anzahl der Winkel kann bei der Diskretisierung des Dualraums frei gewählt werden. Durch Wahl eines hohen Wertes wird das Ergebnis genauer, allerdings wird die Präzision mit einer erhöhten Rechendauer erkauft. Es existieren mehrere Ansätze zur Beschleunigung der Transformation, indem beispielsweise der Gradient der einzelnen Pixel genutzt wird, um die Menge der möglichen Geraden einzuschränken (siehe [20]) oder probabilistische Ansätze, die nur eine zufällig ausgewählte Teilmenge der Pixel betrachten (siehe [21]). Es sei außerdem darauf hingewiesen, dass die Hough Transformation auf allgemeine Formen ausgedehnt werden kann (siehe [22],[23]), solange eine geeignete Parametrisierung der gesuchten Form erfolgt.


## 2.3 Radon Transformation

Die *Radon Transformation* wurde 1917 von Johann Radon eingeführt und gehört zur Gruppe der Integraltransformationen [24]. Die Einsatzmöglichkeiten der Radon Transformation liegen unter anderem in der Auswertung

von Bildern aus der Tomographie und sind in Form der allgemeinen Radon Transformation sehr vielseitig. In diesem Abschnitt wird lediglich die Radon Transformation für Geraden beschrieben und auf ihre Verwandtschaft mit der Hough Transformation eingegangen.

Wie bei der Hough Transformation werden Geraden durch den Abstand zum Koordinatenursprung  $r$  und den Winkel  $\phi$  parametrisiert (siehe Abb. 6). Bei der Radon Transformation werden zu einer Geraden  $(r, \phi)$  alle Punkte  $(x, y)$  gesucht, die auf dieser Gerade liegen. Dies ist der Unterschied zur Hough-Transformation, bei der ausgehend von den Koordinaten  $(x, y)$  eines Punktes alle Geraden  $(r, \phi)$ , auf denen der Punkt liegt, gesucht werden.

Um alle Punkte auf der Geraden zu finden, wird zuerst der Punkt der Geraden errechnet, der am nächsten am Nullpunkt des Koordinatensystems liegt und anschließend die Gerade abgeschritten:



Die originale Formulierung der Radon Transformation lautet [24]:

$$\mathcal{R}(r, \phi) = \int_R I(r \cos \phi - s \sin \phi, r \sin \phi + s \cos \phi) ds$$

wobei  $I(x, y)$  der binäre Farbwert Bildpunktes  $(x, y)$  ist.

Das Ergebnis der Radon-Transformation ist dasselbe, wie das der Hough-Transformation, allerdings unterscheiden sich die Verfahren im Hinblick auf eine effiziente Implementierung. Zwar hängen die Geschwindigkeiten auch vom Verhältnis von hellen zu dunklen Punkten (siehe [25]) und der Speicherstruktur ab, diese Faktoren betreffen allerdings beide Verfahren gleichermaßen. Bei der parallelen Ausführung unterscheiden sich die Verfahren jedoch stark: Bei der Hough Transformation gibt jeder Punkt im Eingangsbild eine Stimme für alle Geraden, die diesen Punkt schneiden, ab. Dadurch kommt es bei einer nicht sequentiellen Implementierung zu kollidierenden Schreibzugriffen, sodass Techniken zur Synchronisation notwendig sind. Bei der Radon Transformation wird das Eingangsbild ausgelesen und auf der gesuchten Geraden liegende Punkte aufsummiert. Dadurch entstehen bei einer nicht sequentiellen Implementierung kollidierende Lesezugriffe, die auf den meisten Plattformen unproblematisch sind.

## 2.4 RANSAC

Im Bereich der Robotik und des Rechnersehens werden für die Wahrnehmung der Umgebung häufig Modelle verwendet. Unabhängig von der Wahl des Modells birgt das Finden der bestmöglichen Parameter Schwierigkeiten, da die aufgenommenen Daten der Sensoren nicht fehlerfrei sind. Klassische Verfahren, wie die Methode der kleinsten Quadrate, sind darauf ausgerichtet, kleine Fehler auszugleichen, sie versagen jedoch, wenn Messpunkte mit großen Fehlern vorliegen. Üblicherweise beinhalten die Messungen der Sensoren zwar kleine Abweichungen, oftmals werden Modelle jedoch auch in späteren Verarbeitungsschritten eingesetzt, in denen bereits eine Klassifikation der Daten vorgenommen wurde. Sollte es dabei zu einer Fehlklassifikation kommen, handelt es sich meist um einen großen Ausreißer mit entsprechend großem Einfluß auf die Parametersuche (siehe [26]).

Bei dem RANdom SAMple Consensus(kurz RANSAC) genannten Verfahren, das 1981 von Fischler und Bolles in [26] vorgestellt wurde, handelt es sich um ein Verfahren zur Parameteranpassung, das besonders resistent gegenüber großen Ausreißern ist. Statt wie üblich, die optimalen Parameter für alle Daten zu suchen, beginnt das iterative Verfahren mit einer zufällig ausgewählten Punktmenge.

**Data** : Punkte  $P$ , an die das Modell angepasst werden soll  
**Result** : Modell  $M$ , falls ein ausreichend gutes Modell gefunden wurde

Wähle  $n$  Punkte aus  $P$  aus - genannt  $S$   
 Passe das Modell an  $S$  an - genannt  $M$   
 Füge alle Punkte aus  $P$  zu  $M$  hinzu, die durch  $M$  abgedeckt werden (Schwellwert Abstand  $m$ )  
 Falls  $M$  nun genug Punkte hat (Schwellwert  $t$ )  
     Passe  $M$  an die erweiterte Punktmenge an  
 Falls  $M$  nicht genug Punkte hat  
     Fang von vorne an oder terminiere, falls die maximale Anzahl an Iterationen  $k$  erreicht ist

**Algorithmus 1** : RANSAC Algorithmus (aus [26])

Der Algorithmus besitzt mehrere freie Parameter:

- die maximale Anzahl an Iterationen  $k$
- der Wert  $n$  entscheidet, mit wie vielen Punkten das Anfangsmodell gebildet wird
- der Schwellwert  $m$  entscheidet, ab welcher Distanz ein Punkt  $p$  durch ein Modell  $M$  abgedeckt wird

- der Schwellwert  $t$  entscheidet, wie viele Punkte durch das gefundene Modell abgedeckt werden müssen, damit dieses ein gültiges Ergebnis darstellt.

Die Werte  $n$  und  $t$  können als absolute Werte oder als prozentualer Anteil der eingegebenen Datenpunkte festgelegt werden. Die Anzahl der zufällig ausgewählten Anfangspunkte  $n$  kann auf die minimale Anzahl von Punkten gesetzt werden, die notwendig ist, um die Parameter des Modells eindeutig festzulegen. Da die Verfahren zur Bestimmung der Parameter für das Modell unterschiedlich sind und Verfahren wie lineare Regression auch mit größeren Punktmengen umgehen können, kann die Anzahl der Startpunkte auch höher gewählt werden.

Da der Algorithmus auch ohne Ergebnis terminieren kann, bietet die Festlegung des Schwellwertes  $t$  die Möglichkeit, zu bestimmen, ob gar kein Ergebnis einem schlechten Ergebnis vorgezogen wird. Falls die Eingangsdaten einen hohen Anteil an Rauschen oder Ausreißern aufweisen, kann durch prozentuale Festlegung von  $t$  festgelegt werden, dass das gesuchte Modell mindestens 90% der eingegebenen Punkte abdecken muss.

