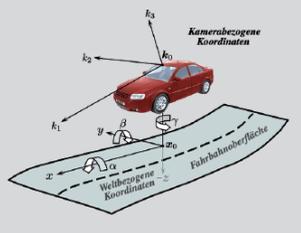
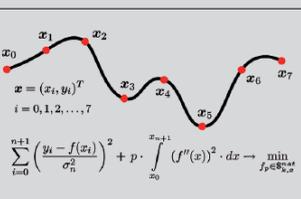
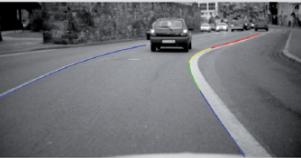


Institut für Mess- und Regelungstechnik
Universität Karlsruhe (TH)
Nr. 013



Dipl.-Ing. Markus Cech

Fahrspurschätzung aus monokularen Bildfolgen für innerstädtische Fahrer- assistenzanwendungen



Markus Cech

**Fahrspurschätzung aus monokularen Bildfolgen
für innerstädtische Fahrerassistentenanwendungen**

**Schriftenreihe
Institut für Mess- und Regelungstechnik,
Universität Karlsruhe (TH)**

Band 013

Fahrspurschätzung aus monokularen Bildfolgen für innerstädtische Fahrer- assistenzanwendungen

von
Markus Cech



universitätsverlag karlsruhe

Dissertation, Universität Karlsruhe (TH)
Fakultät für Maschinenbau
Tag der mündlichen Prüfung: 01.07.2008

Impressum

Universitätsverlag Karlsruhe
c/o Universitätsbibliothek
Straße am Forum 2
D-76131 Karlsruhe
www.uvka.de



Dieses Werk ist unter folgender Creative Commons-Lizenz
lizenziiert: <http://creativecommons.org/licenses/by-nc-nd/3.0/de/>

Universitätsverlag Karlsruhe 2009
Print on Demand

ISSN: 1613-4214
ISBN: 978-3-86644-351-8

Vorwort

Die vorliegende Dissertation entstand im Rahmen einer Kooperation zwischen dem Institut für Mess- und Regelungstechnik der Universität Karlsruhe (TH) und dem Kompetenzzentrum für umfelderfassende Sensorik der Robert Bosch GmbH. Mein Dank gilt all denen, die mir die Forschung in diesem spannenden Umfeld ermöglicht und mich dabei unterstützt haben.

Herrn Professor Dr.-Ing. C. Stiller, dem Leiter des Institutes, danke ich herzlich für die Betreuung der Arbeit, die zahlreichen Anregungen sowie die sehr motivierende und jederzeit gewährte Unterstützung. Besonders bedanke ich mich für die Vielfalt inspirierender Gespräche, von der Vision des autonomen Fahrens bis zur konkreten Umsetzung entscheidender Details der Arbeit. Die von Anfang an klaren Ziele und Erfolgskriterien haben mir während der gesamten Entstehung einen vorausschauenden und zuverlässigen Orientierungsrahmen gegeben.

Herrn Professor Dr.-Ing. K. Diepold danke ich für die kurzfristige Übernahme des Korreferats und das Interesse an meiner Arbeit.

Herrn Dr.-Ing. W. Niehsen und Herrn Dr.-Ing. W. Niem, meinen Betreuern seitens Bosch, verdanke ich die Freiheit des wissenschaftlichen Arbeitens in einem Industrieunternehmen. Ich bedanke mich für die maßgeschneiderte Einbindung in die Unternehmensabläufe und die konstruktive Kritik zu den Inhalten meiner Arbeit. Meinen Kollegen in Hildesheim danke ich für ihre alltägliche Unterstützung. Sie haben mir jederzeit das Gefühl gegeben, als Doktorand einen wertvollen Beitrag zu den Zielen der Abteilung zu leisten.

Meinen Mitdoktoranden Steffen Brüggert, Martin Gründig, Dietrich Bähring, Andreas Busse und Alan Koncar danke ich für ihre Begeisterung für innovative, technisch fundierte Lösungen und die tolle Zusammenarbeit. Ebenfalls bedanke ich mich bei Britta Hummel, Christian Duchow und Thao Dang vom MRT für den offenen Austausch von Ideen, Konzepten und Ergebnissen sowie für ihre freundliche Unterstützung bei praktischen Fragen zum Ablauf der Promotion.

Meiner Frau Ariane danke ich für die Freiräume, die sie mir für die Arbeit geschaffen hat. Und für ihre Nachsicht, wenn dies das ein oder andere Mal zu Lasten der Familie geschah.

Kurzfassung

Umfelderfassende Fahrerassistenzsysteme beurteilen die Situation des eigenen Fahrzeugs anhand seiner Lage innerhalb der Fahrspur und der relativen Position und Geschwindigkeit von Objekten entlang der vermuteten Trajektorie. Die Kenntnis der vorausliegenden Fahrspurgeometrie nimmt für viele Assistenzfunktionen die zentrale Rolle ein.

Abhängig von der konkreten Anwendung erfordern vorausschauende Assistenzfunktionen die Vorhersage des zukünftigen Verkehrsszenarios im Bereich von Millisekunden bis zu einigen Sekunden. Diese Anforderung lässt sich in Innenstädten mit deutlich geringeren Vorausschauweiten als im Hochgeschwindigkeitsbereich auf Autobahnen erfüllen. Andererseits sind innerstädtische Fahrspurverläufe grundsätzlich abwechslungsreicher als gut ausgebaute Landstraßen und Autobahnen. Für ein technisches System zur maschinellen Wahrnehmung der vorausliegenden Fahrspurgeometrie bedeutet dies, dass wenig invariante Abbildungseigenschaften der Fahrspur *a-priori* bekannt sind.

In dieser Arbeit wird ein modellbasierter Schätzer für innerstädtische Fahrspurverläufe in monokularen Bildfolgen entwickelt und im Versuchsfahrzeug realisiert. Es wird ein stochastisches Modell der lokalen Abbildungseigenschaften der Fahrspurberandung aufgestellt. Ähnliche Beobachtungen, definiert als einzelne Bildpunkte oder gerade Liniensegmente, werden dabei zu semantischen Einheiten gruppiert. Die Analyse der menschlichen Wahrnehmung deutet darauf hin, dass intelligente Lebewesen visuelle Information analog zusammenfassen, um ein Verständnis ihrer Umwelt aufzubauen.

Die Luminanz der Bildpunkte, ihr Kontrast und die Richtung der Luminanzänderung werden als statistisch unabhängige Attribute der Beobachtung aufgefasst. Zur Reduktion der Rechenkomplexität wird zusätzlich gefordert, dass nur lokale Maxima der Luminanzänderung gültige Beobachtungen der Fahrspurberandung darstellen. Diese Einschränkung ermöglicht die Approximation des Bildinhalts durch Liniensegmente, ein typisches Verkehrsszenario wird dabei auf wenige hundert Linien abgebildet.

Ohne Näherungswerte für die ungefähre Lage der Fahrspur ist es nicht möglich, eine sinnvolle Erwartungshaltung über die globalen Eigenschaften der Fahrspur im Bild zu motivieren. Bei der Initialisierung werden daher zunächst nur schwache Annahmen über die lokalen Berandungselemente direkt vor dem eigenen Fahrzeug formuliert. Aus ihnen wird eine Verteilungsdichte abgeleitet, die beobachteten Liniensegmenten eine *a-priori* Wahrscheinlichkeit für den räumlichen Ursprung der Fahrspurberandung zuordnet.

Im Allgemeinen lässt sich die Fahrspurberandung nicht durch eine einzige Linie approximieren. Vom weiteren Verlauf der Berandung wird angenommen, dass der zugrunde liegende Zufallsprozess durch eine Markov-Kette beschreibbar ist. Liniensegmente mit ähnlichen geometrischen und radiometrischen Eigenschaften werden als zusätzliche Berandungselemente aufgefasst, die den Fahrspurverlauf in Richtung größerer Entfernung erweitern. Die globale Güte der Schätzung ist durch die Länge und Ähnlichkeit der beitragenden Linien bestimmt.

Als neues Modell zur geometrischen Beschreibung innerstädtischer Fahrspurverläufe wird die Spline-Approximation eingeführt. Dieser Ansatz erlaubt die explizite Kontrolle der Glattheit der Schätzung, ohne die globale Form möglicher Fahrspurgeometrien einzuschränken. Zur Anbindung an nachgelagerte Assistenzfunktionen unterstützt er die optimale Segmentierung von beliebigen Berandungsgeometrien in eine minimale Anzahl kubischer Polynome.

Im Gegensatz zur initialen Detektion ist die globale Lage der Fahrspur während der zeitlichen Verfolgung näherungsweise bekannt. Die Unsicherheit in der Prädiktion entsteht alleine durch die geänderte Position und Orientierung der Kamera. Während die gerichteten Anteile der Kameradynamik von separaten Sensoren mit hoher Güte erfasst werden, lassen sich die hochfrequenten Schwingungen um die Einbaulage der Kamera aus monokularen Bildfolgen innenstädtischer Szenarien nur schwer schätzen. Zur quantitativen Bestimmung der Unsicherheit wird ein explizites Modell der physikalischen Schwingung der Kamera aufgestellt und dessen Parameter experimentell analysiert.

Die zeitliche Verfolgung der Fahrspurberandung ist mit Bezug zum 2D-Raster des optischen Sensors realisiert. Die prädierten Modelleigenschaften bilden die *a-priori* Information über den Zufallsprozess, die Schätzung wird senkrecht zum vorhergesagten Berandungsverlauf aktualisiert. Erwartete Abbildungsattribute und aktuelle Beobachtung werden für jeden Bildpunkt unabhängig von seiner Bildnachbarschaft bewertet, die Schätzung wird damit robust gegen lokale Störungen.

Die entwickelte Fahrspurschätzung ist als Basiskomponente für verschiedene Assistenzfunktionen von Interesse. Die Berechnung des geschätzten Fahrspurverlaufs erfolgt schritt haltend mit dem Bildeinzug im Versuchsfahrzeug. Experimentelle Ergebnisse belegen die Leistungsfähigkeit der Algorithmen in anspruchsvollen Situationen, unter anderem zur Detektion von Bordsteinkanten und Approximation enger Kurven. Als Indikator für die Zuverlässigkeit des Verfahrens wird ein Vergleich mit einer kommerziellen Fahrspurschätzung gezeigt. Besonders vielversprechend erscheint die Anwendung im niedrigen Geschwindigkeitsbereich, beispielsweise in Verbindung mit einem innerstädtischen Stop&Go-Assistenten.

Schlagnorte: Bildinterpretation – Fahrerassistenz – Fahrspur – Innenstadt – Markov – Spline

Abstract

Surround-sensing driver assistance systems provide positioning and relative velocity data about the host vehicle's environment. The estimated position and orientation of the host vehicle with respect to the lane course ahead has critical impact upon the performance of many assistance functions.

Dependent on the specific application, surround-sensing driver assistance functions need to anticipate the impending traffic scenario in the range of milliseconds to a few seconds. In comparison to high-speed applications on motorways, driving in urban environments can satisfy this requirement by applying significantly shorter look-ahead-distances. Conversely, urban lanes are intrinsically not as clearly defined as country roads or motorways. The design of a computer vision-based system for urban lane detection and tracking has to cover a wider variety of lane characteristics, where only weak invariant features are known in advance.

This thesis addresses lane detection and tracking with a camera mounted on a vehicle moving in urban environments. A stochastic appearance model of local lane boundary features in monocular image sequences is created, and implemented, in an experimental vehicle. Similar image primitives, such as points and straight lines, are clustered to semantically related observations. Analyses of human perception indicate that living beings follow a similar scheme to build up an understanding from visual information.

The primitives' brightness, their local contrast and the direction of maximum brightness change are considered as statistically independent observations. These attributes influence the likelihood that a primitive belongs to the lane boundary. An additional constraint is introduced to enable real-time processing of the algorithms; the exact position of the lane boundary is defined by local contrast maximas, other points are not further processed. This simplification allows the approximation of a typical urban traffic scenario by a few hundred straight line segments.

During the initialization phase, it is impossible to infer a valid expectation about the global properties of the lane appearance in the camera's field of view. Thus, at the outset, initialization is founded on weak assumptions about the local lane attributes immediately in front of the host vehicle.

Generally, the lane course can not be approximated by a single line. A spatial tracking scheme attempts to extend the boundary to larger distances. It assumes that the underlying stochastic process fulfills the Markov constraint. Line segments with similar geometric and radiometric attributes are semantically linked to compound shapes that are considered lane boundary candidates. Each of the shapes is assigned a probability for the representation of the lane boundary. The match between the expected lane attributes and the observed shapes is deduced from the length and the similarity of the contributing lines.

The Smoothing Spline is introduced as a novel method to describe the shape of urban lanes. As opposed to models previously discussed in literature, this approach enables explicit

control of curve smoothness without limiting the range of global geometries. It supports tracking algorithms in the image plane and features an optimal segmentation of the spline curve into a minimum set of third order polynomials. Thus, the information about arbitrary lane geometries can be provided to subsequent driver assistance functions at an adequate level.

Temporal tracking of the lane boundaries is implemented with respect to the 2D-grid of the optical sensor. Compared to the weak assumptions during the initialization phase, tracking can rely on rather strong a-priori knowledge about the global lane appearance in the image. A prediction / correction technique is applied to update the spline curve with new measurements. The uncertainty in the update is caused solely by the changed camera position. The directional components of the camera movement are retrieved from dedicated sensors with high accuracy. An explicit model of the physical camera dynamics is introduced to analyze the impact of the high-frequency oscillations around its mounting position; its parameters are determined experimentally.

The presented lane detection and tracking algorithms are intended as basic components for different driver assistance functions. The online estimator, implemented in the experimental vehicle, processes the image sequence in realtime. Experimental results demonstrate the system's performance in visually demanding scenarios, such as detecting curbs and approximating narrow curves. The reliability of the estimator is indicated by a benchmark against a commercial state-of-the-art lane detection software. The developed algorithms are particularly suited for urban assistance functions at low speed, e. g. to support an inner-city Stop&Go-Assistent.

Keywords: Computer Vision – Driver Assistance – Lane – Innercity – Markov – Spline

Inhaltsverzeichnis

Symbolverzeichnis	IX
1 Einleitung	1
1.1 Modelle als Träger von a-priori Information	3
1.2 Schwerpunkt und Zielsetzung	5
1.3 Übersicht	5
2 Aufgabendefinition und bestehende Ansätze	7
2.1 Bildentstehung als Abstraktionsprozess	8
2.2 Position und Orientierung der Kamera	10
2.3 Merkmale der Fahrspur im Einzelbild	14
2.3.1 Kantenbasierte Ansätze	16
2.3.2 Regionenbasierte Ansätze	18
2.3.3 Spektrale Ansätze	18
2.3.4 Angepasste Schwellen bei Entscheidungen	20
2.4 Rekonstruktion von Tiefeninformation	21
2.4.1 Disparität	21
2.4.2 Optischer Fluss	22
2.4.3 Inverse projektive Geometrie	25
2.4.4 Photomischdetektoren	28
2.5 Modelle der Fahrspurgeometrie	28
2.5.1 Modellierung der Fahrspur in der Welt	30
2.5.2 Modellierung der Fahrspur im Bild	34
2.6 Schätzung von Modellparametern	37
2.6.1 Parameterschätzung als Optimierungsproblem	37
2.6.2 Prädiktion zukünftiger Werte	42

2.7	Grenzen bestehender Ansätze	44
2.8	Zusammenfassung von Kapitel 2	45
3	Modellierung der innerstädtischen Fahrspur	47
3.1	Abstraktion der Abbildungseigenschaften	48
3.1.1	Invariante Attribute der Beobachtung	48
3.1.2	Gesetze der Gestalttheorie	52
3.1.3	Räumliche Kontinuität	55
3.1.4	Zeitliche Kontinuität	55
3.2	Mathematische Modellbildung	56
3.2.1	Approximation der Berandungsgeometrie	56
3.2.2	Initiale Detektion der Berandung	62
3.2.3	Zeitliche Verfolgung des Splines	72
3.3	Parameter der Modellbildung	76
3.4	Zusammenfassung von Kapitel 3	76
4	Schätzung des Fahrspurverlaufs	79
4.1	Berechnung der Merkmale	80
4.1.1	Kantendetektion	80
4.1.2	Konturextraktion	82
4.1.3	Polygonapproximation	82
4.2	Initiale Detektion	84
4.2.1	Initialisierung möglicher Berandungen	85
4.2.2	Berechnung des wahrscheinlichsten Pfades	86
4.2.3	Detektion vorausfahrender Fahrzeuge	86
4.3	Berechnung der Spline-Parameter	88
4.4	Zeitliche Verfolgung	91
4.4.1	Prädiktion der Splinekurve	91
4.4.2	Integration der Beobachtung	92
4.5	Zusammenfassung von Kapitel 4	94

5	Experimentelle Ergebnisse	95
5.1	Konfiguration der Modellparameter	96
5.1.1	Varianzen des Markov-Modells der Fahrspurberandung	97
5.1.2	Regularisierung der Spline-Approximation	98
5.1.3	Parameter der Nickwinkelschwingung	98
5.2	Bewertung funktionaler Eigenschaften	100
5.2.1	Erkennung unterschiedlicher Berandungstypen	100
5.2.2	Approximation variabler Berandungsgeometrien	103
5.2.3	Güte der zeitlichen Prädiktion	106
5.2.4	Detektion freierwerdender Fläche	108
5.3	Validierung in innerstädtischen Umgebungen	108
5.4	Realisierte Rechenzeiten	114
5.5	Erweiterungsmöglichkeiten	115
5.6	Zusammenfassung von Kapitel 5	115
6	Zusammenfassung	117
A	Mathematische Herleitungen und Details	121
A.1	Pseudo-Inverse als Maximum Likelihood Schätzer	121
A.2	Approximation mit natürlichen kubischen Splines	124
A.2.1	Spline-Interpolation	124
A.2.2	Spline-Approximation	126
A.3	Effiziente Invertierung pentadiagonaler Matrizen	130
A.3.1	Allgemeine pentadiagonale Matrizen	131
A.3.2	Symmetrische pentadiagonale Matrizen	134
	Abbildungsverzeichnis	135
	Literaturverzeichnis	137

Symbolverzeichnis

Abkürzungen

2D/3D	zweidimensional / dreidimensional
BCCE	B rightness C onstancy C onstraint E quation
fps	f rames p er s econd
LDA	L ane D etection A lgorithm
PMD	P hotomisch d etektor

Notationsvereinbarungen

Konstanten, Bezeichner	nicht kursiv: a, b, c, \dots
Skalare	nicht fett, kursiv: a, b, c, \dots
Vektoren	fett, kursiv: $\mathbf{a}, \mathbf{b}, \mathbf{c}, \dots$
Matrizen	fett, kursiv, groß: $\mathbf{A}, \mathbf{B}, \mathbf{C}, \dots$
Zufallsvariablen	nicht kursiv, groß: A, B, C, \dots
Zufallsvektoren	fett, groß: $\mathbf{A}, \mathbf{B}, \mathbf{C}, \dots$
Mengen	kalligraphisch, groß: $\mathcal{A}, \mathcal{B}, \mathcal{C}, \dots$

Koordinatensysteme

$\mathbf{b} = (u, v)^T$	Bildkoordinatensystem ¹ $\in \mathbb{R}^2$
$\mathbf{k} = (k_1, k_2, k_3)^T$	Kamerakoordinatensystem ^{1,2} $\in \mathbb{R}^3$
$\mathbf{x} = (x, y, z)^T$	Weltkoordinatensystem ² $\in \mathbb{R}^3$
$\boldsymbol{\alpha} = (\alpha, \beta, \gamma)^T$	Winkelgrößen ² bzgl. Weltkoordinaten $\in \mathbb{R}^3$

¹ Das Bild- und das Kamerakoordinatensystem sind in Abbildung 2.3 auf Seite 11 definiert.

² Der Zusammenhang zwischen Kamerakoordinaten und weltbezogenen Größen ist in Abbildung 2.4 auf Seite 13 dargestellt.

Häufig verwendete Symbole

\propto	Proportionalität
\mapsto	Abbildung
$:=$	Definition
$\stackrel{!}{=}$	Identitätsforderung
\emptyset	leere Menge
$ \cdot $	Betrag einer Zahl, L_1 -Norm
$\ \cdot\ $	Euklidische Norm, L_2 -Norm
$\angle(\cdot)$	Richtungsoperator (für Vektoren)
$[\cdot]$	Adressoperator (für Attribute der Beobachtung)
∇	Nabla-Operator
$*$	Faltungsoperator
$**$	Faltungsoperator (zweidimensional)
\mathbf{a}	allgemeiner Parametervektor
$\arg\{\cdot\}$	Argument einer Funktion
e	Eulersche Konstante
\mathbf{e}	Einheitsvektor
$E\{\cdot\}$	Erwartungswert
$f(\cdot)$	allgemeine Funktion, Verteilungsdichtefunktion
$g(\mathbf{b}, t)$	Bildserie
$\mathbf{l}_j(g(\mathbf{b}))$	j-tes Liniensegment der Polygonapproximation
ξ_t^-	Beobachtung der Fahrspurberandung zum Zeitpunkt t
ξ_t^+	Approximation der Fahrspurberandung zum Zeitpunkt t
ρ_k	k-te Komponente der Kostenfunktion eines Zustandsübergangs zwischen Modell und Beobachtung
$O(\cdot)$	Komplexitätsklasse (Ordnung) eines Algorithmus
$\mathbf{r}(s)$	Splinekurve (2D)
s	räumlicher Parameter der Splinekurve
S	allgemeine Splinefunktion
\hat{x}	Schätzwert von x
\bar{x}	empirischer Mittelwert von x
\mathbf{x}^T	Transposition des Vektors \mathbf{x}
$\sigma^2(x) = \text{var}\{x\}$	empirische Varianz von x

Kapitel 1

Einleitung

Ein wesentliches Qualitätsmerkmal umfelderfassender Fahrerassistenzsysteme ist die Verfügbarkeit in verschiedenen Umgebungen. Während die meisten vorhandenen Systeme die Sicherheit und den Komfort des Fahrers auf Autobahnen und Landstraßen verbessern, werden zukünftige Systeme die Anwendung auf Innenstädte erweitern. Eine denkbare Anwendung im innerstädtischen Bereich ist ein Stop&Go-Assistent, bei dem das eigene Fahrzeug einem direkt vorausfahrenden Fahrzeug mit geringer Geschwindigkeit folgt.

In den letzten Jahren haben zwei Rennen autonomer Fahrzeuge in den USA die Leistungsfähigkeit technisch möglicher Assistenzsysteme demonstriert. Bei der Grand Challenge [Def05] im Oktober 2005 ist es unbemannten Fahrzeugen erstmals gelungen, eine Strecke von 130 Meilen durch die Wüste Nevadas allein auf Basis von GPS-Information und umfelderfassender Sensorik zu planen und zurückzulegen. Das schnellste Fahrzeug bewältigte die Distanz mit einer durchschnittlichen Geschwindigkeit von über 30 km/h.

Im November 2007 fand in Kalifornien das erste Rennen in bebautem Gebiet statt. Auf dem Gelände einer Kaserne ging es bei der Urban Challenge [Def07b] darum, in einem 60 Meilen langen städtischen Parcours mit anderen Fahrzeugen nach geltenden Verkehrsregeln zu kooperieren. Die Universität Karlsruhe erreichte mit dem Team AnnieWay [Mrt07] das Finale der mit 3.5 Millionen Dollar Preisgeld dotierten Veranstaltung [Def07a].

Die Anforderungen an kommerzielle Assistenzsysteme sind jedoch nicht ausschließlich durch ihre technische Realisierbarkeit bestimmt [Hom05]. Vielmehr bewegen sich diese Systeme in einem komplexen Spannungsfeld aus technischen Lösungen, rechtlichen Rahmenbedingungen und nicht zuletzt gesellschaftlicher



(a) Aufnahme von einer Landstraße



(b) Aufnahme aus einer Innenstadt

Abbildung 1.1: Fahrspuren auf Landstraßen sind im Sichtbereich der Kamera moderat gekrümmt, die seitliche Begrenzung bilden helle Markierungen. Fahrspurgeometrien in Innenstädten sind häufig durch die umgebende Infrastruktur bestimmt, die Abgrenzung zu benachbarten Gehsteigen bildet meist ein Bordstein.

Akzeptanz. Insbesondere wird von ihnen erwartet, dass sie eine hohe Zuverlässigkeit zu vertretbaren Kosten liefern. Welche Lösungen sich mittelfristig am Markt durchsetzen werden, ist aus heutiger Sicht schwer abzusehen.

Aus funktionaler Sicht scheinen innerstädtische Assistenzsysteme gute Voraussetzungen für zukünftige Komfortfunktionen zu haben. Ein Stop&Go-Assistent könnte zum Beispiel in den Großstädten dem Fahrer das häufige Anfahren und Abbremsen in Stausituationen abnehmen und damit den alltäglichen Weg zwischen Arbeitsplatz und Wohnort angenehmer gestalten. Aufgrund der geringen Geschwindigkeiten lässt sich das Risiko möglicher Fehlfunktionen gut absichern und Fragen der Produkthaftung sind vergleichsweise gut abzuschätzen.

Was bleibt, ist die Frage nach der technischen Realisierung. Für viele Assistenzfunktionen nimmt dabei die Schätzung der vorausliegenden Fahrspurgeometrie eine zentrale Rolle ein. Direkt dient sie als Steuergröße zur lateralen Führung des Fahrzeugs, indirekt beeinflusst sie das geschätzte Gefahrenpotential erkannter Objekte entlang der vermuteten Trajektorie. Ein Fußgänger innerhalb der Fahrspur – beispielsweise beim Überqueren eines Zebrastreifens – ist stärker gefährdet als ein Fußgänger auf dem Gehsteig.

Die grundlegende Herausforderung bei der Schätzung von Fahrspurverläufen in Innenstädten besteht darin, der Vielfalt möglicher Szenarien gerecht zu werden, s. bspw. Abbildung 1.1(b). Die meisten bekannten Verfahren modellieren die Fahrspurgeometrie häufig durch eine moderate, im Sichtbereich der Kamera nahezu

konstante Krümmung. Die konkrete Realisierung dieser Annahmen sind parametrische Modelle mit wenigen Zustandsgrößen, vgl. u. a. [Dic92]. Weiterhin wird meist davon ausgegangen, dass die Fahrspur durch helle Markierungen begrenzt ist. Diese Art der Beschreibung ist für innerstädtische Fahrspurverläufe ungeeignet [Hei02]. Ihre Krümmung wird regelmäßig durch die umgebende Infrastruktur bestimmt. Die Abgrenzung zu benachbarten Gehsteigen bildet häufig ein Bordstein und keine farbige Markierung.

Zur innerstädtischen Fahrspurschätzung auf Basis optischer Sensoren gibt es bereits Untersuchungen. Stellvertretend seien hier der Urban Traffic Assistant UTA [Fra98] der Daimler-Chrysler Forschung sowie die Studie des IITBs¹ zum Versuchsfahrzeug DARVIN [Hei00] genannt. Beide Konzepte verwenden Stereo-Kamerasysteme zur Umfelderkennung, die zweite Untersuchung nutzt zusätzlich Information einer digitalen Straßenkarte.

Aus heutiger Sicht stellt sich die Frage, ob eine Fahrspurschätzung für innerstädtische Assistenzfunktionen bereits mit nur einer Kamera hinreichend gut gelöst werden kann. Diese Fragestellung wird in der vorliegenden Arbeit untersucht.

1.1 Modelle als Träger von a-priori Information

Die grundsätzlichen Stärken und Schwächen maschinellen Sehens sind in der wissenschaftlichen Diskussion weitgehend unstrittig. Algorithmen der Bildverarbeitung sind dem Menschen in der Auswertung lokaler Bildnachbarschaften weit überlegen. Ihre Stärke liegt insbesondere in der akkuraten und ermüdungsfreien Analyse großer Datenmengen. In der Interpretation globaler Bildinhalte sind sie im Vergleich zur menschlichen Wahrnehmung schwach und stör anfällig [Jäh02]. Insbesondere in natürlichen Umgebungen scheint eine zuverlässige Umfelderkennung allein auf Basis beobachteter Bildpunkte daher unmöglich.

Modelle² interessierender Größen bieten die Möglichkeit, *a-priori* Information über die erwarteten Eigenschaften der Abbildung als weitere Bedingungen in die Schätzung globaler Bildinhalte einzubringen. Abbildung 1.2 zeigt an einem anschaulichen Beispiel, dass auch der Mensch unbewusst Modelle als Vorwissen in der Wahrnehmung visueller Eindrücke verwendet. Für den Betrachter zeigt sich intuitiv ein Würfel. Allein durch die dargestellten Ecken und Kreise lässt sich diese

¹ Fraunhofer-Institut für Informations- und Datenverarbeitung.

² Der allgemeine Modellbegriff ist sehr umfassend. Eine Beschreibung findet sich in Definition 2.1. Im Kontext der Bildverarbeitung meint der Modellbegriff meist die Spezifikation invarianter Eigenschaften der Abbildung und die parametrische Abstraktion der Form interessierender Größen.

Interpretation nicht erklären. Offensichtlich verfügt der Mensch über eine Erwartungshaltung, die eine derartige Anordnung zu einem Würfel zusammenfügt. Die Erklärung dieser Phänomene ist Gegenstand der Neuropsychologie, insbesondere der Gestaltpsychologie. Die für die vorliegende Arbeit wesentlichen Erkenntnisse der Neurologen sind im Kapitel 3.1.2 zusammengefasst.

Systeme des maschinellen Sehens setzen Modelle als Träger von *a-priori* Information expliziter ein als die menschliche Wahrnehmung. Meist ist dabei das Modell eng an eine ganz bestimmte Anwendung gebunden. Die Aufgabe der Modellbildung besteht darin, abbildungsinvariante Eigenschaften der interessierenden Größe zu erkennen und sie formal zu beschreiben.

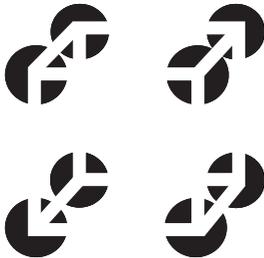


Abbildung 1.2: *Ein imaginärer Würfel. Die Kanten existieren nicht. Sie werden vom Gehirn erzeugt.*

Sagen eignen sich nicht zur direkten Verarbeitung durch ein maschinelles System.

In dieser Arbeit wird ein Abbildungsmodell für innerstädtische Fahrspurverläufe in monokularen Bildsequenzen entwickelt. Motiviert ist die Modellbildung durch die Erklärungen der Gestaltpsychologen, wie Menschen visuellen Wahrnehmungen eine Bedeutung zuweisen und damit ein Verständnis ihrer Umwelt aufbauen [Kan96a]. Eine ganz zentrale Rolle bei den Arbeiten der Neurologen spielt dabei die Frage, wie Menschen aus einzelnen Elementen ihrer Beobachtung auf zusammengehörige Einheiten schließen.³ Die Gestalttheorie macht allerdings nur qualitative Aussagen, die in dieser Form ausschließlich durch intelligente Lebewesen interpretierbar sind. Die Aussagen eignen sich nicht zur direkten Verarbeitung durch ein maschinelles System.

Im Gegensatz zur Wahrnehmung intelligenter Lebewesen basiert die maschinelle Interpretation von Bildfolgen auf formalen Metriken, die die Abbildungseigenschaften interessierender Größen der Umgebung quantitativ modellieren. In der vorliegenden Arbeit wird ein gestaltbasiertes Modell für den Anwendungsfall maschineller Fahrspurschätzung in Innenstädten aufgestellt.

³ Im Kontext des maschinellen Sehens wird diese Aufgabe häufig als Segmentierung oder Klassifikation bezeichnet.

1.2 Schwerpunkt und Zielsetzung

Gegenstand dieser Arbeit ist die Auswertung monokularer Bildfolgen, die aus bewegten Fahrzeugen in Innenstädten aufgenommen werden. Eine beispielhafte Aufnahme zeigt Abbildung 1.1(b). Das Hauptziel der Studie ist die Entwicklung eines modellbasierten Schätzverfahrens für die vorausliegende Fahrspurgeometrie und dessen Realisierung im Versuchsfahrzeug.

Ausgelegt ist die Fahrspurschätzung als Basiskomponente für innerstädtische Assistenzfunktionen im niedrigen Geschwindigkeitsbereich. Es sollen Vorausschauzeiten von minimal drei Sekunden unterstützt werden. Bei einer Geschwindigkeit von 30 km/h entspricht dies einer minimalen Vorausschauweite von 25 Metern.

1.3 Übersicht

Die Schätzung der vorausliegenden Fahrspurgeometrie aus Bildsequenzen ist seit drei Jahrzehnten Gegenstand intensiver Forschung. Es existiert eine sehr große Anzahl wissenschaftlicher Publikationen, zwischen denen oft deutliche inhaltliche Überschneidungen bestehen. **Kapitel 2** gibt einen thematisch geordneten Überblick zu bestehenden Ansätzen und diskutiert deren Stärken und Schwächen. Mit Blick auf die innerstädtische Fahrspurschätzung aus monokularen Bildfolgen werden die Grenzen bestehender Ansätze aufgezeigt.

In **Kapitel 3** werden invariante Merkmale der Fahrspur im Bild identifiziert und ein stochastisches Modell der lokalen Eigenschaften innerstädtischer Fahrspurberandungen aufgestellt. Aus den qualitativen Erklärungen der Gestalttheorie wird eine Metrik zur rechnergestützten Schätzung des vorausliegenden Fahrspurverlaufs entwickelt. Als neues Modell zur Beschreibung der Fahrspurgeometrie im Sichtbereich der Kamera wird die Spline-Approximation eingeführt. Zur Initialisierung des Modells werden Liniensegmente als atomare Beobachtungen aufgefasst und deren Verbundwahrscheinlichkeiten als Markov-Kette beschrieben. Die zeitliche Verfolgung detektierter Fahrspurberandungen basiert auf einem integralen Fehlermaß, sie ist damit robust gegen einzelne Störungen in der Beobachtung.

Die Berechnung der modellbasierten Schätzung der vorausliegenden Fahrspurgeometrie für gegebene Bildfolgen wird in **Kapitel 4** beschrieben. Dabei wird zeigen, dass die größte Herausforderung der Aufgabe in der robusten Auswahl der wahren Fahrspurberandung aus einer Vielzahl möglicher Hypothesen besteht. Andere Verkehrsteilnehmer und die städtische Infrastruktur besitzen Abbildungseigenschaften, die aus Sicht der rechnergestützten Interpretation monokularer Bild-

folgen in unübersichtlichen Situationen mit Fahrspurmerkmalen zu verwechseln sind. Als wesentliche Randbedingung wird von der Umsetzung im Versuchsfahrzeug gefordert, dass die Schätzung schritthaltend mit dem Bildeinzug realisiert ist.

In **Kapitel 5** wird die Leistungsfähigkeit der entwickelten Fahrspurschätzung experimentell bestimmt. Es werden Kennzahlen zur Zuverlässigkeit und Genauigkeit des entwickelten Schätzers ermittelt, um einen objektiven Vergleich mit anderen Verfahren zu ermöglichen. Anhand realer Bildfolgen wird das Verhalten der Fahrspurdetektion in Innenstädten demonstriert.

Mathematische Herleitungen und Details sowie wesentliche Aspekte der Implementierung im Versuchsfahrzeug finden sich im **Anhang A**.

Kapitel 2

Aufgabendefinition und bestehende Ansätze

Fahrerassistenzsysteme auf Basis optischer Sensoren werden von vielen Experten als eine der vielversprechendsten Anwendungen des maschinellen Sehens bewertet [Sun04]. Gleichzeitig hat sich aber auch die Auffassung durchgesetzt, dass die Vision vom vollständig autonomen Fahren in beliebiger Umgebung in naher Zukunft nicht als kommerzielles Produkt realisierbar sein wird [Sti05].

In den letzten Jahren sind aus den Erfahrungen der ersten kommerziellen Assistenzsysteme kritische Auseinandersetzungen mit den etablierten Ansätzen entstanden. Sie geben einen sehr fundierten Überblick über die Stärken und Schwächen dieser Verfahren. Stellvertretend seien hier die Arbeiten von [Mau05], [Bis05], [McC06], [Kas03] und [Ber02] genannt. Besondere Bedeutung für die vorliegende Studie hat der Artikel von [Hei02], der auf Verfahren zur innerstädtischen Fahrerassistenz fokussiert. Einen Trend in der wissenschaftlichen Diskussion der letzten Jahre kann man in einer ersten Konsolidierung etablierter Ansätze sehen.

Gleichzeitig sind neue Verfahren vorgeschlagen worden, hauptsächlich begründet durch Fortschritte im Bereich der Bildinterpretation und der verfügbaren Rechenleistung. Als richtungsweisend sind u. a. die Einführung von gelernten Kaskaden einfacher Klassifikatoren zur schnellen Objektdetektion [Vio01] und Arbeiten zu Aktiven Konturen [Kas87], [Bla98] anzusehen. Letztere wurden 2004 aufgegriffen, um die Kontur von Fahrspurverläufen direkt im Bild zu schätzen [Wan04].

Auch im Bereich der Entfernungsschätzung mit bewegten Kameras wurden wesentliche Erkenntnisse auf dem Weg zu alltagstauglichen Systemen erzielt. So stellt [Ste04] ein Verfahren vor, um dichte Bewegungsfelder aus monokularen

Bildfolgen in bisher nicht gekannter Qualität und Geschwindigkeit zu schätzen. Die Arbeiten von [Dan07], [Dan06a] ermöglichen die Nachführung der Kalibrierung einer Stereo-Kamera während der normalen Nutzung des Assistenzsystems. Im Bereich der Sensorik kombinieren Photomischdetektoren die optische Umfeld erfassung mit einer Abstandsmessung nach dem Laufzeitprinzip. Sie liefern für jeden Bildpunkt eine korrespondierende Entfernung in der Welt und erlauben damit eine dreidimensionale Umfeld erfassung. Schon heute sind PMDs mit bis zu 160×120 3D-Pixeln bei Wiederholraten von über 100 Bildern pro Sekunde verfügbar [Bux05]. Es ist zu vermuten, dass PMD-Sensoren weitreichenden Einfluss auf zukünftige Assistenzsysteme haben werden.

Dieses Kapitel gibt einen thematisch geordneten Überblick zu bestehenden Ansätzen videobasierter Fahrspurschätzung. Für die vorliegende Arbeit wesentliche Aspekte der Literatur werden diskutiert und mit Blick auf die innerstädtische Fahrspurschätzung aus monokularen Bildfolgen bewertet.

2.1 Bildentstehung als Abstraktionsprozess



Abbildung 2.1: Kamera für videobasierte Fahrerassistenzsysteme. In dieser Arbeit kamen ähnliche Sensoren zum Einsatz.

Bildentstehung ist ein verlustbehafteter – und daher irreversibler – Abstraktionsprozess. Verloren gehen alle Informationen, die nicht durch den verwendeten Sensor erfasst werden. In dieser Arbeit werden monochromatische, natürliche Bildfolgen vorausgesetzt. Als einzige explizite Information enthalten diese Bildfolgen zeitlich aufeinander folgende zweidimensionale Strukturen von Grauwerten. Alle Aussagen, die über diesen Informationsgehalt hinausgehen, lassen sich nur schätzen. Um eine sinnvolle Strategie zum Schätzen der Fahrspurgeometrie zu entwickeln, ist es somit notwendig, die wesentlichen Eigenschaften der Bildentstehung zu verstehen.

Kameras messen einfallende Strahlung, die von aktiven Strahlungsquellen und allen nicht vollständig absorbierenden Objekten im Sichtbereich der Kamera ausgeht. Fasst man die auf von allen Quellen auf ein Element des Bildsensors einfallende Strahlung in einer Funktion $h(\mathbf{b}, t)$ zusammen, so ergibt sich der Grauwert $g(\mathbf{b})$ dieses Bildpunktes zum Zeitpunkt t gemäß Gleichung 2.1.1:

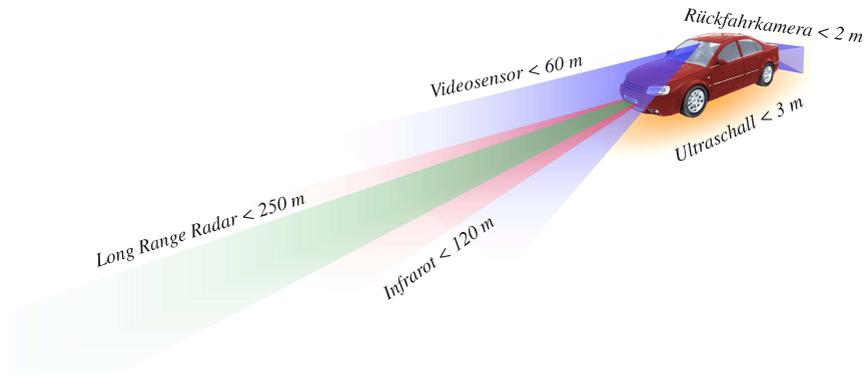


Abbildung 2.2: Sichtbereiche umfelderfassender Sensoren für Fahrerassistenzsysteme. Wesentliche Kenngrößen der Sensoren sind ihr Öffnungswinkel, die Reichweite und das Frequenzspektrum der erfassten Signale. In blau ist der typische Sichtbereich von Videosensoren skizziert. Der Intensitätsverlauf deutet die abnehmende Auflösung des Sensors in Richtung größerer Entfernungen an.

Speziell für innerstädtische Assistenzfunktionen erscheint der Einsatz von optischen Sensoren vielversprechend. Im Vergleich zu den Anwendungen für Autobahnen und Landstraßen lassen sich weniger Einschränkungen über die erwarteten Eigenschaften anderer Verkehrsteilnehmer und der umgebenden Infrastruktur formulieren. Gefordert ist daher ein breites Spektrum erfassbarer Objekte und ein großer Öffnungswinkel des Sensors. Durch die niedrigeren Geschwindigkeiten spielt die limitierte Reichweite des Sensors eine untergeordnete Rolle: Angemessene Vorhersagen des zukünftigen Verkehrsszenarios werden mit geringeren Vorausschauweiten realisiert.

$$g(\mathbf{b}, t) = c(h) \cdot \int_0^t h(\mathbf{b}, t') dt' \quad (2.1.1)$$

$c(h)$ bezeichnet dabei die Kennlinie der Kamera. Üblich sind lineare Zuordnungen zwischen einfallender Strahlung und resultierendem Grauwert. Für Fahrerassistenzsysteme werden aber auch Kameras mit logarithmischen Kennlinien eingesetzt, um in schwierigen Beleuchtungssituationen – bspw. bei Blendung durch entgegenkommende Fahrzeuge in der Nacht – Objekte mit geringem Kontrast zu erfassen.

Bilder sind projektive Abbildungen der dreidimensionalen Wirklichkeit. Reale Kameras besitzen eine Optik, die einfallende Strahlung auf die Bildebene projiziert. Ein einfaches Modell für die Optik des Bildaufnahmesystems ist die ideale Lochkamera, bei der alle Strahlen in einem gemeinsamen Projektionszentrum zusammenlaufen. Abbildung 2.3 zeigt schematisch den Aufbau der idealen Lochkamera.

Der elementare Informationsverlust der Bildentstehung wird in Abbildung 2.3(b) deutlich: Alle Punkte eines Strahls zum Projektionszentrum der Kamera werden auf den identischen Bildpunkt abgebildet. Mathematisch beschrieben wird dies durch die Projektionsgleichung 2.1.2. Koordinaten der Wirklichkeit sind in dem relativ zur Kamera ruhenden Kamerakoordinatensystem $\mathbf{k} = (k_1, k_2, k_3) \in \mathbb{R}^3$ angegeben, die Bildkoordinaten \mathbf{b} haben ihren Ursprung im Bildhauptpunkt \mathbf{b}_0 . Die Lage und Orientierung des Kamerakoordinatensystems für die in dieser Arbeit diskutierte Anwendung geht aus Abbildung 2.4 hervor.

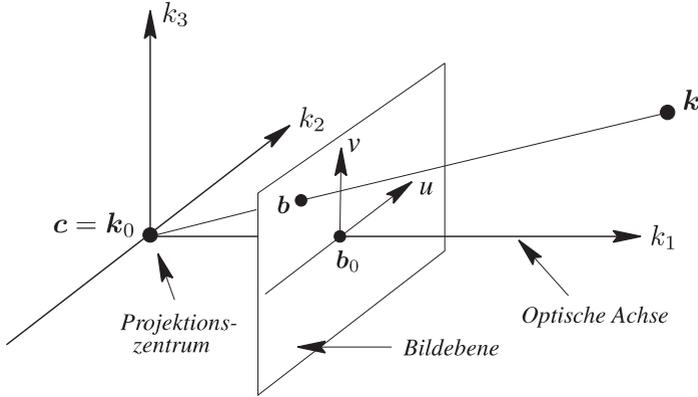
$$\mathbf{k} = \begin{pmatrix} k_1 \\ k_2 \\ k_3 \end{pmatrix} \mapsto \mathbf{b} = \begin{pmatrix} u \\ v \end{pmatrix} = \begin{pmatrix} f \cdot \frac{k_2}{k_1} \\ f \cdot \frac{k_3}{k_1} \end{pmatrix} \quad (2.1.2)$$

f bezeichnet die Kamerakonstante des Bildaufnahmesystems, sie wird in Bildpunkten angegeben. In dieser Arbeit wird von kalibrierten Kameras ausgegangen, die Kamerakonstante wird daher wie alle anderen Parameter der inneren und äußeren Abbildungsgeometrie als bekannt vorausgesetzt. Eine umfassende Diskussion der initialen Kalibrierung von Kameras aus monokularen Bildfolgen findet sich in [Abr00].