Die Anzahl der Iterationen  $k$  kann stochastisch abgeschätzt werden, wenn die Wahrscheinlichkeit  $w_n$  bekannt ist, die angibt, wie wahrscheinlich es ist, dass ein zufällig ausgewählter Punkt zu den Punkten gehört, die durch das zu findende Modell abgedeckt werden sollen. Die Gegenwahrscheinlichkeit  $1 - w_n$  beschreibt also, wie viele der Punkte grobe Ausreißer sind. Der Erwartungswert von  $k$  ist (nach [26]):

$$b = (1 - w_n)$$

$$E(k) = b + 2*b*(1-b) + 3*b*(1-b)^2 + \dots + i*b*(1-b)^{i-1} + \dots = \frac{1}{b} = w^n \quad (1)$$

$$\sigma(k) = \sqrt{E(k^2) - E(k)^2} = \sqrt{1 - w^n} * \frac{1}{w^n}$$

Somit kann ein geeigneter Wert für die Anzahl an Iterationen durch Erwartungswert und Standardabweichung gebildet werden. Das Problem kann aber auch anders angegangen werden, indem man festlegt, dass die Wahrscheinlichkeit, dass zu Beginn einer Iteration ausschließlich gute Datenpunkte ausgewählt werden, mindestens  $p$  betragen soll.

$$(1 - p) = (1 - w^n)^k \quad (2)$$

$$k = \frac{\ln(1 - p)}{\ln(1 - w^n)} \quad (3)$$

## 2.5 Kalman Filter

Bei der Auswertung von Sensorinformationen gibt es einige Herausforderungen zu bewältigen, beispielsweise starkes Rauschen oder widersprüchliche

Messungen. Eine Lösung, die statistisch in vielerlei Hinsicht als optimal gesehen werden kann, wurde bereits 1960 von Kalman vorgestellt [27]. Das als Kalman Filter bekannte Verfahren liefert eine Schätzung für den Zustand des Systems, die sowohl von mehreren Sensoren und deren Genauigkeit, als auch aller bisherigen Messwerte der Sensoren abhängt [28].





Abbildung 9: Voraussage des Kalman-Filters, basierend auf zwei bestehenden Messungen des Systemzustands (nach [29])

Die Schätzung des Filters ist unter folgenden Annahmen als optimal anzusehen, insofern, als dass sie den statistischen Fehler minimiert [29].

- Das zu modellierende System muss linear sein, da die vom Filter verwendete Vorhersage durch eine lineare Abbildung beschrieben wird.
- Das Rauschen der Sensoren muss weiß sein, das heißt, es muss sich über das gesamte Frequenzband gleichmäßig erstrecken und es darf keine Korrelation zur Zeit geben.
- Das Rauschen, sowohl der Sensordaten als auch das der Systemvorhersage, muss als Normalverteilung beschrieben werden können.

Der Kalman Filter arbeitet in diskreten Zeitintervallen, in denen jeweils neue Messungen der Sensoren vorliegen. Für jede Messung besteht die Schätzung des Zustands aus zwei Schritten, die auch als Vorhersage und Korrektur bezeichnet werden.



Im ersten Schritt wird aus den bisher erhaltenen Daten eine a-priori-Schätzung des Zustands rekursiv errechnet:

$$x_k^- = Ax_{k-1} + Bu_{k-1}$$

dabei ist  $A$  eine lineare Abbildung, die aus dem Zustand  $x_{k-1}$  den Zustand  $x_k$  berechnet. Das Matrixprodukt  $Bu_{k-1}$  ist optional und gibt einem die Möglichkeit Steuerungsbefehle  $u_{k-1}$ , die den Zustand  $x_k$  beeinflussen, bei der a-priori-Schätzung miteinzubeziehen.

Die Kovarianzmatrix wird ebenfalls a-priori geschätzt:

$$P_k^- = AP_{k-1}A^T + Q$$

dabei ist  $Q$  die Kovarianzmatrix des Filterrauschens und  $P_{k-1}$  die alte Kovarianzmatrix des vorherigen Schritts. Durch Schätzung der Kovarianzmatrix existiert nun ein Maß, wie groß die Konfidenz in die a-priori-Schätzung des Zustands ist. Dies ist von Vorteil, um im nächsten Schritt zu bestimmen, wie stark diese Zustandsschätzung durch den neuen Messwert beeinflusst werden soll.

$$K_k = P_k^- H^T (H P_k^- H^T + R)^{-1}$$

Der als „Kalman-Gain“ bezeichnete Faktor  $K_k$  bestimmt, wie groß der Einfluss der neuen Sensordaten auf die Schätzung sein wird. Er ist abhängig von der a-priori-Kovarianzmatrix  $P_k^-$ , der Matrix  $H$ , die eine Abbildung zwischen Zustand und Messung darstellt, und der Kovarianzmatrix des Sensorrauschens  $R$ .

Im Korrektur-Schritt fließt die neue Messung in die Schätzung ein:

$$\hat{x}_k = x_k^- + K_k(z_k - Hx_k^-)$$

$$P_k = (I - K_k H) P_k^-$$

Hier wird die Rolle des Faktors  $K_k$  deutlich. Wenn gar kein Sensorrauschen vorhanden ist, besteht die korrigierte Schätzung des Zustands nur noch aus dem neuen Sensorwert:

$$\lim_{R_k \rightarrow 0} K_k = H^{-1}$$

und damit

$$\lim_{R_k^- \rightarrow 0} \hat{x}_k = x_k^- + H^{-1}(z_k - Hx_k^-) = H^{-1}z_k$$

Wenn auf der anderen Seite die Kovarianz des Filters gegen 0 strebt, wird der a-priori-Schätzwert ohne Rücksicht auf den neuen Messwert übernommen:

$$\lim_{P_k^- \rightarrow 0} K_k = 0$$

und damit

$$\lim_{P_k^- \rightarrow 0} \hat{x}_k = x_k^-$$

*Einsatz:* Die Vorteile des Kalman Filter sind seine Optimalität, die Möglichkeit der effizienten Berechnung und seine Robustheit. Er findet sowohl in seiner ursprünglichen Form, als auch in Form zahlreicher Erweiterungen, Anwendung in den Bereichen Lokalisierung, Navigation und Sensordatenverarbeitung. Im Zuge der Spurerkennung wird er in den meisten Arbeiten zur Stabilisierung der Ergebnisse genutzt (siehe [\[13\]](#)[\[16\]](#)[\[17\]](#)[\[11\]](#)[\[30\]](#)[\[31\]](#)).

### 3 Straßenerkennung

Die Aufgabe der Straßenerkennung ist es, die Punkte einer Punktwolke zu extrahieren, die zur Straßenoberfläche gehören. Neben den Hindernissen abseits der Straße stellen vor allem andere Verkehrsteilnehmer eine Herausforderung dar, da sie in Bewegung sind und somit mehrfach als Hindernis wahrgenommen werden könnten. Aus diesem Grund werden die Daten für jede Umdrehung des Sensors einzeln ausgewertet und klassifiziert bevor eine Zusammenfügung mit Daten vorheriger Messungen geschieht.

#### 3.1 Höhenniveaus

Der einfachste Ansatz zur Extraktion der Straßenoberfläche ist es, die Straße als Ebene unter dem Fahrzeug zu betrachten und alle Punkte zu verwerfen, die zu weit von ihr entfernt liegen. Da das Rauschen des Sensors mit der Distanz zunimmt, existiert allerdings kein globaler Schwellwert für die Entfernung von der Ebene, der die Punkte korrekt trennt (siehe Abb. 10).