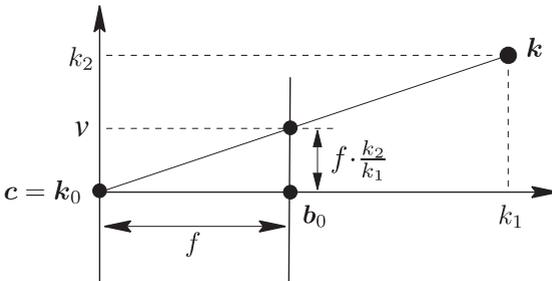
In der Umkehrung bedeutet die Projektionsgleichung 2.1.2, dass eine eindeutige Zuordnung von Bildpunkten zu Positionen der dreidimensionalen Wirklichkeit allein aufgrund eines beobachteten Bildes nicht möglich ist. Im Abschnitt 2.4 werden Verfahren vorgestellt, die durch weitere Beobachtungen und Annahmen auf die zum Bildpunkt korrespondierende Entfernung schließen lassen.

2.2 Position und Orientierung der Kamera

Im vorherigen Abschnitt wurde gezeigt, dass die projektive Abbildung beobachteter Objekte von der inneren und äußeren Geometrie der verwendeten Kamera abhängt. Sinnvolle Erwartungen an Größe und Bewegung realer Objekte lassen sich



(a) Modellierung des Bildaufnahmesystems als ideale Lochkamera



(b) Perspektivische Projektion der Wirklichkeit auf die Bildebene

Abbildung 2.3: Abbildungsgeometrie der idealen Lochkamera. \mathbf{c} bezeichnet das Projektionszentrum, es bildet den Ursprung \mathbf{k}_0 des Kamerakoordinatensystems. \mathbf{b}_0 symbolisiert den Bildhauptpunkt und f die Kamerakonstante.¹ Der wesentliche Informationsverlust der projektiven Abbildung wird deutlich: Alle Punkte eines Strahls zum Projektionszentrum werden auf den identischen Bildpunkt abgebildet. Die Entfernung des Punktes \mathbf{k} geht bei der Projektion $\mathbf{k} \mapsto \mathbf{b}$ verloren, sie kann aus der beobachteten Abbildung nur unter zusätzlichen a-priori Annahmen über das beobachtete Szenario geschätzt werden.

¹ Die Kamerakonstante ist der Maßstabsfaktor der projektiven Abbildung. Sie ist annähernd gleich der Brennweite des Kameraobjektivs und wird in Bildpunkten des optischen Sensors angegeben.

hingegen nur bezüglich einer weltfesten Beschreibung ihrer Position formulieren. Assistenzfunktionen benötigen somit Entfernungsangaben in einem weiteren Koordinatensystem.

Häufig wird dazu ein mitbewegtes Koordinatensystem \boldsymbol{x} unter dem Fahrzeug eingeführt, vgl. Abbildung 2.4. Die x -Achse liegt dabei in der Fahrbahnebene und ist parallel zur Längsachse des Fahrzeugs orientiert.

Eine der elementaren Aufgaben videobasierter Fahrerassistenzsysteme besteht darin, die bei der Projektion auf die Bildebene verlorene Entfernung k_1 entlang der optischen Achse des Sensors zu schätzen. Diese Verfahren zielen darauf ab, den Bildpunkten \boldsymbol{b} Koordinaten der dreidimensionalen Wirklichkeit in dem relativ zur Kamera ruhenden Kamerakoordinatensystem \boldsymbol{k} zuzuordnen.

Zur Transformation zwischen den beiden Koordinatensystemen \boldsymbol{k} und \boldsymbol{x} ist es notwendig, die Ruhelage und relative Bewegung zwischen Kamera und Fahrbahnebene zu kennen. Aus den aktuellen Parametern der Bewegung lässt sich für kleine Zeitdifferenzen Δt vorhersagen, wo die zukünftige Beobachtung der Fahrspur zu erwarten ist [Bar01]. Was als eine kleine Zeitdifferenz Δt anzusehen ist, wird durch die Trägheit der Relativbewegung bezogen auf die Beobachtungsrate $1/t_s$ bestimmt. In dieser Arbeit ist die Beobachtungsrate $1/t_s = 25$ fps durch den Videosensor vorgegeben. Es stellt sich daher die Frage, ob die Relativbewegung zwischen Kamera und Fahrspur ausreichend gut zu präzisieren ist, um die vermutete Lage der Beobachtung in 40 ms sicher vorherzusagen.

Im Allgemeinen kennt jede Bewegung im \mathbb{R}^3 sechs Freiheitsgrade, von denen drei die translatorischen und drei die rotatorischen Anteile beschreiben. Für die hier diskutierte Transformation ergeben sich folgende Vereinfachungen:

- die Fahrspur ruht mit Bezug zu dem weltfesten Koordinatensystem \boldsymbol{x} , die Relativbewegung zwischen beiden Koordinatensystemen ist somit identisch mit der Bewegung der Kamera,
- die Geschwindigkeit in Fahrtrichtung $v_{ego} = \partial x / \partial t$ und der Gierwinkel $\gamma(t)$ sind durch externe Sensoren mit hoher Güte bekannt,
- die Änderung des lateralen Versatzes $\partial y / \partial t$ wird aus $v_{ego}(t)$ und $\gamma(t)$ berechnet,²

² Bei der Berechnung wird vorausgesetzt, dass das Fahrzeug fahrbahnparallel fährt. Diese Annahme ist in der praktischen Anwendung zumindest näherungsweise gegeben.

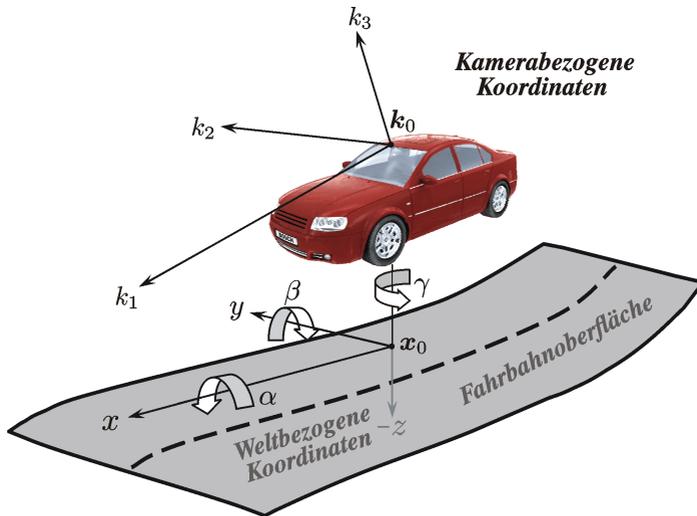


Abbildung 2.4: Koordinatensysteme mit Bezug zur Kamera und zur Fahrbahnoberfläche. Die k_1 -Achse ist im ersten Fall identisch mit der optischen Achse der Kamera, im zweiten Fall ist die x -Achse parallel zur Längsachse des Fahrzeugs orientiert. α bezeichnet den Rollwinkel der Kamera, β den Nickwinkel und γ den Gierwinkel. Die Transformation zwischen beiden Koordinatensystemen kennt sechs Freiheitsgrade, die sich aus monokularen Bildfolgen innerstädtischer Verkehrsszenarien nur mit großer Unsicherheit schätzen lassen.

- die Variation der Einbauhöhe der Kamera z_c ist durch das Fahrzeug auf wenige Zentimeter eingeschränkt und kann vernachlässigt werden, vgl. u. a. [Fra00].

Es wird deutlich, dass die Translation und Rotation grundsätzlich unterschiedliche Charakteristika aufweisen. Die Translation beschreibt eine gerichtete Bewegung der Kamera entlang der Trajektorie des Fahrzeugs, deren Komponenten durch dedizierte Sensoren mit hoher Güte erfasst werden. In Kombination mit einfachen kinematischen Modellen lassen sich aus diesen Beobachtungen akkurate Vorhersagen der zukünftigen Position der Kamera ableiten [Fra00].

Im Gegensatz dazu ist die Rotation der Kamera durch eine vglw. hochfrequente Schwingung um ihre Einbaulage gekennzeichnet. Ihre Komponenten weisen dynamische Anteile auf, die nur mit großer Unsicherheit beobachtet werden können.

Die beiden unbekanntenen Bewegungskomponenten sind somit die zeitlichen Änderungen des Nickwinkels $\beta(t)$ und des Rollwinkels $\alpha(t)$ aus Abbildung 2.4. Ihre Dynamik gilt es zu modellieren. Die Rotation zwischen beiden Koordinatensystemen ist durch die Rotationsmatrix 2.2.1 gegeben:

$$\mathbf{R}(\alpha(t), \beta(t), \gamma(t)) = \begin{pmatrix} r_{11}(t) & r_{12}(t) & r_{13}(t) \\ r_{21}(t) & r_{22}(t) & r_{23}(t) \\ r_{31}(t) & r_{32}(t) & r_{33}(t) \end{pmatrix} = {}^3 \quad (2.2.1)$$

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

Bertram u. a. untersuchen in [Ber00] den Anwendungsfall einer dynamischen Leuchtweitenregelung für Fahrzeuge und schlagen eine explizite Modellierung der physikalischen Schwingungseigenschaften des Nickwinkels $\beta(t)$ vor. Die Argumentation wird in dieser Arbeit aufgegriffen, vgl. Abschnitt 3.2.3.1 auf Seite 72.

2.3 Merkmale der Fahrspur im Einzelbild

Es gibt eine unendliche Vielzahl von Abbildungen des Fahrspurverlaufs vor dem eigenen Fahrzeug. Abhängig von der Beleuchtung der Szene, der Reflektanz der Fahrbahnoberfläche und dem Blickwinkel der Kamera erzeugt das Aufnahmesystem unterschiedliche Bilder des Fahrspurverlaufs. Aus Sicht der Schätzung der vorausliegenden Fahrspurgeometrie handelt es sich bei diesen Einflüssen um Störungen der Beobachtung, die keine Auswirkung auf das Ergebnis der Interpretation haben dürfen.

Die meisten bekannten Verfahren zur Identifikation der Fahrspurgeometrie setzen daher nicht auf dem ursprünglich von der Kamera aufgenommenen Bild auf. In einer sensornahen Bildvorverarbeitung extrahieren sie zunächst charakteristische

³ Aus Platzgründen sind die Zeitabhängigkeiten in der ausführlichen Rotationsmatrix nicht aufgeführt. Es gilt aber weiterhin $\alpha = \alpha(t)$, $\beta = \beta(t)$, $\gamma = \gamma(t)$.



(a) Innerstädtisches Verkehrsszenario aus Sicht der Kamera

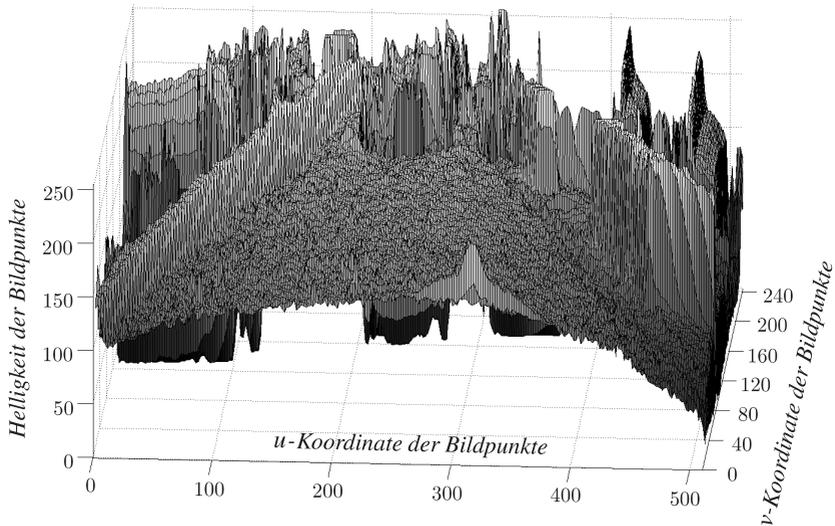
(b) Mathematisch orientierte Sicht $g = f(u, v)$ der identischen Szene

Abbildung 2.5: Zwei Ansichten eines innerstädtischen Verkehrsszenarios. Abbildung 2.5(a) zeigt die Szene aus Sicht der Kamera, für den menschlichen Betrachter ist der Fahrspurverlauf offensichtlich. Abbildung 2.5(b) zeigt das identische Szenario in einer mathematisch orientierten Darstellung $g = f(u, v)$. Die Erfahrung der gewohnten Wahrnehmung wird ausgeblendet. In dieser Ansicht wird deutlich, wie schwer es ist, eindeutige Merkmale der Fahrspur zu finden. Insbesondere hebt sich die rechte Fahrspurberandung nur wenig von der Fahrbahntextur ab.

Merkmale⁴ der Fahrspur im Bild, die weitgehend unabhängig von Störungen der Beobachtung sind. In ihrem Kern lassen sich diese Ansätze auf Kombinationen aus Glättungsoperationen und numerischen Ableitungen zurückführen.

Die in der Literatur zur videobasierten Fahrspurschätzung diskutierten Abbildungsmerkmale lassen sich in drei Gruppen unterteilen. Regionenbasierte Ansätze (Abschnitt 2.3.2) modellieren die Bildpunkte der Fahrbahnoberfläche als ein zusammenhängendes Gebiet kohärenter Eigenschaften. Komplementär dazu gehen kantenbasierte Ansätze (Abschnitt 2.3.1) davon aus, dass die Bildpunkte der Fahrspurberandung eine Gruppe kohärenter Eigenschaften bilden. Der spektrale Ansatz aus [Kre99] (Abschnitt 2.3.3) basiert auf der Annahme, dass die Abbildung der Fahrspur im Frequenzspektrum charakteristische Merkmale aufweist.

In allen drei Fällen geht es letztlich darum, Bildpunkte der Fahrspur auf Grund von formalen Merkmalen ihrer lokalen Bildnachbarschaft möglichst eindeutig von allen anderen Bildpunkten zu unterscheiden. Abbildung 2.5 verdeutlicht, welche Einschränkung sich aus der Forderung nach lokalen Bildnachbarschaften ergibt. Im Kontext der gesamten beobachteten Szene ist der Fahrspurverlauf für den menschlichen Betrachter offensichtlich, vgl. Abbildung 2.5(a). Abbildung 2.5(b) zeigt die identische Helligkeitsverteilung als zweidimensionale Oberfläche $g = f(u, v)$ über den Koordinaten des Bildsensors. In dieser mathematisch orientierten Darstellung wird die Erfahrung der menschlichen Wahrnehmung ausgeblendet, der globale Bildinhalt bleibt verborgen. In dieser Ansicht wird deutlich, wie schwer es ist, eindeutige Merkmale der Fahrspur zu finden. Insbesondere hebt sich die rechte Fahrspurberandung und der Parkstreifen nur wenig von der Fahrbahntextur ab.

Die Detektion charakteristischer Abbildungsmerkmale ist grundsätzlich nicht das Ziel der Bildinterpretation, sondern eine elementare Vorbereitung der anschließenden Interpretation. Die Qualität der Merkmale lässt sich folglich nur im Kontext der gesamten Anwendung beurteilen. In diesem Abschnitt werden die bekannten Abbildungsmerkmale der Fahrspur vorgestellt und ihre Anwendung auf innerstädtische Fahrspurverläufe diskutiert.

2.3.1 Kantenbasierte Ansätze

Der Begriff Kante ist in der Bildinterpretation mit unterschiedlichen Bedeutungen belegt [Jia02], u. a. sind unterschiedliche Kantenprofile bekannt [Zio98]. Zusammenfassend lässt sich eine Kante als signifikante Änderung eines Attributs der

⁴ Eine Definition und Diskussion des Begriffs Merkmal im Kontext der visuellen Umfeldwahrnehmung autonomer Fahrzeuge findet sich in [Hof04], Abschnitt 1.2.

Beobachtung in einem lokalen Bildbereich beschreiben [Ver91]. In dieser Arbeit ist das betrachtete Attribut die Intensität des Grauwertbildes.

Die meisten Verfahren zur videobasierten Fahrspurschätzung basieren auf Kanten [Kas03]. Sie gehen davon aus, dass die Fahrspurberandungen der realen Welt mit Kanten im beobachteten Bild korrespondieren. In der konkreten Umsetzung sind sie häufig durch mehrstufige Verfahren realisiert, deren Qualität anhand der folgenden drei Gütekriterien bewertet wird:

Detektionsrate – Minimierung der Wahrscheinlichkeit für das Übersehen von Kantenpunkten („false negatives“) und das fälschliche Markieren von Nicht-Kantenpunkten („false positives“)

Lokalisierungsgenauigkeit – Kantenpunkte sollen die Kante möglichst exakt markieren

Eindeutigkeit – jeder Kantenpunkt soll genau ein Mal markiert werden

Der populärste Kantendetektor der Gegenwart ist der Canny-Operator [Jia02]. Bemerkenswert an dem Verfahren ist, dass die drei Kriterien in der Herleitung des Operators explizit berücksichtigt sind [Can83], [Can86]. Die Lösung basiert auf der Berechnung des geglätteten Gradienten $\nabla g(\mathbf{b})$:

$$g(\mathbf{b}) = n(\mathbf{b}, \sigma) ** g'(\mathbf{b}); \quad \|\nabla g(\mathbf{b})\| = \sqrt{\left(\frac{\partial g(\mathbf{b})}{\partial u}\right)^2 + \left(\frac{\partial g(\mathbf{b})}{\partial v}\right)^2} \quad (2.3.1)$$

$$\angle(\nabla g(\mathbf{b})) = \arctan\left(-\frac{\partial g(\mathbf{b})}{\partial u} / \frac{\partial g(\mathbf{b})}{\partial v}\right); \quad 0 \leq \angle(\nabla g(\mathbf{b})) \leq \pi$$

Das aufgenommene Bild $g'(\mathbf{b}) = g'(u, v)$ wird zunächst mit der zweidimensionalen Gaußfunktion $n(\mathbf{b}, \sigma)$ gefaltet. Es entsteht das geglättete Bild $g(\mathbf{b})$, das anschließend partiell in Richtung der Koordinaten (u, v) abgeleitet wird. Das Ergebnis wird dargestellt als Betrag $\|\nabla g(\mathbf{b})\|$ und Richtung $\angle(\nabla g(\mathbf{b}))$ des Grauwertgradienten. Zusätzlich wird vorausgesetzt, dass die Richtung $\angle(\nabla g)$ orthogonal zur Modellrichtung der Kante verläuft. Dieses Kriterium wird verwendet, um die exakte Position der Kante im lokalen Maximum des Kontrasts $\|\nabla g\|$ zu berechnen.

Maßgeblich motiviert durch die Ergebnisse der UTA-Studie [Fra98], [Fra00], [Fra02] wird in dieser Arbeit eine kantenbasierte Merkmalerfassung auf Basis des

Canny-Operators umgesetzt. Ergebnisse der Berechnung sind im Abschnitt 4.1.1 zusammengefasst. Neuere Ansätze schlagen weitere Verbesserungen der Detektionsleistung auf Basis komplexerer Auswertungen vor [Köt03a], [Köt03b].

Eine Vielzahl von Verfahren zur Fahrspurdetektion setzen helle Fahrspurmarkierungen auf dunkler Fahrbahntextur voraus, stellvertretend seien hier die Arbeiten von [Go199] und [Geh02] genannt. Für innerstädtische Anwendungen sind diese Ansätze zu selektiv, bspw. werden Bordsteinkanten häufig nicht erkannt [Pae00a].

2.3.2 Regionenbasierte Ansätze

Regionenbasierte Ansätze zur Bildsegmentierung modellieren die interessierende Größe als eine zusammenhängende Fläche kohärenter Eigenschaften. Als Voraussetzung für dieses Vorgehen muss sich die Oberflächentextur der Größe signifikant von ihrer Umgebung unterscheiden.

Ist diese Voraussetzung erfüllt, erzielen regionenbasierte Verfahren häufig die besseren Ergebnisse als kantenbasierte Ansätze [Jäh02]. Dies ist maßgeblich dadurch begründet, dass mehr Bildpunkte zur Schätzung beitragen und das Ergebnis damit robuster gegen Beobachtungsfehler wird. In Kombination mit statischen Kameras zur Verkehrsüberwachung oder Farbkameras zur Detektion von Verkehrszeichen und Ampeln aus bewegten Fahrzeugen sind erfolgreiche Implementierungen bekannt [Kas03].

In einigen frühen Arbeiten wird die Anwendung von regionenbasierten Verfahren zur Fahrspurschätzung diskutiert [Enk97]. Die Abbildung der Fahrbahnoberfläche wird als nahezu homogenes Gebiet modelliert.

Bereits aus einer theoretischen Betrachtung wird deutlich, dass beliebige geteerte Flächen als gültige Beobachtung bewertet werden. Eine gezielte Abgrenzung der eigenen Fahrspur zu benachbarten Fahrspuren, Parkstreifen oder Gehwegen ist nicht möglich, vgl. Abbildung 2.6. Speziell in Innenstädten erscheint es darüber hinaus häufig schwierig, die Fahrbahnoberfläche von umgebenden Gebäuden zu unterscheiden [Hei02].

In dieser Arbeit wird daher kein regionenbasierter Ansatz verfolgt.

2.3.3 Spektrale Ansätze

Kreucher und Lakshmanan diskutieren in [Kre99] einen Algorithmus zur Erkennung von Fahrspurverläufen auf Basis von Merkmalen des Frequenzspektrums lokaler Bildnachbarschaften.



Abbildung 2.6: Regionenbasierte Segmentierung der Fahrbahnoberfläche aus Abbildung 2.5. Angenommen wird, dass der Bildbereich direkt vor dem Fahrzeug (symbolisiert durch das rote Kreuz) zur Oberfläche gehört. Ausgehend von dieser Position wird rekursiv nach benachbarten Bildpunkten gesucht, die ähnliche Helligkeitswerte besitzen.

Zur konkreten Berechnung wurde der Flood Fill-Algorithmus aus [Int05] verwendet. Grün eingezeichnete Bildpunkte sind als Fahrbahnoberfläche klassifiziert worden. Das Verfahren detektiert die Fahrspur und den benachbarten Parkstreifen als ein zusammenhängendes Gebiet, die rechte Begrenzung der Fahrspur wird nicht erkannt. Das Ergebnis ist typisch für innerstädtische Szenarien, häufig werden auch angrenzende Gehsteige als Fahrbahnoberfläche interpretiert. In dieser Arbeit wird daher ein kantenbasierter Ansatz bevorzugt, vgl. Abbildung 2.10.

$$\mathbf{G}_b \propto \sum_{i=0}^{n-1} \sum_{j=0}^{n-1} g_{ij} \cdot \cos\left(\frac{(2i+1) \cdot u \cdot \pi}{2 \cdot n}\right) \cdot \cos\left(\frac{(2j+1) \cdot v \cdot \pi}{2 \cdot n}\right) \quad (2.3.2)$$

Die Autoren verwenden die Diskrete Kosinustransformation (DCT) aus Gleichung 2.3.2, um quadratische Blöcke der Größe $n = 8$ Pixel in den Frequenzbereich zu transformieren. Die g_{ij} bezeichnen die Helligkeitswerte an den Positionen (i, j) des Eingangsblocks. \mathbf{G}_b ist die ebenfalls quadratische Matrix der korrespondierenden DCT-Koeffizienten.

Kreucher und Lakshmanan analysieren die Koeffizientenmatrix \mathbf{G}_b auf Muster, die diagonaldominanten Kanten im Ortsraum entsprechen. Dahinter steckt die Annah-

me, dass moderat gekrümmte Fahrspurverläufe bei der verwendeten Kamerageometrie auf nahezu diagonale Kanten abgebildet werden. Die Annahme ausschließlich diagonaldominanter Fahrspurverläufe ist für die Abbildung innerstädtischer Verkehrsszenarien nicht haltbar, bspw. treten in Kreuzungsbereichen Kanten beliebiger Vorzugsrichtung auf.

Die Transformation 2.3.2 kann auch zur Optimierung der Rechenzeit sinnvoll sein [Jäh02]. Faltungsoperationen im Ortsraum reduzieren sich bspw. auf einfache Multiplikationen im Frequenzbereich. Insbesondere bei der Verwendung aufwändiger Merkmale zahlen sich die einmaligen Kosten für die Transformation aus.

2.3.4 Angepasste Schwellen bei Entscheidungen

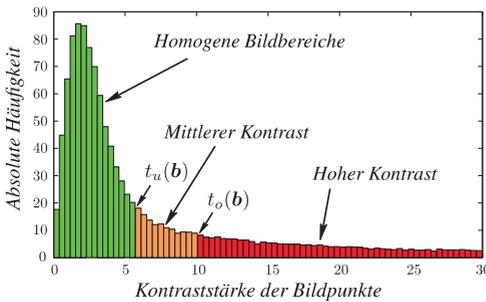


Abbildung 2.7: Histogramm der Kontrastverteilung $\nabla g(\mathbf{b})$ aus Abbildung 2.5. Grüne Anteile symbolisieren Bildpunkte in homogenen Bereichen, orange mittlere und rote hohe Kontraststärke. Die beiden Entscheidungsschwellen der Hysterese werden aus der Verteilung berechnet.

Aus der wissenschaftlichen Betrachtung lassen sich harte Entscheidungsschwellen $t(\mathbf{b})$ bei der Analyse natürlicher Bilder $g(\mathbf{b})$ nur schwer herleiten. Es ist nicht zu begründen, warum kleine Änderungen $\Delta g(\mathbf{b})$ des Eingangssignals zu qualitativ unterschiedlichen Interpretationen führen.

Andererseits ist es für die praktische Umsetzung der Algorithmen vielfach notwendig, vermutlich irrelevante Information so früh wie möglich zu unterdrücken. Die Wahl der Entscheidungsschwellen hat dabei maßgeblichen Einfluss auf das

Ergebnis der nachfolgenden Schätzung.

Oftmals lassen sich zutreffende Entscheidungsschwellen aus dem vermuteten Bildinhalt und dem zugrunde liegenden Datenmodell herleiten. Beispielhaft ist in Gleichung 2.3.3 die allgemeine Definition einer zweistufigen Schwellwertfunktion $t(\mathbf{b})$ mit der oberen Schwelle $t_o(\mathbf{b})$ und der unteren Schwelle $t_u(\mathbf{b})$ angegeben. Die Prädikatsfunktion $f(\mathbf{b}, n(\mathbf{b}))$ entscheidet aufgrund lokaler Nachbarschaften $n(\mathbf{b})$, welche Schwelle an Bildposition \mathbf{b} anzuwenden ist.

$$t(\mathbf{b}) = \begin{cases} t_u(\mathbf{b}) \vee \{g(\mathbf{b}) \mid f(\mathbf{b}, n(\mathbf{b})) = true\} \\ t_o(\mathbf{b}) \vee \{g(\mathbf{b}) \mid f(\mathbf{b}, n(\mathbf{b})) = false\} \end{cases} \quad (2.3.3)$$

Abbildung 2.7 verdeutlicht das Prinzip der Berechnung. Weitere Details zur Berechnung angepasster Entscheidungsschwellen finden sich bspw. in [Ver91]. In dieser Arbeit wird ein Hysterese-Schwellwert an die globale Kontrastverteilung des Bildes angepasst. Die Grenzen $t_o(\mathbf{b})$ und $t_u(\mathbf{b})$ werden zur Maskierung gültiger Merkmalspunkte verwendet.

2.4 Rekonstruktion von Tiefeninformation

Im weiteren Verlauf der Arbeit werden geometrische Modelle der Fahrspur diskutiert, vgl. Kapitel 2.5. Grundsätzlich unterschieden werden dabei Modelle mit Bezug zur realen Welt (vgl. Kapitel 2.5.1) und mit Bezug zum beobachteten Bild (vgl. Kapitel 2.5.2). Stärken und Schwächen beider Ansätze werden wesentlich davon beeinflusst, wie gut die Entfernung beobachteter Bildpunkte rekonstruiert werden kann.

Bildfolgen enthalten keine explizite Information über den Abstand beobachteter Bildpunkte. Abbildung 2.3(b) macht anschaulich klar, dass die Entfernung der Bildpunkte bei der projektiven Abbildung auf den optischen Sensor verloren geht.

Dieses Kapitel stellt den Stand der Technik grundsätzlich verschiedener Ansätze zur Schätzung von Tiefeninformation aus Bildsequenzen vor. Eine detaillierte Diskussion aktueller Verfahren zu diesem Thema findet sich in [Gar03].

2.4.1 Disparität

Binokulare Kamerasysteme sind aus zwei Bildsensoren aufgebaut, die aus unterschiedlichen Blickwinkeln auf die Szene schauen. Die Kameras werden so angeordnet, dass eine hohe Überdeckung beider Bildinhalte erreicht wird. Dazu werden die optischen Achsen der Sensoren annähernd parallel ausgerichtet und der Abstand der Kameras wird signifikant kleiner gewählt als die Distanz beobachteter Objekte.

Abbildung 2.8(a) zeigt ein einfaches Modell der Abbildungsgeometrie des binokularen Kamerasystems. Die Projektionszentren c und c' beider Kameras und der

beliebige Punkt \boldsymbol{x} der dreidimensionalen Wirklichkeit spannen die Epipolarebene \boldsymbol{E} auf. Der Schnitt der Epipolarebene mit der Bildebene \boldsymbol{B}' ergibt die Epipolarlinie \boldsymbol{l}' des Punktes \boldsymbol{b} . Die korrespondierende Abbildung \boldsymbol{b}' kann nur entlang dieser Geraden liegen, die Suche reduziert sich damit auf ein eindimensionales Problem. Die Verschiebung der Bildpunkte \boldsymbol{b} und \boldsymbol{b}' wird Disparität genannt.

Aus Sicht der Fahrspurerkennung kann die Lage der Epipolarlinien als bekannt vorausgesetzt werden. Algorithmen zur initialen Kalibrierung (vgl. [Abr00]) und zur Nachführung von Änderungen [Dan06a] ermitteln und überwachen die Lage und innere Abbildungsgeometrie der Kameras im laufenden Betrieb.

2.4.2 Optischer Fluss

Der optische Fluss ist die beobachtbare Verschiebung von Grauwertstrukturen in zeitlich aufeinander folgenden Bildern. Die Berechnung des optischen Flusses stützt sich auf die Annahme, dass Grauwertstrukturen entlang ihrer Bewegungstrajektorien über der Zeit erhalten bleiben.

Ein direkter Rückschluss von der wahrgenommenen Bewegung auf die Entfernung beobachteter Bildpunkte ist nicht möglich. Neben der Bewegung der Kamera trägt auch die Bewegung beobachteter Objekte zur Verschiebung von Helligkeiten im Bild bei. Weiteres Vorwissen über die wahre Bewegung in der beobachteten Szene erlaubt jedoch stochastische Aussagen zur vermuteten Entfernung des Bildpunkts. Insbesondere kann für Strukturen der Fahrspuroberfläche vorausgesetzt werden, dass sie mit Bezug zur dreidimensionalen Wirklichkeit ruhen.⁵

Eine zeitliche Folge von zweidimensionalen Bildern wird durch die Helligkeitsverteilung $g(\boldsymbol{b}, t)$ beschrieben, bei der g der Grauwert an der Position $\boldsymbol{b} = (u, v)$ zum Zeitpunkt t ist. Bereits im Jahr 1981 formulierten Horn und Schunk die Brightness Constancy Constraint Equation (BCCE)⁶ [Hor81]. Sie stellt eine Analogie zwischen der Kontinuitätsgleichung der Hydrodynamik und der wahrnehmbaren Bewegung in Bildfolgen her. Als die zur Dichte der Flüssigkeit analoge Größe modellieren sie die Grauwertstruktur $g(\boldsymbol{b}, t)$ des Bildes. Analytisch fassen sie den optischen Fluss folglich als Nullstelle des totalen Differentials der Helligkeitsverteilung g auf.

⁵ Die isolierte Betrachtung des optischen Flusses erlaubt somit – entgegen der Überschrift von Abschnitt 2.4 – keine Rekonstruktion der Tiefeninformation. Weitere Bildmerkmale und Modellannahmen über die Fahrbahnoberfläche sind notwendig, um die Entfernung von 3D-Positionen der Fahrspur zu schätzen, s. u.a. [Ste00].

⁶ In der Literatur wird die Gleichung auch als Optical Flow Constraint (OFC) oder Image Brightness Constancy Equation (IBCE) bezeichnet.

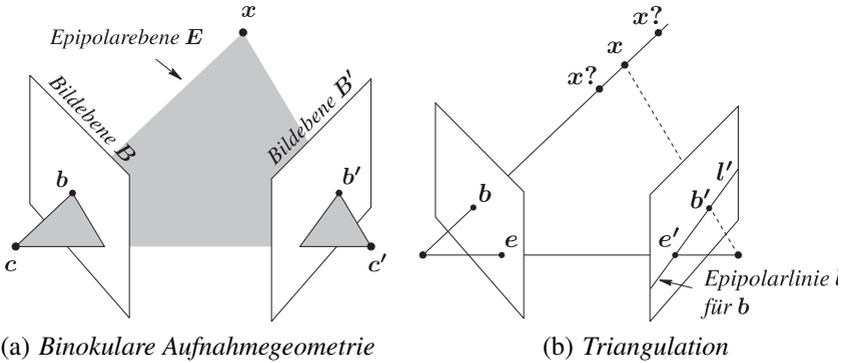


Abbildung 2.8: Punktkorrespondenzen im binokularen Kamerasystem.⁷ Die Projektionszentren c und c' beider Kameras und der Punkt x der dreidimensionalen Wirklichkeit spannen die Epipolarebene E auf. e und e' bezeichnen die Epipole beider Bildebenen. Der Schnitt von E mit der zweiten Bildebene ergibt die Epipolarlinie l' zum Bildpunkt b . Die korrespondierende Abbildung b' kann nur entlang dieser Linie erfolgen. Häufig werden die Kamerasgeometrien derart rektifiziert, dass die Epipolarlinien mit den Bildzeilen übereinstimmen. Aus der beobachteten Disparität der Bildpunkte b und b' und der Kalibrierung der Kameras lässt sich die 3D-Position von x durch Triangulation rekonstruieren.

$$\begin{aligned} \frac{dg(\mathbf{b}(t), t)}{dt} &= \frac{\partial g}{\partial u} \cdot \frac{\partial u}{\partial t} + \frac{\partial g}{\partial v} \cdot \frac{\partial v}{\partial t} + \frac{\partial g}{\partial t} = 0 & (2.4.1) \\ &= \begin{pmatrix} \frac{\partial g}{\partial u} & \frac{\partial g}{\partial v} \end{pmatrix} \cdot \begin{pmatrix} \frac{\partial u}{\partial t} \\ \frac{\partial v}{\partial t} \end{pmatrix} + \frac{\partial g}{\partial t} = (\nabla g)^T \cdot \mathbf{v} + \frac{\partial g}{\partial t} \end{aligned}$$

Der optische Fluss ist damit das Verhältnis von der räumlichen zur zeitlichen Ableitung der Helligkeit. Wie in der Bildverarbeitung üblich, bezeichnet der Vektor $\mathbf{v} = (v_u, v_v)^T$ dabei die wahrnehmbare Verschiebung der Koordinaten $\mathbf{b} = (u, v)^T$ eines Bildpunkts zwischen zwei zeitlich aufeinander folgenden Bildern.

⁷ Eine ursprüngliche Version dieser Abbildung stammt aus [Har03].

Die numerische Bestimmung des optischen Flusses ist bis heute Gegenstand wissenschaftlicher Diskussion. Um beide Komponenten von \mathbf{v} zu ermitteln, sind mindestens zwei Bedingungen für jede Position \mathbf{b} notwendig. Die skalare Gleichung 2.4.1 liefert jedoch nur eine. Als zusätzliche Bedingung fordern Horn und Schunk daher einen räumlich glatten Verlauf des optischen Flusses und minimieren die gewichtete Summe aus BCCE und Glattheitsterm über lokale Bildnachbarschaften.

Minimierung und Diskretisierung von 2.4.2 führt zu zwei Gleichungen für jeden Bildpunkt, aus denen sich die Komponenten v_u und v_v des Bewegungsvektors \mathbf{v} bestimmen lassen. λ bezeichnet dabei das Gewicht des Glattheitsterms.

$$\iint_B \underbrace{\left(\nabla g^T \cdot \mathbf{v} + \frac{\partial g}{\partial t} \right)^2}_{BCCE} + \lambda \cdot \underbrace{\left(\|\nabla v_u\|^2 + \|\nabla v_v\|^2 \right)}_{Glattheitsterm} dudv \rightarrow \min \quad (2.4.2)$$

Ein sehr effizientes Verfahren zur praktischen Berechnung dichter Bewegungsfelder aus natürlichen Bildfolgen wird in [Ste04] vorgestellt. Auf Basis der Census Transformation wird die lokale Nachbarschaft jedes Bildpunkts in einer Signatur kodiert, welche als Index einer Lookup Tabelle dient. Bei diesem Ansatz ist der Aufwand für die anschließende Suche korrespondierender Bereiche in zeitlich aufeinander folgenden Bildern linear zur Größe n des Suchfensters. Die Komplexität klassischer Ansätze ist hingegen $O(n^2)$. Abbildung 2.9 zeigt die geschätzten Verschiebungsvektoren für ein typisches innerstädtisches Verkehrsszenario.

Stein u. a. diskutieren in [Ste00] ein direktes Verfahren zur Schätzung der Relativbewegung zwischen der Kamera und der Fahrbahnoberfläche. Nach ihrer Argumentation sind merkmalsbasierte Ansätze für diese Anwendung ungeeignet. Die Textur der Fahrbahnoberfläche ist häufig annähernd homogen oder besteht aus linearen Strukturen. Durch das Blendenproblem in der Abbildung kann in dieser Situation nur die Bewegungskomponente bestimmt werden, die senkrecht zu der Kante verläuft.

Folgt das Fahrzeug einem nur moderat gekrümmten Fahrspurverlauf, ist die Bewegung aber maßgeblich durch die nicht messbare Verschiebungskomponente entlang der beobachtbaren Kanten bestimmt. Stein empfiehlt daher, den optischen Fluss für beliebig gewählte Bildausschnitte zu bestimmen und die Verschiebungsvektoren anschließend über ein robustes Schätzverfahren zu plausibilisieren.

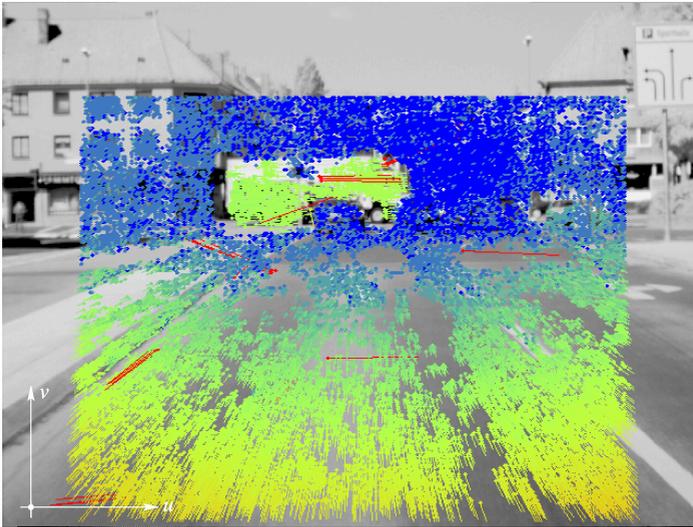


Abbildung 2.9: *Optisches Flussfeld eines innerstädtischen Verkehrsszenarios, berechnet nach dem Algorithmus von [Ste04]. Der Betrag des Flusses ist als Wärmebild kodiert: Ruhende Bildpunkte sind dunkelblau dargestellt, wärmere Farben repräsentieren größere Beträge. Deutlich zu erkennen ist der kreuzende LKW im Hintergrund. Aber auch die schwache Textur der Fahrbahnoberfläche bietet ausreichend Information, um ein vglw. dichtes Flussfeld zu schätzen. Die dunkelrot eingezeichneten Vektoren sind grobe Fehler in der Schätzung.*

2.4.3 Inverse projektive Geometrie

Wie in Abschnitt 2.1 bereits festgestellt wurde, ist es nicht möglich, den Informationsverlust der projektiven Abbildung auf den Bildsensor durch eine inverse Operation zu kompensieren.

Der Begriff Inverse projektive Geometrie⁸ meint entgegen seiner wörtlichen Bedeutung eine Transformation des beobachteten Bildes unter zusätzlichen Annahmen [Mal91]. In der Literatur zur videobasierten Fahrspurschätzung bezeichnet er die Projektion aller Bildpunkte auf die Fahrbahnoberfläche, deren geometrische Lage bzgl. der Kamera als bekannt angenommen wird [Ber98], [Fra99]. In anderen Bereichen der Bildverarbeitung wird diese Projektion von Bildinhalten auf a -

⁸ In englischer Originalliteratur wird Inverse projektive Geometrie als Inverse Perspective Mapping bezeichnet [Mal91].

priori bekannte 3D-Modelle der betrachteten Szene als Texture Surface Mapping bezeichnet, um die Eigenschaften der Abbildung klarer zu benennen [Grü05].

In der videobasierten Fahrspurschätzung wird die Geometrie der Fahrbahnoberfläche häufig durch die Ebene $z = 0$ des Weltkoordinatensystems x aus Abbildung 2.4 approximiert. Im einfachsten Fall wird darüber hinaus angenommen, dass die dynamische Lage der Fahrbahnoberfläche bzgl. des Kamerakoordinatensystems aus Abbildung 2.4 durch die Parameter der statischen Kamerakalibrierung hinreichend gut beschrieben ist. Eine Diskussion dieser Annahme für innerstädtische Umgebungen findet sich in Abschnitt 2.2.

Die in dieser Arbeit verwendeten Kameras verfügen über eine konstante Winkelauflösung. Beim Einbau in das Fahrzeug werden kleine Werte für den Gierwinkel zwischen optischer Achse der Kamera und Längsachse des Fahrzeugs realisiert ($\gamma \approx 0^\circ$), um vorausschauende Assistenzfunktionen sinnvoll zu unterstützen.

Auch der Rollwinkel α zwischen Bildebene und Fahrbahnoberfläche wird klein gewählt ($\alpha \approx 0^\circ$). Viele Algorithmen der Bildauswertung lassen sich effizienter gestalten, wenn die ausgezeichneten Achsen der Bildebene mit horizontalen bzw. vertikalen Strukturen der Wirklichkeit übereinstimmen (vgl. u. a. [Vio01]).

Mit diesen Voraussetzungen lässt sich eine hinreichend gute Näherung für die Zuordnung von Bildpunkten zu Positionen der dreidimensionalen Wirklichkeit gemäß Gleichungen 2.4.3, 2.4.4 und 2.4.5 formulieren. Die Entfernung x der Bildpositionen \mathbf{b} ist vollständig durch den jeweiligen Zeilenindex v bestimmt. Insbesondere folgt daraus auch, dass alle Punkte \mathbf{b} einer Bildzeile die identische Entfernung x entlang der Längsachse des Fahrzeugs zur Fahrbahnoberfläche besitzen.

$$x(\mathbf{b}) = x(v) \approx^9 \frac{z_c}{\tan(\beta(v))} \quad (2.4.3)$$

z_c bezeichnet die kalibrierte Einbauhöhe der Kamera über der Fahrbahnoberfläche, $\beta(v)$ den Nickwinkel zwischen der Fahrbahnebene und dem Sichtstrahl zum Bildpunkt $\mathbf{b} = (u, v)$. Er berechnet sich aus

$$\beta(v) = \frac{v - v_{fp}}{v_{bild}} \cdot \Delta\beta \quad \forall v > v_{fp}, \quad (2.4.4)$$

⁹ Zwei Annahmen liegen der Näherung zugrunde: Die Fahrbahnoberfläche lässt sich durch eine Ebene approximieren, und die relative Position und Orientierung der Kamera entspricht ungefähr der kalibrierten Ruhelage. Sind beide Annahmen erfüllt, gilt die Näherung exakt.