Abbildung 10: links: Artefakt eines stehenden Autos, rechts: Artefakte eines fahrendes Autos

#### 3.2 Repräsentation der Messdaten

Um die Straßenoberfläche zu extrahieren wird daher ein umgekehrter Ansatz gewählt. Es wird nach allen Punkten gesucht, die nicht zur Straßenoberfläche gehören, sogenannten Hindernissen. Um die Interpretation und Verarbeitung der Sensordaten möglichst präzise und effizient zu gestalten, sollte die Datenstruktur die folgenden Aufgaben erleichtern:

- Bordstein- und Hinderniserkennung
- Erstellung eines Bildes der Straßenoberfläche
- Verwerfen aller Punkte hinter einem entdeckten Hindernis
- Verarbeitung der Intensitäten

### 3.2.1 Gitternetz

Eine Möglichkeit besteht darin, die XY-Ebene in verschiedene Zellen zu unterteilen. Zur Hinderniserkennung kann überprüft werden, in welcher Zelle besonders viele Punkte liegen oder wie groß der Abstand zwischen minimalen und maximalem Z-Wert ist. Ein weiterer Vorteil ist, dass die Transformation zu einem Bild der Straßenoberfläche aufgrund der Strukturähnlichkeit vereinfacht wird.




Abbildung 11: Rot: erkannte Hindernisse, Orange: verworfener Bereich hinter einem Hindernis

Die Berechnung der Schatten der Hindernisse ist jedoch sehr ungenau, wodurch Messpunkte der Straßenoberfläche verloren gehen können (Abb. 11). Die Verarbeitung der Intensitäten kann durch Erstellen eines Histogramms für jede Distanz und anschließender Angleichung geschehen. Dabei ist jedoch problematisch, dass möglicherweise Messpunkte verschiedener Laser in derselben Zelle gespeichert sind und somit vermischt werden, wodurch die baulichen Unterschiede der Laser nicht mehr ausgeglichen werden können.

### 3.2.2 Polares Gitternetz

Eine weitere denkbare Struktur ist das polare Gitternetz, das auch in [17] Verwendung findet.

Ein Vorteil der Struktur für die Normalisierung der Intensitäten ist, dass alle auf einem Ring liegenden Punkte einen ähnlichen Abstand zum Sensor

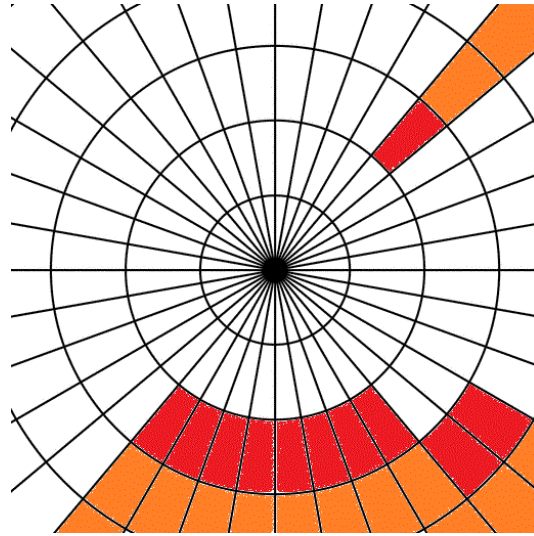


Abbildung 12: Rot: erkannte Hindernisse, Orange: verworfener Bereich hinter den Hindernissen

haben und damit auch einen ähnlichen Beleuchtungswinkel. Es ist außerdem leichter, Zellen anhand der Menge der Punkte als Hindernis zu klassifizieren. Man benötigt dafür nur einen globalen Schwellwert, da die Tatsache, dass die einzelnen Zellen in der Ferne größer werden, durch den Umstand, dass die Dichte der Messpunkte in der Entfernung geringer wird, wieder aufgehoben wird. Die Berechnung der Schatten der Hindernisse ist präzise und effizient (siehe Abb. 12).

Für eine gute Klassifizierung ist die Größe der Zellen sowohl im Winkel  $\alpha$  als auch der Länge  $l$  entscheidend. Wenn die Größe zu klein gewählt wird, kann es passieren, dass Hindernisse nicht mehr anhand einer Zelle erkannt werden können, da die Punkte auf mehrere Zellen verteilt wurden. Werden andererseits die Zellen zu groß gewählt, wird das Ergebnis zu ungenau. Dies hätte zur Folge, dass Punkte verworfen werden, da diese zu nah an einem Hindernis liegen und somit zu derselben Zelle gezählt werden.

### 3.2.3 Sensorbild

Eine direkte und damit effiziente Möglichkeit der Speicherung ist, ein Bild der vom Laser gesammelten Daten zu erstellen. In einem solchen Bild werden in jeder Zeile die Daten eines Lasers für verschiedene horizontale Winkel dargestellt.

Jeder Laser misst die Entfernungen und Intensitäten entlang eines Rings um das Fahrzeug. Wenn das Fahrzeug eben auf einer Ebene steht, ist die gemessene Entfernung zur Straßenoberfläche für alle Winkel konstant. Wenn der Laser jedoch auf ein Hindernis stößt, wird eine geringere Tiefe gemessen. Im




Abbildung 13: Oben: gemessene Intensitäten, Unten: gemessene Distanz

nächsten Abschnitt wird beschrieben, wie dadurch eine Hinderniserkennung realisiert werden kann. Diese Darstellungsform behält polare Eigenschaften, da jede Spalte die Messungen aus einem horizontalen Winkel darstellt. Dadurch bleibt das Werfen von Schatten hinter den Hindernissen präzise und effizient.

Struktur	Hinderniserkennung	Schatten	Intensitäten
Gitternetz	je Zelle	ungenau	je Distanz
Polargitter	je Zelle	genau	je Distanz
Sensorbild	je Messpunkt	genau	je Laser

Es ist zu erwarten, dass eine Hinderniserkennung je Messpunkt ein präziseres Ergebnis liefert, als eine Klassifizierung der Zellen einer Gitterstruktur. In [3] wurde bereits festgestellt, dass die Klassifizierung einzelner Zellen aufgrund von Messungenauigkeiten problematisch ist. Es konnte kein Schwellwert gefunden werden, der einerseits klein genug für eine Erkennung von besonders kleinen Hindernissen wie Bordsteinen ist und andererseits eine geringe False-Positive-Rate aufweist. Die Normalisierung der Intensitäten ist ebenfalls ein Vorteil des Sensorbildes, da im Gegensatz zu den Gitterstrukturen die Intensitäten der verschiedenen Laser nicht gemeinsam, sondern getrennt betrachtet werden und dadurch bauliche Unterschiede zwischen den Lasern ausgeglichen werden können.

### 3.3 Bordstein- und Hinderniserkennung


In diesem Abschnitt wird gezeigt, wie eine Erkennung von Hindernissen anhand der unverarbeiteten LIDAR-Daten funktioniert. Die gesammelten Daten einer Umdrehung bestehen für jeden der 64 Laser aus 2000 Messungen, die jeweils in einem anderen horizontalen Winkel ausgeführt wurden. Eine Messung  $x_{ij} = (\alpha_i, \theta_j, r_{ij}, I_{ij})$  besteht aus den Werten:

$\alpha_i$  der vertikale Montagewinkel des Lasers  $i$

$\theta_j$  der horizontale Winkel der Messung  $j$  (Azimuth)

$r_{ij}$  die gemessene Tiefe des Lasers  $i$  in Richtung  $(\alpha_i, \theta_j)$

$I_{ij}$  die gemessene Intensität (wird in diesem Abschnitt nicht verwendet)

Abbildung 14: Messung der Distanz  $r$  im Winkel  $\alpha$  aus der Höhe  $y$ 

Da der Winkel  $\alpha_i$  und die Montagehöhe  $y$  des Sensors bekannt und unveränderlich sind, kann durch  $\hat{r}_i = \frac{y}{\sin \alpha_i}$  der erwartete Messwert  $\hat{r}_i$  für jeden Laser bestimmt werden (Abb. 14).