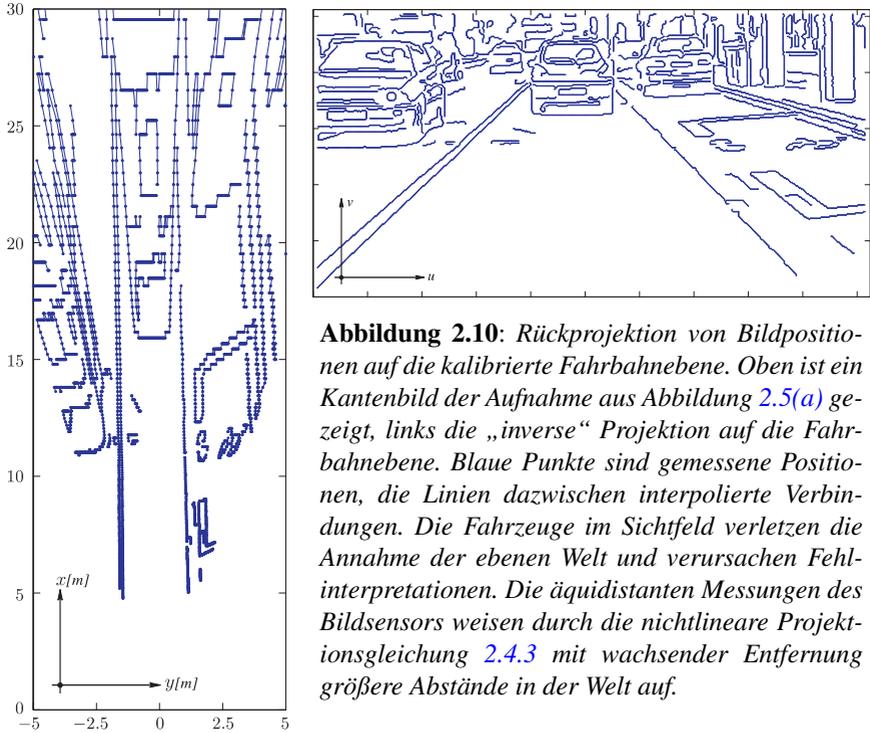


Abbildung 2.10: Rückprojektion von Bildpositionen auf die kalibrierte Fahrbahnebene. Oben ist ein Kantenbild der Aufnahme aus Abbildung 2.5(a) gezeigt, links die „inverse“ Projektion auf die Fahrbahnebene. Blaue Punkte sind gemessene Positionen, die Linien dazwischen interpolierte Verbindungen. Die Fahrzeuge im Sichtfeld verletzen die Annahme der ebenen Welt und verursachen Fehlinterpretationen. Die äquidistanten Messungen des Bildsensors weisen durch die nichtlineare Projektionsgleichung 2.4.3 mit wachsender Entfernung größere Abstände in der Welt auf.

wobei v_{fp} den Zeilenindex des kalibrierten Fluchtpunktes, u_{bild} die Höhe des Bildes und $\Delta\beta$ den vertikalen Öffnungswinkel der Kamera bezeichnet. Für $v \leq v_{fp}$ ist $\beta(v) \leq 0$, es existiert kein Schnittpunkt des Sichtstrahls mit der kalibrierten Fahrbahnebene.

Das Verhältnis von $x(\mathbf{b})$ zu der kalibrierten Brennweite f_u bildet den Skalierungsfaktor der Abbildung des Bildpunktes \mathbf{b} . Die korrespondierende seitliche Ablage $y(\mathbf{b})$ berechnet sich damit näherungsweise zu

$$y(\mathbf{b}) = y(u, v) \approx \frac{x(v)}{f_u} \cdot (u - u_{fp}) \quad (2.4.5)$$

Abbildung 2.10 verdeutlicht zwei wesentliche Eigenschaften der inversen projektiven Geometrie: Die äquidistanten Messungen des Bildsensors weisen durch die

nichtlineare Projektionsgleichung 2.4.3 mit wachsender Entfernung größere Abstände in der Welt auf, Fahrzeuge im Sichtfeld der Kamera verletzen die Annahme der ebenen Welt und verursachen Fehlinterpretationen.

2.4.4 Photomischdetektoren

Von den bisher vorgestellten Verfahren zur optischen Entfernungsschätzung erlauben nur die binokularen Kamerasysteme eine tatsächliche Vermessung des 3D-Umfelds vor dem eigenen Fahrzeug. Die Qualität der geschätzten Entfernungen ist dabei maßgeblich durch die Unsicherheiten bei der Stereo-Korrespondenzanalyse bestimmt, vgl. Abschnitt 2.4.1. In natürlichen Bildfolgen limitiert das Messprinzip die Entfernungsschätzung damit auf signifikante Diskontinuitäten in der Grauwertstruktur. Die Anwendung von Stereo-Kameras in kommerziellen Assistenzsystemen wird zusätzlich durch die Kosten für den zweiten Sensor und die aufwendige Korrespondenzanalyse erschwert.

Photomischdetektoren (PMDs) realisieren eine optische Entfernungsschätzung ohne diese Limitierungen. Aktuelle Fortschritte bei dieser Technologie lassen vermuten, dass diese Technologie in naher Zukunft Anwendung im automobilen Umfeld finden wird. Buxbaum und Hagebeucker stellen in [Bux05] einen derartigen PMD-Sensor vor. Er liefert neben der Helligkeitsverteilung auch die Entfernung der einzelnen Bildpunkte im Blickfeld der Kamera. Wie beim Radar wird die Entfernung der Pixel über die Laufzeit eines ausgesendeten Signals zu der beobachteten Objektoberfläche und zurück bestimmt. Die derzeit leistungsfähigsten PMD-Sensoren haben 160×120 3D-Pixel und erreichen Wiederholraten bis zur 200 fps. Im Rahmen des Förderprojektes 3D-STAM wurde ein miniaturisierter PMD-Sensor aufgebaut und auf seine Leistungsfähigkeit in automobilen Anwendungen untersucht [Vdi03].

Bei den praktischen Umsetzungen in dieser Arbeit kamen keine PMD-Sensoren zum Einsatz. Aus der theoretischen Betrachtung scheint die Kombination zum hier realisierten Konzept vielversprechend.

2.5 Modelle der Fahrspurgeometrie

Die Linienführungen realer Fahrspurverläufe ergeben sich aus Anforderungen der Fahrdynamik und einer möglichst guten Anpassung an die umgebende Landschaft. Teilstücke der Linienführung werden dabei durch Trassierungselemente definiert, die den Verlauf der Fahrspur mathematisch beschreiben. Im Straßenbau werden

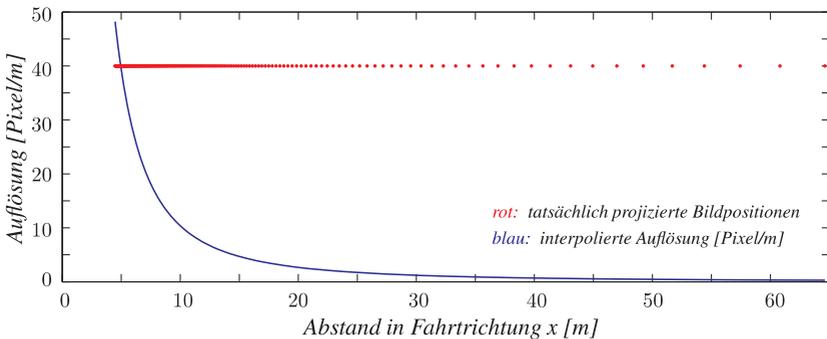


Abbildung 2.11: Auflösung der Fahrbahnoberfläche im Bild. Mit den Vereinfachungen der Gleichung 2.4.3 werden den Bildzeilen des optischen Sensors Entfernungen der dreidimensionalen Wirklichkeit zugeordnet. In rot dargestellt sind die tatsächlich auf die Ebene projizierten Bildpositionen (vgl. auch Abbildung 2.10), die blaue Kurve zeigt die interpolierte Auflösung der Fahrbahnoberfläche in Fahrtrichtung [Pixel/m]. Unter der Annahme konstanter Beobachtungsfehler in der Bildebene nimmt neben der Anzahl der Beobachtungen auch die Genauigkeit der einzelnen Projektion mit wachsender Entfernung überproportional ab.

Für innerstädtische Assistenzfunktionen lassen sich die geforderten zeitlichen Vorhersagen mit der Auswertung einer vglw. geringen Vorausschauweite erzielen. Dies ermöglicht prinzipiell robustere und genauere Schätzungen des interessierenden Fahrspurverlaufs.

Geraden und Kreise als Trassierungselemente konstanter Krümmung verwendet, ein linearer Übergang zwischen ihnen wird durch Klothoiden realisiert, vgl. Abbildung 2.12. Reale Fahrspurgeometrien sind somit aus unterschiedlichen mathematischen Basiselementen zusammengesetzt.

Geometrische Modelle der Fahrspur beschreiben eine parametrische Abstraktion der Form des vorausliegenden Fahrspurverlaufs im Sichtbereich der Kamera. Während die in Kapitel 2.3 diskutierten Abbildungsmerkmale der Fahrspur lokale Nachbarschaften weniger Bildpunkte auswerten, ergänzen geometrische Modelle das Schätzverfahren um *a-priori* Information über umfassendere Eigenschaften der Fahrspur, vgl. auch Abbildung 3.1.

Der allgemeine Modellbegriff ist sehr abstrakt und in verschiedenen wissenschaftlichen Disziplinen mit unterschiedlichen Bedeutungen belegt. In dieser Arbeit wird einer Auffassung aus der Modelltheorie gefolgt, die ein Modell durch drei Eigenschaften definiert [Mod06]:

Definition 2.1 (Modell) 1. Ein Modell ist eine Repräsentation natürlicher oder künstlicher Originale. 2. Es erfasst nicht alle Attribute des Originals, sondern nur diejenigen, die dem Modellschaffer bzw. Modellnutzer relevant erscheinen. 3. Ein Modell ist einem Original nicht von sich aus zugeordnet. Die Zuordnung wird durch die Fragen Für wen?, Warum? und Wozu? relativiert.

Eine angemessene Modellierung ist damit maßgeblich durch die beabsichtigte Anwendung bestimmt und kann nur in ihrem Kontext beurteilt werden. In diesem Abschnitt werden aus der Literatur bekannte Modelle der Fahrspurgeometrie vorgestellt und ihre Anwendung zur innerstädtischen Fahrspurschätzung aus monokularen Bildfolgen diskutiert. Unterschieden werden dabei Modelle mit Bezug zur dreidimensionalen Wirklichkeit (vgl. Abschnitt 2.5.1) und Modelle mit Bezug zum zweidimensionalen Raster des Bildsensors (vgl. Abschnitt 2.5.2).

2.5.1 Modellierung der Fahrspur in der Welt

Modelle des Fahrspurverlaufs mit Bezug zur dreidimensionalen Wirklichkeit beschreiben die vorausliegende Geometrie der Fahrspur in einem Weltkoordinatensystem, vgl. bspw. x in Abbildung 2.4. Bei dieser Vorgehensweise lassen sich die geometrischen Modelle direkt aus den Richtlinien zum Straßenbau [Rzs06] ableiten.

Bereits 1992 führten Dickmanns und Mysliwetz in [Dic92] ein Polynom dritten Grades als analytisch geschlossene Approximation der horizontalen Fahrspurgeometrie im Sichtbereich der Kamera ein. Ausgehend von der linearen Änderung der Krümmung $a_h(l)$ ¹⁰ einer Klothoide entlang ihrer Bogenlänge l_d

$$a_h(l_d) = a_{0h} + a_{1h} \cdot l_d \quad (2.5.1)$$

bestimmt sich der Gierwinkel $\gamma_d(l_d)$ der Tangente an der Klothoide gegenüber der z -Achse aus Abbildung 2.4 zu

$$\gamma_d(l_d) = \int_0^{l_d} a_h(l'_d) \, dl'_d = a_{0h} \cdot l_d + a_{1h} \cdot \frac{l_d^2}{2}. \quad (2.5.2)$$

¹⁰ In der Originalliteratur werden die Krümmungsparameter mit c bezeichnet. In dieser Arbeit wird der zu schätzende Parametervektor für alle Modelle einheitlich mit a gekennzeichnet.

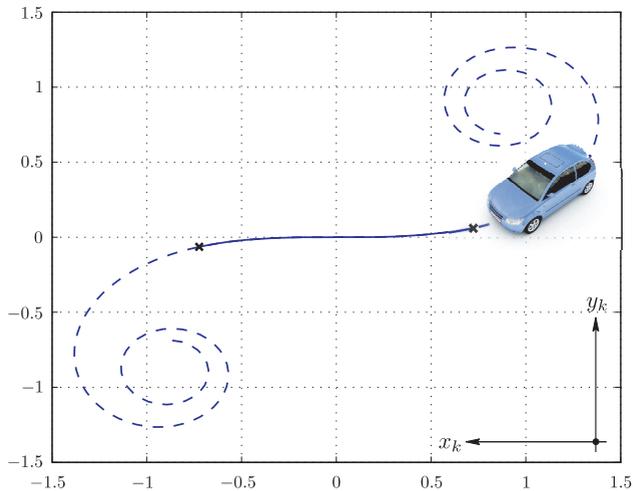


Abbildung 2.12: Einheitsklothoide im Intervall $l = [-5,5]$. Klothoiden stammen aus der Differentialgeometrie, ihr unabhängiger Parameter l ist die Bogenlänge entlang des Kurvenverlaufs. Definiert sind Klothoiden über die Eigenschaft, dass sich ihre Krümmung c linear mit der Bogenlänge l ändert ($c \propto l$). Im Straßenbau werden sie verwendet, um Übergänge zwischen Elementen mit konstanter Krümmung zu realisieren. Als Modell für die Fahrspurschätzung sind sie jedoch ungeeignet, da keine explizite Form zur Bestimmung ihrer Parameter existiert. Für moderate Änderungen der Fahrtrichtung wird in [Dic92] daher die Approximation durch ein Polynom dritten Grades eingeführt. Eine hohe Approximationsgüte erreicht die Näherung im Bereich von $\pm 15^\circ$, hier als durchgezogene Linie dargestellt. Innerstädtische Fahrspurverläufe unterliegen im Sichtbereich der Kamera häufig signifikanten Richtungsänderungen, die diese Annahme verletzen.

Dickmanns und Mysliwetz gehen von moderat gekrümmten Fahrspurverläufen aus, wie sie bei Autobahnen und gut ausgebauten Landstraßen üblich sind, vgl. Abbildung 2.12. Damit stimmt die Bogenlänge $l_d(\mathbf{p})$ vom Ursprung bis zu einem Punkt \mathbf{p} näherungsweise mit dessen Entfernung $x_k(\mathbf{p})$ im kartesischen Koordinatensystem \mathbf{x} aus Abbildung 2.4 überein.

Eine hohe Approximationsgüte erreicht das Modell im Bereich $\gamma_d(\mathbf{p}) \leq \pm 15^\circ$, der in Abbildung 2.12 als durchgezogene Linie gekennzeichnet ist. Für diese kleinen Werte von γ_d gilt:

$$l_d(\mathbf{p}) = \int_0^{\mathbf{p}} \cos(\gamma_d(\mathbf{p}')) d\mathbf{p}' \approx x_k(\mathbf{p}) \quad (2.5.3)$$

Mit der Näherung aus Gleichung 2.5.3 vereinfacht sich die Bestimmung der seitlichen Ablage $y_k(\mathbf{p})$ des Punktes \mathbf{p} für kleine Winkel $\gamma_d(\mathbf{p})$ zu

$$y_k(\mathbf{p}) = \int_0^{\mathbf{p}} \sin(\gamma_d(\mathbf{p}')) d\mathbf{p}' \approx y_{k,0} + \frac{a_{0h}}{2} \cdot x_k^2(\mathbf{p}) + \frac{a_{1h}}{6} \cdot x_k^3(\mathbf{p}) \quad (2.5.4)$$

Mit den in Abschnitt 2.6 vorgestellten Verfahren lassen sich die gesuchten Krümmungen a_{0h} und a_{1h} aus Gleichung 2.5.4 explizit bestimmen. In Kombination mit kantenbasierten Merkmalen (vgl. Abschnitt 2.3.1) auf Basis von [For93] wird dieser Ansatz als Lösung der videobasierten Fahrspurschätzung auf Autobahnen und Landstraßen betrachtet.

In Innenstädten erzwingt die umgebende Infrastruktur regelmäßig signifikante Änderungen der horizontalen Fahrspurkrümmung entlang kurzer Abschnitte der Linienführung, bspw. in Kreuzungsbereichen (vgl. Abbildung 1.1(b)) oder an Verkehrsinseln. Die elementaren Vereinfachungen der Gleichungen 2.5.3 und 2.5.4 sind nicht mehr zulässig, die Modellierung innerstädtischer Fahrspurverläufe erfordert flexiblere Ansätze [Beh98], [Fra97]. Im Rahmen der UTA-Studie [Fra98] stellen Paetzold und Franke in [Pae00b] fest, dass die Beschreibung innerstädtischer Fahrspurgeometrien im Sichtbereich der Kamera durch ein globales Modell niedriger Ordnung nicht möglich ist. Modelle höherer Ordnung werden ebenfalls als Lösung ausgeschlossen, da sie zu Oszillationen entlang der stückweise glatten Trassierungselemente neigen [Hei02].

Der grundsätzliche Ansatz zur Modellierung innerstädtischer Fahrspurgeometrien ist daher in der wissenschaftlichen Diskussion weitgehend unstrittig: Anstelle einer globalen Beschreibung werden die unterschiedlichen Trassierungselemente im Sichtbereich der Kamera auf eine Menge lokaler Polynome niedriger Ordnung abgebildet.

Franke u. a. approximieren in [Fra97], [Fra98] und [Fra99] extrahierte Konturen durch Geradensegmente, die in einer Datenbank organisiert werden. Als Attribute der Geraden definieren sie ihre Position mit Bezug zur kalibrierten Fahrbahnebene

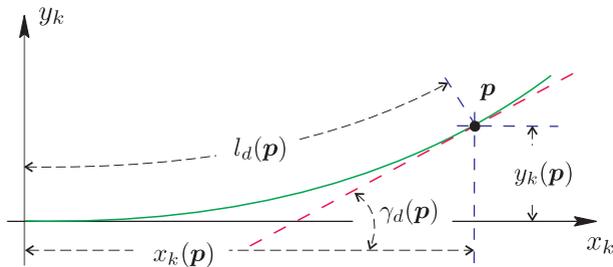


Abbildung 2.13: Approximation der Klothoide aus Abbildung 2.12. Der Index d kennzeichnet Parameter der Differentialgeometrie, der Index k Parameter der kartesischen Beschreibung. Der Zusammenhang zwischen beiden Darstellungen ist in den Gleichungen 2.5.2 bis 2.5.4 definiert.

(vgl. Abschnitt 2.4.3), ihre Länge, Orientierung, Parallelität und Kollinearität. Alle Geraden, die ein nicht näher beschriebenes Ähnlichkeitsmaß übersteigen, werden als mögliche Fahrspurberandungen klassifiziert. Beispielhafte Ergebnisse sind in den oben genannten Artikeln visualisiert.

Splines ergänzen den lokalen Einfluss zwischen Beobachtungen und Modellparametern um einen stetigen Übergang zwischen aufeinander folgenden Segmenten, vgl. [Her96], [Uns99]. Wang u. a. nutzen diese Eigenschaft und modellieren die Fahrspurgeometrie in [Wan98] und [Wan00] mit Catmull-Rom Splines. Als wesentliche Eigenschaft dieser Splines heben die Autoren hervor, dass die Kontrollpunkte der einzelnen Polynome direkt auf dem Kurvenverlauf liegen. Die Parameter des Kurvenverlaufs lassen sich damit explizit aus der Kontrastverteilung im Bild (vgl. bspw. Abbildung 4.2) berechnen.

Heimes wertet in [Hei00] Information von einer kommerziellen digitalen Straßenkarte aus, um den Fahrspurverlauf vor dem eigenen Fahrzeug zu modellieren. Die Karte enthält die Position von Stützstellen der Fahrspurgeometrie. Jeweils zwei Stützstellen sind mit einem Liniensegment verbunden, welches Attribute dieses Fahrspursegments enthält. Die ungefähre Position und Orientierung des eigenen Fahrzeugs wird aus einem DGPS-Signal ermittelt, die präzise Anpassung und die zeitliche Verfolgung basiert auf der Bildfolge einer Stereo-Kamera. Insbesondere in visuell schwierigen Situationen an innerstädtischen Kreuzungen oder bei vorübergehender Verdeckung von Fahrspurberandungen erzielen Heimes u. a. bemerkenswerte Ergebnisse, vgl. auch [Hei02].

2.5.2 Modellierung der Fahrspur im Bild

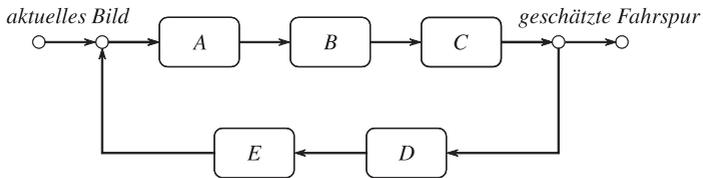
Modelle des Fahrspurverlaufs in der Bildebene beschreiben die vorausliegende Geometrie der Fahrspur mit Bezug zum Raster des optischen Sensors, repräsentiert durch das Bildkoordinatensystem \mathbf{b} aus Abbildung 2.3. Im Gegensatz zu der weltbezogenen Darstellung aus Abschnitt 2.5.1 ist das Modell damit nicht mehr unabhängig von der Abbildungsgeometrie der verwendeten Kamera, bietet andererseits aber folgende Vorteile:

- Beobachtete Bildpositionen und Fahrspurmodell haben das Bildkoordinatensystem aus Abbildung 2.3 als gemeinsame Bezugsgröße. Die Unsicherheit der dynamischen Transformation zwischen unterschiedlichen Koordinatensystemen ist aus der Rückkopplungsschleife zur Fahrspurschätzung ausgekoppelt (vgl. Blöcke A, C und D in Abbildung 2.14(b)).
- Die Anzahl notwendiger Rechenoperationen wird reduziert. Während beim weltbezogenen Ansatz in Abbildung 2.14(a) jede beobachtete Bildposition transformiert wird, werden bei der bildbezogenen Schätzung nur die Parameter des Modells umgerechnet. Die Rücktransformation des Modells in die Bildebene entfällt (vgl. Block E in Abbildung 2.14(b)).
- Im allgemeinen Fall unterstützt die Fahrspurschätzung mehrere Assistenzfunktionen mit unterschiedlichen Anforderungen an die weltbezogene Darstellung der vorausliegenden Fahrspurgeometrie. Eine flexible Modellierung der Fahrspur im Bild ermöglicht angepasste Transformationen für die verschiedenen Anwendungen (vgl. Blöcke B_i in Abbildung 2.14(b) und die Intention der Modellbildung aus Definition 2.1).

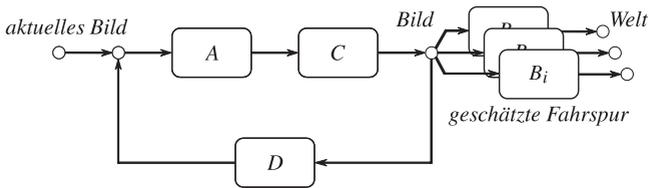
Aus dieser Motivation heraus schlagen verschiedene Autoren bildbezogene Modelle der Fahrspurgeometrie vor:

Guiducci u. a. analysieren in [Gui99] und [Gui00] die Projektion der Klothoidenapproximation aus [Dic92] auf die Bildebene. Sie nehmen eine planare Fahrbahnoberfläche an und setzen die Einschränkungen des Abschnitts 2.4.3 bzgl. der Abbildungsgeometrie der verwendeten Kameras voraus. Unter diesen Annahmen lässt sich die Fahrspurgeometrie im Bild als Hyperbel beschreiben:

$$u - u_{fp} = \underbrace{a_0 \cdot (v - v_{fp})}_{\text{Gerade}} + \underbrace{\frac{a_1}{v - v_{fp}} + \frac{a_2}{(v - v_{fp})^2} + \dots}_{\text{Horizontale Asymptote}} \quad (2.5.5)$$



(a) Fahrspurschätzung mit Bezug zur Welt



(b) Fahrspurschätzung mit Bezug zur Bildebene

Abbildung 2.14: Prinzipielle Struktur der Fahrspurschätzung mit Bezug zum Weltkoordinatensystem x aus Abbildung 2.4 bzw. zum Bildkoordinatensystem b aus Abbildung 2.3. Die Blöcke A bis E symbolisieren folgende Funktionalitäten:

- A: Berechnung der Bildmerkmale, abhängig von der Lage des Modells
- B: Transformation in weltbezogene Darstellung (Merkmale bzw. Modell)
- C: Aktualisierung der Schätzung auf Basis der Beobachtungen
- D: Prädiktion des Modells auf den nächsten Beobachtungszeitpunkt
- E: Rücktransformation des weltbezogenen Modells in die Bildebene

Während sich die weltbezogene Schätzung besser aus den physikalischen Attributen der Beobachtungen begründen lässt, sind die unterschiedlichen Einflussfaktoren auf die Schätzung beim bildbezogenen Ansatz besser separiert. Eine genauere Betrachtung findet sich in den Abschnitten 2.5.1 und 2.5.2.

Der Index fp kennzeichnet die Koordinaten des Fluchtpunkts, $(u-u_{fp},)$ ist der laterale Versatz in Abhängigkeit vom Zeilenindex v . Im unteren Bildbereich bestimmt die konstante Steigung a_0 eine nahezu lineare Änderung der seitlichen Ablage, bei gekrümmten Fahrspuren wird die asymptotische Annäherung an den Horizont maßgeblich durch die Koeffizienten a_1 und a_2 der Hyperbelerme dominiert.

Während sich a_0 und a_1 stabil aus den Bilddaten schätzen lassen, sind die Hyperbelterme höherer Ordnung auf Grund mangelnder Beobachtungsdichte in größeren Entfernungen mit hoher Unsicherheit behaftet. Die Autoren beschränken sich daher auf die Schätzung dieser beiden Parameter und stellen ein Verfahren zu ihrer Initialisierung vor.

Aus Sicht übergeordneter Assistenzfunktionen ist bemerkenswert, dass die Parameter des Modells direkt zu physikalischen Größen der realen Welt korrespondieren. Die konkrete Umrechnung ist im Anhang von [Gui99] dargelegt.

Wang u. a. diskutieren in [Wan04] die weitgehend formfreie Beschreibung der vorausliegenden Fahrspurgeometrie mit B-Splines. Abhängig von der Anzahl verwendeter Basispolynome sind nahezu beliebige Geometrien darstellbar. Die Autoren präsentieren Ergebnisse für drei und vier Basispolynome und belegen eine größere Flexibilität in der Darstellung möglicher Fahrpurverläufe. Initialisiert werden die Splines auf Basis von Liniensegmenten, die das Ergebnis von lokalen Hough-Transformationen in statisch festgelegten Bildbereichen sind.

Zur zeitlichen Verfolgung der Polynome nutzen die Autoren den von Kass u. a. in [Kas87] veröffentlichten Snake-Algorithmus. Die optimale Lage der Kurve im Bild berechnet sich aus einer kooperativen Ausgleichung zwischen Krümmungsenergie und akkumulierter Kontraststärke entlang des Kurvenverlaufs. Die analytische Beschreibung der Ausgleichung und die numerische Bestimmung ihrer Lösung sind ausführlich im Anhang A.2 dargelegt.

Snake-Algorithmen minimieren die Energie des Splines in einer iterativen Suche und betrachten das nächstliegende lokale Minimum als die gesuchte Lösung. Maßgeblichen Einfluss auf die Qualität der Approximation hat daher die korrekte Initialisierung der ungefähren Lage der Splinekurve. Unter dieser Voraussetzung erzielen Snakes in vielen Bereichen der Bildinterpretation beeindruckende Resultate, vgl. u. a. [Klu95], [Bam98], [Kan99], [Yag00].

Wang u. a. nutzen in ihrer Arbeit dichte Felder der Kontraststärke, um die optimale Lage der Splines zu bestimmen (vgl. bspw. Abbildung 4.2(a)). Aufgrund der Größe des resultierenden Suchraums dauert die Initialisierung des Verfahrens vier Sekunden, die Aktualisierung der Schätzung läuft mit 2 fps. Eine direkte Umsetzung von B-Snakes im Versuchsfahrzeug ist daher noch nicht möglich.

Als elementare Vereinfachung werden in dieser Arbeit daher nur lokale Maxima der Kontraststärke als gültige Beobachtung der Fahrspurberandung betrachtet, vgl. Abschnitt 2.3.1. Ergebnisse der Berechnung sind im Abschnitt 4.1 visualisiert.

2.6 Schätzung von Modellparametern

In den Abschnitten 2.2 und 2.5 wurden Modelle zur Beschreibung der Kameradynamik bzw. der Fahrspurgeometrie im Blickfeld der Kamera vorgestellt. Bisher wurde nichts darüber gesagt, wie die unbekanntes Koeffizienten der Modelle aus den Beobachtungen bestimmt werden. In diesem Kapitel werden Kriterien diskutiert, die bestimmte Schätzverfahren als sinnvoll rechtfertigen. Eine detaillierte, mathematisch exakte Diskussion aktueller Algorithmen zur Parameterschätzung findet sich in [Zha97].

Die grundlegende Idee zur Schätzung von Modellparametern wurde bereits 1795 von K.-F. Gauß formuliert, vgl. [Sor70]. Im Kontext astronomischer Studien motiviert er die Anwendung von Schätzverfahren wie folgt:¹¹

Axiom 2.1 (Motivation zum Schätzen) *If the astronomical observations and other quantities on which the computation of orbits is based were absolutely correct, the elements also, whether deduced from three or four observations, would be strictly accurate [...] and, therefore, if other observations were used, they might be confirmed but not corrected. But since all our measurements and observations are nothing more but approximations to the truth, the same must be true of all calculations resting upon them, and the highest aim of all computations made concerning concrete phenomena must be to approximate, as nearly as practicable, to the truth. But this can be accomplished in no other way than by a suitable combination of more observations than the number absolutely requisite for the determination of the unknown quantities. [...]*

Schätzung bedeutet somit, bzgl. eines zu definierenden Optimierungskriteriums eine bestmögliche Lösung zu berechnen [May79]. Dieses Kapitel diskutiert die Eigenschaften unterschiedlicher Optimierungskriterien und -strategien.

2.6.1 Parameterschätzung als Optimierungsproblem

Die Auswertung des hochaufgelösten Sensorsignals liefert häufig einen Beobachtungsvektor mit deutlich mehr Elementen als unbekanntes Koeffizienten in den parametrischen Modellen zur Beschreibung der Kameradynamik und der Fahrspurgeometrie, vgl. Abschnitte 2.3, 2.4.2, 2.2 und 2.5.

Eine exakte Anpassung der Modellparameter an die Beobachtung ist somit nicht möglich und wäre nach den Annahmen des Axioms 2.1 auch nicht sinnvoll. Die

¹¹ Ursprünglich hat Gauß das Axiom in lateinischer Sprache verfasst, vgl. [Gau63].

Lösung des überbestimmten Gleichungssystems ist eine Optimierungsaufgabe im Sinne der Ausgleichsrechnung.

2.6.1.1 Vermittelnde Ausgleichung

Algorithmen zur vermittelnden Ausgleichung von Beobachtungsfehlern gehen davon aus, dass sich alle Beobachtungen durch einen einzigen Parametervektor interpretieren lassen. Implizit setzen diese Ansätze eine hinreichend große Stichprobe von Beobachtungen voraus, bei der die Verteilung der Beobachtungsfehler *a-priori* bekannt ist. Unter dieser Annahme wird das Optimierungskriterium der Ausgleichung unabhängig von den Eigenschaften der Beobachtungsdaten formuliert und das Verfahren zur Berechnung der Lösung lässt sich geschlossen angeben.

In den folgenden Abschnitten werden drei Werkzeuge zum Entwurf von vermittelnden Schätzfunktionen vorgestellt.

Minimierung der Fehlerquadrate

Neben der grundsätzlichen Motivation zum Schätzen (vgl. Axiom 2.1) geht auch die konkrete Methodik zum Entwurf eines bestmöglichen Schätzers im Sinne der kleinsten Fehlerquadrate auf K.-F. Gauß zurück. Als Optimierungskriterium definiert er in [Gau63] folgende Eigenschaft der Schätzung:

Axiom 2.2 (Methode der kleinsten Quadrate) *The most probable value of the unknown quantities will be that in which the sum of the squares of the differences between the actually observed and the computed values multiplied by the numbers that measure the degree of precision becomes a minimum.*

Modelliert wird ein funktionaler Zusammenhang zwischen beobachteten Funktionswerten \mathbf{b} mit zugeordneten Variablen \mathbf{x} , der von einem unbekanntem Parametervektor \mathbf{a} abhängt. Für jede Beobachtung existiert ein Gewicht $1/\sigma$. Die wahrscheinlichste Schätzung $\hat{\mathbf{a}}_{mkq}$ bestimmt sich aus

$$\hat{\mathbf{a}}_{mkq} = \arg \min_{\mathbf{a}} \left\| \frac{\mathbf{b} - f(\mathbf{x}, \mathbf{a})}{\boldsymbol{\sigma}} \right\|^2 \Rightarrow \sum_{i=0}^{n-1} \left(\frac{b_i - f(x_i, \mathbf{a})}{\sigma_i} \right)^2 \Bigg|_{\hat{\mathbf{a}}_{mkq}} \stackrel{!}{=} \min \quad (2.6.1)$$

In der ursprünglichen Fassung ist die Methode der kleinsten Quadrate somit eine Definition. Das theoretische Fundament des Optimierungskriteriums wurde

erst später entwickelt: Für normalverteilte Beobachtungsfehler lässt sich zeigen, dass die Minimierung der quadratischen Residuen zwischen Modell und Beobachtung gleichzeitig den bestmöglichen Schätzer im Sinne der Maximum Likelihood Schätzung darstellt (vgl. Seite 40 und Anhang A.1). Die breite Anwendbarkeit des Optimierungskriteriums beruht auf dem Zentralen Grenzwertsatz der Statistik (vgl. [Bro91], Seite 677).

Bei mehrdimensionalen Beobachtungen stellt sich die Frage, wie der Abstand zwischen Modell und Beobachtung zu ermitteln ist. Vereinfachend wird als Fehlermaß häufig die Abweichung in Richtung einer der ausgezeichneten Achsen des verwendeten Koordinatensystems definiert, s. bspw. Gleichung 2.6.1. De Groen diskutiert in [dG96] das Verfahren der Totalen Fehlerquadrate, nach dem der senkrechte Abstand zwischen Modell und Beobachtung als Abweichung betrachtet wird. Besondere Bedeutung bekommt diese Unterscheidung, sobald die Residuen gegenüber dem Beobachtungsintervall nicht mehr vernachlässigbar sind.

Maximum Likelihood (ML) Schätzung

Das Prinzip der Maximum Likelihood Schätzung basiert auf einer Zufallsvariablen B , deren Verteilungsdichte f sich abhängig von einem zunächst unbekanntem Parametervektor \mathbf{a} beschreiben lässt, d. h. $f = f(B; \mathbf{a})$. Für statistisch unabhängige Elemente b_1, \dots, b_n einer realisierten Beobachtung \mathbf{b} wird das Eintreten dieser Beobachtung als Funktion des unbekanntem Parametervektors \mathbf{a} aufgefasst:

$$\begin{aligned} \hat{\mathbf{a}}_{mle} &= \arg \max_{\mathbf{a}} \underbrace{\{P(B | \mathbf{a})\}}_{L(\mathbf{a})} = \arg \max_{\mathbf{a}} \left\{ \prod_{i=0}^{n-1} P(b_i | \mathbf{a}) \right\} & (2.6.2) \\ &= \arg \max_{\mathbf{a}} \left\{ \sum_{i=0}^{n-1} \ln P(b_i | \mathbf{a}) \right\} = \arg \min_{\mathbf{a}} \left\{ \sum_{i=0}^{n-1} -\ln f_{B|\mathbf{a}}(b_i | \mathbf{a}) \right\} \end{aligned}$$

Die Lösung $\hat{\mathbf{a}}_{mle}$ wird Maximum Likelihood Schätzung für den wahren Parametervektor \mathbf{a} genannt. Die praktische Bestimmung der ML-Schätzungen für die Werte des Parametervektors $\hat{\mathbf{a}}_{mle}$ basiert auf Methoden der Differentialrechnung. Häufig wird dabei ausgenutzt, dass die Likelihood Funktion $L(\mathbf{a})$ genau dort ihr Maximum hat, wo $\ln(L(\mathbf{a}))$ maximal ist. Die resultierende Summe in Gleichung 2.6.2 ist leichter zu differenzieren als ein Produkt.

Die Bestimmung der ML-Schätzung für normalverteilte Beobachtungsfehler findet sich im Anhang A.1.

Maximum A-Posteriori (MAP) Schätzung

Das Prinzip der Maximum Likelihood stützt die plausibelsten Parameter zur Erklärung einer realisierten Beobachtung ausschließlich auf die erwartete Verteilungsdichte der Beobachtungsfehler, vgl. Seite 39. Häufig ist es darüber hinaus sinnvoll, weitere – bereits vor der Realisierung bekannte – Bedingungen bei der Bestimmung der vermutlichen Ursache für die Beobachtung einzubeziehen.

Die *Maximum A-Posteriori*-Schätzung erweitert daher das Prinzip der ML-Schätzung um eine Erwartungshaltung, die aufgrund von Vorwissen bereits vor der Realisierung der Beobachtung bekannt ist. Formal wird der MAP-Schätzer über das Bayes'sche Theorem hergeleitet [Bro91], das Ergebnis lässt sich für statistisch unabhängige Beobachtungen \mathbf{b} wie folgt formulieren:

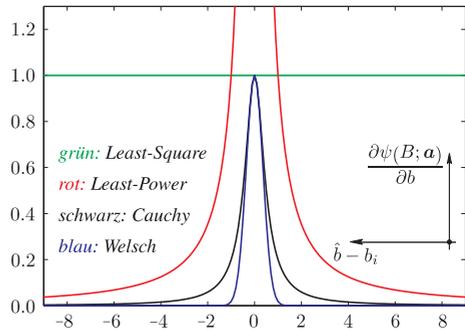
$$\begin{aligned}
 \hat{\mathbf{a}}_{map} &= \arg \max_{\mathbf{a}} \left\{ P(\mathbf{a} | B) \right\} =^{12} \arg \max_{\mathbf{a}} \left\{ P(B | \mathbf{a}) \cdot P(\mathbf{a}) \right\} & (2.6.3) \\
 &= \arg \max_{\mathbf{a}} \left\{ \prod_{i=0}^{n-1} P(b_i | \mathbf{a}) \cdot P(\mathbf{a}) \right\} \\
 &= \arg \max_{\mathbf{a}} \left\{ \sum_{i=0}^{n-1} \ln P(b_i | \mathbf{a}) + \ln P(\mathbf{a}) \right\} \\
 &= \arg \min_{\mathbf{a}} \left\{ \sum_{i=0}^{n-1} -\ln f_{B|\mathbf{a}}(b_i | \mathbf{a}) - \ln f_A(\mathbf{a}) \right\}
 \end{aligned}$$

Die Lösung $\hat{\mathbf{a}}_{map}$ ist die Maximum A-Posteriori Schätzung für den wahren Parametervektor \mathbf{a} . $P(\mathbf{a})$ bezeichnet die unbedingte Wahrscheinlichkeit für die Realisation des Parametervektors \mathbf{a} und wird *a-priori* Wahrscheinlichkeit genannt. Der Faktor $P(B | \mathbf{a})$ ist die in Gleichung 2.6.2 definierte Likelihood $L(\mathbf{a})$,

Angewendet auf die videobasierte Schätzung von Fahrspurverläufen analysiert ein MAP-Schätzer, wie weit die Bildinformation einer *a-priori* vermuteten Abbildung der Fahrspur entspricht. Etwas salopp formuliert wird das Vorwissen über die vermutete Position während der Initialisierung des Schätzers aus typischen Fahrspurverläufen abgeleitet, vgl. Abschnitt 3.2.2.2. Während der zeitlichen Verfolgung wird die *a-priori* Information aus der vorherigen Beobachtung und der erwarteten Änderung bestimmt, s. Abschnitte 2.2, 2.6.2, 3.2.3.1 und 5.1.3.

¹² Die Identität der geklammerten Terme ist nicht gegeben, auf der rechten Seite wurde auf den konstanten Skalierungsfaktor $1/P(B)$ verzichtet. Die Lösung für den Parametervektor $\hat{\mathbf{a}}_{map}$ ist davon unabhängig, bzgl. dieser Größe gilt die Gleichheit.

Abbildung 2.15: Einflussfunktionen $\partial\psi/\partial b$ zur robusten Parameterschätzung. Um die Auswirkung einzelner grober Messfehler zu limitieren, werden in M -Schätzern häufig Least-Power, Cauchy oder Welsch Funktionen verwendet. Im Gegensatz dazu gewichtet die vermittelnde Ausgleichung nach der Methode der kleinsten Quadrate alle Beobachtungen gleich.



2.6.1.2 Robuste Ausgleichung

Im Abschnitt 2.6.1.1 wurden Algorithmen vorgestellt, die aus unsicheren Beobachtungen eine bestmögliche Lösung bzgl. der *a-priori* erwarteten Verteilung der Messungenauigkeiten berechnen. Jede Beobachtung wird dabei als eine annähernde Beschreibung der Wirklichkeit aufgefasst (vgl. Axiom 2.1), Störungen werden ausschließlich durch Ungenauigkeiten in den Beobachtungen erklärt. Bei der Auswertung natürlicher Bildfolgen lässt sich diese Annahme nicht sinnvoll rechtfertigen. Einzelne Elemente der Beobachtung weisen durch Mehrdeutigkeiten im Sensorsignal regelmäßig signifikante Abweichungen von der angenommenen Verteilung auf, vgl. bspw. Abbildung 2.9. Als Konsequenz weichen geschätzte und wahre Parameter bei ausschließlich vermittelnder Ausgleichung häufig deutlich voneinander ab.

Verfahren zur robusten Ausgleichung von Beobachtungsfehlern zeichnen sich dadurch aus, dass die geschätzten Modellparameter weniger stark durch einzelne grobe Fehler in den Beobachtungen beeinflusst werden. Umgangssprachlich formuliert sind sie unempfindlicher gegenüber Abweichungen von der erwarteten Verteilungsdichte der Messfehler. Nach einer Definition von G. Box aus [Pre92b]¹³ ist ein stochastischer Schätzer robust, wenn er folgende Eigenschaft aufweist:

Definition 2.2 (Robustes Schätzverfahren) *Ein Schätzverfahren ist robust, wenn es unempfindlich gegenüber kleinen Abweichungen von den idealisierten Annahmen ist, für die es optimiert wurde. Was als eine kleine Abweichung zu betrachten ist, ist durch die spezifische Umsetzung des Schätzverfahrens vorgegeben.*

¹³ In [Pre92b] ist Robuste Schätzung in englischer Sprache als „estimation procedure that is insensitive to small departures from the idealized assumptions for which the estimator is optimized“ definiert.

Eine robuste Erweiterung des Prinzips der Maximum Likelihood Schätzung aus Gleichung 2.6.2 ist die Klasse der M-Schätzer. Ihre Eigenschaften werden im folgenden Abschnitt diskutiert.

M-Schätzer

M-Schätzer erweitern das Fehlermodell der Maximum Likelihood Schätzung aus Gleichung 2.6.2. Sie ersetzen die Verteilungsdichte der erwarteten Messungenauigkeiten $f(B; \mathbf{a})$ durch eine Funktion $\psi(B; \mathbf{a})$, die den Einfluss vermuteter grober Fehler in den Beobachtungen \mathbf{b} limitiert.

$$\hat{\mathbf{a}}_{me} = \arg \min_{\mathbf{a}} \left\{ \sum_{i=0}^{n-1} \psi_{b_i}(b_i; \mathbf{a}) \right\} \Rightarrow \sum_{i=0}^{n-1} \left(\frac{\partial \psi_{b_i}(b_i; \mathbf{a})}{\partial \mathbf{a}} \right) \Big|_{\hat{\mathbf{a}}_{me}} \stackrel{!}{=} 0 \quad (2.6.4)$$

Jede Lösung der Gleichung 2.6.4 wird M-Schätzer genannt. In der Literatur werden verschiedene Funktionen für $\psi(B; \mathbf{a})$ vorgeschlagen, vgl. u. a. [Zha97], Seite 33. Für viele dieser Funktionen lässt sich keine explizite Lösung für $\hat{\mathbf{a}}_{me}$ angeben. In der numerischen Umsetzung wird ein M-Schätzer daher häufig als iterative Kleinste-Quadrate Schätzung mit paralleler Anpassung der Gewichte der Beobachtungen \mathbf{b} realisiert, vgl. u. a. [Int05].