Bei einer großen Abweichung vom Erwartungswert kann davon ausgegangen werden, dass ein Hindernis oder ein Abgrund vorliegt. Die in einer Umdrehung des Sensors abgetastete Umgebung jedes Lasers entspricht dem Mantel eines Kegels. Die Schnittpunkte mit der Straßenebene bilden in Abwesenheit von Rollen und Nicken des Fahrzeugs einen Kreis.




Abbildung 15: Der Abstand zwischen den Kreisen der Laser 0 und 1 wird durch ein Hindernis gestört

Für die Erkennung von kleinen Hindernissen ist es aufgrund von Ungenauigkeiten in den Messungen sinnvoll, den Abstand der Kreise zueinander zu betrachten, anstatt getrennte Erwartungswerte für die Kreise festzulegen (siehe Abb. 15). Hinzu kommt, dass die Kreise durch Roll- und Nickbewegungen des Fahrzeugs zu Ellipsen werden, deren Form sich mit der Zeit verändert. Aus diesen Gründen wird in [3] empfohlen, den Abstand eines Ringes als Funktion der gemessenen Distanz aufzufassen.

### 3.3.1 Umsetzung

Gesucht ist eine Funktion  $d(i + 1) = a * d(i)$ , die die erwartete Distanz für den Laser  $i + 1$  basierend auf der Messung von Laser  $i$  beschreibt. Da jedoch der Abstand  $\alpha_{i+1} - \alpha_i$  zwischen zwei Lasern nicht gleichmäßig ist, kann kein Wert  $a$  gefunden werden, der für alle Laser funktioniert. Sinnvoller ist daher eine Funktion, bei der ein Wert  $a_i$  für jeden Laser festgelegt wird, der vom Abstand des Lasers zu seinem Nachbarn  $\alpha_{i+1} - \alpha_i$  abhängt. Um eine solche Funktion im vorhinein festzulegen, bedarf es präziser Informationen über die vertikale Ausrichtung  $\alpha_i$  jedes Lasers. In der Praxis hat sich herausgestellt, dass die vom Hersteller gelieferten Angaben zur vertikalen Ausrichtung der Laser für diesen Verwendungszweck zu unpräzise sind.

Durch die vorerst fehlenden Kalibrierungsdaten können keine präzise Erwartungswerte definiert werden. Daher muss zunächst auf ein einfacheres Modell für die Hinderniserkennung zurückgegriffen werden.

### 3.3.2 Vertikale Hinderniserkennung

Im vereinfachten Modell wird zuerst jede Messung  $x_{ij} = (\alpha_i, \theta_j, r_{ij}, I_{ij})$  im Vergleich zur Messung  $x_{i+1,j}$  des darüberliegenden Lasers betrachtet. Eine mögliche Heuristik zur Detektion von Hindernissen lautet: die gemessene Distanz des höher strahlenden Lasers darf nicht kleiner sein, als die des niedriger ausgerichteten Lasers.

$$C_v(x_{ij}) = \begin{cases} 1 & r_{ij} \geq r_{i+1,j} \\ 0 & \text{sonst} \end{cases}$$

Für große Hindernisse ist diese Heuristik zur Erkennung bereits ausreichend (Abb. 16). Sie bietet außerdem den Vorteil, unabhängig von der genauen Ausrichtung der einzelnen Laser zu sein, solange zumindest die Reihenfolge der Laser in vertikaler Richtung bekannt ist.



Abbildung 16: Klassifikation durch vertikales Vergleichen

### 3.3.3 Horizontale Hinderniserkennung

Im Gegensatz zur vertikalen Hinderniserkennung arbeitet die horizontale Hinderniserkennung nicht auf lokaler Ebene. Ein lokaler Vergleich zwischen den Messungen  $x_{i,j}$  und  $x_{i,j+1}$  des gleichen Lasers würde lediglich den Rand eines Hindernisses sichtbar machen. Da die vertikale Hinderniserkennung bereits grobe Hindernisse erkannt hat, kann davon ausgegangen werden, dass

die meisten Messungen, die nicht als vertikale Hindernisse klassifiziert wurden, die Distanz und Intensität der Straßenoberfläche beinhalten. Daher funktioniert nun folgende Heuristik: Ein Punkt ist ein horizontales Hindernis, wenn der Abstand zwischen der gemessenen Distanz  $r_{ij}$  und dem Mittelwert  $\mu_i$  aller gemessenen Distanzen dieses Lasers größer ist als ein bestimmter Schwellwert  $t$ .

$$C_h(x_{ij}) = \begin{cases} 1 & |r_{ij} - \mu_i| \geq t \\ 0 & \text{sonst} \end{cases}$$

$$\text{mit } \mu_i = \frac{1}{n} \sum_{j=1}^n r_{ij}$$



Abbildung 17: Klassifikation durch horizontales Vergleichen

Im Bild ist die horizontale Hinderniserkennung mit einem Schwellwert von 10% des Mittelwerts  $\mu_i$  zu sehen. Im Vergleich zur vertikalen Klassifizierung ist jedoch zu beobachten, dass weit entfernte und sehr nahe Hindernisse nicht so zuverlässig erkannt wurden.

### 3.3.4 Kombination der Klassifikationen

Die Ergebnisse der beiden Heuristiken werden durch ein logisches Oder verknüpft. Um Sensorrauschen zu kompensieren, werden isolierte Punkte, die als Hindernis markiert wurden, ignoriert. Im folgenden Schritt wird die Klassifikation in jeder Zeile nach oben hin fortgesetzt, um die Bereiche hinter den Hindernissen zu verwerfen (Abb. 19).



Abbildung 18: Verknüpfung der horizontalen und vertikalen Klassifikation

### 3.3.5 Kalibrierung durch Rückkopplung

Bis hierhin wurde die ursprüngliche Idee eines Erwartungswerts für jeden Laser mangels präziser Kalibrierungsdaten verworfen und durch einfachere



Abbildung 19: Endgültige Klassifikation mit Hindernis-Schatten

Heuristiken ersetzt. Mithilfe dieser Heuristiken wurde eine Hinderniserkennung umgesetzt, die eine gute Trennung zwischen Straßenoberfläche und Hindernissen leistet. Mithilfe dieser Daten ist es nun wiederum möglich, eine Kalibrierung der einzelnen Laser zu erstellen, da die Punkte der Straßenoberfläche nahezu einer ebenen, freien Fläche entsprechen.