2.6.2 Prädiktion zukünftiger Werte

Dynamische Systeme können ihren Zustand nicht beliebig schnell ändern. Für hinreichend kurze Abtastintervalle t_s zwischen aufeinander folgenden Beobachtungen \mathbf{b} sind die Werte der beschreibenden Modellparameter \mathbf{a} korreliert. In der hier diskutierten videobasierten Fahrspurschätzung ist es somit sinnvoll, aus den aktuellen Parametern und der vermuteten Änderung des Systemzustands (vgl. Abschnitt 2.2) eine Erwartungshaltung für die zukünftige Beobachtung abzuleiten.

Im Abschnitt 2.6.1.1 wurde bereits das *Maximum A-Posteriori* Prinzip zur Einbindung von *a-priori* Information in die Schätzung von Modellparametern diskutiert. Insbesondere für die Integration von aktuellen Beobachtungen und Systemwissen zur Prädiktion zukünftiger Werte bieten das Kalman-Filter und das Partikelfilter leistungsfähige mathematische Werkzeuge zur Umsetzung dieses Prinzips.

Die grundsätzliche Funktionsweise beider Verfahren ist in Abbildung 2.16 dargestellt. In den folgenden Abschnitten werden die wesentlichen Eigenschaften des Kalman-Filters und des Condensation Algorithmus kurz vorgestellt.

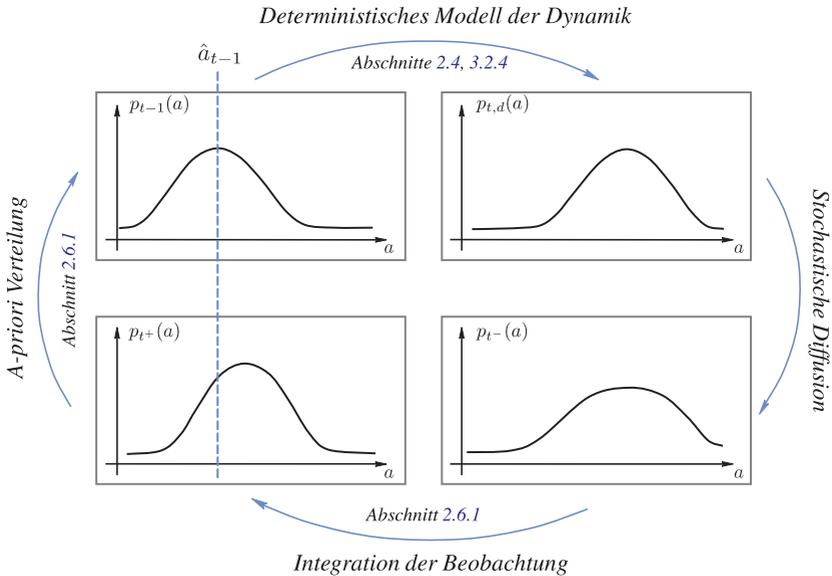


Abbildung 2.16: Integration von Systemwissen und Beobachtungen für einen Parameter a mit normalverteilter Wahrscheinlichkeitsdichte $f(a)$.¹⁴ Der Wert des Parameters zum Zeitpunkt $t - 1$ wird durch die Anwendung des dynamischen Systemmodells (vgl. Abschnitte 2.2, 3.2.3.1) auf den folgenden Beobachtungszeitpunkt t präzidiert. Die Unsicherheit in der Prädiktion wird auf eine stochastische Diffusion abgebildet. Die Integration der Beobachtung b_t (vgl. Seite 40) führt zu einer Korrektur des vorhergesagten Wertes, die Unsicherheit der Schätzung nimmt durch die zusätzliche Information ab. Das Kalman-Filter (vgl. Seite 43) implementiert eine geschlossene Lösung dieses Prinzips für Parameter mit normalverteilter Wahrscheinlichkeitsdichte, das Partikelfilter (vgl. Seite 44) realisiert eine numerische Umsetzung für beliebige Verteilungsdichten. Jede Verteilungsdichte ist dabei durch eine Menge von Realisationen approximiert.

Kalman-Filter

Das Kalman-Filter beschreibt die Änderung der Parameter eines dynamischen Systems mit linearen stochastischen Differenzgleichungen. In seiner ursprünglichen Form basiert es auf der Annahme, dass die Verteilungsdichte der Parameter durch eine Normalverteilung approximiert werden kann. Der Zustand des Systems wird durch einen Schätzwert für jeden Parameter und die zugehörige Kovarianzmatrix geschlossen beschrieben. Die Lösung der Differenzgleichung erfolgt durch Matrixinversion.

Eine ausführliche Diskussion des ursprünglichen Kalman-Filters und aktueller Erweiterungen für nichtlineare Systeme findet sich in [Wei03]. Der Entwurf numerisch stabiler Kalman-Filter für ungünstig konditionierte Beobachtungen erfordert eine sorgfältige Analyse des Systemverhaltens [Sou98], [Ham83].

Partikelfilter

Partikelfilter und ihre Anwendung in der Interpretation von Bildfolgen gehen maßgeblich auf die Arbeit von Isard und Blake zum CONDENSATION-Algorithmus zurück [Isa98]. Sie erweitern das Fehlermodell des Kalman-Filters auf multimodale Verteilungsdichten und verfolgen mehrere Hypothesen \hat{a} über den wahren Wert a des zu schätzenden Parameters.

Der Zustand eines Systemparameters a wird durch eine Menge von Abtastwerten a_s repräsentiert, vgl. u. a. [Bla98], Abbildung 12.5. Die Verteilung der Abtastwerte entspricht dabei der gegebenen Wahrscheinlichkeitsverteilung $p_{t-1}(a)$ aus dem vorherigen Zeitschritt, die Beobachtungsdichte wird auf wahrscheinliche Werte des Parameters konzentriert. Für jeden Abtastwert wird die Verschiebung und anschließende Verifikation anhand der Bildinformation separat berechnet.

Die Wahl einer angemessenen Anzahl von Abtastwerten a_s ist ein wesentliches Entwurfskriterium für einen spezifischen Partikelfilter. Viele Abtastwerte verbessern die Genauigkeit des Verfahrens, erhöhen aber den benötigten Rechenaufwand.

Ein Partikelfilter zur videobasierten Fahrspurschätzung wird in [Apo03] vorgestellt.

2.7 Grenzen bestehender Ansätze

Die Auswertung monokularer Bildfolgen zur Schätzung der vorausliegenden Fahrspurgeometrie aus bewegten Fahrzeugen ist in der wissenschaftlichen Literatur bislang fast ausschließlich im Kontext visuell einfacher Szenarien auf Autobahnen und Landstraßen analysiert worden. Daneben existieren umfangreiche Studien zu innerstädtischen Assistenzfunktionen auf Basis binokularer Umfelderkennung, teilweise wird zusätzlich Information von digitalen Straßenkarten verwendet.

Mit Blick auf die in dieser Arbeit diskutierte Aufgabe lassen sich folgende Fragen aus dem aktuellen Stand der Forschung noch nicht abschließend beantworten:

¹⁴ Eine ähnliche Darstellung des Partikelfilters zur zeitlichen Verfolgung beliebiger Wahrscheinlichkeitsdichten findet sich in [Bla98] im Kapitel 12.

- Die häufig wechselnden Verkehrsszenarien in Innenstädten erfordern regelmäßig neue Initialisierungen des Schätzverfahrens im laufenden Betrieb. Elementare Bedeutung hat somit die Frage, wie der Fahrspurverlauf vor dem eigenen Fahrzeug ohne bekannte Näherungswerte geschätzt werden kann.
- Bislang hat sich kein Modell zur Beschreibung der innerstädtischen Fahrspurgeometrie im Sichtbereich der Kamera durchgesetzt. Einigkeit herrscht darüber, dass ein lokales Modell mit stetigem Übergang zwischen den Elementen sinnvoll ist. Splines werden als vielversprechender Ansatz angesehen. Fraglich ist die konkrete Umsetzung, bspw. ob eine bildbezogene oder etablierte weltbezogene Modellierung vorzuziehen ist (vgl. Abbildung 2.14).
- Die Güte der Prädiktion der geschätzten Fahrspur auf den nächsten Beobachtungszeitpunkt ist maßgeblich durch die hochfrequenten Schwingungen der Kamera um ihre Einbaulage bestimmt (vgl. Abschnitt 2.2). Sie lassen sich aus monokularen Bildfolgen innerstädtischer Verkehrsszenarien nur mit großer Unsicherheit schätzen. Ein explizites Modell der Kameraschwingung könnte als Systemwissen die Fahrspurschätzung zeitlich stabilisieren.
- Für die effiziente Umsetzung von Assistenzfunktionen im Versuchsfahrzeug stellt sich die Frage, wie die direkte Vermessung der Fahrspur und die Detektion von Fahrzeugen integriert werden können. In Innenstädten liefern vorausfahrende Fahrzeuge im Nahbereich vor der Kamera häufig einen indirekten Hinweis auf den Verlauf der Fahrspur. Gleichzeitig verdecken sie dabei die Sicht auf weite Bereiche der Fahrbahnoberfläche, die Auswertung lokaler Bildmerkmale führt in diesen Situationen regelmäßig zu groben Schätzfehlern.

Diese Punkte werden im weiteren Verlauf der Arbeit behandelt. Entscheidend für den praktischen Nutzen der Studie sind Antworten auf die ersten beiden Fragen. Sie stehen daher im Mittelpunkt der Untersuchung.

2.8 Zusammenfassung von Kapitel 2

In diesem Kapitel wurden bekannte Ansätze zur videobasierten Fahrspurschätzung aus bewegten Fahrzeugen behandelt. Ein Indiz für die fundamentale Bedeutung dieser Komponente für vorausschauende Fahrerassistenzsysteme ist die Vielzahl von wissenschaftlichen Veröffentlichungen zu dem Thema. Inhaltlich zeigen die einzelnen Publikationen oft deutliche Überschneidungen. In der systematischen

Analyse werden folgende Aspekte deutlich, die sich weitgehend unabhängig voneinander diskutieren lassen:

Ausgangspunkt der Schätzverfahren ist die Identifikation invarianter Abbildungsmerkmale der Fahrspur, vgl. Abschnitt 2.3. In diesem Schritt geht es darum, Bildpunkte der Fahrbahnoberfläche oder ihrer Berandung auf Grund von formalen Merkmalen ihrer lokalen Bildnachbarschaft möglichst eindeutig von allen anderen Bildpunkten zu unterscheiden. Insbesondere in innerstädtischen Verkehrsszenarien ist es aber unmöglich, allein auf dieser Auswertung eine robuste Schätzung des Fahrspurverlaufs aufzubauen. Verkehrsteilnehmer und die umgebende Infrastruktur verursachen häufig ähnliche Merkmale im Bild, neben Ungenauigkeiten in der Messung ist die Beobachtung somit auch durch grobe Messfehler gestört.

Klassische optische Sensoren liefern keine explizite Information über den Abstand beobachteter Bildpunkte. Eine der elementarsten Aufgaben videobasierter Fahrerassistenzsysteme ist die Assoziation von Bildinhalten mit Positionen der dreidimensionalen Wirklichkeit. Abschnitt 2.4 fasst die unterschiedlichen Lösungsansätze zusammen.

Geometrische Modelle des Fahrspurverlaufs ergänzen die Schätzung um eine *a-priori* Erwartung an die Form des vorausliegenden Fahrspurverlaufs. Die Modelle definieren eine parametrische Beschreibung der Fahrspurgeometrie mit Bezug zum Weltkoordinatensystem x aus Abbildung 2.4 oder dem Bildkoordinatensystem b aus Abbildung 2.3. In beiden Fällen beschränken sie die globale Form möglicher Linienführungen im Blickfeld der Kamera. In Kombination mit robusten Schätzverfahren (Abschnitt 2.6.1.2) ist es somit möglich, grobe Fehler in den beobachteten Abbildungsmerkmalen zu eliminieren und Messungenauigkeiten auszugleichen.

Zeitlich aufeinander folgende Schätzungen des Fahrspurverlaufs werden durch die erwartete Kamerabewegung gestützt, vgl. Abschnitt 2.2. Aus einer angemessenen Modellierung der Fahrzeugdynamik lassen sich Näherungswerte für zukünftige Schätzungen vorhersagen. Neben der beobachteten Bildfolge basiert die zeitliche Verfolgung der Fahrspur damit auch auf Systemwissen über das eigene Fahrzeug.

Die Limitierungen der bekannten Verfahren für den Anwendungsfall der innerstädtischen Fahrspurschätzung aus monokularen Bildfolgen sind im Abschnitt 2.7 bewertet. Potential für prinzipielle Verbesserungen bieten flexible Modelle der Fahrspurgeometrie, mit denen sich lokale Abschnitte des Berandungsverlaufs exakt beschreiben lassen. Splines erscheinen als ein vielversprechender Ansatz. Die Herausforderung an das Schätzverfahren besteht darin, sie robust zu initialisieren und über der Zeit zu verfolgen.

Kapitel 3

Modellierung der innerstädtischen Fahrspur

Im vorherigen Kapitel wurde dargelegt, dass eine globale Modellierung der Abbildungseigenschaften innerstädtischer Fahrspurverläufe im Sichtbereich der Kamera nicht möglich ist. Vielmehr erscheint es sinnvoll, die *a-priori* Annahmen auf lokale Bereiche der Beobachtung einzuschränken. In diesem Kapitel wird daher ein MAP-Schätzer auf Basis eines lokalen, stochastischen Modells von Abbildungseigenschaften der Fahrspurberandung in monokularen Bildfolgen $g(\mathbf{b}, t)$ entwickelt. Die Modellbildung ist hierarchisch organisiert: Zwischen der physikalischen und symbolischen Beschreibung des Verkehrsszenarios werden dabei fünf Abstraktionsstufen unterschieden, vgl. Abbildung 3.1.

Im Abschnitt 3.1 werden zunächst qualitative Annahmen über die charakteristischen Eigenschaften der Fahrspur im Bild aufgestellt. Ausgehend von allgemein gültigen Kriterien für gute Merkmale zur computergestützten Analyse lokaler Bildausschnitte werden im Abschnitt 3.1.1 weitgehend invariante Eigenschaften der Fahrspurberandung diskutiert und bewertet. Die höheren Abstraktionsebenen werden im Abschnitt 3.1.2 behandelt. Sie befassen sich mit der Frage, warum einzelne Elemente der visuellen Beobachtung als zusammengehörige Fahrspurberandung wahrgenommen werden. Motiviert ist die Modellbildung auf diesen Abstraktionsstufen durch Erkenntnisse aus der Neuropsychologie. Sie erklären u. a. auch, warum der menschliche Betrachter die Anordnung aus Abbildung 1.2 auf Seite 4 als Würfel interpretiert.

Das mathematische Modell der innerstädtischen Fahrspur wird im Abschnitt 3.2 formuliert. Die erforderliche Flexibilität zur geometrischen Beschreibung innerstädtischer Fahrspurverläufe wird mit der Spline-Approximation aus [Rei67] rea-

liert. Im Gegensatz zu bekannten Verfahren erlaubt dieser Ansatz eine explizite Kontrolle der Glattheit der Schätzung, ohne die globale Form möglicher Fahrspurverläufe zu limitieren. Die Annahme einer maximalen Ordnung des geometrischen Modells wird durch eine vermutete Glattheit des Fahrspurverlaufs ersetzt. Um die Unsicherheit der dynamischen Transformation zwischen bild- und weltbezogenen Koordinaten nicht über der Zeit zu akkumulieren, wird die Fahrspurgeometrie direkt in der Bildebene \mathbf{b} beschrieben.

Die Initialisierung der Spline-Approximation ist im Abschnitt 3.2.2 beschrieben. Der Bildinhalt wird durch eine Menge von Linien annähernd beschrieben, sie werden als atomare Beobachtungen zur Detektion aufgefasst. Als mathematisches Konzept zur Modellierung der Fahrspurberandungen werden Markov-Ketten verwendet. Zur Berechnung der optimalen Lösung für ein gegebenes Bild wird der Viterbi-Algorithmus aus [Vit67] eingesetzt.

Aus der zeitlichen Betrachtung der beobachteten Bildfolge $g(\mathbf{b}, t)$ ergeben sich weitere Bedingungen für die Schätzung der Fahrspur. Die zeitliche Verfolgung der Berandungen basiert auf der näherungsweise bekannten Lage der Fahrspur im Bild. Dies erlaubt die Modellierung eines integralen Fehlermaßes, mit dem die Schätzung robust gegen einzelne Störungen in der Beobachtung wird, vgl. Abschnitt 3.2.3.

Ziel der folgenden Abschnitte ist es, invariante Abbildungseigenschaften der Fahrspur zu identifizieren (Abschnitte 2.3, 3.1.1) und eine sinnvolle Erwartungshaltung an die Form des Fahrspurverlaufs zu formulieren (Abschnitte 3.1.2 ff., 3.2).

3.1 Abstraktion der Abbildungseigenschaften

In diesem Abschnitt werden qualitative Annahmen über die Abbildungseigenschaften der Fahrspur in monokularen Bildfolgen $g(\mathbf{b}, t)$ innerstädtischer Verkehrsszenarien formuliert. Sie werden im Abschnitt 3.2 mathematisch konkretisiert, um die Interpretation des Modells durch ein maschinelles System zu ermöglichen.

3.1.1 Invariante Attribute der Beobachtung

Die Eigenschaften der grundsätzlich verschiedenen Klassen von Fahrspurmerkmalen im Bild und die Entscheidung für einen kantenbasierten Ansatz wurden bereits im Abschnitt 2.3 diskutiert bzw. begründet. Ziel der folgenden Abschnitte ist es, Abbildungseigenschaften der innerstädtischen Fahrspurberandung zu identifizie-

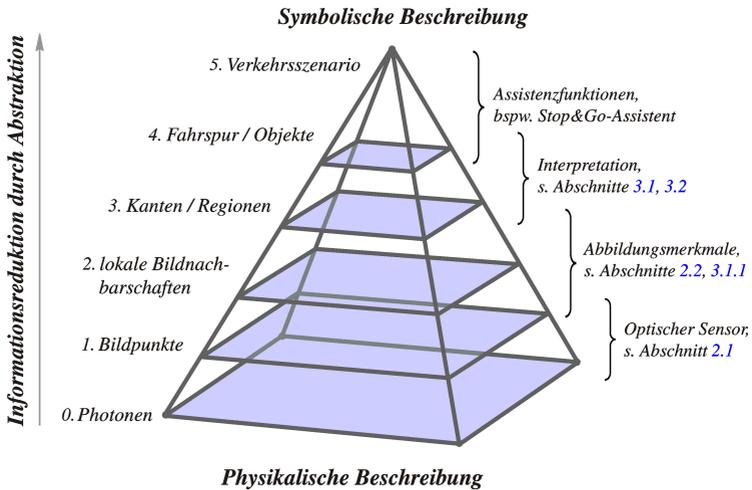


Abbildung 3.1: Abstraktionsgrade der Modellbildung. Auf der linken Seite der Pyramide sind die verschiedenen Abstraktionsstufen zur Beschreibung videobasierter Fahrerassistenzsysteme dargestellt. Gegenstand dieser Arbeit ist die Modellbildung (Kapitel 3) und die algorithmische Berechnung (Kapitel 4) für den Anwendungsfall innerstädtischer Fahrspurschätzung mit einer monokularen Kamera.

ren, die weitgehend invariant gegenüber dem Typ der Berandungselemente, der Form des Fahrspurverlaufs und der aktuellen Beleuchtungssituation sind.

Innerstädtische Fahrspurverläufe sind durch helle Fahrspurmarkierungen, Bordsteinkanten oder die umgebende Infrastruktur berandet. Ihre Abbildung in der beobachteten Bildfolge $g(\mathbf{b}, t)$ wird von unterschiedlichen Faktoren der dreidimensionalen Wirklichkeit beeinflusst. Sie lassen sich wie folgt klassifizieren (vgl. [Grü05]):

- **Geometrische Faktoren:** Form des Fahrspurverlaufs (vgl. Abschnitte 2.5, 3.1.3), Lage und Orientierung der Kamera (vgl. Abschnitt 2.2, 3.1.4), Aufnahmegeometrie der Kamera (vgl. Abschnitt 2.1),
- **Radiometrische Faktoren:** Beleuchtungssituation, Reflektanz der Fahrbahntextur bzw. der Fahrspurberandung,
- **Störfaktoren:** Verdeckung durch andere Verkehrsteilnehmer (vgl. Abschnitt 4.2.3) bzw. Objekte der Infrastruktur, Rauschen der Kamera.

In der Praxis ist eine vollständige Modellierung aller bildbeeinflussenden Faktoren unmöglich. Insbesondere in natürlichen Umgebungen lassen sich einige Faktoren nicht mit hinreichender Sicherheit beschreiben. Für die Auswertungen der zweiten Abstraktionsstufe aus Abbildung 3.1 definiert Jähne daher in [Jäh03] Kriterien zur systematischen Analyse von geeigneten Attributen der Beobachtung. Nach seiner Argumentation zeichnen sich gute Merkmale durch folgende Eigenschaften aus:

- **Informationsreduktion:** *Relevante Information der Beobachtung bleibt erhalten, irrelevante Information wird eliminiert.*
- **Unabhängigkeit:** *Jedes Merkmal trägt eine neue Information, die möglichst unabhängig von der Information der anderen Merkmale ist.*
- **Erwartungstreue:** *Das Merkmal weist keinen systematischen Fehler auf.*
- **Robustheit:** *Das Merkmal ist unempfindlich gegenüber den erwarteten Störungen der Beobachtung.*
- **Sicherheit:** *Der statistische Fehler des Merkmals ist bekannt, ein Versagen des Merkmals wird durch das Berechnungsverfahren erkannt.*

Ausschlaggebend für die Wahl geeigneter Merkmale ist somit neben der Modellierung der Beobachtung auch die Beschreibung der erwarteten Störungen. Die geforderten Invarianzen hängen von der spezifischen Anwendung ab.

In den hier diskutierten Bildfolgen sind die radiometrischen Faktoren der Bildentstehung durch äußere Umgebungseinflüsse – bspw. den Typ der Berandung, Regen oder den Stand der Sonne – vorgegeben. Besondere Bedeutung hat damit die geforderte Robustheit der Merkmale gegenüber Änderungen dieser Größen. Vereinfachend wird davon ausgegangen, dass Störungen der Beobachtung in ähnlicher Form auf den gesamten Bildinhalt einwirken.

Unter diesen Voraussetzungen ist der absolute Grauwert $g(\mathbf{b})$ als primäres Merkmal der Beobachtung ungeeignet, vgl. Abbildung 2.5(b). Stattdessen sind der Betrag und die Richtung des lokalen Gradienten aus Gleichung 2.3.1 weitgehend invariante Abbildungseigenschaften der Fahrspurberandung, vgl. Abbildung 4.2(a).

Natürliche Bildfolgen weisen eine hohe Korrelation zwischen benachbarten Grauwerten auf. Aus Sicht der Informationsreduktion und Erwartungstreue ist es sinnvoll, die exakte Position der Fahrspurberandung im lokalen Maximum des Kontrasts zu definieren. Aus dem Histogramm der Kontrastverteilung (siehe Abschnitt 2.3.4) lassen sich zudem angepasste Anforderungen an die minimale Kontraststär-

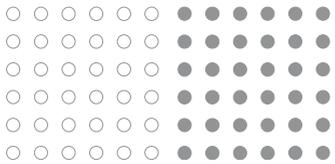
ke beobachteter Fahrspurberandungen bestimmen, die weitgehend invariant gegenüber Änderungen der globalen Beleuchtungssituation sind. Die Minimalforderung wird dabei durch Bordsteinkanten definiert, die häufig sehr geringen Kontrast aufweisen, vgl. Abbildung 2.5.

Aufbauend auf diesem primären Merkmal zur Lokalisierung der Fahrspurberandungen enthält das Bild weitere Information, aus der sich sekundäre Attribute der Berandungselemente ableiten:

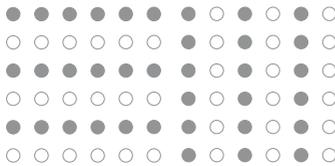
- **Richtung des Grauwertgradienten:** *Die Textur der Fahrbahnoberfläche ist häufig dunkler als die angrenzende Berandung. Offensichtlich ist diese Eigenschaft bei hellen Fahrspurmarkierungen, sie trifft in weiten Teilen aber auch auf Bordsteine und allgemeine Texturkanten zu. Es erscheint daher sinnvoll, am Übergang von der Fahrbahn zu den Berandungselementen einen positiven Grauwertgradienten zu erwarten. Diese Annahme führt auch dazu, dass bei hellen Markierungen immer die innere Kante als Fahrspurberandung interpretiert wird.*
- **Absoluter Grauwert:** *Unter ansonsten gleichen Bedingungen liefert der absolute Grauwert ein zusätzliches Indiz zur Bewertung von beobachteten Kantenpunkten. Insbesondere in Abgrenzung zu geometrisch oft ähnlich verlaufenden Teernähten sind hellere Bildpunkte bei mehreren Hypothesen als die wahrscheinlichere Beobachtung der Fahrspurberandung anzusehen.*
- **Lineare Struktur:** *In einer umfassenderen Betrachtung leitet sich ein weiteres Merkmal aus der glatten Form des Fahrspurverlaufs her. Auf dem Abstraktionsniveau zwischen der zweiten und dritten Stufe der Pyramide aus Abbildung 3.1 lässt sich fordern, dass die Fahrspurberandung gerichtete Strukturen im Bild verursacht. Lokale Abschnitte der Berandung können somit durch Geraden approximiert werden. Dieses Merkmal wird zur weiteren Informationsreduktion während der Initialisierung der Schätzung genutzt.*

Die Forderung nach unabhängigen Merkmalen begrenzt die Anzahl sinnvoller Attribute der Beobachtung. Alle weiteren bildbeeinflussenden Faktoren werden als Teil des Rauschens behandelt.

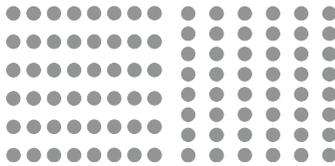
Insgesamt erscheint die einheitliche Modellierung von hellen Fahrspurmarkierungen, Bordsteinkanten und allgemeinen Texturübergängen wenig selektiv. Es ist zu erwarten, dass die sensornahe Abstraktion neben den wahren Beobachtungen der Fahrspurberandung zu einer hohen Anzahl fälschlicher Weise markierter Bildpositionen führt, vgl. Abbildung 4.2(b) auf Seite 81.



(a) Unstrukturierte Punkte



(b) Ähnliche Punkte



(c) Nahe Punkte

Abbildung 3.2: Anschauliche Visualisierung der Gestaltgesetze zur Strukturierung optischer Reize.¹ Die Felder identischer Punkte in Abbildung 3.2(a) können entweder als Muster von Zeilen oder Muster von Spalten gesehen werden. Die Felder in Abbildung 3.2(b) und 3.2(c) sind dagegen eindeutig interpretierbar, da sie weitere visuelle Hinweise enthalten. In 3.2(b) führt die Ähnlichkeit einiger Punkte zu einem ausgeprägtem Zeilen- oder Spaltenmuster, während in 3.2(c) allein die räumliche Anordnung bestimmt, ob der menschliche Betrachter ein horizontales oder vertikales Muster erkennt.

Ein weiteres Gestaltgesetz beschreibt die Wahrnehmung des imaginären Würfels, der bereits in Abbildung 1.2 dargestellt wurde. Die Kanten des Würfels werden vom Gehirn nach dem Gesetz der guten Fortsetzung erzeugt.

3.1.2 Gesetze der Gestalttheorie

Im Abschnitt 3.1.1 wurde die blockorientierte Auswertung direkter Bildnachbarschaften behandelt. Alle bisherigen Aussagen beziehen sich auf die unteren drei Abstraktionsgrade der Modellbildung aus Abbildung 3.1. In diesem Kontext lässt sich noch nicht erklären, warum der menschliche Betrachter die Anordnung aus Abbildung 1.2 als Würfel wahrnimmt. Auf dieser Abstraktionsstufe besteht die Abbildung aus einer Menge von Kanten und Kreissegmenten.

Dieser Abschnitt betrachtet die Stufen drei und vier der Modellbildung. Er befasst sich mit der Frage, wie aus den einzelnen Elementen der Beobachtung eine Wahrnehmung zusammengehöriger Einheiten entsteht. Motiviert ist die Modellbildung auf diesen Abstraktionsstufen durch Erkenntnisse aus der menschlichen Neuropsychologie, insbesondere der Gestaltpsychologie. Dort existieren Erklärungen, wie Menschen visuelle Reize zu einem Ganzen kombinieren und damit ein Verständnis ihrer Umwelt aufbauen.

¹ Die Abbildung stammt aus [Kan96a].

Anhand von Reizmustern zeigen die Gestaltpsychologen, dass das menschliche Gehirn wechselseitige Beziehungen zwischen den Elementen der Beobachtung analysiert, siehe Abbildung 3.1.2. Es verwendet dabei Annahmen über die visuelle Repräsentation der Welt, um die Elemente der sensorischen Information zu semantischen Einheiten zusammenzufassen. Diese aktiven Aspekte der menschlichen Wahrnehmung folgen den Gestaltgesetzen, die Muster, Form, Farbe, Entfernung und Bewegung von Objekten im Sichtfeld betreffen, vgl. [Kan96a].

Bei ihren Untersuchungen setzen die Gestaltpsychologen erwachsene Menschen mit vollständig ausgebildetem Sehvermögen voraus. Übertragen auf ein technisches System handelt es sich damit um die Analyse binokularer Bildfolgen mit Farbinformation. Nach den aktuellen Erkenntnissen existieren jedoch parallele Bahnen für Tiefe und Form, für Farbinformation und für Bewegung. Die Gestaltgesetze sind für jede Bahn separat anwendbar (vgl. [Kan96a], Kapitel 21) und gelten damit auch für monochromatische Bildfolgen.

Im Einzelnen haben die Neurologen folgende Gesetzmäßigkeiten definiert:

- **Gesetz der Ähnlichkeit:** *Einander ähnliche Elemente werden eher als zusammengehörige Einheiten wahrgenommen als einander unähnliche, vgl. Abbildung 3.2(b).*
- **Gesetz der Nähe:** *Elemente mit geringen Abständen zueinander werden als zusammengehörige Einheiten wahrgenommen, vgl. Abbildung 3.2(c).*
- **Gesetz der guten Fortsetzung:** *Elemente, die auf einer durchgehenden Linie oder Kurve angeordnet sind, werden als zusammengehörig wahrgenommen, vgl. Abbildung 1.2.*
- **Gesetz der guten Gestalt:** *Gemeinsame Einheiten der Wahrnehmung bilden sich stets so aus, dass das Ergebnis eine möglichst einfache und einprägsame Gestalt darstellt.*
- **Gesetz der Geschlossenheit:** *Linien, die eine Fläche umschließen, werden unter sonst gleichen Umständen eher als Einheit aufgefasst als diejenigen, die sich nicht zusammenschließen.*
- **Gesetz des gemeinsamen Schicksals:** *Mehrere sich gleichzeitig bewegende Elemente werden als Einheit wahrgenommen, vgl. Abbildung 2.9.*

Mit dieser Argumentation lässt sich erklären, warum die Anordnung von Linien und Kreissegmenten aus Abbildung 1.2 als Würfel interpretiert wird. Der menschliche Betrachter kombiniert die verschiedenen Aspekte des Bildes, so dass eine

größtmögliche Übereinstimmung mit einem bekannten Objekt entsteht. Insbesondere geht er von unvollständiger Information aus und ergänzt die fehlenden Kanten nach dem Gesetz der guten Fortsetzung.

Der imaginäre Würfel demonstriert eine weitere Eigenschaft der menschlichen Wahrnehmung: Selbst bei visuell einfachen Anordnungen sind mehrere Gestaltgesetze an der Interpretation des Bildinhalts beteiligt. Die Entscheidung für einen Würfel wird von allen² Gesetzen beeinflusst. Es handelt sich um eine kooperative Auswertung der unterschiedlichen Aspekte.

Neben den kombinatorischen Regeln zur Gruppierung zusammengehöriger Bildinhalte beschreiben die Neurologen die menschliche Wahrnehmung als multistabilen Entscheidungsprozess. Anhand von sogenannten Kippfiguren³ zeigen sie, dass nach der Entscheidung für eine Interpretation bereits die zweitbeste Erklärungsmöglichkeit ausgeblendet wird.⁴ Demnach ist es Menschen nicht möglich, zwei oder mehr konkurrierende Hypothesen simultan zu verfolgen.

Die Wahrnehmung komplexer Abbildungen folgt dem identischen Prinzip. Menschen fokussieren anscheinend immer nur ein Objekt, für das sie separate Entscheidungen treffen. Die Leistungsfähigkeit der menschlichen Wahrnehmung ist dabei maßgeblich durch die Aufmerksamkeitssteuerung begründet: Ausgehend von dominanten Objekten im Vordergrund bauen intelligente Lebewesen sukzessive ein Verständnis der gesamten Szene auf. Die Gestaltpsychologen gehen davon aus, dass Bewegung und Farbe wesentlich zur Steuerung der Aufmerksamkeit beitragen.

Nach dieser Argumentation beobachten Menschen in unübersichtlichen Situationen im Straßenverkehr vorrangig andere Verkehrsteilnehmer und die umgebende Infrastruktur. Alltagsstaugliche Assistenzfunktionen für Innenstädte erfordern somit eine Integration von Fahrspur-schätzung und Objekterkennung.

Diese Auffassung wird inzwischen auch zunehmend in der wissenschaftlichen Diskussion technischer Fahrerassistenzsysteme vertreten. Mit Blick auf die Anwendung in Innenstädten seien hier insbesondere die Arbeiten von Franke und Joos [Fra00] sowie Hummel u. a. [Hum07] genannt.

² Das Gesetz des gemeinsamen Schicksals bildet hier eine Ausnahme. Es wertet Bewegung als Kriterium zur Gruppierung aus und ist auf einzelne Bilder nicht anwendbar.

³ Kippfiguren sind Bilder, die optische Inversionen demonstrieren, vgl. bspw. [Kan96a], Seite 396 ff. Abhängig von der initialen Entscheidung ist es dem Betrachter lange Zeit unmöglich, die inverse Interpretation des Bildinhalts zu erkennen.

⁴ Die Psychologen sprechen von einer „der Sieger bekommt alles“-Strategie der Wahrnehmung.

3.1.3 Räumliche Kontinuität

Im Allgemeinen ist in 2D-Strukturen keine eindeutige Ordnung definiert. Es ist unmöglich, Beziehungen über Vorgänger und Nachfolger aufzustellen. Als universelles Werkzeug zur Modellierung zusammengehöriger Bildinhalte fordern die Gestaltungsgesetze aus Abschnitt 3.1.2 daher die wechselseitige Analyse der 2D-Information des Bildsensors. Für den hier betrachteten Fall ergibt sich jedoch eine weitreichende Vereinfachung:

Die Abbildung der Fahrspurberandung erzeugt lineare Strukturen mit einer beobachtbaren Richtung. Entlang des Kurvenverlaufs lässt sich eine Kontinuität zwischen aktueller Beobachtung und möglichen Nachfolgern fordern. Ist das erste Element der Beobachtung bekannt, stellt es Bedingungen an den weiteren Fahrspurverlauf. Die wiederholte Anwendung dieses Prinzips modelliert die Fahrspurberandung als eine Kette ähnlicher Elemente.

Die Annahme nach einer wechselseitigen Analyse von Bildinhalten reduziert sich damit auf eine räumliche Kontinuitätsbedingung entlang des Fahrspurverlaufs. Angewendet auf die invarianten Abbildungsmerkmale der Berandung aus Abschnitt 3.1.1 bestimmen die Gestaltungsgesetze der Ähnlichkeit, der Nähe und der guten Fortsetzung die räumliche Bindung zwischen den Elementen der Beobachtung.

3.1.4 Zeitliche Kontinuität

Die Aussagen zur räumlichen Kontinuität aus Abschnitt 3.1.3 gelten in analoger Form auch für die zeitliche Betrachtung der Fahrspurberandung. In dieser Richtung ist die Kontinuität der Beobachtung durch die Reihenfolge der Bilder explizit vorgegeben. Als weiteres Kriterium für zusammengehörige Bildinhalte fordert das Gesetz des gemeinsamen Schicksals zusätzlich die gleichzeitige Bewegung der einzelnen Elemente der Beobachtung bzgl. der realen Welt.

Die Unsicherheit in der zeitlichen Kontinuität aufeinander folgender Beobachtungen der Fahrspurberandung ist ausschließlich durch die geänderte Position und Orientierung der Kamera bestimmt, vgl. Abschnitt 2.2. In dieser Arbeit werden die Geschwindigkeit und der Lenkwinkel des eigenen Fahrzeugs durch dedizierte Sensoren mit hoher Güte erfasst. Die maßgebliche Unsicherheit bei der Aktualisierung der Schätzung entsteht ausschließlich durch die Schwingung der Kamera um ihre Einbaulage. Die erwartete Korrelation zeitlich aufeinander folgender Beobachtungen ist im Vergleich zu der erwarteten räumlichen Kontinuität sehr hoch.

3.2 Mathematische Modellbildung

In diesem Abschnitt werden die qualitativen Annahmen über die Abbildung der innerstädtischen Fahrspur in einer beobachteten Bildfolge $g(\mathbf{b}, \mathbf{t})$ mathematisch formuliert. Zunächst wird im Abschnitt 3.2.1 die Spline-Approximation als geometrisches Modell der Berandungen mit Bezug zum 2D-Raster \mathbf{b} des Bildsensors eingeführt. Seine Initialisierung und zeitliche Verfolgung in gegebenen Bildfolgen werden in den Abschnitten 3.2.2 und 3.2.3 behandelt.

3.2.1 Approximation der Berandungsgeometrie

Gegeben sei eine geordnete Punktmenge $\mathbf{b}_i = (u_i, v_i)^T, i = 0, 1, \dots, n$ äquidistanter Bildpositionen,⁵ an denen die linke oder die rechte Fahrspurberandung beobachtet wurde. Es ist bekannt, dass die Werte von \mathbf{b}_i mit einer Standardabweichung σ_i behaftet sind. Vereinfachend wird angenommen, dass die Standardabweichung aller beobachteten Bildpositionen identisch sei, $\sigma_i = \sigma_n \forall i$.

Unter diesen Voraussetzungen und den qualitativen Annahmen zur Form des Fahrspurverlaufs aus Abschnitt 3.1.2 wird die Beschreibung der Fahrspurgeometrie nun mathematisch formuliert:

3.2.1.1 Spline-Approximation

Splines sind Funktionen, die stückweise aus Polynomen zusammengesetzt sind. Ein guter Einstieg in den mathematischen Hintergrund zu Splines und ihren Anwendungen findet sich in [dB02].

In diesem Abschnitt wird das Optimierungskriterium der Spline-Approximation aus [Rei67] zur geometrischen Beschreibung der Fahrspurberandung im Bild eingeführt.

Zwischen zwei benachbarten Beobachtungen \mathbf{b}_i und \mathbf{b}_{i+1} wird der Kurvenverlauf jeweils durch zwei Polynome $u_i(s)$ und $v_i(s)$ beschrieben. s definiert den räumlichen Parameter entlang der Kurve:

$$\mathbf{r}_i(s) = \begin{cases} u_i(s) = c_{ui} + d_{ui} \cdot (s - i) + e_{ui} \cdot (s - i)^2 + f_{ui} \cdot (s - i)^3 \\ v_i(s) = c_{vi} + d_{vi} \cdot (s - i) + e_{vi} \cdot (s - i)^2 + f_{vi} \cdot (s - i)^3 \end{cases} \quad (3.2.1)$$

⁵ Im Interesse kompakter Notation wird hier $\|\mathbf{b}_{i+1} - \mathbf{b}_i\| = 1$ vorausgesetzt.

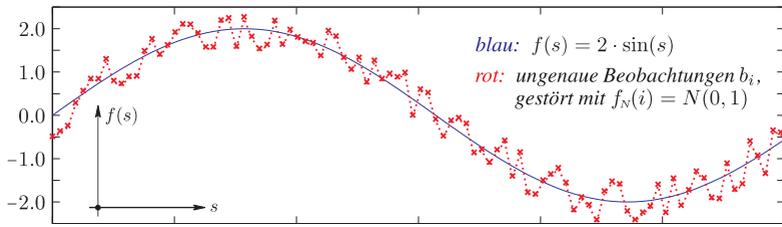
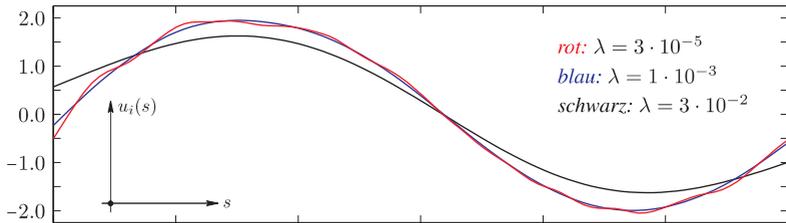
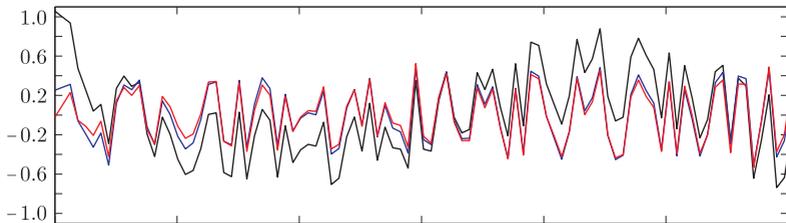
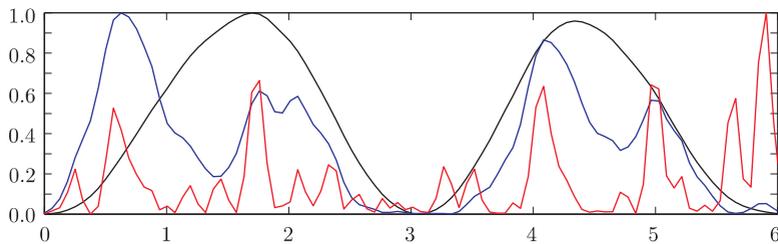
(a) Ungenaue Beobachtungen b_i einer Sinus-Funktion $f(s)$ (b) Spline-Approximationen $r(s, \lambda)$ nach Gleichung 3.2.3 und 3.2.4(c) Residuen $b_i - c_i$ der Approximationen, Kodierung vgl. 3.3(b)(d) Betrag der Krümmung $r''(s, \lambda)$, jeweils normiert auf $[0, 1]$

Abbildung 3.3: Eigenschaften der Spline-Approximation. In diesem Beispiel wird die Funktion $f(s) = 2 \cdot \sin(s)$ im Intervall $s = [0, 6]$ betrachtet. Die Beobachtung ist durch additives, weißes, normalverteiltes Rauschen $N(0, 1)$ gestört, vgl. Abb. 3.3(a). Die gegenläufigen Optimierungskriterien der Approximation werden deutlich: Je glatter der Spline $r(s, \lambda)$, desto größer sind die Residuen, vgl. Abb. 3.3(c) und 3.3(d). Die analytische Krümmung des Splines wird dabei explizit bestimmt.

Die Segmente des Fahrspurverlaufs werden als Kurven $\mathbf{r}_i(s) = (u_i(s), v_i(s))^T$ modelliert, um nahezu beliebige Formen approximieren zu können. Eine funktionale Darstellung $v = r_i(u)$ wäre bspw. in Kreuzungsbereichen nicht haltbar, in denen regelmäßige horizontale Fahrspurverläufe im Bild auftreten.

Die Polynome $u_i(s)$ und $v_i(s)$ werden Basispolynome der Splinekurve $\mathbf{r}(s)$ genannt.⁶ Da es sich um Polynome dritten Grades handelt, wird die resultierende Kurve als kubischer Spline bezeichnet.

Die Koeffizientenvektoren \mathbf{c}_i , \mathbf{d}_i , \mathbf{e}_i und \mathbf{f}_i sind die zu bestimmenden Parameter der Splinekurve.⁷ Besondere Bedeutung kommt den Werten von \mathbf{c}_i zu, sie sind der jeweilige Funktionswert des Basispolynoms an der i -ten Beobachtung.

Von der gesuchten Splinekurve $\mathbf{r}(s)$ wird gefordert, dass sie die beobachteten Bildpositionen \mathbf{b}_i glatt approximiert. Aus dieser Forderung ergeben sich folgende Bedingungen für aufeinander folgende Segmente $\mathbf{r}_i(s)$ und $\mathbf{r}_{i+1}(s)$:

$$\mathbf{r}_i(i+1) \stackrel{!}{=} \mathbf{r}_{i+1}(i+1) \quad \mathbf{r}'_i(i+1) \stackrel{!}{=} \mathbf{r}'_{i+1}(i+1) \quad \mathbf{r}''_i(i+1) \stackrel{!}{=} \mathbf{r}''_{i+1}(i+1) \quad (3.2.2)$$

In Kombination mit dem Optimierungskriterium der Spline-Approximation aus Gleichung 3.2.3 werden die Koeffizientenvektoren bestimmt.⁸ Das Kriterium umfasst zwei Bedingungen, die bei ungenauen Beobachtungen \mathbf{b}_i entgegengesetzte Auswirkungen auf die Basispolynome $\mathbf{r}_i(s)$ haben. Der erste Summand beschreibt eine möglichst gute Annäherung an die beobachteten Bildpositionen \mathbf{b}_i , der zweite die *a-priori* vermutete Glattheit der Approximation. Über den Parameter $\lambda(i)$ werden die beiden Einflussfaktoren für die i -te Beobachtung gewichtet:

$$\mathbf{r}(s, \lambda) = \sum_{i=0}^{n-1} \left[\underbrace{\frac{\|\mathbf{c}_i - \mathbf{b}_i\|^2}{\sigma_n^2}}_{\text{Abb. 3.3(c)}} + \lambda(i) \cdot \int_i^{i+1} \underbrace{[\mathbf{r}''(s)]^2 \cdot ds}_{\text{Abb. 3.3(d)}} \right] \rightarrow \min \quad (3.2.3)$$

In Erweiterung zu der weitaus häufigeren Spline-Interpolation von exakten Stützstellen wird bei der Spline-Approximation nicht erwartet, dass die Kurve durch die beobachteten Bildpositionen \mathbf{b}_i verläuft. Sie fordert vielmehr eine minimale

⁶ $\mathbf{r}(s)$ bezeichnet die gesamte Splinekurve, $\mathbf{r}_i(s)$ hingegen die Basispolynome des i -ten Segments.

⁷ Der Index i kennzeichnet die Position des Basispolynoms entlang der Splinekurve $\mathbf{r}_i(s)$.

⁸ Eine ausführliche Herleitung der Berechnungsvorschrift für die Koeffizienten der Splinekurve findet sich im Anhang A.2.

Glattheit des wahren Kurvenverlaufs. Andererseits wird die Ordnung des globalen Modells aber nicht limitiert: Die Anzahl lokaler Basispolynome $r_i(s)$ ist durch die Anzahl beobachteter Bildpositionen b_i bestimmt. n Beobachtungen werden durch $2 \times (n - 1)$ Polynome beschrieben.

Abbildung 3.3 stellt das Ergebnis der Spline-Approximation von 100 verrauschten Beobachtungen b_i einer Sinus-Funktion für drei unterschiedliche (konstante) Werte λ_n dar. Es wird deutlich, dass größere Werte von λ zu einem glatteren Kurvenverlauf mit größeren Residuen führen, vgl. Grafiken 3.3(c) und 3.3(d). Im Extremfall $\lambda \rightarrow \infty$ konvergiert die Approximation gegen die Ausgleichsgerade nach der Methode der kleinsten Quadrate, für $\lambda \rightarrow 0$ nähert sie sich der natürlichen Spline-Interpolation an. Die Herleitung dieser Eigenschaft ist im Abschnitt A.2.2 beschrieben.

3.2.1.2 Adaptive Regularisierung des Splines

Aus Abbildung 3.4(b) geht hervor, wie stark die Krümmung entlang der rechten Fahrspurberandung im Bild 3.4(a) variiert. Damit ist anschaulich klar, dass die Annahme eines konstanten Wertes für den Gewichtungsterm $\lambda(i)$ zur Spline-Approximation von innerstädtischen Fahrspurberandungen nicht haltbar ist.

Eine starke Glättung in Bereichen hoher Krümmung führt grundsätzlich dazu, dass die Splinekurve $r(s, \lambda)$ dem wahren Kurvenverlauf nicht folgen kann,⁹ vgl. Abbildung 3.3(b) und 3.3(d). Gleichzeitig ist es in nahezu geraden Bereichen des Fahrspurverlaufs durchaus sinnvoll, die Ungenauigkeiten Δb_i in den Beobachtungen b_i durch eine starke Glättung zu kompensieren.

In dieser Arbeit werden die Gewichte $\lambda(i)$ daher abhängig von der Krümmung $r''_i(s)$ an den beobachteten Bildpositionen b_i bestimmt:

$$1/\lambda_k(i) \propto r''_{i,k-1}(s) \quad (3.2.4)$$

Die Berechnung erfolgt iterativ, k bezeichnet den Index der Iteration. Initial wird ein konstanter Wert λ_0 angenommen. Er wird ausreichend groß gewählt, um die vermuteten Ungenauigkeiten in den Beobachtungen auszugleichen. Ausgehend von dieser Schätzung wird $\lambda_k(i)$ in Bereichen hoher Krümmung zu kleineren Werten angepasst.

⁹ Umgangssprachlich ausgedrückt „kürzt der Spline die Kurve ab“.

Im experimentellen Teil der Arbeit wird sich zeigen, dass bereits zwei Iterationen genügen, um eine hinreichend angepasste Regularisierung der Approximation zu erzielen.

3.2.1.3 Optimale Ordnung des Splines

Im vorherigen Abschnitt wird die Flexibilität bei der Approximation globaler Kurvenverläufe durch eine sehr hohe Ordnung des geometrischen Modells ermöglicht.¹⁰ Als interne Repräsentation der Berandungsgeometrie innerhalb der Fahrspurschätzung ist diese Darstellung vertretbar, zur Anbindung an Assistenzfunktionen ist eine kompaktere Beschreibung notwendig, vgl. Abbildung 2.14 auf Seite 35. Es stellt sich daher die Frage, wie die minimale Ordnung eines geometrischen Modells bestimmt werden kann, um den Fahrspurverlauf hinreichend gut zu approximieren.

Im Kern geht es bei der Aufgabe darum, anhand welcher Kriterien die Grenzen der Segmente bestimmt werden können. Heimes u. a. diskutieren in [Hei02] die Anpassung von stückweise definierten Geraden und Kreissegmente, um innerstädtische Fahrspurgeometrien zu beschreiben. Bislang hat sich jedoch keine Lösung in der wissenschaftlichen Diskussion durchgesetzt.

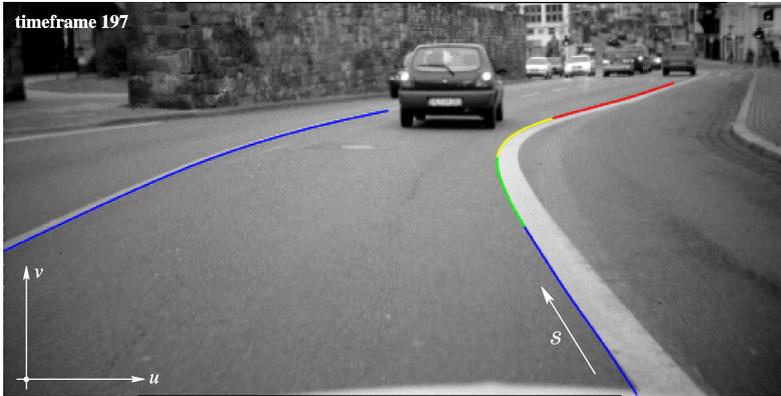
Im Abschnitt 2.5.1 auf Seite 30 ff. wurde gezeigt, dass kubische Polynome gute Approximationseigenschaften für Funktionsverläufe $y(x)$ mit näherungsweise konstanter Krümmungsänderung $y'''(x)$ besitzen.¹¹ Diese Eigenschaft wird hier ausgenutzt, um die Ordnung der Splinekurve zu optimieren.

Während der Spline-Approximation wird der Krümmungsverlauf $r''(s)$ entlang der geschätzten Fahrspurberandung explizit berechnet, vgl. Gleichung A.2.15 auf Seite 127. Häufig werden höhere Ableitungen von natürlichen Signalverläufen durch den immer stärkeren Einfluss der Ungenauigkeiten dominiert, die Ergebnisse sind damit unbrauchbar. Abbildung 3.4 widerlegt diese Auffassung für die hier betrachtete Anwendung: Der Graph in Abbildung 3.4(b) zeigt, wie stabil die geschätzte Krümmung entlang realer Beobachtungen verläuft.

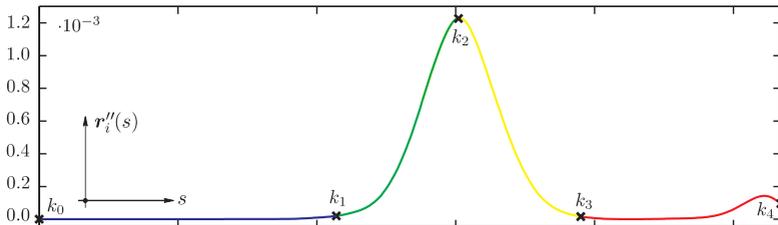
Die Krümmungsänderung kann damit als numerische Ableitung des Krümmungsverlaufs robust bestimmt werden, vgl. Abbildung 3.4(c). Eine einfache Segmen-

¹⁰ Die Ordnung einer Splinefunktion $r(s)$ ist definiert als die Anzahl der Basispolynome, die zu ihrer Beschreibung notwendig sind [dB02]. Für n Beobachtungen ergibt sich bei der Spline-Approximation die Ordnung $(n - 1)$. Typische Werte von n liegen im Bereich von 150 – 300.

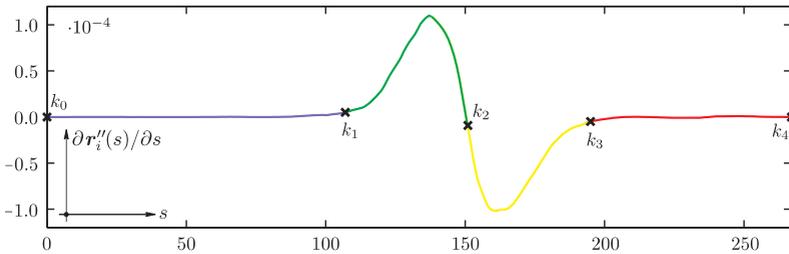
¹¹ Unter anderem begründen Dickmanns u. a. damit die Approximation von moderat gekrümmten Klothoiden durch ein kubisches Polynom [Dic92].



(a) Spline-Approximation der linken und rechten Fahrspurberandung



(b) Krümmungsverlauf $r''_i(s)$ entlang der rechten Fahrspurberandung



(c) Krümmungsänderung $r'''_i(s)$ entlang der rechten Fahrspurberandung

Abbildung 3.4: Geschätzte Ordnung der approximierenden Splinekurve $\mathbf{r}(s, \lambda) = (u(s), v(s))^T$. Die Farben kennzeichnen unterschiedliche Segmente der Kurve: Während zur Beschreibung der linken Berandung ein Segment ausreicht, sind aufgrund der variablen Krümmungsänderung am rechten Rand vier Segmente erforderlich. Abbildung 3.4(a) visualisiert das Ergebnis der Schätzung, in Abbildung 3.4(b) und 3.4(c) sind die Krümmung bzw. deren Änderung entlang des Index s dargestellt. Die schwarzen Kreuze k_j , $j = 0, \dots, 4$ markieren die Unterbrechungen, sie werden mit dem Douglas-Peucker Algorithmus [Dou73] bestimmt.

tierung des Signalverlaufs $r''(s)$ mit dem Douglas-Peucker Algorithmus [Dou73] reicht zur Bestimmung der minimalen Ordnung des Splines aus.¹²

Als Ergebnis wird in dem Beispiel aus Abbildung 3.4 die Ordnung des beschreibenden Splines für die rechte Fahrspurberandung von 270 auf fünf reduziert, am linken Fahrbahnrand ist sogar die Ordnung eins bereits hinreichend.

3.2.2 Initiale Detektion der Berandung

Im vorherigen Abschnitt wurde eine geordnete Menge von Bildpositionen $\mathbf{b}_i = (u_i, v_i)$, $i = 0, 1, \dots, n$ vorausgesetzt, an denen die Fahrspurberandung im Bild beobachtet wurde. Dieser Abschnitt behandelt die Frage, wie die Bildpositionen \mathbf{b}_i in einem gegebenen Bild $g(\mathbf{b})$ bestimmt werden, ohne dass die globale Lage der Fahrspur näherungsweise bekannt ist.

Mit bekannten Algorithmen der Bildanalyse ist es möglich, Konturen in einem Bild zu detektieren und durch eine Menge von Linien $\mathbf{l}_j(g(\mathbf{b}))$, $j = 0, 1, \dots, m$ annähernd zu beschreiben.¹³ Die Linien dienen während der initialen Detektion der Fahrspurberandungen als übergeordnete Struktur zur schnellen und robusten Gruppierung von lokalen Maxima der Kontrastverteilung $\nabla g(\mathbf{b})$. Jedes Linienelement wird als atomare Beobachtung aufgefasst, ihm sind die Attribute gemäß Definition 3.2.5 zugeordnet.

$$\mathbf{l}_j = (\mathbf{x}_a, \mathbf{x}_e, \gamma, \mathbf{b}_i, n_b, \|\overline{\nabla g}\|, \angle(\overline{\nabla g}), \bar{g})^T \quad (3.2.5)$$

$$\mathbf{x}_a = (x_a, y_a)^T : \text{Anfangskordinaten der Linie}$$

$$\mathbf{x}_e = (x_e, y_e)^T : \text{Endkordinaten der Linie}$$

$$\gamma : \text{Winkel der Linie zur Längsachse des Fahrzeugs}$$

$$\mathbf{b}_i : \text{Koordinaten der approximierten Bildpunkte}$$

$$n_b : \text{Anzahl der Bildpunkte der Linie}$$

$$\|\overline{\nabla g}\| : \text{Länge des gemittelten Grauwertgradienten}$$

$$\angle(\overline{\nabla g}) : \text{Richtung des gemittelten Grauwertgradienten}$$

$$\bar{g} : \text{mittlerer Grauwert der Linie}$$

¹² Das Prinzip des Douglas-Peucker Algorithmus ist im Abschnitt 4.1.3 zusammengefasst.

¹³ Die Berechnung der Liniensegmente in dieser Arbeit ist im Abschnitt 4.1 beschrieben.

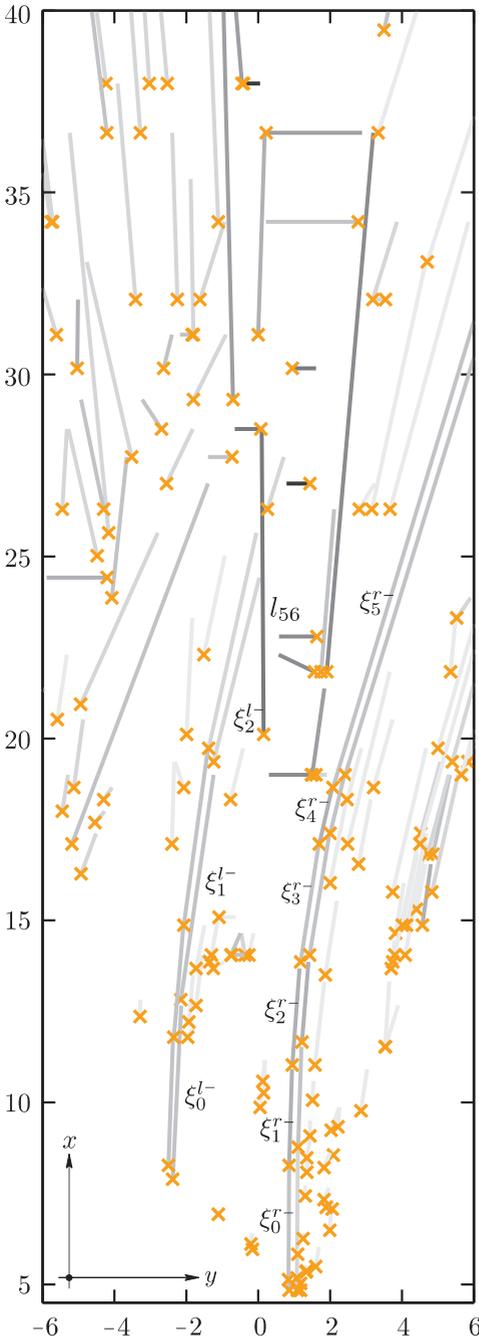


Abbildung 3.5: *Liniensegmente $l_j(g(\mathbf{b}))$, extrahiert aus Abbildung 3.4(a). Zur Projektion auf die kalibrierte Fahrbahnebene $z = 0$ des Weltkoordinatensystems \mathbf{x} werden die Zusammenhänge aus Abschnitt 2.4.3 genutzt, vgl. Seite 25 ff. Die ξ_k^- markieren die wahren Beobachtungen der Fahrspurberandung.*

Von jeder Linie l_j sind die Attribute aus Definition 3.2.5 bekannt. Die Kreuze markieren die Startpositionen \mathbf{x}_s der Elemente. Entgegen der üblichen Darstellung natürlicher Bilder repräsentiert der Grauwert der Linien ihren mittleren Kontrast $\|\nabla g\|$. Je dunkler die Linien eingezeichnet sind, desto höher ist ihr Kontrast.

Aufbauend auf den Linienattributen wird im Abschnitt 3.2.2 ein MAP-Schätzer für den Verlauf der Fahrspurberandung formuliert. Der räumliche Ursprung der Berandung wird im Nahbereich vor dem eigenen Fahrzeug vermutet, vgl. ξ_0^- und ξ_0^r . In diesem Bereich lassen sich weitreichende a-priori Annahmen über die Berandungselemente aufstellen. Vom weiteren Verlauf der Berandung wird erwartet, dass ihm ein eindimensionaler stochastischer Prozess zugrunde liegt. Er sei durch eine einseitige Markov-Kette erster Ordnung beschreibbar. Aus dieser Eigenschaft ergeben sich Bedingungen für nachfolgende Elemente entlang der Fahrspurberandung.

Im weiteren Verlauf der Arbeit werden die einzelnen Attribute der Linien über den Operator $[\cdot]$ adressiert.¹⁴ Im Interesse einheitlicher Notation werden alle Attribute in einem Vektor \mathbf{a} zusammengefasst. $l_j[\mathbf{a}]$ wird als Zustand der j-ten Linie aufgefasst.

Mit diesen Definitionen lässt sich die Fahrspurberandung ξ als eine geordnete Menge von Linien l formulieren.¹⁵ Jedes Berandungselement ξ_k adressiert genau ein Liniensegment $\xi_k = l_j$ der Beobachtung. Der k-te Zustand der Fahrspurberandung $\xi_k[\mathbf{a}]$ ist damit identisch dem Parametervektor $l_j[\mathbf{a}]$ des j-ten Linienelements. Die Ordnungsrelation innerhalb von ξ ist durch den Index k definiert:

$$\xi_0^- = \{ \xi_0^-, \xi_1^-, \dots, \xi_k^-, \dots, \xi_{n_k-1}^-, \xi_{n_k}^- \} \quad (3.2.6)$$

In Abgrenzung zur Spline-Approximation der Berandungsgeometrie symbolisiert der Exponent – die ursprüngliche Beobachtung der Linienelemente.¹⁶ Der Index 0 kennzeichnet die initiale Detektion zum Abtastzeitpunkt $t_s = 0$. n_k ist die Anzahl von Elementen, die zum Berandungsverlauf beitragen. Abhängig von der Krümmung des Fahrspurverlaufs und der Sichtweite der Kamera variiert der Wert.

Auf dieser Basis wird der wahrscheinlichste Verlauf der Fahrspurberandung $\hat{\xi}_0^-$ gesucht, der sich aus einer realisierten Beobachtung l^{17} ergibt. Im Sinne der MAP-Schätzung ist er als Lösung des folgenden Ausdrucks definiert (vgl. Abschnitt 2.6.1.1 auf Seite 40):

$$\begin{aligned} \hat{\xi}_{0,map}^- &:= \arg \max_{\xi_0^-} \left\{ P(\Xi | L) \right\} \stackrel{Gl. 2.6.3}{\propto} \arg \max_{\xi_0^-} \left\{ P(L | \Xi) \cdot P(\Xi) \right\} \quad (3.2.7) \\ &= \arg \min_{\xi_0^-} \left\{ \underbrace{\sum_{k=1}^{n_l} -\ln f_{\mathbf{a}}(L_j[\mathbf{a}] | \xi_{<k}^-[\mathbf{a}]) - \ln f_{\mathbf{a}}(\Xi_0[\mathbf{a}])}_{\text{Kosten } \rho(\xi_0^-) \text{ der Fahrspurberandung } \xi_0^-} \right\} \\ &= \arg \min_{\xi_0^-} \left\{ \underbrace{\sum_{k=1}^{n_l} -\ln f_{\mathbf{a}}(L_j[\mathbf{a}] | \xi_{<k}^-[\mathbf{a}])}_{\text{bedingte Kosten } \rho_k(\xi_k^- = l_j)} - \underbrace{\ln f_{\mathbf{a}}(\Xi_0[\mathbf{a}])}_{\text{unbedingte Kosten } \rho_0(\xi_0^- = l_j)} \right\} \end{aligned}$$

¹⁴ So meint der Ausdruck $l_j[\bar{g}]$ bspw. den mittleren Grauwert des j-ten Linienelements.

¹⁵ Eine Unterscheidung zwischen linker und rechter Berandung ist hier noch nicht notwendig. Sie wird im Abschnitt 3.2.2.2 eingeführt.

¹⁶ Die Spline-Approximation der Berandungsgeometrie wird im weiteren Verlauf mit ξ_k^+ bezeichnet.

¹⁷ Der Ausdruck l bezeichnet die Menge aller Linienelemente. Im Gegensatz dazu kennzeichnet l_j genau das j-te Element.

Gleichung 3.2.7 modelliert die Fahrspurberandung als einen multidimensionalen Zufallsvektor Ξ , der durch seine *a-posteriori* Verteilungsfunktion $P(\Xi | L)$ beschrieben ist. f_{α} bezeichnet dabei die Verteilungsdichte des Parametervektors α . $\xi_{<k}^-$ fasst alle bereits realisierten Berandungselemente zusammen. Mit den Umformungen aus Gleichung 2.6.3 auf Seite 40 lässt sich die gesuchte Lösung $\hat{\xi}_0^-$ als Minimum des Kostenterms $\rho(\xi_0^-)$ bestimmen.

Die gesamten Kosten $\rho(\xi_0^-)$ setzen sich aus zwei Anteilen zusammen:

- $\rho_k(\xi_k^- = l_j)$ beschreibt die bedingten Kosten der Realisierung des k -ten Berandungselements, $k > 0$. Die zuvor realisierten Elemente $\xi_{<k}^-$ bedingen dabei die Likelihood der Beobachtung von ξ_k^- , vgl. Abschnitt 3.2.2.1.
- $\rho_0(\xi_0^- = l_j)$ beschreibt die unbedingten Kosten der Realisierung des ersten Berandungselements ξ_0^- . Dieser Term leitet sich aus der *a-priori* Information über den räumlichen Ursprung der Fahrspurberandung her, vgl. Abschnitt 3.2.2.2.

Mit diesen Definitionen ist die mathematische Struktur der Modellbildung festgelegt.

3.2.2.1 Markov-Modell der Fahrspurberandung

In diesem Abschnitt werden die Anforderungen zur räumlichen Kontinuität der Fahrspurberandung aus Abschnitt 3.1 formal erfasst. Aufbauend auf der Ordnungsrelation aus Gleichung 3.2.6 wird die Fahrspurberandung ξ_0^- als eindimensionaler stochastischer Prozess aufgefasst. Von ihm wird angenommen, dass er durch eine einseitige Markov-Kette erster Ordnung beschreibbar ist.¹⁸

Entlang des Fahrspurverlaufs wird die Verbundwahrscheinlichkeit zwischen aufeinander folgenden Berandungselementen ξ_k^- und $\xi_{k'}^-$ durch folgenden Ausdruck definiert [Rab86]:

$$P(\Xi_k | \xi_{k'}^- = l_{i'} \ \forall \ k' < k) \stackrel{!}{=} P(\Xi_k | \xi_{k-1}^- = l_i) \quad (3.2.8)$$

Gleichung 3.2.8 modelliert die Fahrspurberandung als einseitige Markov-Kette erster Ordnung. Die Wahrscheinlichkeit für die Realisierung des Berandungselements ξ_k^- ist damit vollständig durch den direkten Vorgänger $\xi_{k-1}^- = l_i$ bestimmt.

¹⁸ Ähnlich strukturierte Probleme finden sich in der Dekodierung von Sprachsignalen, vgl. [Rab89].

Im Mittel ändere sich ein bestimmtes Attribut zwischen Vorgänger und Nachfolger nicht, vgl. die Annahmen aus Abschnitt 3.1. Zwischen den Elementen ξ_k^- und ξ_{k-1}^- besteht somit eine umso stärkere semantische Bindung, je ähnlicher ihre jeweils korrespondierenden Attribute a_i ¹⁹ sind. Abweichungen von dieser Erwartungshaltung werden mit Bezug zum Weltkoordinatensystem \mathbf{x} aus Abbildung 2.4 auf Seite 13 als normalverteilt angenommen. Einzige Parameter des Modells sind die Varianzen σ_i^2 der Verteilungsdichten.

Vereinfachend werden die Attribute \mathbf{a} der Linienelemente aus Definition 3.2.5 als untereinander statistisch unabhängig angenommen.²⁰ Die multidimensionale Verteilungsdichte $f_{\mathbf{a}}(L_j | \xi_{<k}^-)$ aus Gleichung 3.2.7 lässt sich somit in das Produkt der Dichtefunktionen über die Attribute a_i aus Definition 3.2.5 separieren.

Mit diesen Annahmen bedingt die Realisierung des Berandungselements ξ_{k-1}^- einen Satz unabhängiger Komponenten ρ_i , die additiv zur Kostenfunktion $\rho(\xi_k^- = l_j)$ für die Beobachtung des nachfolgenden Elements $\xi_k^- = l_j$ beitragen.

Benachbarte Elemente des Berandungsverlaufs dürfen keinen signifikanten lateralen Versatz aufweisen. Gleichung 3.2.9 definiert daher den senkrechten Abstand des Startpunkts $l_j[\mathbf{x}_s]$ von der vorherigen Berandungsgeraden als Kosten ρ_{\perp} des Zustandsübergangs:

$$\rho_{\perp} := \frac{1}{\sigma_{\perp}^2} \cdot \underbrace{\left((\cos(\xi_{k-1}^-[\gamma]), -\sin(\xi_{k-1}^-[\gamma])) \cdot \begin{pmatrix} l_j[x_s] - \xi_{k-1}^-[x_e] \\ l_j[y_s] - \xi_{k-1}^-[y_e] \end{pmatrix} \right)^2}_{:= \text{Kosten } \rho_{\perp} \text{ der normalen Abstandskomponente, vgl. Abbildung 3.6}} \quad (3.2.9)$$

Die tangentiale Abstandskomponente zwischen dem Startpunkt der aktuellen Beobachtung $l_j[\mathbf{x}_s]$ und dem Endpunkt des vorherigen Berandungselements $\xi_{k-1}^-[\mathbf{x}_e]$ wird daher zu Null erwartet. Abweichungen werden nach Gleichung 3.2.10 als Kosten ρ_{\parallel} des Zustandsübergangs bewertet:

$$\rho_{\parallel} := \frac{1}{\sigma_{\parallel}^2} \cdot \underbrace{\left((\sin(\xi_{k-1}^-[\gamma]), \cos(\xi_{k-1}^-[\gamma])) \cdot \begin{pmatrix} l_j[x_s] - \xi_{k-1}^-[x_e] \\ l_j[y_s] - \xi_{k-1}^-[y_e] \end{pmatrix} \right)^2}_{:= \text{Kosten } \rho_{\parallel} \text{ der tangentialen Abstandskomponente, vgl. Abbildung 3.6}} \quad (3.2.10)$$

¹⁹ a_i bezeichnet ein beliebiges Attribut aus der Definition 3.2.5.

²⁰ Eine Ausnahme bilden der Winkel γ und die Gradientenrichtung $\angle(\nabla g)$. Diese Attribute werden als statistisch abhängig betrachtet. Diese Abhängigkeit wird im Abschnitt 3.2.2.2 aufgelöst.

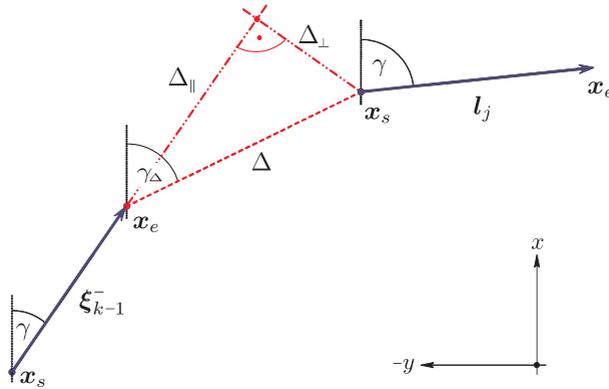


Abbildung 3.6: Geometrische Ähnlichkeit der Linienelemente ξ_{k-1}^- und l_j . Die normale und tangentielle Abstandskomponente zwischen beiden Elementen sind mit Δ_{\perp} bzw. Δ_{\parallel} bezeichnet. Je geringer sie sind, desto kleiner sind nach Gleichung 3.2.9 und 3.2.10 die assoziierten Kostenterme ρ_{\perp} bzw. ρ_{\parallel} . Auch ist davon auszugehen, dass die aktuelle Beobachtung l_j , das vorherige Berandungselement ξ_{k-1}^- und die imaginäre Verbindungsgerade Δ im Mittel kollinear verlaufen. Differenzen der korrespondierende Winkelgrößen γ führen gemäß Gleichung 3.2.11 zu weiteren Kosten ρ_{γ} des Zustandsübergangs $\xi_{k-1}^- \mapsto l_j$.

Es ist davon auszugehen, dass die aktuelle Beobachtung l_j , das vorherige Berandungselement ξ_{k-1}^- und die imaginäre Verbindungsgerade Δ kollinear verlaufen. Als Erwartungswert besitzen alle drei Elemente daher den identischen Winkel γ zur Längsachse des Fahrzeugs:

$$\rho_{\gamma} := \frac{1}{\sigma_{\gamma}^2} \cdot \left(\underbrace{\omega_{\Delta} \cdot \left[\frac{(l_j[\gamma] - \gamma_{\Delta})^2 + (\gamma_{\Delta} - \xi_{k-1}^-[\gamma])^2}{2} \right]}_{\text{Kosten } \rho_{\gamma_{\Delta}} \text{ der Winkeldifferenzen von } l_j \text{ und } \xi_{k-1}^- \text{ zur Detektionslücke } \Delta} + \underbrace{(1 - \omega_{\Delta}) \cdot [l_j[\gamma] - \xi_{k-1}^-[\gamma]]^2}_{\text{Kosten } \rho_{\gamma_l} \text{ der Winkeldifferenz zwischen Modell } l_j \text{ und Beobachtung } \xi_{k-1}^-} \right) \quad (3.2.11)$$

$$\text{mit } \omega_{\Delta} := \frac{\|l_j[\mathbf{x}_s] - \xi_{k-1}^-[\mathbf{x}_e]\|^2}{c_{\Delta} + \|l_j[\mathbf{x}_s] - \xi_{k-1}^-[\mathbf{x}_e]\|^2}, \quad c_{\Delta} = \text{konstant}$$

Eine gesonderte Behandlung benötigt der triviale Spezialfall $l_j[\mathbf{x}_s] \approx \xi_{k-1}^-[\mathbf{x}_e]$. In diesem Fall ist der Winkel γ_Δ der Verbindungslinie nicht belastbar.²¹ Es erscheint daher sinnvoll, ausschließlich $l_j[\gamma]$ und $\xi_{k-1}^-[\gamma]$ auszuwerten. ω_Δ realisiert einen kontinuierlichen Übergang zwischen beiden Betrachtungsweisen, c_Δ ist eine noch zu definierende Konstante.

Neben der geometrischen Anordnung von l_j und ξ_{k-1}^- tragen auch die radiometrischen Eigenschaften beider Liniensegmente zu den Kosten des Zustandsübergangs bei. Sie sind in einer Funktion ρ_r zusammengefasst:

$$\rho_r := \underbrace{\frac{1}{\sigma_c^2} \cdot \left(l_j[\|\nabla g\|] - \xi_{k-1}^-[\|\nabla g\|] \right)^2}_{\text{Kosten } \rho_c \text{ der Kontrastdifferenz, vgl. Abbildung 3.5}} + \underbrace{\frac{1}{\sigma_g^2} \cdot \left(l_j[\bar{g}] - \xi_{k-1}^-[\bar{g}] \right)^2}_{\text{Kosten } \rho_g \text{ der Grauwertdifferenz}} \quad (3.2.12)$$

$$+ \underbrace{\frac{1}{\sigma_{\uparrow}^2} \cdot \left(\Gamma(l_j[\angle(\nabla g)] - \xi_{k-1}^-[\angle(\nabla g)]) \right)^2}_{\text{Kosten } \rho_{\uparrow} \text{ der Sekordifferenz, vgl. Abbildung 4.1}}$$

$$\text{mit } \Gamma(\dots) = \begin{cases} 0 & \underbrace{\left| l_j[\angle(\nabla g)] - \xi_{k-1}^-[\angle(\nabla g)] \right| \leq \pi}_{\text{Gradienten von } l_j \text{ und } \xi_{k-1}^- \text{ verlaufen parallel}} \\ \text{falls} & \\ 1 & \underbrace{\left| l_j[\angle(\nabla g)] - \xi_{k-1}^-[\angle(\nabla g)] \right| > \pi}_{\text{Gradienten von } l_j \text{ und } \xi_{k-1}^- \text{ verlaufen antiparallel}} \end{cases}$$

Die Kontrast- und Grauwertdifferenz von l_j und ξ_{k-1}^- gehen unmittelbar als kontinuierliche Größen in die korrespondierenden Kostenterme ρ_c bzw. ρ_g ein.

Anders verhält es sich bei der Richtungsdifferenz der Grauwertgradienten $\angle(\nabla g)$. Sie wird binär ausgewertet. Die Sprungfunktion Γ ordnet Richtungsdifferenzen kleiner π den Wert Null zu, andernfalls ist der Wert Eins. Die Kosten ρ_{\uparrow} berücksichtigt somit nur, ob die Gradienten von l_j und ξ_{k-1}^- grundsätzlich parallel oder antiparallel verlaufen.²²

²¹ Für $l_j[\mathbf{x}_s] = \xi_{k-1}^-[\mathbf{x}_e]$ ist er nicht definiert, für kleine Abstandswerte wird er von den Ungenauigkeiten der beiden Messungen dominiert.

²² Ihrer Natur nach ist auch die Orientierung des Grauwertgradienten $\angle(\nabla g)$ eine kontinuierliche Größe. Sie ist jedoch mit der Modellrichtung γ der Linie korreliert, die Kosten der Orientierungsdifferenz wurden bereits in Gleichung 3.2.11 betrachtet. Salopp formuliert geht es „nur noch“ darum, ob das Bild links oder rechts der Kante heller wird.

$$\rho_k(\xi_k^- = l_j) \Big|_{t=0} := \rho_{\perp} + \rho_{\parallel} + \rho_{\gamma} + \rho_r \quad \forall \quad k > 0 \quad (3.2.13)$$

Gleichung 3.2.13 fasst die Kosten des Zustandsübergangs $\xi_{k-1}^- \mapsto l_j$ zusammen. $t = 0$ kennzeichnet die initiale Detektion. Die wesentlichen Freiheitsgrade des Modells sind die Varianzen σ_k^2 der Kostenterme ρ_k .

3.2.2.2 Verteilungsdichte des räumlichen Ursprungs

Das Markov-Modell aus dem vorherigen Abschnitt setzt voraus, dass die in Gleichung 3.2.5 definierten Attribute des vorherigen Berandungselements ξ_{k-1}^- bekannt sind. Sie werden benötigt, um Bedingungen an das nachfolgende Element ξ_k^- zu formulieren. Diese Forderung lässt sich für das erste Element $\xi_{k=0}^-$ nicht erfüllen. Es sind daher einige *a-priori* Annahmen über seinen imaginären Vorgänger $\xi_{k=-1}^-$ erforderlich. Dieses Element wird im weiteren Verlauf als räumlicher Ursprung der Fahrspurberandung bezeichnet.

Das Markov-Modell lässt offen, wo der Ursprung der Berandung zu erwarten ist. Aufgrund der stärkeren *a-priori* Information über die Lage der Fahrspur erscheint es sinnvoll, den Ursprung im Nahbereich direkt vor dem eigenen Fahrzeug zu definieren.

Bislang wurde in der Modellbildung noch keine Unterscheidung zwischen linker und rechter Fahrspurberandung getroffen. Dies ist nun notwendig, da linker und rechter Ursprung offensichtlich unterschiedliche Koordinaten x_e besitzen. Konkret werden daher zwei imaginäre Berandungselemente ξ_{-1}^{l-} und ξ_{-1}^{r-} mit folgenden Attributen eingeführt:

$$\xi_{-1}^{l-} := \left(n.a., \left(0, \frac{-w}{2} \right), 0, \emptyset, n.a., c_{-1}, s_{-1}^l, g_{-1} \right)^T \quad (3.2.14)$$

$$\xi_{-1}^{r-} := \left(n.a., \left(0, \frac{w}{2} \right), 0, \emptyset, n.a., c_{-1}, s_{-1}^r, g_{-1} \right)^T$$

Die Struktur der Vektoren aus Gleichung 3.2.14 folgt der Liniendefinition 3.2.5 auf Seite 62. Irrelevante Attribute sind mit *n.a.* gekennzeichnet. w symbolisiert die erwartete Fahrspurbreite. Den Linien ist eine leere Menge \emptyset von Bildpositionen

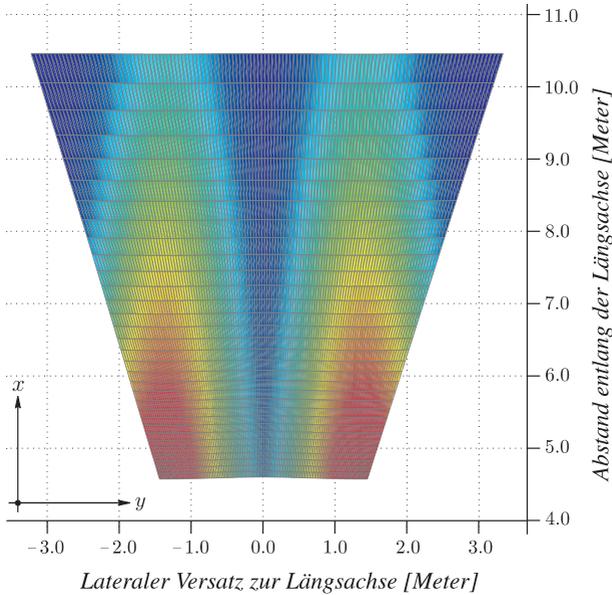


Abbildung 3.7: A-priori Verteilungsdichte der Endkoordinaten $\xi_{-1}^{l,r-}[x_e]$ des räumlichen Ursprungs der linken bzw. rechten Fahrspurberandung mit Bezug zur kalibrierten Fahrbahnebene $z = 0$ aus Abbildung 2.4. Gut zu erkennen ist der trapezförmige Erfassungsbereich der Kamera. Die Verteilungsdichte ist als Wärmebild kodiert: Rote Bereiche kennzeichnen die wahrscheinlichen Startpositionen $\xi_0^{l,r-}[x_s]$ des ersten Berandungselements aus Gleichung 3.2.6. In Richtung blauer Bereiche nimmt die Wahrscheinlichkeit ab. Die Varianz des lateralen Versatzes σ_{\perp}^2 zur Längsachse des Fahrzeugs ist dabei signifikant kleiner als die des Abstandes in Fahrtrichtung σ_{\parallel}^2 .

b_i zugeordnet. c_{-1} , s_{-1}^l , s_{-1}^r und g_{-1} bezeichnen die radiometrischen Eigenschaften des räumlichen Ursprungs, sie sind abhängig von der verwendeten Kamera zu konfigurieren.

Als konkrete Werte für die longitudinale Position $\xi_{-1}^{l,r-}[x_e]$ der Endpunkte und den Gierwinkel $\xi_{-1}^{l,r-}[\gamma]$ wird jeweils Null erwartet. Es wird somit von einer parallelen Ausrichtung zwischen der Längsachse des Fahrzeugs und den Fahrspurberandungen $\xi_{-1}^{l,r-}$ ausgegangen, das erste Berandungselement wird seitlich neben dem Fahrzeug vermutet.

Die Bestimmung des Erwartungswerts für die laterale Abstandskomponente

$\xi_{-1}^{l-}[y_e]$ basiert auf der Annahme, dass die Kamera in der Mitte einer Fahrspur bekannter Breite w positioniert ist.²³ Daraus resultiert $\xi_{-1}^{l-}[y_e] = -\xi_{-1}^{r-}[y_e] = -w/2$.

3.2.2.3 Globale Optimalitätsbedingung

Jeder Zustandsübergang $\xi_k^- \mapsto \xi_{k+1}^-$ verursacht zusätzliche Kosten $\rho_k > 0$ entlang des Berandungsverlaufs, siehe Gleichung 3.2.13. Die Kosten entlang eines beliebigen Pfades ξ_0^- wachsen monoton in Richtung größerer Entfernungen.

Die alleinige Minimierung der Kosten ρ würde somit immer genau das ersten Linienelement ξ_0^- als gesuchte Lösung betrachten.²⁴ Diese Annahme ist in Innenstädten nicht haltbar, vgl. Abschnitt 2.5.

Als Optimierungskriterium für die bestmögliche Schätzung der Fahrspurberandung wird daher ein Verhältnis aus der Länge und den akkumulierten Kosten des Pfades definiert:

$$\hat{\xi}_{t=0}^{l,r-} := \max_{\rho, \xi_0^-} \left(\frac{\sum_{k'=0}^k \xi_{k'}^- [n_b]}{\rho_0 + \sum_{k'=1}^k \rho_{k'}} \right) \quad (3.2.15)$$

$\xi_{k'}^- [n_b]$ bezeichnet die Länge des k' -ten Berandungselements, gemessen als Anzahl n_b beitragender Bildpositionen b_i . Eine Schätzung ist somit umso besser, je mehr Bildpositionen b_i entlang eines Pfades beobachtet werden.²⁵

Die Konstante ρ_0 wird als unabhängiger Parameter zur Konfiguration der bevorzugten Pfadlänge eingeführt. Größere Werte von ρ_0 führen dazu, dass unter ansonsten gleichen Umständen längere Pfade als bestmögliche Schätzung angesehen werden. Kleinere Werte von ρ_0 bevorzugen kürzere Pfade und limitieren das Risiko von Schätzfehlern in größerer Entfernung.²⁶

Hohe Kosten für zusätzliche Zustandsübergänge $\xi_k^- \mapsto \xi_{k+1}^-$ können dazu führen, dass die globale Güte der Schätzung entlang eines beobachteten Pfades ξ_0^- sinkt.

²³ In Kombination mit einer digitalen Straßenkarte wäre es möglich, eine genauere Schätzung für die Breite der Fahrspur aus der Klasse der Straße abzuleiten.

²⁴ Mit anderen Worten wäre das zugrunde liegende Fahrspurmodell bei dieser Optimierungsstrategie eine Gerade.

²⁵ Eine Limitierung des Modells liegt darin, dass unterbrochene Fahrspurmarkierungen prinzipiell eine geringere Güte als durchgezogene Markierungen aufweisen.

²⁶ Umgangssprachlich ausgedrückt handelt es sich um eine konservativere Schätzung der Berandung.

Es ist daher nicht hinreichend, ausschließlich die Güte der vollständigen Pfade zu betrachten. Angewendet wird die globale Optimalitätsbedingung aus Gleichung 3.2.15 auf alle Zustandsübergänge der Pfade.

3.2.3 Zeitliche Verfolgung des Splines

Die weitgehend formfreie Beschreibung der Fahrspurgeometrie mit einer Splinekurve flexibler Ordnung ermöglicht die zeitliche Verfolgung der Fahrspurberandungen ξ_t^+ direkt in der Bildebene \mathbf{b} aus Abbildung 2.3(a) auf Seite 11. Die prinzipiellen Stärken dieses Ansatzes wurden bereits im Abschnitt 2.5.2 auf Seite 34 zusammengefasst.

Die maßgebliche Unsicherheit bei der Prädiktion der Splinekurve wird durch die Nickwinkelschwingung $\beta(t)$ der Kamera um ihre Einbaulage verursacht. In der Bildebene resultiert daraus ein konstanter Beobachtungsfehler,²⁷ der unabhängig von der Bildposition \mathbf{b} ist. Dies bedeutet eine weitere Vereinfachung der algorithmischen Umsetzung einer bildbezogenen Verfolgung der Fahrspurberandung.

Die folgenden Abschnitte modellieren die wesentlichen Aspekte der zeitlichen Verfolgung der Spline-Parameter. Als Grundlage wird die Rückkopplung aus Abbildung 2.16 auf Seite 43 als bekannt vorausgesetzt.