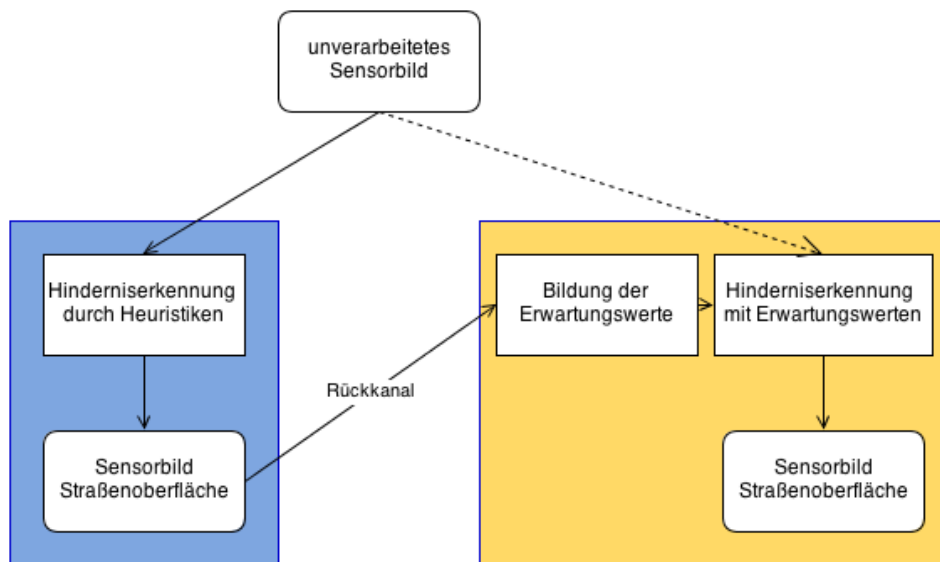


Abbildung 20: Feedback-Schleife zur Hinderniserkennung

Zur Erkennung von Hindernissen wurden zwei miteinander verwandte Werte gebildet: Zum Einen wird für jeden Laser der Median aller Distanzmessungen der Straßenoberfläche gebildet. Zum anderen wird der Median des Abstands zwischen zwei Laserringen gebildet. Wird nun bei einer Messungen entweder die Tiefeninformation oder der Abstand zum nächsten Ring um mehr als 10% des Median überschritten, liegt ein Hindernis vor. Das Ergebnis dieses Verfahrens ist zwar ebenso eine funktionierende Hinderniserkennung, es ergibt sich jedoch keine signifikant bessere Erkennungsrate gegenüber den vorgestellten Heuristiken.

## 4 Fahrspurerkennung

### 4.1 Aufgabenstellung

Nachdem im vorherigen Schritt bereits alle Punkte, die nicht Teil der Straßenoberfläche sind, entfernt wurden, sollen nun die Spurmarkierungen extrahiert werden. Als Daten stehen dazu nur die Intensitäten der Remissionsstrahlung in Form eines Sensorbilds zur Verfügung, da die Tiefeninformationen keine Unterscheidung zwischen Spurmarkierung und Straßenoberfläche zulassen.

Gegeben sei eine Menge von Messungen

$$x_{ij} = (\alpha_i, \theta_j, r_{ij}, I_{ij})$$

Gesucht wird ein binärer Klassifikator

$$C(x_{ij}) = \begin{cases} 1 & x_{ij} \text{ ist Spurmarkierung} \\ 0 & \text{sonst} \end{cases}$$

### 4.2 Probleme der Sensorbilder




Abbildung 21: Spurmarkierungen mit hoher Reflektivität

In Abb. 21 ist der Optimalfall dargestellt, in dem sich die Reflektivität der Markierungen deutlich von der des Asphalts abhebt. Ein so hoher Kontrast ist meist nur auf Autobahnen anzutreffen, auf denen die Farbe frisch aufgetragen wurde.




Abbildung 22: Spurmarkierungen mit niedriger Reflektivität

In Abb. 22 lässt sich mit dem Auge eine noch eine Linie ausmachen, es ist jedoch unmöglich, einzelne Streifen zu identifizieren. Des Weiteren weisen die gemessenen Intensitäten der Nachbarspur ein besonders starkes Rauschen auf.

Während Probleme wie eine niedrige Reflektivität der Spurmarkierungen auf die verwendete Farbe und Verschmutzung, z.B. durch Reifenabrieb, zurückgeführt werden können, gibt es jedoch auch Probleme die durch den LIDAR

entstehen. Die Helligkeit der einzelnen Laser unterscheidet sich teilweise untereinander stark. Es gibt einige Laser, die lediglich niedrige Intensitäten messen und somit kaum Informationen liefern. Umgekehrt gibt es auch Laser, die ausschließlich hohe Intensitäten zurückliefern.

### 4.3 Schwellwert-Ansatz

Ein simpler und weit verbreiteter Ansatz zur Klassifizierung der Messpunkte ist der Vergleich mit einem festgelegten oder dynamischen Schwellwert. Bei diesem Verfahren werden weder die Form noch der Ort des Messpunktes betrachtet, sondern lediglich die gemessene Intensität.

$$C(x_{ij}) = \begin{cases} 1 & I_{ij} \geq t \\ 0 & \text{sonst} \end{cases}$$

Genau so wichtig wie die Wahl des Schwellwertes ist es, dass die Intensitäten der einzelnen Messungen miteinander vergleichbar sind. In den unverarbeiteten Intensitätsdaten der Sensors gibt es Laser, deren dunkelste Messung heller ist als alle Messungen eines anderen Lasers, obwohl beide Laser einen vergleichbaren Abschnitt abtasten.

#### 4.3.1 Angleichung der Intensitätsniveaus

Zur Vergleichbarkeit der Messungen wird für jeden Laser der arithmetische Mittelwert seiner Messungen gebildet:

$$\mu_i = \frac{1}{n} \sum_{j=1}^n I_{ij}$$

$n \hat{=}$  Anzahl der Messungen eines Lasers

Anschließend wird ein gemeinsames Referenzniveau für alle Mittelwerte festgelegt:

$$\Phi = \frac{1}{m} \sum_{i=1}^m \mu_i$$

$m \hat{=}$  Anzahl der Laser

Zu allen Messungen eines Lasers wird als Korrekturkonstante die Differenz des Lasers zum Referenzniveau addiert:

$$I'_{ij} = I_{ij} + (\Phi - \mu_i)$$




Abbildung 23: Vergleich zwischen unkorrigierten (links) und korrigierten Intensitätswerten (rechts)

#### 4.3.2 Statischer Schwellwert

Bei der Wahl des Schwellwerts  $t$  gibt es die Möglichkeit einen konstanten Schwellwert für alle Sensorbilder zu verwenden. Dieser Ansatz ist einfach, funktioniert aber nur unter der Annahme, dass die Intensitäten in allen Szenarien auf dem gleichen Niveau liegen. Dies ist jedoch nicht der Fall, da die Materialwahl der Straßenoberfläche und der Farbe in verschiedenen Orten zu unterschiedlichen Intensitätsniveaus führen.

#### 4.3.3 Adaptive Schwellwertverfahren

Statt eines konstanten Schwellwertes kann je nach Verteilung der Intensitäten ein adaptives Schwellwertverfahren angewandt werden [32]. Da adaptive Schwellwertverfahren immer versuchen, die bestmögliche Trennung zwischen zwei Intensitätsklassen zu finden, liegt ihnen die Annahme zugrunde, dass überhaupt mehrere Intensitätsklassen vorliegen. Dies ist dann problematisch, wenn im Sensorbild gar keine Spurmarkierungen durch die Intensität zu erkennen sind und in Folge dessen ein adaptiver Schwellwert berechnet wird, der fälschlicherweise die Straßenoberfläche selbst in mehrere Klassen aufteilt. Die Verfahren funktionieren nur dann gut, wenn eine bimodale Verteilung der Intensitäten vorliegt. Leider liegt stattdessen jedoch ein stetiger Übergang zwischen den beiden Klassen vor (Abb. 24).