3.2.3.1 Dynamik der Kamerabewegung

Im Abschnitt 2.2 wurde der Einfluss der Kameradynamik auf die zeitliche Verfolgung der Fahrspur bereits qualitativ diskutiert. Mit Blick auf die quantitative Bestimmung der Unsicherheit in der Prädiktion auf den nächsten Beobachtungszeitpunkt wird in diesem Abschnitt ein mechanisches Modell der Nickwinkelschwingung $\beta(t)$ kurz vorgestellt. Das Modell ist in analoger Form auch auf den Rollwinkel $\alpha(t)$ übertragbar, eine ausführliche Herleitung und die Umsetzung im Kalman-Filter findet sich in [Cec04].

Abbildung 3.8 visualisiert die Abstraktion des Fahrzeugs auf das gedämpfte Feder-Masse System. Mathematisch wird die resultierende Schwingung durch die Differentialgleichung 3.2.16 beschrieben.

Die linke Seite der Gleichung beschreibt die inhärente Nickwinkelschwingung $\beta(t)$ des Fahrzeugs im ungestörten Fall. Die Kenngrößen der Schwingung sind die

²⁷ Die im Versuchsfahrzeug verwendeten Kameras verfügen über eine konstante Winkelauflösung, vgl. Abschnitt 2.4.3.

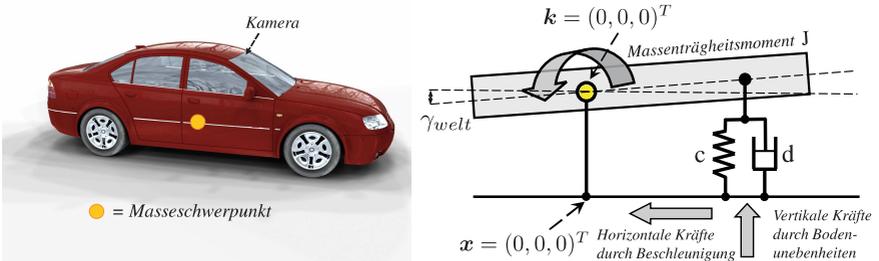


Abbildung 3.8: Mechanisches Modell zur zeitlichen Verfolgung der Nickwinkelschwingung $\beta(t)$ der Kamera. Das Ego-Fahrzeug auf der linken Seite der Abbildung wird abstrahiert auf eine gedämpfte Feder-Masse Anordnung, die rechts schematisch dargestellt ist. Grundlage des Modells ist eine Analyse der physikalischen Schwingungseigenschaften des Fahrzeugs, sie ist aus [Ber00] bekannt. Die beiden wesentlichen Kenngrößen sind die jeweils auf das Massenträgheitsmoment normierte Federkonstante c und Dämpfungskonstante d der Anordnung. Sie werden durch Experimente numerisch bestimmt, vgl. Abschnitt 5.1.3. Die daraus abgeleitete Eigenfrequenz ω_0 charakterisiert die Trägheit der Schwingung und bestimmt maßgeblich die Varianz der prädierten Lage der Fahrspur.

Federkonstante c und die Dämpfungskonstante d der Anordnung, jeweils normiert auf das rotatorische Massenträgheitsmoment J des Fahrzeugs.

$$\underbrace{\frac{c}{J} \cdot \beta(t) + \frac{d}{J} \cdot \frac{\partial \beta(t)}{\partial t} + \frac{\partial^2 \beta(t)}{\partial t^2}}_{\text{Inhärente Nickwinkelschwingung}} = \underbrace{\frac{b}{J} \cdot \frac{\partial v(t)}{\partial t}}_{\text{Beschleunigung}} + \underbrace{\mu(t)}_{\text{Systemrauschen}} \quad (3.2.16)$$

Die Resonanzfrequenz ω_0 der Anordnung bestimmt die maximale Änderung des Nickwinkels $\beta(t)$ zwischen zwei Beobachtungszeitpunkten. Sie wird im Abschnitt 5.1.3 experimentell ermittelt.

Die rechte Seite der Gleichung modelliert den externen Einfluss von Geschwindigkeitsänderungen und Systemrauschen $\mu(t)$ auf den Nickwinkel des Fahrzeugs.

3.2.3.2 Prädiktion der Splinekurve

Es gelten die Annahmen zur inversen projektiven Geometrie aus Abschnitt 2.4.3 auf Seite 25. Mit diesen Voraussetzungen existiert ein eindeutiger, statischer Zu-

sammenhang zwischen der prädierten 3D-Bewegung der Kamera und der erwarteten Lage der Splinekurve ξ_{t+1}^+ am nächsten Abtastzeitpunkt $t+1$.

Die gerichteten Anteile der Kamerabewegung werden mit dem Einspurmodell aus [Sta03] beschrieben. Eingangsgrößen des Modells sind die Geschwindigkeit und der Lenkwinkel des eigenen Fahrzeugs, die von separaten Sensoren mit hoher Güte erfasst werden. Alle rotatorischen Komponenten der Kamerabewegung aus Abschnitt 2.2 werden zu Null angenommen. Als Ergebnis liefert die Prädiktion die vorhergesagten Koordinaten ξ_{t+1}^- der Splinekurve.

3.2.3.3 Integration der Beobachtung

Das Konzept zur Initialisierung der Fahrspurberandung basiert auf Konturen und ist damit das Ergebnis einer sequentiellen Bildauswertung. Grundsätzlicher Nachteil aller dieser Verfahren ist die Anfälligkeit gegenüber einzelnen Störungen. Somit erscheint eine zeitliche Verfolgung auf Basis der Algorithmen zur initialen Detektion ungeeignet, da sie nach Definition 2.2 auf Seite 41 nicht robust ist.

Die globale Lage der Fahrspurberandung im Bild ist bei der zeitlichen Verfolgung näherungsweise bekannt, vgl. Abschnitt 2.2 auf Seite 10. Dies erlaubt eine Integration von prädierten Modelleigenschaften und aktueller Beobachtung auf der zweiten Abstraktionsstufe der Modellbildung, vgl. Abbildung 3.1. Störungen einzelner Bildpunkte verursachen dabei leicht geänderte, aber keine qualitativ unterschiedlichen Ergebnisse der Schätzung.²⁸ Dieser Eigenschaft kommt elementare Bedeutung für alltagstaugliche Assistenzsysteme zu.

Unter ähnlichen Randbedingungen haben sich in weiten Teilen der Signalverarbeitung sogenannte Aktive Konturen²⁹ zur exakten Anpassung von Splinekurven an beobachtete Daten durchgesetzt. Bei diesen Lösungsansätzen werden die Parameter des Splines solange variiert, bis die kooperative Minimierung über die Kontraststärke und den Krümmungsverlauf entlang der Kurve ein lokales Minimum erreicht [Bla98]. Aktive Konturen erzielen für viele Anwendungen Ergebnisse in bislang nicht gekannter Qualität [Uns99].

Aktive Konturen gehören zu den sehr rechenintensiven „brute force“³⁰ Methoden, die ihre Leistungsfähigkeit aus einer erschöpfenden Suche über den möglichen Lösungsraum beziehen [Bla98], [dB94]. Als Konsequenz berichten bspw. Wang

²⁸ Im Gegensatz dazu kann bei der initialen Detektion ein einzelner gestörter Bildpunkt dazu führen, dass eine gesamte Kontur nicht zustande kommt, da sie in zwei „vernachlässigbare“ Anteile zerfällt.

²⁹ In englischer Originalliteratur werden Aktive Konturen als Snakes oder Active Contours bezeichnet.

³⁰ Für diesen Fachbegriff existiert, soweit ersichtlich, keine treffende deutsche Übersetzung.

u. a. in [Wan04] Rechenzeiten von mehreren hundert Millisekunden für die Aktualisierung einer einfachen Spline-Konfiguration zweiter Ordnung zur zeitlichen Verfolgung von S-Kurven. Aktuell sind Aktive Konturen daher noch nicht mit den Echtzeitanforderungen einer Umsetzung im Versuchsfahrzeug vereinbar.

In dieser Arbeit wird das Konzept der Aktiven Konturen daher weitgehend vereinfacht. Es gelten nach wie vor die Voraussetzungen des Abschnitts 3.1.1 auf Seite 48, insbesondere werden nur lokale Maxima der Kontrastverteilung $\|\nabla g(\mathbf{b})\|$ als gültige Beobachtungen betrachtet. Das Ähnlichkeitsmaß zwischen Modell und Beobachtung ist durch die bereits definierten Kostenterme aus den Gleichungen 3.2.9, 3.2.11 und 3.2.12 gegeben:

$$\rho_k(\xi_k^- = \mathbf{b}_i) \Big|_{t+1} := \rho_\perp(\xi_{t+1}^-, \mathbf{b}_i) + \rho_\gamma^{31}(\xi_{t+1}^-, \mathbf{b}_i) + \rho_r(\xi_{t+1}^-, \mathbf{b}_i) \quad (3.2.17)$$

Die Aktualisierung des Berandungsverlaufs basiert nach Gleichung 3.2.17 auf der wiederholten Anwendung des bereits aus der Initialisierungsphase bekannten Prinzips.³² Für alle Beobachtungszeitpunkte $t > 0$ dienen die prädierten Berandungsattribute ausschließlich als Erwartungswerte für die Elemente ξ_k^- der Fahrspurberandung zum nachfolgenden Abtastzeitpunkt $t + 1$. Nach Realisierung der Beobachtung ist die exakte Position der Berandung weiterhin durch das lokale Maximum des Grauwertgradienten bestimmt, welches die geringste Distanz im Markov-Modell aufweist.

In der Initialisierungsphase wurde zusätzlich der tangentielle Abstand zwischen zwei Linien als weiterer Kostenterm 3.2.10 berücksichtigt. Aufgrund des umfangreicheren Vorwissens liefert er jedoch keinen sinnvollen Beitrag zur zeitlichen Verfolgung, vgl. die konkrete Berechnung im Abschnitt 4.4.2. Mit der gleichen Begründung entfällt auch die gesonderte Betrachtung zur räumlichen Initialisierung der Schätzung aus Abschnitt 3.2.2.2.

³¹ Die Orientierung des Bildpunkts \mathbf{b}_i wird dabei senkrecht zur Orientierung $\angle(\nabla g(\mathbf{b}_i))$ des Grauwertgradienten angenommen.

³² Alternativ wäre hier auch ein Zustandsraummodell denkbar, um eine explizite Ausgleichung zwischen Prädiktion und aktueller Messung zu realisieren. Aufgrund der hohen Korrelation aufeinander folgender Beobachtungen ist der prädierte Fahrspurverlauf jedoch mit einem systematischen Fehler behaftet, der eine zeitliche Drift in der Schätzung verursachen kann.

3.3 Parameter der Modellbildung

Tabelle 3.1 auf Seite 77 fasst die Parameter des mathematischen Modells zur Schätzung der innerstädtischen Fahrspurberandung zusammen.

Die aufgeführten Parameter sind in der algorithmischen Umsetzung im Versuchsfahrzeug als frei konfigurierbare Größen implementiert.³³ Der Einfluss der Parameter auf die Ergebnisse der Schätzung wird im Kapitel 5 anhand von Experimenten diskutiert.

3.4 Zusammenfassung von Kapitel 3

Dieses Kapitel formuliert ein stochastisches Modell der lokalen Abbildungseigenschaften innerstädtischer Fahrspurberandungen in monochromatischen Bildfolgen. Die Beobachtung der innerstädtischen Fahrspurberandung wird als eindimensionaler Zufallsprozess modelliert. Von ihm wird angenommen, dass er durch eine einseitige Markov-Kette erster Ordnung beschreibbar ist.

Die Modellbildung ist hierarchisch strukturiert, Abbildung 3.1 stellt die unterschiedlichen Abstraktionsstufen anschaulich dar. Es wird grundsätzlich zwischen sensornahen Attributen der Berandungselemente und der aktiven Analyse semantisch zusammengehöriger Beobachtungen unterschieden.

Die Abbildungen von hellen Fahrspurmarkierungen, Bordsteinkanten und allgemeinen Texturübergängen wurden auf ein einheitliches Beobachtungsmodell zurückgeführt. Als primäres Merkmal wird von den Berandungselementen lediglich gefordert, dass ihre exakte Position im Bild durch ein lokales Maximum des Kontrasts definiert ist. Dieses Kriterium ist wenig selektiv und führt neben der tatsächlichen Beobachtung der Fahrspurberandung zu einer hohen Anzahl fälschlicher Weise markierter Bildpositionen, vgl. Abbildung 4.2(b).

Während der initialen Detektion werden Liniensegmente als atomare Einheiten der Beobachtung aufgefasst. Ausgehend von *a-priori* Annahmen über die Eigenschaften der Fahrspurberandung im Nahbereich vor dem eigenen Fahrzeug wird der Zufallsprozess in Richtung beobachteter Linien ausgewertet. Ähnliche Segmente werden zu semantischen Einheiten gruppiert, die gemeinsam die Fahrspurberandung repräsentieren. Als Ergebnis liefert die initiale Detektion die geordnete Menge der assoziierten Bildpositionen.

³³ Die Resonanzfrequenz ω_0 der Nickwinkelschwingung geht indirekt in die Varianz der zeitlichen Prädiktion der Splinekurve ein.

Name	Kurzbeschreibung, Einfluss	Referenzen
Prozentsatz Bildpunkte mit hohem Kontrast	Canny-Operator, Anpassung des oberen Schwellwerts der minimalen Kantestärke	Abschnitt 2.3.1, Abschnitt 2.3.4, [Can86], [Jia02]
Prozentsatz Bildpunkte mit mittlerem Kontrast	Canny-Operator, Anpassung des unteren Schwellwerts der minimalen Kantestärke	Abschnitt 2.3.1, Abschnitt 2.3.4, [Can86], [Jia02]
Gewichtsfunktion des Glattheitsterms der Spline-Approximation	Adaptive Gewichtsfunktion $\lambda(b)$ aus Gleichung 3.2.3, beeinflusst die Glattheit der Spline-Approximation	Abschnitt 3.2.1.1, Abbildung 3.3, [dB94], [dB02]
Geforderte Güte der Spline-Approximation	Güte der geometrischen Approximation, beeinflusst die optimale Ordnung der beschreibenden Splinekurve	Abschnitt 3.2.1.3, Abbildung 3.4, [Dou73]
Varianzen des Markov-Modells der Fahrspurberandung	Varianzen σ_{\perp}^2 , σ_{\parallel}^2 , σ_{γ}^2 , σ_c^2 , σ_g^2 , und σ_{\parallel}^2 ; beeinflussen die Verbundwahrscheinlichkeit zwischen Berandungselementen	Abschnitt 3.2.2.1, Abschnitt 3.2.3.3
Erwartungswerte des räumlichen Ursprungs der Fahrspurberandung	Attribute x_e , y_e , γ_{-1} , c_{-1} , g_{-1} , s_{-1}^l und s_{-1}^r des imaginären Berandungselements ξ_{-1} ; beeinflussen die Wahl des initialen Liniensegments	Abschnitt 3.2.2.2, Definition 3.2.14
Kosten des räumlichen Ursprungs der Fahrspurberandung	Kosten ρ_0 des räumlichen Ursprungs der Berandung, beeinflussen die bevorzugte Vorausschauweite	Abschnitt 3.2.2.3, Gleichung 3.2.15
Trägheit der Nickwinkelschwingung	Resonanzfrequenz ω_0 der Nickwinkelschwingung, maßgeblicher Indikator für die zeitliche Bindung der Beobachtung	Abschnitt 3.2.3.1, Abbildung 3.8, [Cec04]

Tabelle 3.1: Konfigurationsparameter der Modellbildung.

Zur weitgehend formfreien Beschreibung innerstädtischer Fahrspurgeometrien wurde im Abschnitt 3.2.1.1 die Spline-Approximation aus [Rei67] eingeführt. Diese Splinekurve unterstützt eine kontrollierte Glattheit der lokalen Approximation, ohne den globalen Verlauf möglicher Fahrspurgeometrien zu beschränken.

Die flexible Beschreibung der Fahrspurgeometrie ermöglicht die zeitliche Verfol-

gung der Fahrspurberandung direkt in der Bildebene. Fahrspurmodell und Beobachtung haben damit die Bildkoordinaten als gemeinsame Bezugsgröße. Die von klassischen Ansätzen bekannte Unsicherheit der dynamischen Transformation zwischen bild- und weltbezogenen Größen wird somit aus der Rückkopplung zur zeitlichen Verfolgung der Berandung separiert.

Die Flexibilität bei der Approximation globaler Kurvenverläufe wird durch eine sehr hohe Ordnung der zugrunde liegenden Splinekurve³⁴ ermöglicht. Als interne Repräsentation der Berandungsgeometrie innerhalb der Fahrspurschätzung ist diese Darstellung vertretbar, zur Anbindung an Assistenzfunktionen ist eine kompaktere Beschreibung notwendig.

Interessanter Weise zeigt die Bestimmung der Splineparameter im Abschnitt 3.2.1 eine ausgesprochen stabile Berechnung des Krümmungsverlaufs entlang der Kurve, vgl. bspw. Abbildung 3.4. Auf dieser Basis lässt sich eine geschlossene Lösung zur optimalen Segmentierung des Splines formulieren, um eine geforderte Approximationsgüte mit minimalem Parametersatz zu beschreiben. Typischer Weise reduziert sich die Anzahl notwendiger Basispolynome dabei auf Werte kleiner fünf.

Die Unsicherheit in der zeitlichen Prädiktion der Fahrspurberandung wird maßgeblich durch die Trägheit der Nickwinkelschwingung des eigenen Fahrzeugs bestimmt. Im Abschnitt 3.2.3.1 wurde ein mechanisches Modell der Kameran-schwingung aufgestellt, um die Resonanzfrequenz der Schwingung zu bestimmen. Ziel ist es, den Einfluss der Schwingung auf die Genauigkeit der Spline-Prädiktion quantitativ abzuschätzen.

Im Vorgriff auf das noch ausstehende Ergebnis der quantitativen Untersuchung erscheint die zeitliche Bindung zwischen aufeinander folgenden Beobachtungen höher als die räumliche Bindung entlang des Berandungsverlaufs. Während der zeitlichen Verfolgung erscheint es somit sinnvoller, die prädizierten Modelleigenschaften als *a-priori* Information zur Aktualisierung der Schätzung zu betrachten. Die Richtung des Zufallsprozesses ist senkrecht zum erwarteten Berandungsverlauf definiert.

Da die Annahmen zur zeitlichen und räumlichen Kontinuität des zugrunde liegenden Zufallsprozesses weitgehend identisch sind, unterscheiden sich die definierten Kostenfunktionen kaum. Prädizierte Modelleigenschaften und aktuelle Beobachtung werden für jeden Bildpunkt unabhängig von seiner Bildnachbarschaft bewertet, die Schätzung wird damit robust gegen lokale Störungen.

Die Konfigurationsparameter des Modells sind in Tabelle 3.1 zusammengefasst.

³⁴ Die Ordnung einer Splinekurve ist definiert als die Anzahl der Basispolynome, die zu ihrer Beschreibung notwendig sind [dB02].

Kapitel 4

Schätzung des Fahrspurverlaufs

Im dritten Kapitel wurde ein stochastisches Modell der erwarteten Abbildungseigenschaften innerstädtischer Fahrspurberandungen in Bildfolgen $g(\mathbf{b}, t)$ formuliert. In den folgenden Abschnitten wird die konkrete Umsetzung des Modells beschrieben. Die angewandten Algorithmen zur Erfassung der Fahrspur sind als Stand der Forschung in der Literatur bekannt. Ein wesentlicher Beitrag dieser Arbeit ist die effiziente Realisierung der Verfahren im Versuchsfahrzeug und ihre Anwendung zur Fahrspurerkennung in Innenstädten.

Aus dieser Zielsetzung ergibt sich eine weitreichende Randbedingung an die algorithmische Umsetzung der modellbasierten Schätzung. Um die verfügbare Beobachtungsrate $1/t_s = 25$ Hz des Videosensors vollständig auszunutzen, darf die Berechnung einer Schätzung bei der Online-Realisierung im Versuchsfahrzeug maximal $t_s = 40$ ms beanspruchen. Eine bewusste Unterabtastung der Bildfolge zugunsten komplexerer Analysen einzelner Beobachtungen erscheint wenig sinnvoll, die verlängerte Latenzzeit der Rückkopplung würde die zeitliche Verfolgung der Fahrspur überproportional erschweren.

Für die praktische Berechnung bedeutet dies, hinreichend unwahrscheinliche Hypothesen so früh wie möglich aus der Verarbeitungskette zu entfernen. Dies ist die einzige Möglichkeit, um die Dimension des Suchraums auf eine angemessene Größe zu begrenzen. Um den Einfluss wechselnder Beleuchtungssituationen auf die Ergebnisse der Schätzung zu reduzieren, werden die unvermeidbaren Entscheidungsschwellen in den Algorithmen dynamisch an die Kontrastverteilung des beobachteten Bildes angepasst, vgl. Abschnitt 2.3.4.

4.1 Berechnung der Merkmale

In den folgenden Abschnitten wird die algorithmische Umsetzung der zweiten und dritten Abstraktionsstufe der Modellbildung aus Abbildung 3.1 beschrieben.

In Abgrenzung zur anschließenden Schätzung des Fahrspurverlaufs in den Abschnitten 4.2 ff. geht es hier zunächst um eine rein datengetriebene Auswertung des Bildinhalts. Das Ziel ist, den relevanten Anteil des vom optischen Sensor gelieferten 2D-Signals kompakter darzustellen und parametrisch zu beschreiben. Insbesondere erfordert die Implementierung der im Abschnitt 3.2.2.1 diskutierten Markov-Ketten lineare Strukturen mit einer definierten Richtung.

Die Beschreibung der Algorithmen beschränkt sich auf spezifische Anpassungen für die Implementierung im Versuchsfahrzeug. Am Beispiel des Verkehrsszenarios aus Abbildung 2.5(a) werden die Ergebnisse der Berechnungen visualisiert.

4.1.1 Kantendetektion

3	2	1
4	b	0
5	6	7

Abbildung 4.1: *Freeman-Code der Bildnachschaften des Pixels b .*

In dieser Arbeit wird der Canny-Operator aus [Can86] zur Detektion von Kantenpunkten verwendet. Das Prinzip des Operators ist im Abschnitt 2.3.1 erläutert, die Implementierung ist angelehnt an die Umsetzung aus der Open Computer Vision Bibliothek [Int05].

Die Leistungsfähigkeit des Canny-Operators beruht maßgeblich auf der effizienten Unterdrückung von Nebenmaxima der Kontrastverteilung $\nabla g(b)$. Die Richtung des Grauwertgradienten $\angle(\nabla g(b))$ wird in acht Richtungskanäle quantisiert,¹ um die relevanten Nachbarn² zum Vergleich der Kontraststärke zu bestimmen. Abbildung 4.1 zeigt die verwendete Freeman-Codierung der Richtungskanäle.

Als Kriterium zur Berechnung der Hysterese-Schwellwerte wird gefordert, dass ein bestimmter Prozentsatz des Bildinhalts gültige Kantenpunkte darstellt.

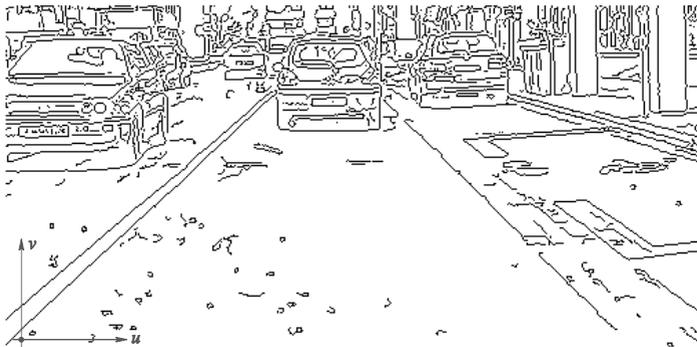
Abbildung 4.2 verdeutlicht die zentrale Herausforderung der Kantendetektion zur

¹ Die Unterdrückung von Nebenmaxima ist die aufwendigste Rechenoperation in der gesamten Verarbeitungskette, vgl. Tabelle 5.2 auf Seite 114. Eine algorithmische Umsetzung ohne diese Vereinfachung würde die verfügbare Rechenleistung im Versuchsfahrzeug um ein Vielfaches übersteigen.

² Im 2D-Gitter des optischen Sensors hat jeder Bildpunkt grundsätzlich acht Nachbarn. Entlang linearer Strukturen des Kontrastverlaufs darf der Vergleich jedoch nur mit den zwei Nachbarn in Richtung des stärksten Gradienten erfolgen.



(a) Kontrastverteilung der Abbildung 2.5, berechnet nach Gleichung 2.3.1



(b) Maske gültiger Merkmalspunkte, berechnet nach [Can86] und adaptiver Schwellwerte, vgl. Abschnitt 2.3.4.

Abbildung 4.2: Blockorientierte Berechnung einer ersten Maske gültiger Merkmalspunkte innerstädtischer Fahrspurberandungen. Abbildung 4.2(a) zeigt die Kontrastverteilung des Originalbildes 2.5. Homogene Bildbereiche sind hell dargestellt, dunkle Bereiche repräsentieren hohen Kontrast. Deutlich erkennbar sind die Fahrzeuge und die Fahrspurmarkierungen. Im Gegensatz dazu weist der Randstein am rechten Fahrbahnrand nur geringen Kontrast auf. Die Entscheidungsschwellen zur Berechnung des binären Maske gültiger Merkmalspositionen müssen entsprechend niedrig gewählt werden, vgl. Abschnitt 2.3.4. Andererseits führt dieses Vorgehen zu einer hohen Anzahl fälschlicher Weise markierter Merkmalspunkte. Sie müssen in einem umfassenderen Kontext als grobe Beobachtungsfehler bzgl. der Fahrspurschätzung klassifiziert werden.

innerstädtischen Fahrspurschätzung: Bordsteinkanten und allgemeine Texturübergänge weisen häufig geringen Kontrast auf. Um diese Berandungselemente zu erfassen, müssen die Entscheidungsschwellen entsprechend niedrig gewählt werden.

4.1.2 Konturextraktion

Die Konturextraktion transformiert die blockorientierte 2D-Repräsentation der Bildinformation b in lineare Strukturen von Bildpositionen b_i . Als unabhängiger Parameter definiert der Index i eine eindeutige Ordnung entlang der Konturen.

Im Allgemeinen kann jeder Bildpunkt in einer Kontur mehrere Nachfolger besitzen. Um diese Mehrdeutigkeit aufzulösen, wird aus der Erwartung stückweise glatter Fahrspurberandungen eine Vorzugsrichtung in der Konturverfolgung definiert. Zusätzlich wird die Korrelation zwischen Modellrichtung der Kante und Orientierung des Grauwertgradienten ausgenutzt,³ es ergibt sich eine sequentielle Suche nach dem wahrscheinlichsten Nachfolger.

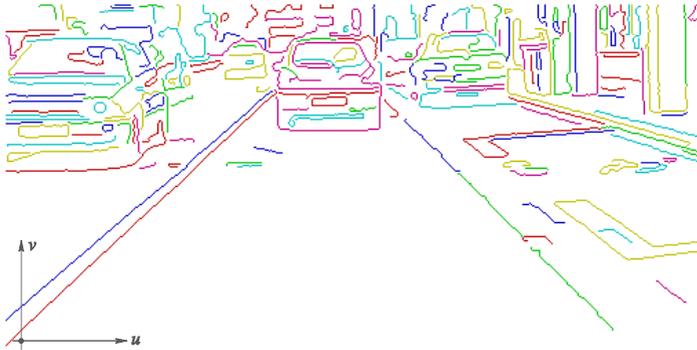
Neben der erzwungenen Linearität der Konturen optimiert diese Vorgehensweise auch die benötigte Rechenzeit, da der Nachfolger im Mittel schneller gefunden wird als bei einer zufälligen Suche. Eine detaillierte Beschreibung des Algorithmus findet sich in [Far95].

Auf Basis der Konturen wird eine umfassendere Annahme des Fahrspurmodells aus Kapitel 3 berechnet. Entlang des Indizes i wird überprüft, ob benachbarte Bildpunkte gerichtete Strukturen einer minimalen Länge ergeben. Angewendet auf das Beispiel aus Abbildung 4.3 werden von 1022 Konturen 218 als relevant und 804 als irrelevant für die nachfolgende Fahrspurschätzung klassifiziert. Das Differenzbild 4.3(b) belegt die Leistungsfähigkeit der Klassifikation, es werden fast ausschließlich Konturen ohne Relevanz unterdrückt.

4.1.3 Polygonapproximation

Mit Blick auf die begrenzte Rechenzeit im Versuchsfahrzeug ist eine weitere Vereinfachung in der Bildrepräsentation notwendig. Die Konturen des vorherigen Abschnitts definieren neben der ursprünglichen Bilddarstellung lediglich eine zweite hochaufgelöste Indexstruktur, über die gültige Kantenpunkte adressiert werden können.

³ Im Mittel steht die Modellrichtung der Kante senkrecht auf der Orientierung des Grauwertgradienten, vgl. Abschnitt 2.3.1.



(a) Aus dem Kantenbild 4.2(b) extrahierte Konturen, die als mögliche Beobachtung bei der Initialisierung der Berandungen betrachtet werden.



(b) Differenz der Bilder 4.2(b) und 4.3(a); lokale Maxima des Kontrasts ohne Relevanz für Initialisierung der Berandungen

Abbildung 4.3: Das in Kapitel 3 formulierte Modell erwartet von Bildpunkten der Fahrspurberandung, dass sie zusammen mit benachbarten Pixeln glatte und gerichtete Strukturen ergeben. Zur initialen Detektion der Fahrspurberandung werden die lokalen Maxima der Kontrastverteilung aus Abbildung 4.2(b) zu Konturen gruppiert, s. Abschnitt 4.1.2. Von gültigen Konturen wird eine minimale Länge und ein minimaler akkumulierter Kontrast gefordert, vgl. Abbildung 4.3(a). Die farbliche Markierung dient ausschließlich der besseren Unterscheidung. Als Ergebnis bleiben lange Konturen geringen Kontrasts erhalten, kürzere Konturen hohen Kontrasts hingegen nicht, vgl. Abbildung 4.3(b). Diese Klassifikation ist durch eine blockorientierte Auswertung lokaler Nachbarschaften nicht möglich.

Für die Analyse semantisch zusammengehöriger Bildinhalte erscheint es dagegen wenig sinnvoll, entlang der Konturen direkt benachbarte Bildpunkte zu betrachten. Konkret würden daraus vier entscheidende Nachteile resultieren:

- *Konturen sind keine parametrische Beschreibung der lokalen Umgebung. Es besteht keine direkte Möglichkeit, funktionale Aussagen über umfassendere Bildstrukturen abzuleiten.*
- *Die radiometrischen Attribute direkt benachbarter Bildpunkte sind in natürlichen Bildfolgen stark korreliert, die Glättungsoperation aus Gleichung 2.3.1 verstärkt die statistische Abhängigkeit weiter.*
- *Konturen verbinden benachbarte Kantenpunkte, auch wenn sie unterschiedliche Objekte der realen Welt abbilden. Sie können daher nicht als atomare Einheiten der Beobachtung angesehen werden.*
- *Das Gitter des optischen Sensors verursacht einen Quantisierungsfehler, dessen Auswirkung auf die geometrischen Merkmale der Beobachtung in der mikroskopischen Betrachtung nicht vernachlässigbar ist.*

Die geometrischen Faktoren des Markov-Modells aus Abschnitt 3.2.2.1 definieren den erwarteten Berandungsverlauf als eine Gerade. Ohne Beschränkung des Modells ist es somit möglich, Geradensegmente als atomare Einheiten für die aktiven Aspekte der Fahrpurschätzung zu definieren.

In der Literatur sind verschiedene Algorithmen zur Approximation von Konturen durch Linien bekannt. Hier wurde das Verfahren von Douglas und Peucker [Dou73] verwendet. Ein beispielhaftes Ergebnis ist in Abbildung 4.4 dargestellt. Im Vergleich zur konturbasierten Bildarstellung ist die Informationsreduktion bemerkenswert: Bei einer geforderten Approximationsgüte von weniger als zwei Bildpunkten werden ungefähr 10^5 Kantenpunkte durch 360 Liniensegmente angenähert.

4.2 Initiale Detektion

Die folgenden Abschnitte beschreiben die Algorithmen zur Realisierung der aktiven Aspekte der Fahrpurschätzung. Sie bauen auf den Ergebnissen der datengetriebenen Bildanalyse auf und implementieren den Übergang zwischen Abstraktionsstufe drei und vier der mathematischen Modellbildung, vgl. Abbildung 3.1.

Die häufig wechselnden Verkehrsszenarien in Innenstädten erfordern regelmäßig neue Initialisierungen des Schätzverfahrens im laufenden Betrieb. Im Mittelpunkt

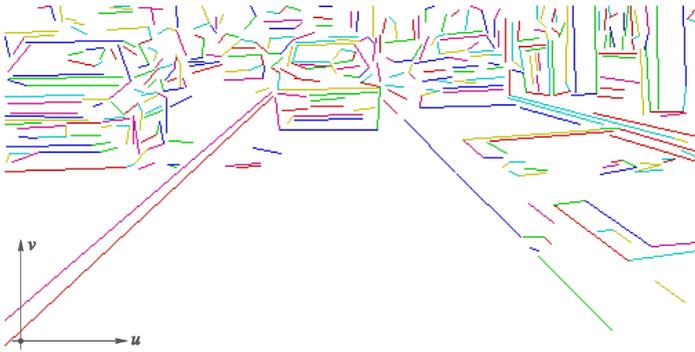


Abbildung 4.4: Beobachtung approximiert durch Polylinien. Die Szene aus Abbildung 2.5(a) wird durch 360 Liniensegmente annähernd beschrieben. Die unterschiedlichen Farben dienen lediglich zur Unterscheidung der Linien. Für den menschlichen Betrachter ist die Information ausreichend, um den Fahrspurverlauf mit hoher Sicherheit im Bild zu detektieren.

der algorithmischen Umsetzung im Versuchsfahrzeug stand daher die robuste Initialisierung des Schätzverfahrens ohne bekannte Näherungswerte für die Lage der Fahrspur.

4.2.1 Initialisierung möglicher Berandungen

Die rekursive Anwendung des Markov-Modells $P(\Xi_k | \xi_{k-1} = l_i)$ aus Gleichung 3.2.8 auf den beobachteten Linienelementen l_k erzeugt eine Baumstruktur $\Upsilon(\xi_k)$, in der jedes Element ξ_{k-1} im Allgemeinen mehrere Nachfolger $\xi_{k_0}, \dots, \xi_{k_n}$ besitzt.⁴ Ähnliche Strukturen werden in weiten Teilen der Informatik auf die Terminologie der Graphentheorie abgebildet [Grt08].

Demnach definieren die Liniensegmente aus Abschnitt 4.1.3 eine Menge von Kanten in einem nicht äquidistanten Gitter. Der Zustand ξ_k einer beliebigen Kante ist durch die Attribute des korrespondierenden Liniensegments aus Gleichung 3.2.5 definiert. Die Knoten v_i , $i = 0, \dots, n_v$ des Gitters sind durch die Zustandsübergänge $\xi_{k-1} \mapsto \xi_k$ gegeben. Mit ihnen sind die Kosten nach Gleichung 3.2.13 assoziiert.

Eine eindeutige Verbindung zwischen einem beliebigen Knoten v_i und der Wurzel

⁴ Als Basisklasse für die Umsetzung der Baumstruktur wird die Implementierung aus [Pec08] verwendet.

v_0 des Baumes wird Pfad genannt. Jeder Pfad repräsentiert eine mögliche Detektion der Fahrspurberandung. Ihnen ist nach Gleichung 3.2.15 eine globale Güte der Schätzung zugeordnet.

4.2.2 Berechnung des wahrscheinlichsten Pfades

Zur Berechnung des wahrscheinlichsten Pfades haben sich rekursive Algorithmen nach dem Optimalprinzip der dynamischen Programmierung [Bel62] durchgesetzt.⁵

In dieser Arbeit wird der Viterbi-Algorithmus aus [Vit67] zur Berechnung der wahrscheinlichsten Pfadsequenz für ein gegebenes Bild $g(\mathbf{b})$ eingesetzt. Eine detaillierte Beschreibung des Algorithmus findet sich in [For73]. Geman und Jedyak haben mit diesem Ansatz bemerkenswerte Detektionsraten von Straßenverläufen in Satellitenaufnahmen der Erdoberfläche erzielt [Gem96]. Formal ist die hier betrachtete Aufgabe ähnlich strukturiert.

Abbildung 4.5 stellt die prinzipielle Funktionsweise des Viterbi-Algorithmus anschaulich dar. Die Effizienz des Verfahrens beruht maßgeblich darauf, aus der Menge alternativer Pfade zu jedem Knoten v_i nur den wahrscheinlichsten in der weiteren Berechnung fortzuführen. Alle weiteren Hypothesen zur Erklärung dieses Zustands werden verworfen. Der Viterbi-Algorithmus garantiert, die Lösung mit maximaler Wahrscheinlichkeit zu finden. Die Komplexität des Verfahrens wächst dabei nur noch bezüglich der Ordnung n des zugrunde liegenden Markov-Modells exponentiell. Typische Werte von n sind kleiner als fünf, vgl. Abschnitt 3.2.2.1.

Besonders wichtig ist diese Vereinfachung in der Berechnung, da neben der räumlichen Nähe auch die radiometrische Ähnlichkeit die Nachbarschaft im Suchraum des Markov-Modells bestimmt. Es ist somit nicht möglich, Nachbarschaften in dem unregelmäßigen Gitter aus Abbildung 4.5 *a-priori* ausschließlich mit der Position der Liniensegmente zu begründen. Vielmehr ist es notwendig, eine hohe Anzahl von Übergangswahrscheinlichkeit aus Gleichung 3.2.13 explizit zu berechnen.

4.2.3 Detektion vorausfahrender Fahrzeuge

In Innenstädten ist die Sicht auf die Fahrbahnoberfläche regelmäßig durch vorausfahrende Fahrzeuge im Nahbereich vor der Kamera verdeckt. Lokale Bildmerk-

⁵ Diese Aussage gilt für Anwendungen außerhalb der videobasierten Fahrspurschätzung. Zwar finden sich in der Literatur ähnliche Modelle mit Entscheidungsbäumen [Gon00] oder sogenannten „Line-Snakes“ [Kan96b], über die Berechnungsstrategien machen die Autoren aber keine Angaben.

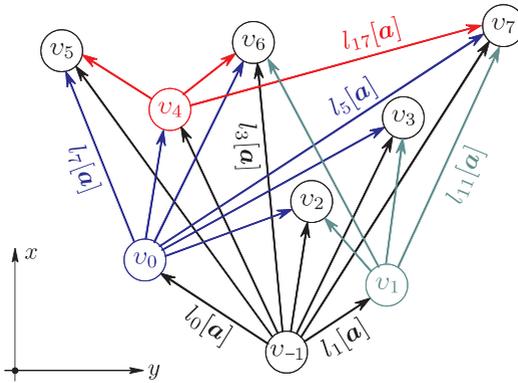


Abbildung 4.5: Räumliche Verfolgung der Fahrspurberandung.⁶ In der Terminologie der Graphentheorie bilden die Liniensegmente l_k die Kanten eines nicht äquidistanten Gitters. Der Zustand der Kanten ist durch die korrespondierenden Attribute $l_k[\mathbf{a}]$ aus Definition 3.2.5 auf Seite 62 bestimmt. v_i sind die Knoten des Gitters, mit ihnen sind die Kosten $\xi_{k-1} \mapsto \xi_k$ nach Gleichung 3.2.13 auf Seite 69 assoziiert.

Zur effizienten Berechnung des wahrscheinlichsten Pfades $\hat{\xi}_{t=0}^{l,r-}$ im Markov-Modell aus Abschnitt 3.2.2 wird der Viterbi-Algorithmus aus [Vit67] eingesetzt. Die Komplexität des Verfahrens steigt exponentiell mit der Ordnung des zugrunde liegenden Markov-Modells. Die farbliche Kennzeichnung einiger Symbole dient ausschließlich der besseren Unterscheidung.

male des Fahrzeugs weisen dabei häufig ähnliche Eigenschaften wie Elemente der Fahrspurberandung auf. Um Verwechslungen zu vermeiden, bietet es sich in diesen Situationen an, das Fahrzeug durch umfassendere Auswertungen gezielt zu detektieren und den Bildbereich für die anschließende Fahrspurschätzung auszublenden [Büc03], [Fra99]. In dieser Arbeit wurde daher ein einfaches Verfahren zur Fahrzeugdetektion in die Bildauswertung integriert.

Vorausfahrende Fahrzeuge verursachen im Bild rechteckige Anordnungen von horizontalen und vertikalen Kontrastverläufen [Hof06]. Die Analyse der einzelnen Merkmale zeigt, dass die Mitte der Heckansicht ausgeprägte horizontale Strukturen aufweist. Sie sind durch Stoßfänger, Heckscheibe, Nummernschild und Schei-

⁶ Abgebildet ist das Prinzip der Berandungsverfolgung. Eine komplette Darstellung müsste ein vollvermaschtes Netz zwischen den Knoten v_i enthalten. Aufgrund der Vielzahl möglicher Zustandsübergänge $l_{k-1} \mapsto l_k$ wurden hier nur einige beispielhafte Übergänge eingezeichnet und benannt.

benwischer verursacht. An den seitlichen Begrenzungen dominieren dagegen vorwiegend vertikale Kanten entlang der Reifen.

Zur schnellen Berechnung der Merkmale zeichnen sich Fahrzeugdetektoren auf Basis gelernter Kaskaden einfacher Klassifikatoren als favorisierte Lösung ab [Sun04], [Ber02]. Als Trainingsverfahren wird meist der Adaboost-Algorithmus aus [Vio01] eingesetzt. Tatsächlich erzielen diese Ansätze Detektionsleistungen in bisher nicht gekannter Qualität [Wit06].

Das dem Adaboost-Verfahren zugrunde liegende Integralbild und die darauf aufbauenden Algorithmen sind mit dem Ansatz dieser Arbeit nicht vereinbar. Für die Detektion direkt vorausfahrender Fahrzeuge ist ein derart spezialisiertes Verfahren auch nicht erforderlich. Eine integrale Betrachtung der bereits im Abschnitt 4.1.1 berechneten Bildmerkmale reicht aus, um sie mit ausreichender Sicherheit zu erkennen. Der Kontrast nahezu horizontaler bzw. vertikaler Kanten wird entlang der Bildspalten akkumuliert. Zur Unterdrückung von Nebenmaxima werden die resultierenden Signalverläufe mit der Spline-Approximation aus Abschnitt 3.2.1.1 geglättet.⁷

Abbildung 4.6 stellt zwei beispielhafte Ergebnisse der Berechnung dar. Die horizontale Bildposition der Fahrzeuge lässt sich aus den lokalen Maxima der Signalverläufe ablesen. Die Mitte der Heckansicht korrespondiert mit signifikanten Maxima des horizontalen Kontrasts, die seitlichen Begrenzungen verursachen Maxima im vertikalen Kontrastverlauf.

Die Breite von Fahrzeugen ist durch die International Standardization Organization normiert [Int78]. Aus dem Verhältnis dieser Vorgabe zur beobachteten Breite im Bild wird die 3D-Position der Fahrzeuge nach Projektionssgleichung 2.1.2 näherungsweise geschätzt. Zur exakten Bestimmung der vertikalen Position des Fahrzeugs im Bild wird nach einer Schattenkante am unteren Fahrzeugrand gesucht, gleichzeitig wird das Ergebnis so plausibilisiert.

4.3 Berechnung der Spline-Parameter

Jedes kubische Basispolynom der Splinekurve $r(s)$ ⁸ wird durch seine Stützstelle c sowie die Steigungs- und Krümmungsparameter d , e und f des Segments beschrieben, vgl. Definition 3.2.1 auf Seite 56.

⁷ Hier ist ein großer (konstanter) Wert für den Glättungsparameter $\lambda(i)$ erforderlich, um die hohe Anzahl von signifikanten Nebenmaxima im ursprünglichen Signalverlauf zu unterdrücken.

⁸ Allgemeine Splinekurven werden in der Modellbildung mit $r(s)$ bezeichnet. Angewendet auf die Approximation der Fahrspurberandung heißt die Kurve ξ_t^+ .