#### 4.3.4 Statistischer Schwellwert

Da die Daten keine gesunde Grundlage für adaptive Verfahren bilden, wird ein Schwellwert gewählt, der aus einer festgelegten Kombination der statistischen Kennzahlen der Verteilung der Intensitäten basiert. Eine gute Klassifikation liefert der Schwellwert

$$t = \Phi + \frac{1}{10}\sigma^2$$

Der globale Mittelwert aller Laser  $\phi$  wurde bereits für die Korrektur der Laserintensitäten verwendet. Darüber hinaus wird nun nach der Korrektur die Varianz  $\sigma^2$  bestimmt und anteilig addiert.




Abbildung 24: Intensitätsverteilung in den Messungen der Fahrbahnoberfläche

#### 4.4 Koordinaten-Transformation

In diesem Schritt sollen die Messungen aus der Form  $(\alpha_i, \theta_j, r_{ij}, I_{ij})$  in Werte der Form  $(x, y, z, I)$  überführt werden, um die gewonnenen Informationen für Steuerbefehle oder die Lokalisation in einer virtuellen Umgebungskarte verwertbar zu machen. Die Koordinaten bleiben vorerst relativ zur Position des Scanners, um unabhängig vom GPS-System und den damit verbundenen Problemen zu bleiben. Allgemein lässt sich eine Rotation eines Vektors um alle drei Achsen durch Multiplikation mit folgender Matrix berechnen:

$$R = \begin{pmatrix} \cos \alpha \cos \beta & \cos \alpha \sin \beta \sin \gamma - \sin \alpha \cos \gamma & \cos \alpha \sin \beta \cos \gamma + \sin \alpha \sin \gamma \\ \sin \alpha \cos \beta & \sin \alpha \sin \beta \sin \gamma + \cos \alpha \cos \gamma & \sin \alpha \sin \beta \cos \gamma - \cos \alpha \sin \gamma \\ -\sin \beta & \cos \beta \sin \gamma & \cos \beta \cos \gamma \end{pmatrix}$$

$\alpha \hat{=}$  Rotation um die z-Achse  $\hat{=}$  Gieren

$\beta \hat{=}$  Rotation um die y-Achse  $\hat{=}$  Nicken

$\gamma \hat{=}$  Rotation um die x-Achse  $\hat{=}$  Rollen

Da wir aber keine globalen Koordinaten benötigen, können wir die Ausrichtung des lokalen Koordinatensystems beliebig festlegen. Der Einfachheit halber wird eine Ausrichtung des Lasers entlang der x-Achsen festgelegt. Dadurch kann die Rechnung vereinfacht werden:

$$R * (1, 0, 0) * r_{ij} = \begin{pmatrix} \cos \alpha \cos \beta \\ \sin \alpha \cos \beta \\ -\sin \beta \end{pmatrix} * r_{ij}$$

Somit erhalten wir aus dem vertikalen Winkel des Lasers und dem horizontalen Winkel der Messung, sowie der gemessenen Distanz einen Punkt  $(x, y, z)$

relativ zur Scannerposition. Die Intensität wird bei der Transformation unverändert übernommen.

## 4.5 Polynomannpassung

Nachdem bereits die Messungen, die zu Spurmarkierungen gehören, gefunden und in eine Punktwolke  $(x, y, z, I)$  transformiert wurden, soll nun erkannt werden, wie viele und welche Art von Spuren vorliegen.

Das Spurmodell beschränkt sich auf ein Polynom zweiter Ordnung, da die erforderliche Punktdichte zur Erkennung der Markierungen nur in einem relativ kurzen Bereich vor dem Fahrzeug erreicht wird.

$$P(x) = cx^2 + bx + a$$

Um eine erste Spur zu finden, wird angenommen, dass das Fahrzeug in einer Spur fährt, die auf beiden Seiten des Fahrzeugs durch eine Markierung abgeschlossen ist. Diese Annahme dient dazu, eine erste Spur zu finden, um Rückschlüsse auf die Positionen weiterer Spuren zu ziehen. Die Annahme, dass das Fahrzeug in einer Spur fährt muss nur für die initiale Messung gültig sein. Sobald eine Spur zuverlässig erkannt wurde, kann diese für die folgenden Messungen als Ausgangsspur dienen.

Um genaue Informationen über die Richtung und den Verlauf des Spur zu bekommen, werden alle Punkte in einem 3m breiten Bereich um die erste Markierung betrachtet und die Spurparameter angepasst. Grundlegende Aufgabe dabei ist es, ein Polynom zweiten Grades zu finden, das möglichst gut auf den Spurmarkierungen *sitzt*. Das Bewertungsmaß kann dabei unterschiedlich definiert werden.

### 4.5.1 Lineare Regression

Eine Möglichkeit einen guten *Sitz* zu definieren, besteht in der Minimierung der quadratischen Abweichung zwischen den Messpunkten und dem Polynom.

$$E(\vec{p}) = \frac{1}{n} \sum_{i=1}^n [y_i - f(x_i)]^2$$

Das Polynom mit dem kleinsten quadratischen Fehler lässt sich durch folgenden Formel finden

$$\vec{p} = (X^T X)^{-1} X^T \vec{y}$$

Ein Problem des quadratischen Fehlermaßes für unsere Anwendung ist jedoch, dass Ausreißer einen unproportional großen Einfluss auf das Ergebnis haben (siehe Abb. 25).




Abbildung 25: Lineare Regression: Grün: Mit Ausreißer, Blau: Ohne Berücksichtigung des Ausreißers

Da sich Ausreißer nicht von vornherein verhindern lassen, wird ein Verfahren benötigt, das Ausreißer erkennt und entsprechend weniger stark berücksichtigt. Ein solches Verfahren ist das in Abschnitt 2.4 beschriebene Random Sample Consensus.

#### 4.5.2 Anwendung von RANSAC zur Polynomannpassung

Das gerade beschriebene Verfahren der kleinsten Quadrate liefert in Abwesenheit von Ausreißern bereits die gewünschten Polynome. Das RANSAC-Verfahren soll in diesem Zusammenhang den Einfluss von Ausreißern reduzieren oder eliminieren. Dazu wird das Verfahren mit folgenden Parametern angewandt:

- die Anzahl an Iterationen  $k$ : Experimente zeigen keinen großen Einfluss auf das Ergebnis, ein relativ geringer Wert von 3 verhindert die Verschwendung von Rechenzeit, falls kein Modell gefunden werden kann.
- der Wert  $n$  entscheidet, mit wie vielen Punkten das Anfangsmodell gebildet wird: ein Wert von 10 Punkten erhöht die Chance, Punkte aus verschiedenen Strichen auszuwählen, wodurch das Startpolynom bereits einen guten Sitz auf den Daten erhält.
- der Schwellwert  $m$  entscheidet, ab welcher Distanz ein Punkt  $p$  durch ein Modell  $M$  abgedeckt wird:  $\frac{40cm}{2}$ , der Abstand sollte nicht größer als eine halbe Spurmarkierung groß sein.

- der Schwellwert  $t$  entscheidet, wie viele Punkte durch das gefundene Modell abgedeckt werden müssen, damit das Ergebnis angenommen wird: Mindestens 25 und mindestens 90% aller Punkte.

Es zeigt sich, dass RANSAC in der Lage ist, Ausreißer aus der linearen Regression auszuschließen und dadurch die Polynomanpassung zu stabilisieren, solange die Anzahl der Ausreißer nicht zu groß wird.