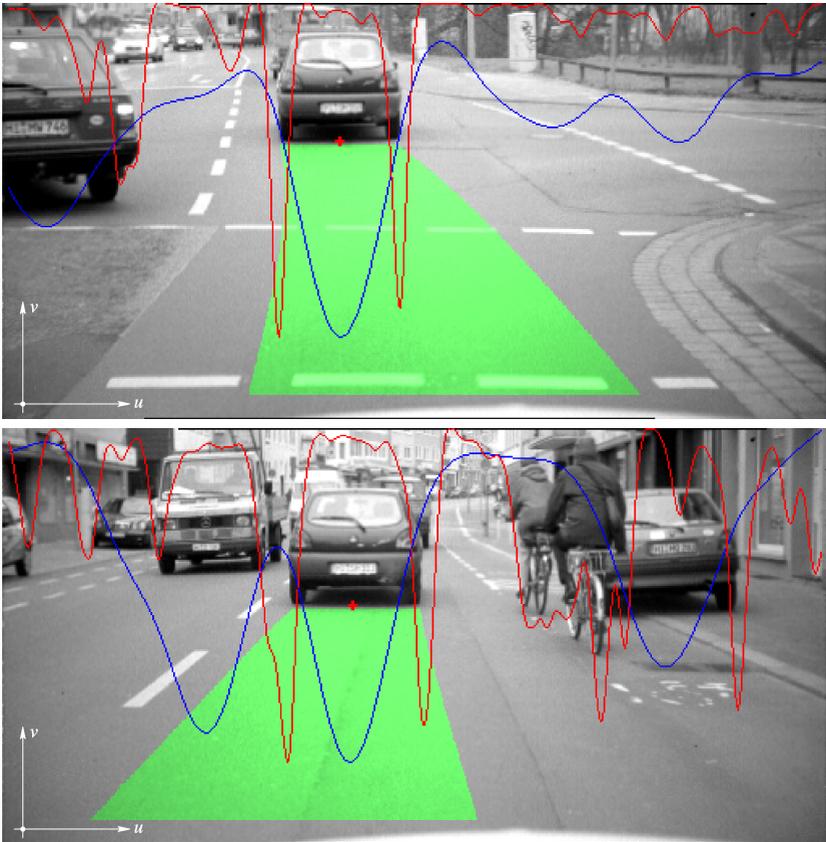


Abbildung 4.6: In Innenstädten wird die Sicht auf die Fahrbahnoberfläche häufig durch vorausfahrende Fahrzeuge im Nahbereich vor der Kamera verdeckt. Direkte Merkmale des Fahrspurverlaufs können in diesen Situationen teilweise nicht vermessen werden. Gleichzeitig liefert die freiwerdende Fläche hinter dem Fahrzeug (in der Abbildungen grün dargestellt) einen indirekten Hinweis auf den möglichen Fahrspurverlauf. Der blaue und rote Kurvenverlauf stellen die über die Bildspalten akkumulierte horizontale bzw. vertikale Kantenintensität anschaulich dar. Die oberste Bildzeile entspricht der Kantenstärke Null, die Intensität steigt zu unteren Bildzeilen hin an. In Abbildung 4.6(b) wird deutlich, dass neben Heck- auch Frontansichten von Fahrzeugen starke horizontale Kanten aufweisen. Vertikale Kanten deuten auf seitliche Begrenzungen von Fahrzeugen hin [Sun04]. Beide Signalverläufe wurden mit der Spline-Approximation aus Abschnitt 3.2.1.1 geglättet.

Für n beobachtete Bildkoordinaten \mathbf{b}_i umfasst die Beschreibung von $\mathbf{r}(s)$ damit $4 \times (n - 1)$ Parameter. Sie werden typischer Weise in kompakter Matrix-Notation zusammengefasst:

$$\boldsymbol{\xi}_i^+ = \begin{pmatrix} c_0 & d_0 & e_0 & f_0 \\ c_1 & d_1 & e_1 & f_1 \\ \vdots & \vdots & \vdots & \vdots \\ c_{n-2} & d_{n-2} & e_{n-2} & f_{n-2} \\ c_{n-1} & d_{n-1} & e_{n-1} & f_{n-1} \end{pmatrix} \in \mathbb{R}^{4 \times (n-1)} \quad (4.3.1)$$

Der numerische Zusammenhang zwischen den Parametern aus Gleichung 4.3.1 und den Bildpositionen \mathbf{b}_i ist im Anhang A.2.2 detailliert hergeleitet. Im Ergebnis läuft die Berechnung der Funktionswerte c_i auf die Lösung eines linearen Gleichungssystems hinaus:

$$c_i = \mathbf{b}_i - \frac{\sigma_n^2}{\lambda(i)} \cdot \mathbf{L} \cdot \left(\mathbf{Q} + \frac{1}{\lambda(i)} \cdot \mathbf{P} \right)^{-1} \cdot \mathbf{L}^T \cdot \mathbf{b}_i \quad (4.3.2)$$

\mathbf{L} , \mathbf{P} und \mathbf{Q} sind abkürzende Bezeichnungen für Matrizen der Dimension $(n - 1) \times (n - 1)$, die als Zwischenprodukt bei der Berechnung entstehen. Maßgeblich für die praktische Umsetzung im Versuchsfahrzeug ist die Frage, wie die Invertierung aus Gleichung 4.3.2 effizient berechnet werden kann. Kritische Parameter sind sowohl die Rechenzeit als auch der Speicherbedarf des Verfahrens. Theoretisch ist die Auflösung linearer Gleichungssysteme zwar vollständig geklärt, für große Matrizen bedeuten nicht angepasste Verfahren jedoch einen immensen Rechenaufwand.⁹

Bedingt durch den lokalen Einfluss der Beobachtungen auf die Spline-Parameter ist der Ausdruck $(\mathbf{Q} + 1/\lambda(i) \cdot \mathbf{P})$ pentadiagonal. Für die Lösung dieser Bandmatrizen existieren rekursive Formen der LR-Zerlegung, bei denen der Aufwand für die Invertierung nur linear mit der Dimension der Matrix wächst [Eng98].

Ein derartiger Algorithmus wurde in dieser Arbeit eingesetzt. Die mathematische Diskussion des Verfahrens findet sich im Anhang A.3. Kenngrößen einer Implementierung in Matlab sind im Internet verfügbar [vW04].

⁹ Die Invertierung beliebiger invertierbarer Matrizen lässt sich bspw. mit der Cramerschen Regel berechnen. Der Algorithmus hat die Komplexitätsklasse $O(N^3)$.

Kritisch zu beurteilen sind zwei Anforderungen der Berechnung an die zugrunde liegenden Beobachtungen \mathbf{b}_i . Es wird vorausgesetzt, dass sie äquidistante Abtastwerte der Splinekurve repräsentieren und mit der identischen Unsicherheit σ_n behaftet sind. Eine Erweiterung für beliebige Beobachtungen ist, soweit ersichtlich, in der Literatur bislang nicht bekannt.

4.4 Zeitliche Verfolgung

Inhaltlich basieren die initiale Detektion und die zeitliche Verfolgung der Fahrspurberandung auf einem nahezu identischen Abstandsmaß, vgl. die Kostenterme aus Gleichung 3.2.13 und 3.2.17. Die Strategien zur Berechnung der Lösung unterscheiden sich dagegen grundsätzlich: Während die initiale Detektion benachbarte Kantenpunkte \mathbf{b}_i zwischenzeitlich zu Liniensegmenten l_j gruppiert, ordnet die zeitliche Verfolgung die ursprünglichen Beobachtungen \mathbf{b}_i direkt dem prädizierten Fahrspurmodell ξ_{t+1}^- zu.

Die algorithmische Umsetzung der zeitlichen Verfolgung wird damit robust gegen einzelne Störungen in den Beobachtungen, vgl. Definition 2.2 auf Seite 41. Die angewandten Algorithmen werden in den folgenden Abschnitten kurz umrissen.

4.4.1 Prädiktion der Splinekurve

Innerhalb der Algorithmen zur Fahrspurschätzung ist die Berandungsgeometrie durch eine Splinekurve ξ_t^+ flexibler Ordnung repräsentiert. Der Abstand benachbarter Stützstellen \mathbf{c}_i entspricht dabei näherungsweise der Auflösung des optischen Bildrasters \mathbf{b} , vgl. Abschnitt 4.3.

Aus praktischen Überlegungen ist es daher ausreichend, ausschließlich die Bildkoordinaten der Stützstellen \mathbf{c}_i auf den nächsten Abtastzeitpunkt $t+1$ zu prädizieren. Zwischen zwei Stützstellen kann der Verlauf der Splinekurve in guter Näherung als Gerade angenommen werden.

Die Bestimmungsgleichungen zur Prädiktion der Stützstellen ergeben sich unmittelbar aus dem Einspurmodell aus Abschnitt 3.2.3.2. Zur Implementierung wurde das Kalman-Filter aus [Int05] verwendet.

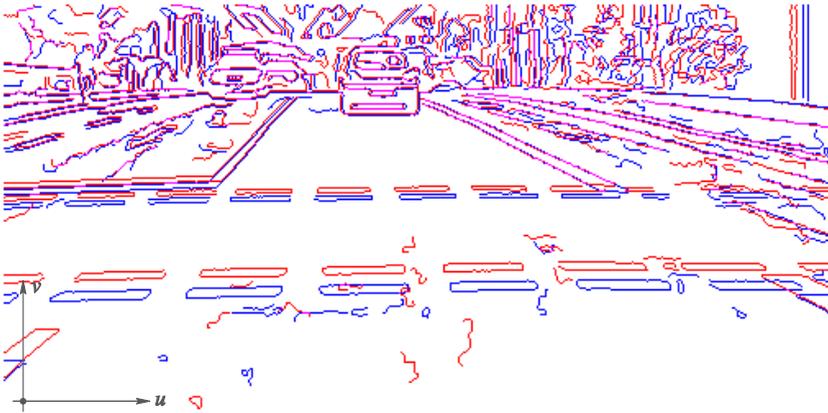


Abbildung 4.7: Zeitliche Verschiebung der Kantenpunkte zwischen zwei Beobachtungen. Dargestellt sind die nach Abschnitt 4.1.2 berechneten Kantenbilder. Rote Punkte kennzeichnen die Beobachtung zum Zeitpunkt $t - 1$, in blau sind die zum Zeitpunkt t detektierten Kanten eingezeichnet. Bildpositionen, an denen zu beiden Zeitpunkten eine Kante erkannt wurde, sind violett dargestellt.

An den horizontalen Markierungen vor dem Fahrzeug wird deutlich, dass die translatorische Fahrzeugbewegung maßgeblich die beobachtete Verschiebung im Bild bestimmt. Auch das Blendenproblem wird anschaulich klar: Entlang der in Fahrtrichtung orientierten seitlichen Fahrsprubegrenzungen ist es nicht möglich, die Verschiebung aus der Bildinformation zu schätzen [Ste00]. Zur Kompensation beider Effekte werden externe Sensoren für die Fahrzeuggeschwindigkeit und den Lenkwinkel ausgewertet, die beide Größen mit hoher Güte erfassen, vgl. Abschnitt 2.2. Die verbleibende Unsicherheit in der Prädiktion ist vergleichsweise gering, sie resultiert hauptsächlich aus der Nickwinkelschwingung des Fahrzeugs, vgl. Abschnitt 3.2.3.1.

4.4.2 Integration der Beobachtung

Abbildung 4.8 stellt das Konzept zur Integration von prädizierter Splinekurve ξ_{t+1}^- und aktueller Beobachtung am Abtastzeitpunkt $t+1$ anschaulich dar. Die gültigen Positionen \mathbf{b}_i des binären Kantenbildes 4.2(b) werden als voneinander unabhängige Beobachtungen ξ_k^- aufgefasst.

Für jeden dieser Bildpunkte \mathbf{b}_i werden die in Gleichung 3.2.17 definierten Kosten bzgl. der prädizierten Kurve berechnet. Positionen mit hinreichend kleinen Kosten

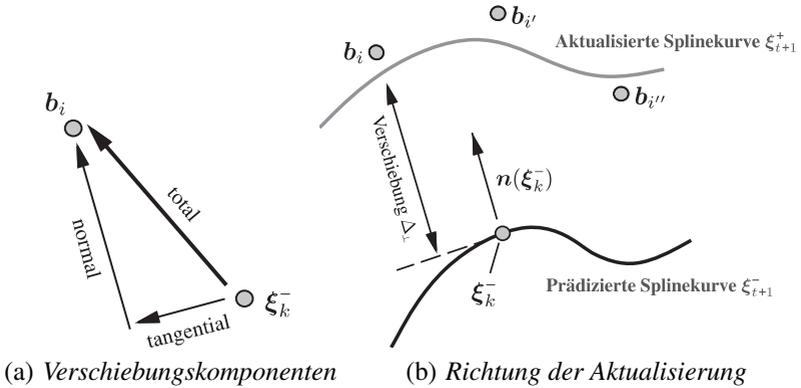


Abbildung 4.8: Aktualisierung der prädizierten Splinekurve ξ_{t+1}^- am Abtastzeitpunkt $t+1$.¹⁰ Die Ungenauigkeiten zwischen der prädizierten Kurve und den beobachteten Merkmalspunkten \mathbf{b}_i der Fahrspurberandung setzen sich aus einer tangentialen und einer normalen Abstandskomponente zusammen, vgl. 4.8(a). Maßgeblich für die Aktualisierung ist ausschließlich die normale Komponente, vgl. 4.8(b). Sie wird in der vorliegenden Arbeit mit der Distanztransformation aus [Int05] berechnet.¹¹

Auf dieser Basis werden jeder gültigen Bildposition aus Abbildung 4.2(b) die in Gleichung 3.2.17 definierten Kosten $\rho_k^-(\xi_k = \mathbf{b}_i)$ zugewiesen. Positionen \mathbf{b}_i mit hinreichend kleinen Kosten werden als Beobachtung der Fahrspurberandung aufgefasst und zur Aktualisierung der Splinekurve $\xi_{t+1}^- \mapsto \xi_{t+1}^+$ verwendet. Die Beobachtungen \mathbf{b}_i werden dabei nicht exakt interpoliert, sondern durch eine glatte Ausgleichskurve annähernd beschrieben.

ρ_i werden als Beobachtung der Fahrspurberandung betrachtet und zur Aktualisierung $\xi_{t+1}^- \mapsto \xi_{t+1}^+$ der Splinekurve verwendet. Die Ordnungsrelation innerhalb der Beobachtungen \mathbf{b}_i ist dabei durch den Bildzeilenindex v definiert.

¹⁰ Die Abbildung stammt ursprünglich aus [Bla98]. Dort wird die Anpassung von Splinekurven an beobachtete Daten im allgemeinen Kontext diskutiert, insbesondere sei auf Abschnitt 6.2 verwiesen.

¹¹ Das Distanzbild wird aus einer hinreichend dicht abgetasteten Punktfolge ξ_k^+ der Splinekurve ξ_{t+1}^+ berechnet.

4.5 Zusammenfassung von Kapitel 4

Dieses Kapitel beschreibt die konkrete Umsetzung des zuvor formulierten Modells der innerstädtischen Fahrspur. Da die Algorithmen als Stand der Forschung in der Literatur bekannt sind, beschränkt sich die Beschreibung auf die wesentlichen Aspekte der hier betrachteten Anwendung.

Die Algorithmen zur Berechnung der Abbildungsmerkmale liefern unterschiedliche Indexstrukturen auf den lokalen Maxima der Kontrastverteilung. Neben den üblichen 2D-Adressen des optischen Rasters steht insbesondere ein kompakte Beschreibung der Konturen des Bildinhalts mit wenigen hundert Liniensegmenten zur Verfügung.

Aufbauend auf dieser Information setzt die Interpretation des Bildinhalts an. Die initiale Detektion der Fahrspurberandungen wird in jedem Bild ausgeführt. Zur Berechnung des wahrscheinlichsten Pfades im Markov-Modell aus der beobachteten Anordnung von Liniensegmenten wird der Viterbi-Algorithmus verwendet. Bereits bekannte Fahrspurgeometrien werden direkt mit beobachteten Bildpositionen b_i aktualisiert. Die implementierten Algorithmen sind eine weitgehend vereinfachte Form der Aktiven Konturen.

Neben den Algorithmen zur Schätzung der Fahrspur unterstützen die berechneten Abbildungsmerkmale eine gezielte Detektion von rechteckigen Anordnungen im Bild, die starke horizontale und vertikale Kontrastverläufe aufweisen. Diese Bildbereiche werden von den weiteren Berechnungen ausgeschlossen, da es sich vermutlich um Front- oder Heckansichten anderer Fahrzeuge handelt.

Die große anwendungsspezifische Anpassung erforderte die Online-Realisierung der Spline-Approximation. Die Approximation basiert auf der Invertierung großer pentadiagonaler Matrizen, typisch sind Dimensionen größer 100. Maßgeblich für die praktische Anwendung ist die Frage, wie die Matrizen invertiert werden. Zur Lösung von Bandmatrizen existieren spezielle rekursive Formen der LR-Zerlegung, die hier angewendet wurden. Eine detaillierte Herleitung und Bewertung der Berechnungsvorschriften findet sich im Anhang [A.3](#).

Kapitel 5

Experimentelle Ergebnisse

Die in den vorherigen Kapiteln entwickelte Fahrspurschätzung wurde im Rahmen dieser Arbeit in einem Versuchsfahrzeug umgesetzt und die Leistungsfähigkeit des Verfahrens in unterschiedlichen Umgebungen analysiert. In diesem Kapitel werden die experimentellen Ergebnisse der Arbeit beschrieben und die Fahrspurschätzung als Basiskomponente für innerstädtische Assistenzfunktionen bewertet.

Im Abschnitt 5.1 werden zunächst konkrete Werte für die Konfigurationsparameter der Algorithmen bestimmt. Das Potential der entwickelten Schätzung wird im Abschnitt 5.2 anhand von visuell und geometrisch anspruchsvollen Situationen belegt. Im Abschnitt 5.3 wird die Leistungsfähigkeit der Algorithmen im alltäglichen Betrieb validiert. Es werden beispielhafte Ergebnisse von Testfahrten in der Hildesheimer Innenstadt gezeigt. Als Referenz werden die Ergebnisse mit einer kommerziellen Umsetzung des Prinzips von Dickmanns u. a. [Dic92] verglichen.

Gemessen an der Vielzahl wissenschaftlicher Publikationen zur videobasierten Fahrspurschätzung werden Metriken zur systematischen Bewertung unterschiedlicher Verfahren bislang recht wenig diskutiert, vgl. [McC06]. Bis auf einige Ausnahmen werden Ergebnisse der Schätzung im Bild visualisiert, als Referenz zur Bewertung dient die subjektive Wahrnehmung des menschlichen Betrachters. Insbesondere gilt dies für Aussagen zur Zuverlässigkeit der Verfahren, bei denen die Frage nach prinzipiell richtigen Ergebnissen beantwortet wird.

Als Kriterium für die Zuverlässigkeit der Fahrspurschätzung wird daher die Rate grundsätzlich korrekt erkannter Fahrspuren betrachtet. Die Genauigkeit des Verfahrens wird anhand der Abweichung zwischen wahrer und geschätzter Position der Fahrspur bewertet. Mit Blick auf die begrenzten Ressourcen im Versuchsfahrzeug werden im Abschnitt 5.3 die erzielten Rechenzeiten vorgestellt.

5.1 Konfiguration der Modellparameter

Innerhalb der mathematischen Modellbildung im Kapitel 3 sind einige Freiheitsgrade zur Anpassung der Fahrspurschätzung definiert worden, vgl. Tabelle 3.1 auf Seite 77. Während der experimentellen Untersuchung der entwickelten Algorithmen wurden folgende Werte konfiguriert:

Name	Numerischer Wert	adaptiv?	Kommentar
Oberer Schwellwert der minimalen Kantenstärke	30te Perzentile der Kontrastverteilung, minimal 4% c_{max}	ja	abhängig von der Beleuchtung der Szene und der Kameradynamik
Unterer Schwellwert der minimalen Kantenstärke	40te Perzentile der Kontrastverteilung, minimal 2% c_{max}	ja	abhängig von der Beleuchtung der Szene und der Kameradynamik
Regularisierung der Spline-Approximation	s. Abbildung 5.1	ja	abhängig von der wahren Krümmung entlang der Kurve
Geforderte Güte der Spline-Approximation	$\Delta f'''(\mathbf{b}) \leq 2 \cdot 10^{-5}$ s. Abbildung 3.4	nein	geometrische Größe; invariant gegenüber Umgebungseinflüssen
Geometrische Erwartungswerte des räumlichen Ursprungs	$x_e = 0 \text{ m}$ $y_e = 1.5 \text{ m}$ $\gamma_{-1} = 0^\circ$	nein	invariante <i>a-priori</i> Annahmen über die Fahrspurgeometrie direkt vor dem eigenen Fahrzeug
Geometrische Varianzen des Markov-Modells	$\sigma_\gamma^2 \ll \sigma_\perp^2 \ll \sigma_\parallel^2$	nein	die erwartete Geometrie der Fahrspurberandung wird nicht variiert
Radiometrische Erwartungswerte des räumlichen Ursprungs	$c_{-1} = 0.1 \cdot c_{max}$ $g_{-1} = 0.75 \cdot g_{max}$ $s_{-1}^l = 3$ $s_{-1}^r = 5$	nein	invariante <i>a-priori</i> Annahmen, skalieren jedoch mit der Kameraauflösung
Radiometrische Varianzen des Markov-Modells	$\sigma_\parallel^2 \ll \sigma_c^2 \ll \sigma_g^2$	nein	feste Werte, skalieren jedoch mit der Kameraauflösung und der Bildvorverarbeitung

Kosten ρ_0 des räumlichen Ursprungs	bestimmt die bevorzugte Vorausschauweite, s. Gleichung 3.2.15	nein	konkreter Wert ist relativ zu den Varianzen des Markov-Modells zu setzen
Trägheit der Nickwinkelschwingung	$f_0 \approx 1,3 \text{ Hz}$ $\beta_{max} \approx 1,5^\circ$	nein	Indikator die für Güte der zeitlichen Prädiktion, siehe Abbildung 5.2(b)

Tabelle 5.1: *Konfiguration der Modellparameter.*

In den folgenden Abschnitten werden die Eigenschaften der wesentlichen Modellparameter kurz zusammengefasst.

5.1.1 Varianzen des Markov-Modells der Fahrspurberandung

Unabhängig von der spezifischen Ausprägung der Fahrspurberandung wird in dieser Arbeit angenommen, dass die Abbildungseigenschaften der Berandungselemente qualitativ einem Markov-Modell folgen. Während der experimentellen Analyse hat sich gezeigt, dass mehrere numerische Instanzen des Modells zu besseren Ergebnissen führen.

Insbesondere wurde sichtbar, dass eine einheitliche Konfiguration zur Detektion von moderat gekrümmten Fahrspuren und engen Kurven in Kreuzungsbereichen nur wenig selektiv sein kann. Im ersten Fall ist die Winkeldifferenz zwischen benachbarten Berandungselementen ausschlaggebend, im zweiten Fall spielt sie eine untergeordnete Rolle. In diesen Situationen entscheiden vielmehr die longitudinale Abstandskomponente und die radiometrische Ähnlichkeit. Analog ist bei unterbrochenen Markierungen eine Detektionslücke in Richtung der Berandung zu erwarten.

Aufgrund der effizienten Implementierung¹ der initialen Detektion ist es möglich, mehrere Instanzen des Markov-Modells parallel zu berechnen. Ein Lernverfahren zur systematischen Bestimmung optimaler Varianzen für unterschiedliche Ausprägungen von Fahrspurberandungen wäre als Ziel einer weiterführenden Studie wünschenswert.

¹ Die realisierten Rechenzeiten der Online-Implementierung sind in Tabelle [5.2](#) auf Seite [114](#) zusammengefasst.

5.1.2 Regularisierung der Spline-Approximation

Die Spline-Approximation der Berandungsgeometrie wirkt krümmungsminimierend, vgl. Abschnitt 3.2.1. Neben der gewünschten Ausgleichung von Ungenauigkeiten in den Beobachtungen wird auch die tatsächliche Krümmung des Berandungsverlaufs reduziert. Als Konsequenz wurde in Gleichung 3.2.4 auf Seite 59 eine adaptive Regularisierung der Splinekurve definiert.

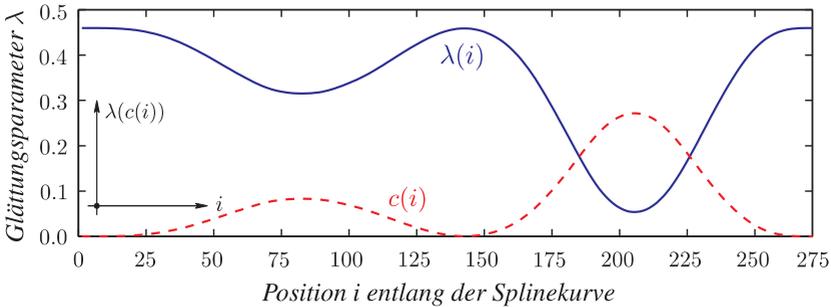


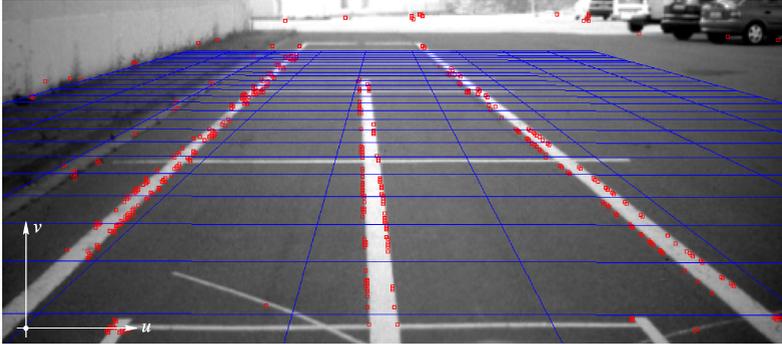
Abbildung 5.1: Adaptive Regularisierung der Spline-Approximation. Dargestellt ist die Abhängigkeit zwischen vermuteter Krümmung der Berandungsgeometrie und der Glättung der Splinekurve. Die gestrichelte rote Linie markiert die Krümmung der rechten Fahrspurberandung aus Abbildung 5.5(b), die blaue Linie zeigt den resultierenden Verlauf des Glättungsparameters $\lambda(c(i))$ nach Gleichung 3.2.4.

Abbildung 5.1 zeigt die geschätzte Krümmung $c(i)$ entlang der rechten Fahrspurberandung aus Abbildung 5.5(b) und den resultierenden Verlauf des Glättungsparameters $\lambda(c(i))$ der Spline-Approximation.

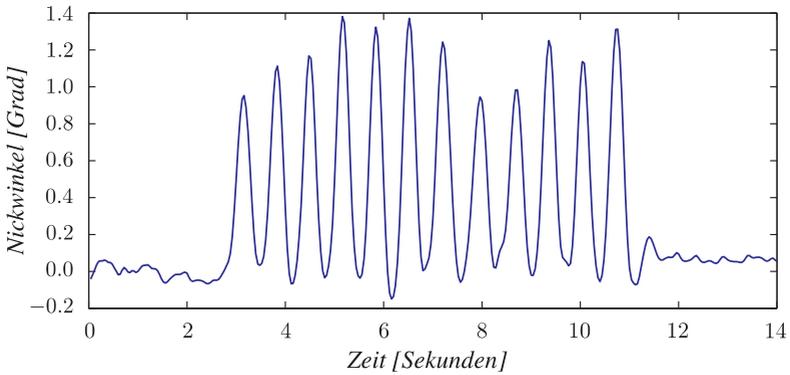
5.1.3 Parameter der Nickwinkelschwingung

Zur quantitativen Abschätzung des Prädiktionsfehlers in der Bildebene \mathbf{b} wurden die Schwingungseigenschaften des eigenen Fahrzeugs experimentell analysiert. Abbildung 5.2(b) zeigt die Nickwinkelschwingung $\beta(t)$ der Kamera um ihre Einbaulage. Die maximale Winkeldifferenz zwischen zwei Abtastzeitpunkten t und $t+40$ ms beträgt ca. 0.25° .

Die verwendeten Kameras besitzen eine konstante Winkelauflösung von ungefähr 15 Bildpunkten/ $^\circ$. Es ist somit davon auszugehen, dass unter normalen Betriebsbedingungen kein Prädiktionsfehler von mehr als fünf Bildpunkten auftreten kann. Typisch sind Werte von ein oder zwei Pixeln.



(a) Kalibrierfeld



(b) Nickwinkelschwingung

Abbildung 5.2: Nickwinkelschwingung $\beta(t)$ der Kamera. Die Unsicherheit der zeitlichen Prädiktion der Splinekurve auf den nächsten Abtastzeitpunkt $t+1$ entsteht maßgeblich aus der Nickwinkelschwingung $\beta(t)$. Andererseits kann sich der Nickwinkel nicht beliebig schnell ändern, sondern ist durch Fahrzeugdynamik limitiert. Um die Resonanzfrequenz ω_0 und die maximale Amplitude β_{\max} der Schwingung quantitativ zu bestimmen, wurde das Versuchsfahrzeug auf dem Kalibrierfeld aus Abbildung 5.2(a) geparkt und extern angeregt. Die roten Punkte wurden von einem Stereo-System vermessen, das blaue Gitter dient zur visuellen Plausibilisierung der Ergebnisse. Abbildung 5.2(b) zeigt den resultierenden Verlauf des Nickwinkels über der Zeit.

Unter den extremen Bedingungen des Experiments stellt sich eine maximal mögliche Auslenkung $\beta_{\max} \approx 1.5^\circ$ gegenüber der kalibrierten Ruhelage der Kamera ein. Die Resonanzfrequenz beträgt $\omega_0 \approx 2\pi \cdot 1.3 \text{ s}^{-1}$, die maximale Winkeldifferenz $\Delta\beta$ zwischen zwei Abtastzeitpunkten ist 0.25° .

5.2 Bewertung funktionaler Eigenschaften

Ausgangspunkt dieser Arbeit war die Frage, wie der Verlauf innerstädtischer Fahrspurgeometrien aus monokularen, monochromatischen Bildfolgen $g(\mathbf{b}, t)$ geschätzt werden kann. Als größte Herausforderungen wurden die unterschiedlichen Abbildungseigenschaften verschiedener Berandungstypen und die Modellierung variabler Berandungsgeometrien betrachtet.

In den folgenden Abschnitten werden die funktionalen Eigenschaften der entwickelten Algorithmen unter diesen visuell und geometrisch anspruchsvollen Anforderungen verifiziert.

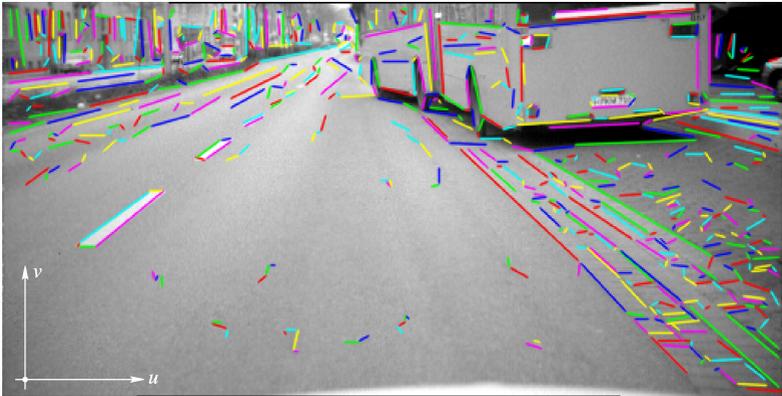
5.2.1 Erkennung unterschiedlicher Berandungstypen

In den Abbildungen 5.3 und 5.4 ist die Detektionsleistung der entwickelten Algorithmen unter unterschiedlichen Bedingungen anschaulich dargestellt. Als Berandungstypen sind unterbrochene Fahrspurmarkierungen, Bordsteine und Randsteine zu erkennen. Letztere sind nahezu als allgemeine Texturübergänge zu klassifizieren.

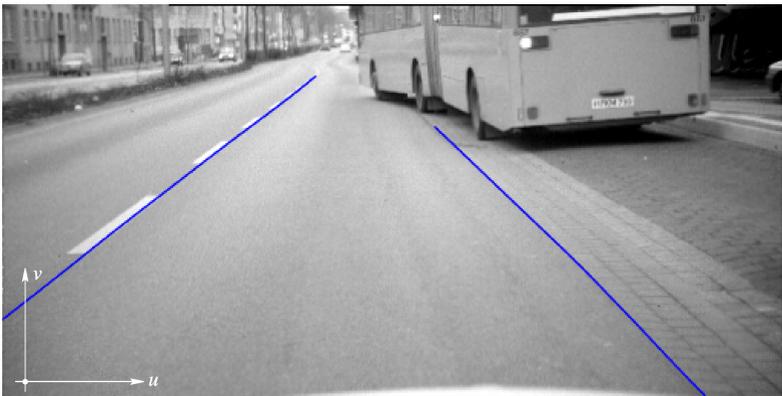
In dieser Arbeit wurden alle Berandungstypen auf einen kantenbasierten Ansatz zurückgeführt, vgl. Abschnitt 3.1.1. In den Beispielen werden die Stärken, aber auch die Limitierungen der einheitlichen Abstraktion deutlich. Positiv zu bemerken ist die Detektionsleistung bei geringem Kontrast, bspw. an der rechten Fahrspurberandung in Abbildung 5.3(b). Das zugrunde liegende Merkmalsbild in Abbildung 5.3(a) liefert aber gleichzeitig auch einen Hinweis darauf, wie mehrdeutig die Auswertung der rechten Berandung ist: Weiter außen liegende Kanten verursachen nahezu identische Anordnungen von Liniensegmenten.

Fahrspurmarkierungen und allgemeine Texturübergänge liegen meist in der Fahrbahnebene. Bordsteinkanten beinhalten dagegen einen nicht vernachlässigbaren Sprung im lateralen Höhenprofil, dessen Bildmerkmale stark von der Ausleuchtung der Szene beeinflusst sind. Abhängig vom Stand der Sonne variiert die Richtung des Grauwertgradienten am Bordstein, außerdem erscheint mal die obere und mal die untere Kante kontrastreicher.

Insgesamt sind die wenig selektiven Anforderungen an die Berandungselemente kritisch zu beurteilen. Gerade in mehrdeutigen Situationen erscheinen aufwendigere Ansätze zur gezielten Erkennung bestimmter Berandungselemente vielversprechender, vgl. bspw. die Arbeiten von Duchow [Duc06], [Duc05]. Spezielle Verfahren zur Detektion von Bordsteinkanten werden, soweit ersichtlich, bislang noch nicht in der wissenschaftlichen Literatur diskutiert.

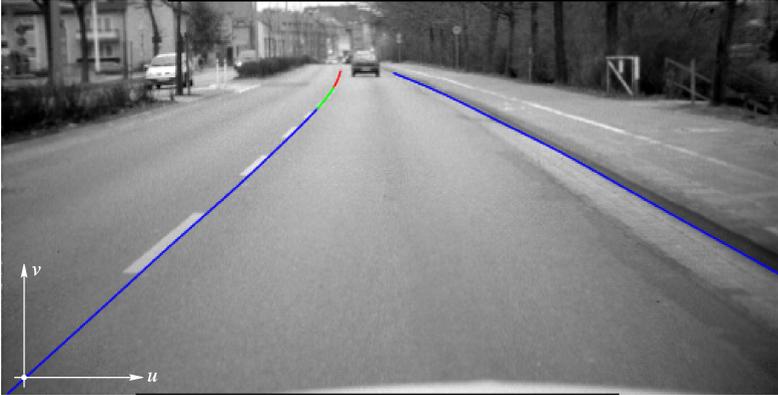


(a) Merkmalsbild extrahierter Liniensegmente



(b) Detektierter Berandungsverlauf

Abbildung 5.3: Detektion von unterbrochenen Fahrspurmarkierungen und allgemeinen Texturübergängen mit geringem Kontrast. Abbildung 5.3(a) zeigt die berechneten Liniensegmente l_j . Positiv zu bewerten ist die Detektionsleistung von allgemeinen Grauwertkanten mit geringem Kontrast. Angewendet auf Randsteine führt der wenig selektive Ansatz aber auch zu einer Vielzahl ähnlicher Berandungshypothesen, vgl. den rechten Fahrspurrand. Es ist abzusehen, dass in diesen Situationen die Innenkante des Randsteins nicht immer richtig erkannt wird. Abhängig von der übergeordneten Assistenzfunktion kann die resultierende Ungenauigkeit jedoch vertretbar sein. In dem gezeigten Beispiel entscheidet sich der Schätzer korrekt, vgl. Abbildung 5.3(b). Unterbrochene Markierungen sind grundsätzlich gut zu detektieren, tangentielle Detektionslücken zwischen Berandungselementen sind inhärenter Bestandteil des Markov-Modells aus Abschnitt 3.2.2.1.



(a) Hohe Vorausschauweite bei guter Sicht



(b) Geringe Vorausschauweite bei Verdeckung

Abbildung 5.4: Detektionsleistung bei unterschiedlichen Vorausschauweiten. Eine unbedingte Forderung nach Fahrspurberandungen konstanter Länge ist in Innenstädten nicht haltbar. In dieser Arbeit wurde daher eine globale Optimalitätsbedingung formuliert, die unter ansonsten gleichen Umständen längere Berandungsverläufe bevorzugt. Sie ist im Abschnitt 3.2.2.3 auf Seite 71 detailliert erläutert. Maßgeblich limitiert wird die Vorausschauweite durch die Kosten der lokalen Zustandsübergänge $\xi_k^- \mapsto \xi_{k+1}^-$ zwischen benachbarten Berandungselementen.

Abhängig von den Anforderungen der übergeordneten Assistenzfunktion kann es sinnvoll sein, geringere Vorausschauweiten zu bevorzugen. In diesem Bereich greifen stärkere a-priori Annahmen über den Fahrspurverlauf, die das Risiko von groben Schätzfehlern limitieren. Zur Realisierung eines Stop&Go-Assistenten erscheinen bspw. wenige Meter als ausreichend.

5.2.2 Approximation variabler Berandungsgeometrien

Enge Kurvenradien in Kreuzungsbereichen und wechselnde Krümmungsänderungen gehören zu den geometrisch anspruchsvollsten Fahrspurverläufen. Es ist weitgehend unstrittig, dass eine stückweise Beschreibung mit Polynomen niedriger Ordnung sinnvoll erscheint. Fraglich ist hingegen, wie die optimale Lösung berechnet werden kann.

In dieser Arbeit wird die Spline-Approximation aus [Rei67] als neues Fahrspurmodell eingeführt, vgl. Abschnitt 3.2.1.1. Es handelt sich dabei um eine Splinekurve flexibler Ordnung, deren Bestimmungsgleichungen die Grundlage für eine optimale Segmentierung des Berandungsverlaufs beinhalten.

Die Abbildungen 5.5 und 5.6 zeigen beispielhafte Ergebnisse der Approximation. Der Berandungsverlauf ist mit Bezug zum 2D-Raster des Bildsensors beschrieben. Die verschiedenen Segmente der Splinekurven sind farblich markiert. Jedes Segment ist durch zwei kubische Basispolynome beschrieben.² Während für einfache Geometrien ein Segment ausreicht, sind für die enge Kurve bzw. die wechselnde Krümmungsänderung in den Beispielen jeweils fünf Segmente notwendig.

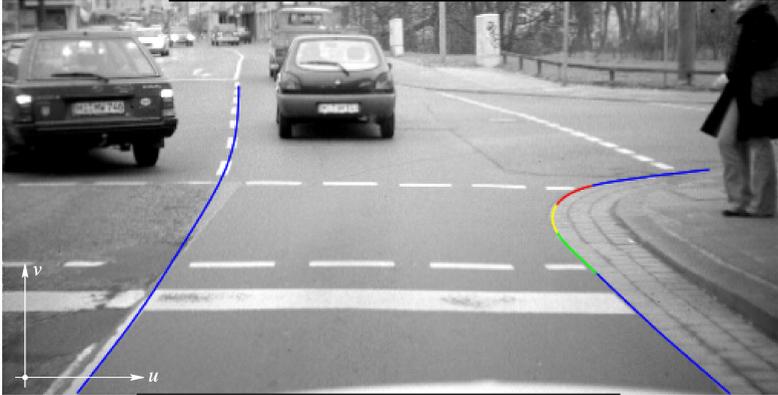
Aus den Abbildungen geht auch die erzielte Genauigkeit der geometrischen Beschreibung hervor. Abweichungen zwischen geschätztem und tatsächlichem Berandungsverlauf sind nicht zu erkennen. Die Ergebnisse bestätigen die Annahme, die exakte Position der Berandung im lokalen Maximum des Kontrasts zu vermuten.

Begünstigt durch die adaptive Regularisierung der Splinekurve aus Abschnitt 3.2.1.2 spielt auch die Frage nach modellbedingten Ungenauigkeiten der geometrischen Approximation eine vernachlässigbare Rolle.³ Negative Auswirkungen auf übergeordnete Assistenzfunktionen aufgrund einer unpassenden Modellierung der Berandungsgeometrie sind auszuschließen.

Umgekehrt folgt daraus aber auch, dass die Spline-Approximation konform zu nahezu beliebigen globalen Geometrien ist. Sie setzt damit voraus, dass die Algorithmen zur initialen Detektion und Verfolgung prinzipiell richtige Beobachtungen der Fahrspurberandung liefern.

² Die Berandung ist als Kurve $(u, v) = \mathbf{f}(z)$ definiert, siehe Gleichung 3.2.1.

³ Im Gegensatz dazu wird in den unteren Abbildungen auf Seite 110 die Ungenauigkeit der Klothoiden-Approximation einer engeren Kurve deutlich sichtbar.



(a) Approximation enger Kurvenradien



(b) Approximation von S-Kurven

Abbildung 5.5: Approximation von engen Kurvenradien und S-Kurven. Zur weitgehend formfreien Beschreibung beliebiger Berandungsgeometrien wurde in dieser Arbeit die Approximation mit Splines flexibler Ordnung eingeführt. Die Modellkomplexität passt sich dabei der beobachteten Geometrie des Fahrspurverlaufs an. Als unabhängiger Parameter bestimmt die vermutete Glattheit der Kurve die Anzahl notwendiger Basispolynome. In den abgebildeten Beispielen sind zur Beschreibung der rechten Berandung jeweils fünf Segmente erforderlich, sie sind farblich unterschieden. Die linken Berandungen lassen sich hingegen mit einem einzigen kubischen Polynom bereits hinreichend gut approximieren. Bezugsgröße der Beschreibung ist das 2D-Raster \mathbf{b} des optischen Sensors. Die Unsicherheit der 3D-Transformation zu weltbezogenen Größen \mathbf{x} wird damit aus der zeitlichen Verfolgung der Kurve entkoppelt.



Abbildung 5.6: Aufspaltung einer Berandungshypothese. Während der initialen Detektion besitzt jedes Berandungselement ξ_{k-1}^- im Allgemeinen mehrere Nachfolger $\xi_{k_1}^-$, $\xi_{k_2}^-$, ..., $\xi_{k_n}^-$. Aus dieser Eigenschaft resultiert eine Baumstruktur von Berandungselementen, in der Aufspaltungen des Berandungsverlaufs möglich sind. Zur effizienten Berechnung der wahrscheinlichsten Pfade wird der Viterbi-Algorithmus verwendet.

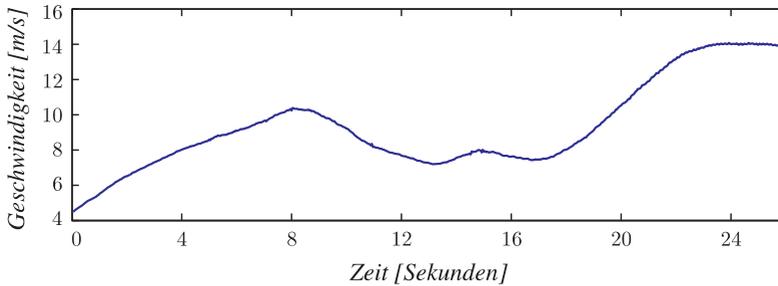
In der Abbildung ist beispielhaft die Aufspaltung der linken Fahrspurberandung dargestellt. Es existieren zwei Hypothesen, die beide den räumlichen Ursprung ξ_0^- am ersten Element der unterbrochenen Markierung vermuten. Im weiteren Verlauf folgt eine Hypothese den nahezu kollinearen Berandungselementen, die andere der Verengung der Fahrspur. Beide Hypothesen erzielen eine ähnliche globale Güte: Die Verengung verursacht aufgrund ihrer Krümmung höhere Kosten, wird andererseits aber auch durch mehr Bildpositionen unterstützt. Farblich gekennzeichnet sind wiederum die Basispolynome der Splinekurve.

Am rechten Fahrspurrand existiert nur eine hinreichend wahrscheinliche Hypothese über den Berandungsverlauf.