Falls die eingegebenen Punkte keine Spurmarkierungen, sondern hauptsächlich aus verrauschten Messungen besteht, zeigt sich ein anderer Vorteil von RANSAC. Durch die Festlegung, dass mindestens 90% der Punkte im Bereich von 20cm am Polynom liegen müssen, würde in diesem Fall kein passendes Polynom gefunden werden. Eine direkte Anwendung von linearer Regression würde in dieser Region ein beliebig wechselndes Polynom zurückgeben.

### 4.5.3 Regionale Aufteilung

Anhand der so gefundenen Markierungen werden die übrig gebliebenen Punkte in Streifen unterteilt, deren Breite und Richtung der gefundenen Spur entspricht.




Abbildung 26: Aufteilung des Umfeldes in Regionen, markiert in 6 verschiedenen Farben

Für jeden Bereich wird durch Anwendung von RANSAC ein Polynom gesucht, das die Richtung und den Verlauf der Spurmarkierungen repräsentiert. Dabei wird ausgenutzt, dass in Bereichen, in denen keine Spurmarkierung erkennbar sind, durch RANSAC kein Polynom zurückgegeben wird. In Bereichen, in die keine Messpunkte fallen, wird durch die Angabe einer Mindestanzahl an Punkten durch RANSAC ebenfalls kein Polynom zurückgegeben (siehe grüner Bereich am oberen Bildrand in Abb. 27).




Abbildung 27: Angepasste Spurpolynome in Regionen, in denen die Kriterien des RANSAC-Algorithmus erfüllt sind




Abbildung 28: Orange: erkannter Gehweg, Pink: nicht erkannter Gehweg

## 5 Ergebnisse

### 5.1 Hinderniserkennung

Die Ergebnisse der Hinderniserkennung bestätigen die Ergebnisse, die bereits in anderen Arbeiten gefunden wurden: Neben großen Hindernissen werden auch kleine Hindernisse wie Bordsteine erkannt (siehe auch [3]). Dadurch kann die Straßensoberfläche gut aus der gesamten Punktwolke extrahiert werden. Problematisch ist jedoch der in Abb. 28 gezeigte Fall, in dem der begrenzende Bordstein im toten Winkel des Scanners liegt.

Die gemessenen Tiefen lassen keine Unterscheidung der Höhenniveaus zwischen Straßensoberfläche und Gehweg zu. Die Erkennung ist darauf angewiesen, den Sprung zwischen den beiden Ebenen, den Bordstein, zu erfassen. Um dieses Problem zu lösen, müssen mehrere Messungen miteinander kombiniert werden. Im einfachsten Fall werden dazu die Messungen in einer gemeinsamen Karte eingetragen. Ein Problem dabei sind bewegliche Hindernisse, da sie in einer vereinigten Karte mehrfach vorkämen, und mehrfach als Hindernis erkannt würden. Ein anderer Ansatz ist, die erkannten Bordsteine als Punkte zu speichern und, ähnlich wie bei Spurerkennungen, eine Funktion an sie anzupassen. Auch in diesem Fall wäre eine Unterscheidung zwischen Bordstein und beweglichen Hindernissen von Nöten.

### 5.2 Spurerkennung

Bei der Erkennung von Spurmarkierungen fällt auf, dass der LIDAR-Sensor deutlich stärker auf einen guten Zustand der Fahrbahnmarkierungen angewiesen ist als Kameras. Für frisch aufgetragene Farbe auf Autobahnen ergibt sich ein deutlicher Kontrast zur Straßensoberfläche, während auf vielbefahrenen Kreuzungen kaum ein Unterschied in der Intensität erkennbar ist. Durch das Zusammenführen mehrerer Aufnahmen des Scanners und einer

Auswertung mithilfe von RANSAC konnte der Einfluss von Ausreißern verringert werden. In Szenarien, in denen sich ein unstrukturiertes Bild von Spurmarkierungen ergibt, gibt das System keine Spur aus.

Die meisten innerstädtischen Spurmarkierungen Berlins sind nicht deutlich genug vom Asphalt zu unterscheiden, sodass das System versagt. Auf der Autobahn oder gut gepflegten innerstädtischen Straßenabschnitten ist das System jedoch in der Lage, die eigene und auch die Nachbarspuren zu erkennen.

### 5.3 Vergleich

Die im Fahrzeug vom Hersteller verbaute Fahrspurerkennung arbeitet mit einer Kamera, die im Bereich der Stoßstange verbaut ist. Es liefert in den meisten Situationen gute Informationen über die linke und rechte Spurmarkierung der eigenen Fahrspur. Da Nachbarspuren jedoch so gut wie nie erkannt werden, ist sie im Gegensatz zum hier entwickelten System nicht für die Lokalisation des Fahrzeugs geeignet. Es gibt allerdings einige Situationen, in denen auch dieses System versagt und einen falschen Verlauf der Fahrspur ausgibt.

Aufgabe	Kamera	LIDAR
Stadtverkehr	Ja	eingeschränkt
Autobahn	Ja	Ja
Nachbarspuren	Nein	Ja

Es gibt also Vorteile beider Systeme, sowie auch Nachteile, die hauptsächlich durch die Schwächen der verwendeten Sensorik bedingt sind. Da die Schwächen von Kameras und LIDAR meistens in unterschiedlichen Szenarios zu Tage treten, ist es sinnvoll eine Kombination beider Systeme einzusetzen.

## 6 Fazit

### 6.1 Zusammenfassung

Zur Modellierung ihrer Umgebung und Planung von Fahrtmanövern erstellen autonome Fahrzeuge eine virtuelle Umgebungskarte, in der Informationen über den Straßenverlauf und andere Verkehrsteilnehmer zusammengetragen werden. Für eine sichere Fortbewegung des autonomen Fahrzeugs ist es notwendig, zu jedem Zeitpunkt die exakte Position des eigenen Fahrzeugs in dieser Karte bestimmen zu können. Die Lokalisation des Fahrzeugs geschieht in den meisten autonomen Fahrzeugen primär durch eine GPS-Einheit und wird dadurch unpräzise oder ist teilweise sogar gar nicht verfügbar.

Aktuelle Fahrspurerkennungssysteme arbeiten auf der Basis von Kameras, die im Frontbereich des Fahrzeugs montiert sind. Sie leisten in der Regel

zuverlässige Einschätzungen über die Position und den Verlauf der eigenen Fahrspur. Da die Position des Fahrzeugs in der virtuellen Umgebungskarte jedoch auch größeren Schwankungen ausgesetzt ist, ist es für die Lokalisation notwendig, neben der eigenen Fahrspur auch alle Nachbarspuren zu erkennen.

Für Erkennung aller Fahrspuren wird auf den Velodyne-LIDAR HDL-64e zurückgegriffen, da er die Umgebung des Fahrzeugs in allen Himmelsrichtungen abtastet und neben Tiefeninformationen auch Intensitäten liefert, die Rückschlüsse auf die Reflektanz der Oberfläche zulassen.

Der erste Teil der Arbeit beschäftigt sich mit der Extraktion der Straßenoberfläche aus den Messdaten, wobei auf verschiedene Probleme wie das Rauschen der Sensoren und die unterschiedliche Ausrichtung der einzelnen Laser eingegangen wird. Im zweiten Teil wird die Straßenoberfläche nach Punkten gefiltert, die eine besonders hohe Intensität aufweisen und eine Anpassung des Spurmodells an die gefundenen Punkte vorgenommen.

Bei der Auswertung des Systems wird deutlich, dass der Kontrast zwischen Asphalt und Fahrbahnmarkierungen in den Intensitätsmessungen von LIDAR-Scannern deutlich geringer ausfällt als in Grauwertbildern einer Kamera.

Das System ermöglicht auf gepflegten Straßenabschnitten die eigene und umliegende Fahrspuren zu erkennen und dabei vom GPS-Signal unabhängig zu bleiben.

## 6.2 Ausblick

Um die Extraktion der Straßenoberfläche zu verbessern, sollte das System um ein Modul erweitert werden, das bewegliche Hindernisse erkennt und verfolgt. Dadurch wäre es möglich, die erkannten Hindernisse aus vergangenen Aufnahmen des Scanners weiterzuverwenden und damit das Problem des toten Winkels zu eliminieren.

Für die Verbesserung der Intensitätsinformationen wäre es im Allgemeinen sinnvoll, eine Fusion mit den Daten der Kameras zu betreiben. Eine Hürde könnten dabei die benachbarten Spurmarkierungen sein, die aufgrund des Aufnahmebereichs der Sensoren durch deutlich weniger Kamerapunkte als LIDAR-Punkte erfasst würden.

Ein übliches Verfahren, um die Position der Spuren vorherzubestimmen, ist das Filtering mithilfe des Kalman Filters. Dieses Verfahren wurde in nahezu allen anderen Arbeiten eingesetzt, um die Erkennungen zu stabilisieren und sollte in Zukunft auch in dieses System integriert werden.

## Literatur

- [1] Dekra Automobil GmbH, *Verkehrssicherheitsreport 2012: Mensch und Technik*, 2012.
- [2] Transport Research Laboratory, *Study on lane departure warning and lane change assistant systems*, 2008.
- [3] M. Montemerlo, J. Becker, S. Bhat, H. Dahlkamp, D. Dolgov, S. Etinger, D. Haehnel, T. Hilden, G. Hoffmann, B. Huhnke, D. Johnston, S. Klumpp, D. Langer, A. Levandowski, J. Levinson, J. Marcil, D. Orenstein, J. Paefgen, I. Penny, A. Petrovskaya, M. Pflueger, G. Stanek, D. Stavens, A. Vogt, and S. Thrun, “Junior: The stanford entry in the urban challenge,” *Journal of Field Robotics*, 2008.
- [4] Autonomos Labs, *Made in Germany*, März 2013. <http://www.autonomos.inf.fu-berlin.de/made-in-germany>.
- [5] Volkswagen, *Technik-Lexikon*, 2012.
- [6] Velodyne LIDAR, Inc., *User’s Manual and Programming Guide HDL-64E S2*, Nov. 2012.
- [7] T. Fujii and T. Fukuchi, eds., *Laser Remote Sensing*. CRC Taylor & Francis, 2005.
- [8] F. Träger, *Springer Handbook of Lasers and Optics*. Springer Berlin Heidelberg, 2007.
- [9] S. Hempel, “Geometrierekonstruktion von LIDAR-Punktwolken zur Echtzeitverarbeitung für autonome Fahrzeuge,” Master’s thesis, Freie Universität Berlin, Berlin, 2009.
- [10] R. N. Clark, *Spectroscopy of Rocks and Minerals, and Principles of Spectroscopy*, vol. 3, ch. 1, pp. 3–58. New York: Wiley and Sons, 1999.
- [11] A. Kirchner and T. Heinrich, “Model based detection of road boundaries with a laser scanner,” in *Proceedings of IEEE Int. Symp. on Intelligent Vehicles*, pp. 93–98, 1998.
- [12] A. Huang, D. Moore, M. Antone, E. Olson, and S. Teller, “Finding multiple lanes in urban road networks with vision and lidar,” *Autonomous Robots*, vol. 26, no. 2, pp. 103–122, 2009.
- [13] T. Ogawa and K. Takagi, “Lane recognition using on-vehicle lidar,” in *Intelligent Vehicles Symposium, 2006 IEEE*, pp. 540–545, 0-0 2006.

- [14] S. Kammel and B. Pitzer, “Lidar-based lane marker detection and mapping,” in *Intelligent Vehicles Symposium, 2008 IEEE*, pp. 1137–1142, june 2008.
- [15] S. Thrun, “Learning occupancy grids with forward models,” in *Intelligent Robots and Systems, 2001. Proceedings. 2001 IEEE/RSJ International Conference on*, vol. 3, pp. 1676–1681, IEEE, 2001.
- [16] X. Chen, B. Kohlmeyer, M. Stroila, N. Alwar, R. Wang, and J. Bach, “Next generation map making: geo-referenced ground-level lidar point clouds for automatic retro-reflective road feature extraction,” in *Proceedings of the 17th ACM SIGSPATIAL International Conference on Advances in Geographic Information Systems*, pp. 488–491, ACM, 2009.
- [17] P. Lindner, E. Richter, G. Wanielik, K. Takagi, and A. Isogai, “Multi-channel lidar processing for lane detection and estimation,” in *Intelligent Transportation Systems, 2009. ITSC’09. 12th International IEEE Conference on*, pp. 1–6, IEEE, 2009.
- [18] P. Hough, “Machine analysis of bubble chamber pictures,” in *Proc. Int. Conf. High Energy Accelerators and Instrumentation*, 1959.
- [19] R. Duda and P. Hart, “Use of the hough transformation to detect lines and curves in pictures,” *Communications of the ACM*, vol. 15, no. 1, pp. 11–15, 1972.
- [20] F. O’Gorman and M. Clowes, “Finding picture edges through collinearity of feature points,” *Computers, IEEE Transactions on*, vol. 100, no. 4, pp. 449–456, 1976.
- [21] N. Kiryati, Y. Eldar, and A. Bruckstein, “A probabilistic hough transform,” *Pattern recognition*, vol. 24, no. 4, pp. 303–316, 1991.
- [22] P. Hough, “Method and means for recognizing complex patterns,” tech. rep., 1962.
- [23] D. Ballard, “Generalizing the hough transform to detect arbitrary shapes,” *Pattern recognition*, vol. 13, no. 2, pp. 111–122, 1981.
- [24] J. Radon, “Über die Bestimmung von Funktionen durch ihre Integralwerte längs gewisser Mannigfaltigkeiten,” *Berichte Sächsische Akademie der Wissenschaften*, no. 69, pp. 262–277, 1917.
- [25] M. Ginkel, C. L. L. Hendriks, and L. J. van Vliet, “An short introduction to the radon and hough transforms and how they relate to each other,” tech. rep., Pattern Recognition Group, Delft University of Technology, Dec. 2003.

- [26] M. Fischler and R. Bolles, “Random sample consensus: a paradigm for model fitting with applications to image analysis and automated cartography,” *Communications of the ACM*, vol. 24, no. 6, pp. 381–395, 1981.
- [27] R. Kalman *et al.*, “A new approach to linear filtering and prediction problems,” *Journal of basic Engineering*, vol. 82, no. 1, pp. 35–45, 1960.
- [28] G. Welch and G. Bishop, “An introduction to the kalman filter,” 1995.
- [29] P. Maybeck, *Stochastic models, estimation and control*, vol. 3. Academic Pr, 1982.
- [30] B. Fardi, U. Scheunert, H. Cramer, and G. Wanielik, “Multi-modal detection and parameter-based tracking of road borders with a laser scanner,” in *Intelligent Vehicles Symposium, 2003. Proceedings. IEEE*, pp. 95–99, IEEE, 2003.
- [31] M. Thuy and F. León, “Lane detection and tracking based on lidar data,” *Metrology and Measurement Systems*, no. 3, pp. 311–321, 2010.
- [32] N. Otsu, “A threshold selection method from gray-level histograms,” *Automatica*, vol. 11, no. 285-296, pp. 23–27, 1975.