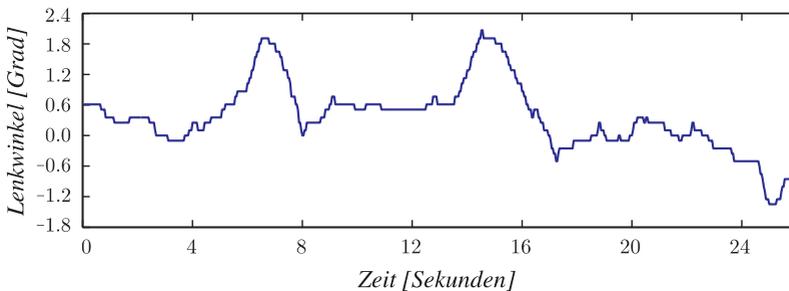
5.2.3 Güte der zeitlichen Prädiktion

Die Geschwindigkeit und der Lenkwinkel des eigenen Fahrzeugs werden von separaten Sensoren erfasst. Abbildung 5.7 zeigt beispielhaft den Verlauf beider Signale, die während der Testfahrt aus Abbildung 5.9 aufgezeichnet wurden. In Kombination mit dem Einspurmodell aus [Sta03] reicht die Qualität dieser Messungen zu einer nahezu exakten Kompensation der gerichteten Anteile der Kamerabewegung zwischen zwei Abtastzeitpunkten aus.⁴

Es wurde bereits mehrfach betont, dass die verbleibende Unsicherheit bei der Modellprädiktion von der Nickwinkelschwingung des Fahrzeugs verursacht wird. Ihre Auswirkungen in der Bildebene ist in Abbildung 5.8 visualisiert.



(a) Signal des Geschwindigkeitssensors



(b) Signal des Lenkwinkelsensors

Abbildung 5.7: *Geschwindigkeit und Lenkwinkel des eigenen Fahrzeugs. Beide Signale werden von externen Sensoren mit hoher Güte erfasst und für die Videoauswertung zur Verfügung gestellt.*

⁴ Einzige Ausnahme sind sehr enge Kurven in Kreuzungsbereichen, bei denen nichtlineare Effekte im Lenkwinkelsensor auftreten.

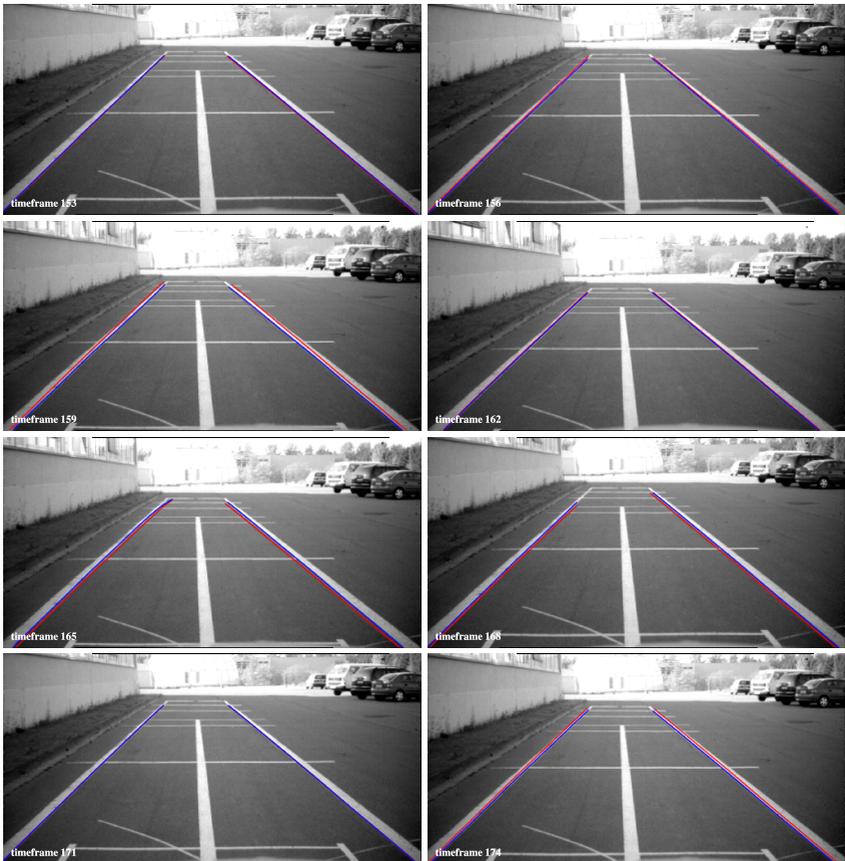


Abbildung 5.8: Auswirkung der Nickwinkelschwingung $\beta(t)$ auf den Prädiktionsfehler in der Bildebene \mathbf{b} . In rot ist die prädizierte Lage ξ_{t+1}^- der Fahrspurberandungen eingezeichnet, blaue Linien sind die mit der neuen Beobachtung aktualisierten Berandungsverläufe ξ_{t+1}^+ .⁵ Dargestellt ist die Nickwinkelschwingung aus Abbildung 5.2 im Intervall $t = 6$ s bis $t = 7$ s. Es zeigt die größte Amplitude der aufgezeichneten Schwingung und ist damit ein Indikator für das erwartete Maximum des Prädiktionsfehlers. Selbst unter dieser extremen Einwirkung auf das Fahrzeug beträgt die Verschiebung zwischen zwei Abtastzeitpunkten nur wenige Bildpunkte. Konkrete Werte hängen von der verwendeten Kamera ab, typisch sind weniger als fünf Pixel.

⁵ Im ersten, vierten und siebten Bild liegt die aktualisierte Kurve direkt auf der Prädiktion. In diesen Fällen wird die rote Kurve überdeckt.

5.2.4 Detektion freiwerdender Fläche

Abbildung 5.9 zeigt auszugweise Ergebnisse der zeitlichen Verfolgung eines vorausfahrenden Fahrzeugs. In grün ist die freiwerdende Fläche hinter dem Fahrzeug eingezeichnet. Sie liefert einen indirekten Hinweis auf die vorausliegende Fahrspurgeometrie.

Der Fahrzeugerkenner beruht auf elementaren Auswertungen der horizontalen und vertikalen Kontrastverläufe im Bild, in den Abbildungen in blau und rot dargestellt. Gemessen an der einfachen Umsetzung sind die Ergebnisse bemerkenswert. Beide Signalverläufe sind ausgesprochen stabil und ermöglichen eine zuverlässige Verfolgung vorausfahrender Fahrzeuge.

5.3 Validierung in innerstädtischen Umgebungen

Die experimentellen Ergebnisse aus dem vorherigen Abschnitt belegen die Leistungsfähigkeit der entwickelten Fahrspurschätzung in einzelnen anspruchsvollen Situationen. Darüber hinaus stellt sich die Frage, in wie weit die inhärente Flexibilität der Algorithmen im alltäglichen Betrieb zu kontrollieren ist.

Das dynamische Systemverhalten ist maßgeblich durch die Wechselwirkung der funktionalen Eigenschaften bestimmt.⁶ Aufgrund der erzwungenen zeitlichen Kontinuität der Schätzung sind die Auswirkungen zwischen direkt aufeinander folgenden Beobachtungen nahezu vernachlässigbar, unter ungünstigen Bedingungen können sie aber zu einer nicht vertretbaren Drift der Schätzung führen.⁷

Die entwickelte Fahrspurschätzung wurde unter den realen Bedingungen der Hildesheimer Innenstadt validiert. Im folgenden Abschnitt werden typische Eigenschaften aufgezeigt und bewertet. Als Referenz werden die Ergebnisse dabei mit einer kommerziellen LDA-Realisierung verglichen.⁸

Ein objektiver Vergleich mit weiteren Fahrspurschätzern erscheint unmöglich, da sich bislang keine gemeinsame Referenz zur Bewertung unterschiedlicher Ansätze durchgesetzt hat. Zwar existieren vereinzelt öffentliche Datenbanken mit Bildfol-

⁶ So ermöglicht bspw. die genauere Spline-Approximation der Berandungsgeometrie kleinere Fangbereiche des Schätzers während der zeitlichen Verfolgung. Gleichzeitig ist sie aber auch empfindlicher gegenüber falsch detektierten Randpositionen in diesen Fangbereichen.

⁷ Insbesondere wirkt sich hier auch die hohe Korrelation zwischen aufeinander folgenden Bildern aus, die eine systematische Drift über der Zeit begünstigt.

⁸ Dies ist eine gute, derzeit am Markt verfügbare Fahrspurschätzung für Autobahnen und gut ausgebaute Landstraßen.

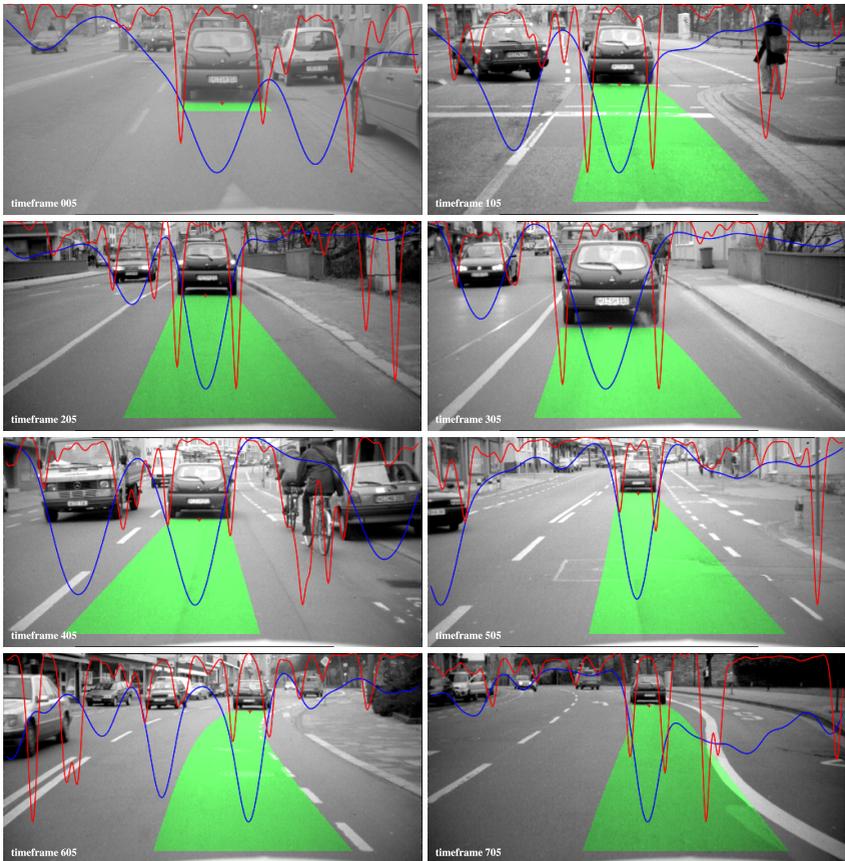
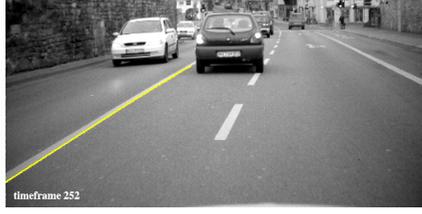
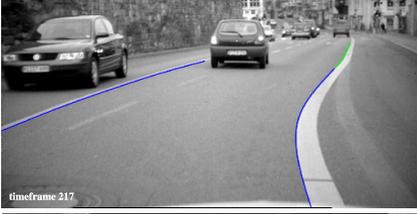
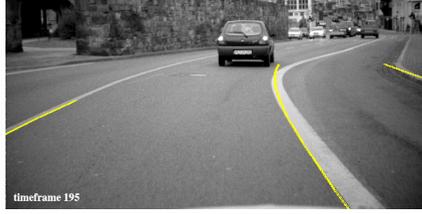
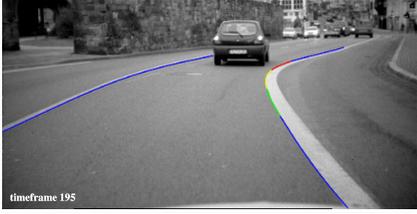
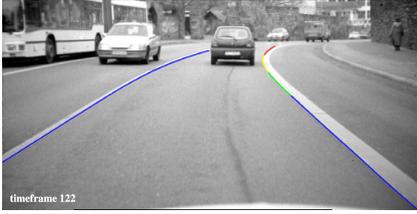
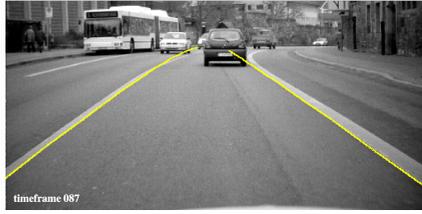
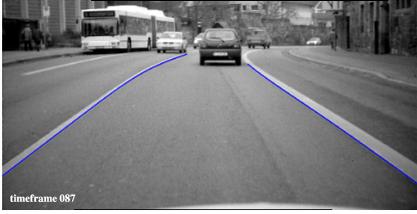
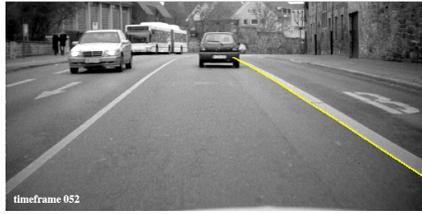
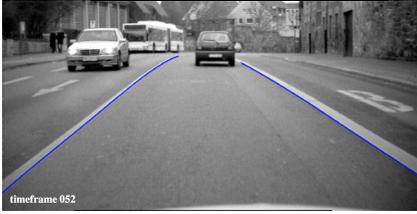


Abbildung 5.9: Trajektorie vorausfahrender Fahrzeuge. Aufbauend auf den Kanthenbildern aus Abschnitt 4.1.1 wurde ein einfacher Fahrzeug-Detektor in die Fahrspurschätzung integriert. Der blaue und rote Kurvenverlauf repräsentieren die horizontale bzw. vertikale Kontraststärke entlang der Bildspalten, das rote Kreuz symbolisiert die vermutete Position des Fahrzeugs. In grün ist die Fläche eingezeichnet, die hinter dem Fahrzeug frei wird. Sie liefert einen indirekten Hinweis auf die vorausliegende Fahrspurgeometrie. Gemessen an der einfachen Umsetzung ist die Stabilität der erzielten Ergebnisse bemerkenswert.

gen von Verkehrsszenarien [Cmu03], sie werden aber nicht als Bezugsgröße aufgegriffen.



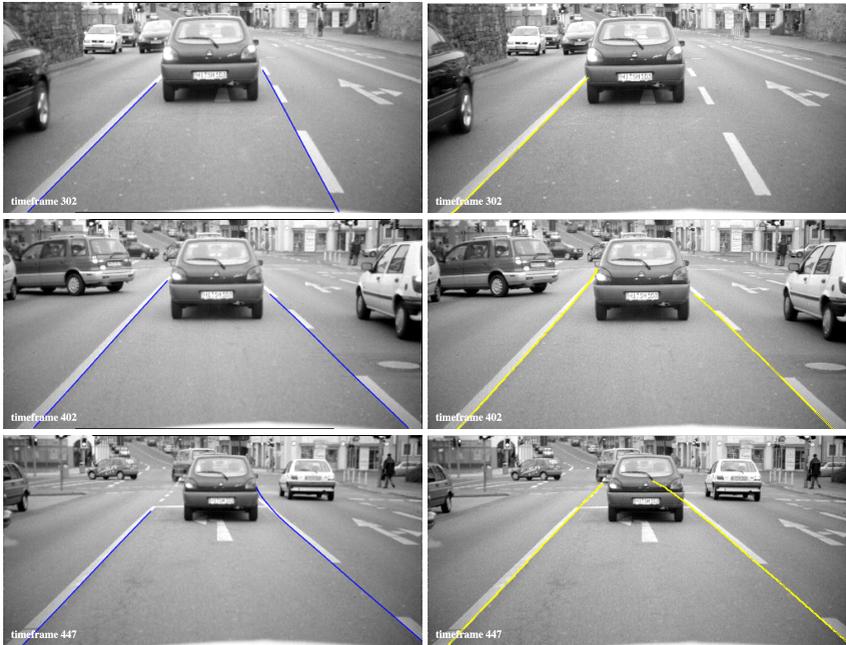
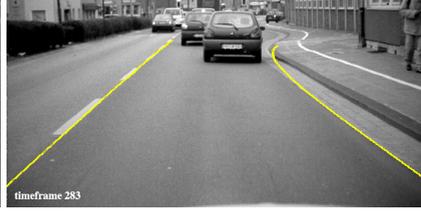
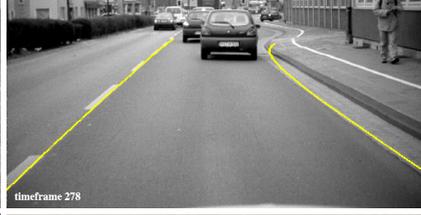
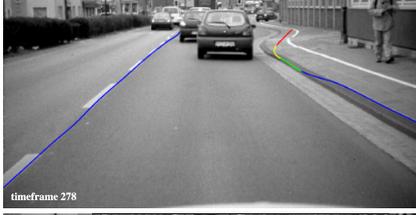
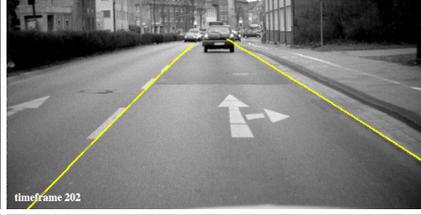
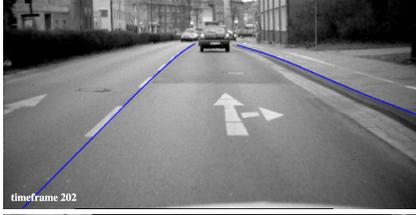
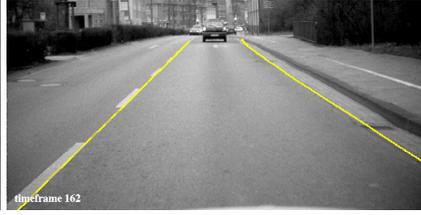
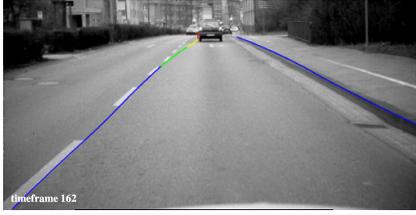
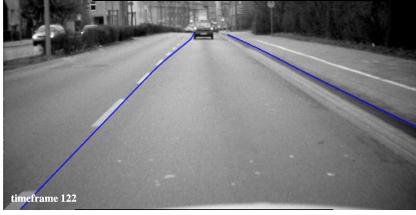
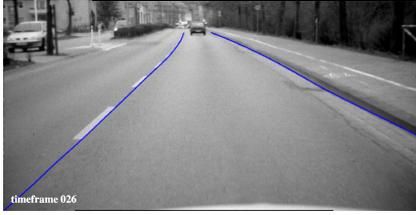


Abbildung 5.10: Zeitliche Verfolgung einer innerstädtischen Kurve. Dargestellt ist ein Vergleich zwischen den in dieser Arbeit entstandenen Algorithmen (linke Spalte) und einer kommerziellen LDA-Software für Autobahnen (rechte Spalte).

Anfangs verhalten sich die Systeme fast identisch, die nahezu gerade Fahrspur ist für beide unproblematisch. Das unterschiedliche Kurvenverhalten deutet sich ab Bild 122 an: Während die hier entwickelten Algorithmen die Kurve approximieren,⁹ kann das kubische Polynom nicht folgen. Dieser Trend verstärkt sich bei der Einfahrt in die Kurve (Bilder 195 und 217) und führt zum Abreißen der LDA-Verfolgung (Bild 242).

Nach einer Neuinitialisierung (Bild 402) verhalten sich beide Systeme wieder ähnlich. Allerdings zeigt sich in Bild 447 der negative Einfluss der wenig selektiven Abbildungsmerkmale, die dieser Arbeit zugrunde liegen: Die rechte Kante des Fahrzeugs wird als Berandung interpretiert und führt zu einer nicht vorhandenen Krümmung im geschätzten Fahrspurverlauf.

⁹ Farblich gekennzeichnet sind die zusätzlichen Segmente, die zur optimalen Beschreibung der Kurve notwendig sind, vgl. Abschnitt 3.2.1.3.



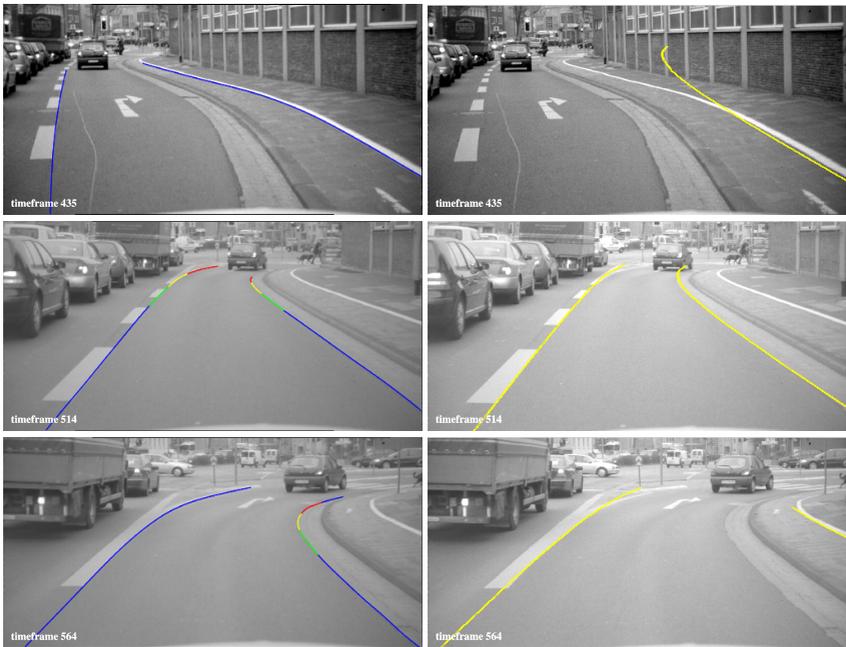


Abbildung 5.11: Zeitliche Verfolgung von Bordsteinkanten und unterbrochenen Markierungen. Die Darstellung folgt dem gleichen Prinzip wie Abbildung 5.10.

Bereits während der Initialisierungsphase verhalten sich beide Systeme am rechten Fahrbahnrand unterschiedlich. Die in dieser Arbeit entwickelten Algorithmen detektieren die kontrastreiche untere Kante des Bordsteins als Fahrspurberandung. Dagegen ist die LDA-Software auf die gezielte Erkennung von Fahrspurmarkierungen ausgelegt. Zeitlich leicht verzögert interpretiert sie die hellen Randsteine als durchgezogene Markierung. Am linken Fahrsprurand erkennen beide Schätzer die unterbrochene Markierung korrekt.

Auch während der zeitlichen Verfolgung werden Unterschiede deutlich. Bis zum Bild 283 sind die dedizierten geometrischen und radiometrischen Annahmen der LDA-Software erfüllt, unter den Bedingungen liefert sie stabile Ergebnisse. Die in dieser Arbeit entwickelten Algorithmen zeigen dagegen eine nicht vertretbare Drift an der rechten Berandung.¹⁰ Auf der Abbiegespur (ab Bild 435) sind sie der LDA-Software wiederum überlegen. Die innere Kante des Bordsteins wird richtig erkannt (Bild 514) und verfolgt (Bild 564).

¹⁰ Die Konfiguration geringerer Vorausschauweiten minimiert das Risiko derartiger Schätzfehler, vgl. Abschnitt 3.2.2.3.

5.4 Realisierte Rechenzeiten

Tabelle 5.2 gibt einen Überblick über die Rechenzeiten der implementierten Algorithmen:

Name	Abhängigkeiten, Referenz	Rechenzeit	Parallel
Numerische Ableitung (<i>Sobel-Operator</i>)	Größe des Bildes, Größe und Separierbarkeit der Filtermaske	3-5 msec	ja
Unterdrückung von Nebenmaxima (<i>Canny-Operator</i>)	Kontrastverteilung im Bild, Wahl des oberen Schwellwertes im Canny-Operator [Can86]	5-8 msec	ja
Konturverfolgung (<i>ursprüngliche Quelle nicht ersichtlich</i>)	Strategie der Nachfolgersuche [Far95], Wahl des unteren Schwellwertes im Canny-Operator	4-6 msec	nein
Polygonapproximation (<i>Douglas-Peucker Algorithmus</i>)	Geforderte Genauigkeit der Linienapproximation [Dou73]	1-3 msec	ja ¹¹
Initiale Detektion (<i>Viterbi-Algorithmus</i>)	Anzahl und Länge detektierter Pfade [Vit67], [For73]	< 1 msec	nein
Modelleinpassung (<i>Spline-Approximation</i>)	Anzahl beitragender Bildpunkte, Strategien zur Matrixinversion [Eng98] und adaptiven Glättung	< 2 msec	nein
Zeitliche Verfolgung (<i>Distanztransformation</i>)	Größe des interessierenden Bildbereichs (maximal Bildgröße) [Int05]	2-7 msec	ja

Tabelle 5.2: *Rechenzeit der realisierten Algorithmen.*

Die Angaben beziehen sich auf einen Intel Pentium 4 Prozessor mit einer Taktrate von 1.6 GHz.

¹¹ Jede Kontur kann unabhängig von allen anderen Konturen durch Linien approximiert werden. Für eine bestimmte Kontur lässt sich die Berechnung hingegen nicht parallelisieren.

5.5 Erweiterungsmöglichkeiten

Bordsteinkanten als wesentliches Element der innerstädtischen Fahrspurberandung werden von den in dieser Arbeit vorgestellten Algorithmen erkannt und aufgrund der erwarteten Breite der Fahrspur als seitliche Begrenzung klassifiziert. Andererseits zeigen die experimentellen Ergebnisse, dass in mehrdeutigen Situationen die hinreichend sichere Abgrenzung zu allgemeinen Texturübergängen ohne Relevanz für die Fahrspurschätzung nicht möglich ist. Als Thema einer weiterführenden Studie wäre es wünschenswert, gezielt Merkmale der Abbildung von Bordsteinkanten in monokularen Bildfolgen zu untersuchen.

Ein Ansatzpunkt zur Optimierung der initialen Detektionsleistung wäre die systematische Bestimmung der Varianzen des Markov-Modells, vgl. Tabelle 5.1 auf Seite 97. Insbesondere erscheint es vielversprechend, mehrere Instanzen für unterschiedliche Ausprägungen der Fahrspurberandung mit einem Lernverfahren zu trainieren. Im zweiten Schritt lässt sich diese Überlegung auch auf die zeitliche Verfolgung der Fahrspur anwenden.

Die verwendete Lösung zur Spline-Approximation setzt äquidistante Beobachtungen b_i mit identischen Unsicherheiten σ_n voraus. Räumliche Detektionslücken müssen daher vor der Berechnung der Splinekurve interpoliert werden. Eine Erweiterung zu nicht äquidistanten Beobachtungen würde das Systemverhalten weiter verbessern.

Mit Blick auf die Ergebnisse von [Hum06] und [Dan06b] lässt sich durch die Integration von Stereo-Information eine qualitativ bessere Zuverlässigkeit erzielen, die auch sicherheitskritischen Anwendungen genügt.

5.6 Zusammenfassung von Kapitel 5

In diesem Kapitel wurde die Leistungsfähigkeit der entwickelten Fahrspurschätzung demonstriert. Anhand von Testfahrten in der Hildesheimer Innenstadt wird die hohe Bandbreite von Situationen vorgestellt, in denen die entstandenen Algorithmen überwiegend gute Ergebnisse erzielen. Unter anderem werden kontrastarme Texturübergänge als Berandungselemente erkannt und enge Kurvenradien in Kreuzungsbereichen approximiert.

Das dynamische Systemverhalten wird im Vergleich zu einer für Autobahnen ausgelegten kommerziellen Fahrspurschätzung bewertet. Während bei dieser Umsetzung negative Auswirkungen aufgrund unzutreffender Modellannahmen zu beobachten sind, sind derartige Effekte bei dem hier entstandenen Schätzer auszuschließen.

ßen. Bei subjektiver Betrachtung durch den menschlichen Beobachter zeigt sich die hohe Genauigkeit der Schätzung.

Die Zuverlässigkeit der entwickelten Fahrspurschätzung hängt stark von den zugrunde liegenden Verkehrsszenarien ab. Eine empirische Analyse verschiedener Ansätze erscheint unmöglich, da sich bislang keine gemeinsame Referenz durchgesetzt hat. Als Trend lässt sich erkennen, dass die hier entstandenen Algorithmen in komplexen Situationen einer kommerziellen LDA-Software überlegen sind. Insgesamt ist die isolierte Fahrspurschätzung auf Basis einer monokularen Kamera in Innenstädten jedoch kritisch zu beurteilen. Die Ergebnisse belegen am Beispiel einer einfachen Fahrzeugerkennung, wie stark elementares Kontextwissen über vorausfahrende Fahrzeuge die Schätzung stabilisieren kann. Diese Beobachtung deckt sich mit der Einschätzung von Hummel [[Hum07](#)].

Kapitel 6

Zusammenfassung

Umfelderfassende Fahrerassistenzsysteme beurteilen die Situation des eigenen Fahrzeugs anhand seiner Lage innerhalb der Fahrspur und der relativen Position und Geschwindigkeit von Objekten entlang der vermuteten Trajektorie. Die Kenntnis der vorausliegenden Fahrspurgeometrie nimmt für viele Anwendungen die zentrale Rolle ein. Assistenzfunktionen zur Spurverlassenswarnung und automomen Führung des Fahrzeugs bauen direkt und ausschließlich auf dieser Information auf. Indirekt beeinflusst sie darüber hinaus das geschätzte Gefahrenpotential erkannter Objekte.

In dieser Arbeit wurde ein modellbasierter Schätzer für innerstädtische Fahrspurverläufe in monokularen Bildfolgen entwickelt und im Versuchsfahrzeug realisiert. Ausgangspunkt der Modellbildung ist die Annahme, dass der Beobachtung von Fahrspurberandungen ein Zufallsprozess zugrunde liegt, der räumlichen und zeitlichen Kontinuitätsbedingungen genügt. Die Luminanz der Bildpunkte, ihr lokaler Kontrast und die Richtung der Luminanzänderung werden als voneinander statistisch unabhängige Attribute der Beobachtung aufgefasst. Auf Basis dieser Information werden gestaltsbasierte Metriken definiert, nach denen ähnliche Bildpunkte zu semantischen Einheiten gruppiert werden. Die Analyse der menschlichen Wahrnehmung deutet darauf hin, dass intelligente Lebewesen visuelle Information ähnlich zusammenfassen, um ein Verständnis ihrer Umwelt aufzubauen.

Die Berechnung der Abbildungsmerkmale ist hierarchisch organisiert. Aus Sicht der hier diskutierten Anwendung enthält das hochaufgelöste Signal des optischen Sensors ein hohes Maß an Redundanz. Für die Online-Realisierung der Fahrspurschätzung im Versuchsfahrzeug ist es essentiell, offensichtlich irrelevante Information durch einfache Operationen zu unterdrücken. Als primäres Abbildungsmerkmal wird die exakte Position der Fahrspurberandung daher im lokalen Maximum

des Kontrasts definiert. Aktuell vorgeschlagene Algorithmen auf Basis von Aktiven Konturen kommen ohne diese Vereinfachung aus, übersteigen in ihrer Komplexität die Rechenleistung aktueller Prozessoren aber um ein Vielfaches. Der in [Wan04] beschriebene Ansatz benötigt für die Aktualisierung einer Schätzung beispielsweise fast eine halbe Sekunde.

Die durch den Sensor vorgegebene Blockstruktur von Bildpunkten ist eine für die initiale Detektion der Fahrspur ungeeignete Informationsrepräsentation. Ihrer Natur nach lassen sich Fahrspurberandungen in lokalen Umgebungen wesentlich eleganter und kompakter durch parametrische Liniensegmente beschreiben. Insbesondere sind Linien eindimensionale Strukturen, denen eine Richtung zugewiesen werden kann. Dies ist eine notwendige Voraussetzung, um das mathematisch einfache Konstrukt der Markov-Ketten zur Berechnung von Verbundwahrscheinlichkeiten während der Initialisierung einer Fahrspurschätzung anzuwenden.

Ohne Näherungswerte für die ungefähre Lage der Fahrspur ist es nicht möglich, eine sinnvolle Erwartungshaltung über die globalen Eigenschaften der Fahrspur im Bild zu motivieren. Bei der Initialisierung der Schätzung werden daher in erster Näherung nur Annahmen über die Position und Ausrichtung der Kamera zu den Fahrspurberandungen formuliert. Sie wird in der Mitte einer Fahrspur bekannter Breite angenommen. Weiterhin lässt sich fordern, dass das Fahrzeug nahezu parallel zu den seitlichen Fahrspurberandungen ausgerichtet ist. Auch ist davon auszugehen, dass unter ansonsten gleichen Bedingungen helle Markierungen auf dunklem Fahrbahnbelag zu bevorzugen sind. Dagegen ist es häufig unzulässig, den longitudinalen Abstand zwischen Kameraposition und Berandungen eng einzugrenzen. Unter anderem beginnen unterbrochene Markierungen regelmäßig erst mehrere Meter vor dem eigenen Fahrzeug.

Liniensegmente, die diesen Anforderungen hinreichend gut genügen, werden als räumlicher Ursprung der Fahrspurberandung betrachtet. Die Attribute der Linien definieren den initialen Zustand der Berandung. Nach dem in [Gem96] vorgestellten Prinzip des Active Testings werden weitere Berandungselemente gesucht, um die Fahrspur rekursiv in Richtung größerer Entfernung zu erweitern. Das gestaltbasierte Ähnlichkeitsmaß bestimmt die lokalen Kosten, die bei der Verbindung zwischen zwei Berandungselementen entstehen. Als globale Güte der Schätzung wird ein Verhältnis aus der Länge und den gesamten Kosten entlang eines Pfades definiert.

Die dynamische Lage der Kamera mit Bezug zur Fahrbahnoberfläche lässt sich aus monokularen Bildfolgen innerstädtischer Verkehrsszenarien nur mit großer Unsicherheit schätzen. Besonders kritisch sind Situationen, in denen andere Verkehrsteilnehmer oder statische Objekte der Infrastruktur weite Teile der Fahrbahnoberfläche verdecken. Um Fehler bei der 3D-Rekonstruktion nicht über der Zeit

zu akkumulieren, wird die Lage der Fahrspur mit Bezug zum zweidimensionalen Raster des optischen Sensors modelliert. Der Zusammenhang zwischen welt- und bildbezogener Darstellung ist über die kalibrierte Fahrbahnebene gegeben. Fahrspurmodell und Beobachtung haben damit die Bildkoordinaten als gemeinsame Bezugsgröße.

Als neues Modell zur geometrischen Beschreibung der Fahrspurberandung wird die Spline-Approximation aus [Rei67] eingeführt. Im Gegensatz zu bekannten Verfahren erlaubt dieser Ansatz eine explizite Kontrolle der Glattheit der Schätzung, ohne die globale Form möglicher Fahrspurgeometrien einzuschränken. Die Regularisierung der Approximation lässt sich von einer Regressionsgeraden nach der Methode der kleinsten Quadrate bis zu einer kubischen Spline-Interpolation beliebig einstellen.

Die Flexibilität bei der Approximation der Berandungsgeometrie wird durch eine hohe Ordnung der zugrunde liegenden Splinekurve ermöglicht. Als interne Repräsentation innerhalb der Fahrspurschätzung ist diese Darstellung vertretbar, zur Anbindung an Assistenzfunktionen ist eine kompaktere Beschreibung notwendig. Interessanter Weise beinhalten die Bestimmungsgleichungen der Spline-Approximation eine ausgesprochen stabile Berechnung des Krümmung entlang der Kurve, die eine geschlossene Lösung zur optimalen Segmentierung des Berandungsverlaufs erlaubt. Meist sind weniger als fünf kubische Segmente zur nahezu exakten Beschreibung der Kurve im Bild ausreichend.

Die Bindung zeitlich aufeinander folgender Schätzungen ist hoch. Die Fahrspur ruht mit Bezug zur Welt, die Unsicherheit bei der Aktualisierung der Schätzung entsteht alleine durch die geänderte Position und Orientierung der Kamera. Wesentlich beeinflusst wird diese Änderung durch die Geschwindigkeit und den Lenkwinkel des Fahrzeugs. Beide Größen werden von separaten Sensoren mit hoher Güte erfasst. Überlagert ist die gerichtete Bewegung der Kamera von hochfrequenten Schwingungen des Nickwinkels $\beta(t)$ um seine Einbaulage, die Resonanzfrequenz der Schwingung wurde experimentell zu $f_0 \approx 1,3 \text{ Hz}$ bestimmt. Unter extremer äußerer Einwirkung erreicht die Amplitude der Schwingung $\beta_{max} \approx 1,5^\circ$. Bei den in dieser Arbeit verwendeten Kameras resultiert daraus eine Unsicherheit in der Prädiktion zukünftiger Beobachtungen von maximal fünf Bildpunkten.

Im Gegensatz zur initialen Detektion ist die globale Lage der Fahrspur im Bild bei der zeitlichen Verfolgung somit näherungsweise bekannt. Die prädierten Modelleigenschaften bilden die *a-priori* Information über den Zufallsprozess, die Schätzung wird senkrecht zum vorhergesagten Berandungsverlauf aktualisiert. Erwartete Abbildungseigenschaften und aktuelle Beobachtung werden für jeden Bildpunkt unabhängig von seiner Bildnachbarschaft bewertet, die Schätzung wird damit ro-

bust gegen lokale Störungen. Besonders wichtig ist diese Eigenschaft bei der Verfolgung von Bordsteinkanten, die häufig nur geringen Kontrast aufweisen.

Die entwickelte Fahrspurschätzung ist als Basiskomponente für verschiedene Assistenzfunktionen von Interesse. Die experimentellen Ergebnisse belegen die Leistungsfähigkeit der Algorithmen in visuell und geometrisch anspruchsvollen Situationen. Unter anderem ist es möglich, engen Kurvenradien und S-Kurven zu folgen und allgemeine Texturübergänge als Berandungselemente zu erkennen.

Ob die Zuverlässigkeit der Schätzung ausreicht, ist auf Basis der durchgeführten Untersuchungen nicht abschließend zu beurteilen. Diese Frage kann nur aus weitergehenden Experimenten im Kontext einer spezifischen Anwendung beantwortet werden. Besonders vielversprechend erscheint die Kombination mit einem innerstädtischen Stop&Go-Assistenten, um vorausfahrenden Fahrzeugen mit niedriger Geschwindigkeit zu folgen.

Das Problem besteht darin, mittels der Serie von m unabhängigen Beobachtungen (b_1, b_2, \dots, b_m) den gesuchten Parametervektor \mathbf{x} bestmöglich zu schätzen. Als notwendige Voraussetzung für die Existenz dieser Schätzung muss $\text{rg}(\mathbf{A}) \geq n$ gelten.

Definition A.1 (Pseudo-Inverse) *Ist die Matrix \mathbf{A} des linearen Gleichungssystems A.1.2 quadratisch und invertierbar, so lautet die Lösung $\mathbf{x} = \mathbf{A}^{-1} \cdot \mathbf{b}$. Für nicht quadratische und nicht invertierbare Matrizen kann man die Lösung in ähnlicher Form $\mathbf{x} = \mathbf{A}^+ \cdot \mathbf{b}$ formulieren. Die Matrix \mathbf{A}^+ heißt Pseudo-Inverse von \mathbf{A} und muss folgende Eigenschaften erfüllen:*

$$(i) \quad \mathbf{A}^+ \cdot \mathbf{A} \cdot \mathbf{A}^+ = \mathbf{A}^+$$

$$(ii) \quad \mathbf{A} \cdot \mathbf{A}^+ \cdot \mathbf{A} = \mathbf{A}$$

Für den Spezialfall, dass $\mathbf{A}^T \cdot \mathbf{A}$ invertierbar ist, lässt sich die Pseudo-Inverse \mathbf{A}^+ aus

$$\mathbf{A}^+ = \left(\mathbf{A}^T \cdot \mathbf{A} \right)^{-1} \cdot \mathbf{A}^T$$

bestimmen (vgl. auch [Mey90], Seite 299).

Die δ_i werden als voneinander unabhängig angenommen. Weiterhin wird vorausgesetzt, dass die einzelnen Beobachtungen mit identischer Unsicherheit behaftet sind und die Wahrscheinlichkeitsdichte der Beobachtungsfehler δ_i normalverteilt ist ($\delta_i \in N(0, \sigma) \forall i$).

Damit gilt für die gemeinsame Dichte des Beobachtungsfehlers δ

$$f(\delta_1, \dots, \delta_m) = \prod_{i=1}^m \left(\frac{1}{\sqrt{2\pi} \cdot \sigma} \cdot \exp \left(-\frac{1}{2 \cdot \sigma^2} \cdot \delta_i^2 \right) \right) \quad (\text{A.1.3})$$

$$\Leftrightarrow f(\delta_1, \dots, \delta_m) = \left(\frac{1}{\sqrt{2\pi} \cdot \sigma} \right)^m \cdot \exp \left(-\frac{1}{2 \cdot \sigma^2} \cdot \sum_{i=1}^m \delta_i^2 \right)$$

Die korrespondierende Likelihood-Funktion liefert die Gleichungen A.1.1 eingesetzt in A.1.3.

$$L = L(\mathbf{x}) \propto \exp \left(-\frac{1}{2 \cdot \sigma^2} \cdot \sum_{i=1}^m (b_i - a_{i1} \cdot x_1 + \dots + a_{in} \cdot x_n)^2 \right) \quad (\text{A.1.4})$$

Existiert eine bestmögliche Schätzung für die Parameter (x_1, x_2, \dots, x_n) , so ist sie durch das Maximum der Likelihoodfunktion A.1.4 bestimmt (vgl. [Bro91]). Im Allgemeinen werden die unbekannt Parameter \hat{x} dabei durch die Nullstellen der partiellen Ableitungen der Likelihoodfunktion nach den Parametern berechnet.

$$\left. \frac{\partial L(\mathbf{x})}{\partial \mathbf{x}} \right|_{\mathbf{x}=\hat{\mathbf{x}}} \stackrel{!}{=} \mathbf{0} \quad (\text{A.1.5})$$

Aufgrund der streng monotonen Steigung der Exponentialfunktion in A.1.4 besitzt die Likelihoodfunktion L ihren maximalen Funktionswert genau im Maximum des Arguments. Für normalverteilte Beobachtungsfehler gemäß A.1.3 bietet sich zur praktischen Bestimmung des Vektors \hat{x} ein alternatives Lösungsverfahren an: Das Argument selbst ist durch die euklidische Norm des Fehlervektors δ gegeben, es kann durch die L_2 -Eigenschaft der Norm in Verbindung mit dem negativen Vorzeichen keine positiven Werte annehmen. Eine Realisierung von \mathbf{x} ist somit umso wahrscheinlicher, je kleiner die euklidische Länge des Fehlervektors δ ist.

Aus dieser Argumentation lässt sich die bestmögliche Schätzung für normalverteilte Beobachtungsfehler durch Minimierung der euklidischen Norm des Fehlervektors δ nach der Methode der kleinsten Quadrate bestimmen. Das Kriterium für die bestmögliche Schätzung lautet hier

$$\begin{aligned} \|\delta\|^2 &:= \delta^T \cdot \delta \stackrel{\text{A.1.2}}{=} (\mathbf{b} - \mathbf{A} \cdot \mathbf{x})^T \cdot (\mathbf{b} - \mathbf{A} \cdot \mathbf{x}) \Big|_{\mathbf{x}=\hat{\mathbf{x}}} \rightarrow \min & (\text{A.1.6}) \\ &= \left(\mathbf{x}^T \cdot \mathbf{A}^T \cdot \mathbf{A} \cdot \mathbf{x} - 2 \cdot \mathbf{b}^T \cdot \mathbf{A} \cdot \mathbf{x} + \mathbf{b}^T \cdot \mathbf{b} \right) \Big|_{\mathbf{x}=\hat{\mathbf{x}}} \rightarrow \min \end{aligned}$$

Folglich lautet die Lösung

$$\begin{aligned} \left. \frac{\partial(\delta^T \cdot \delta)}{\partial \mathbf{x}} \right|_{\mathbf{x}=\hat{\mathbf{x}}} &= \left(2 \cdot \mathbf{x}^T \cdot \mathbf{A}^T \cdot \mathbf{A} - 2 \cdot \mathbf{b}^T \cdot \mathbf{A} \right) \Big|_{\mathbf{x}=\hat{\mathbf{x}}} \stackrel{!}{=} \mathbf{0} & (\text{A.1.7}) \\ \Rightarrow \hat{\mathbf{x}} &= \left(\mathbf{A}^T \cdot \mathbf{A} \right)^{-1} \cdot \mathbf{A}^T \cdot \mathbf{b} \end{aligned}$$

Der Vergleich mit Definition A.1 zeigt, dass die linksseitige Multiplikation der Pseudo-Inversen \mathbf{A}^+ der Designmatrix \mathbf{A} aus Gleichung A.1.2 mit den Beobachtungen \mathbf{b} die bestmögliche Schätzung des Parametervektors \hat{x} nach dem Prinzip der Maximum Likelihood liefert.

A.2 Approximation mit natürlichen kubischen Splines

In den zwei folgenden Abschnitten werden die numerischen Bestimmungsgleichungen für approximierende Splinefunktionen hergeleitet. Die Rechnung ist aus [Nie02] bekannt.

A.2.1 Spline-Interpolation

Betrachtet werde eine Punktmenge $\mathbf{x} = (x_i, y_i)^T$, $i = 0, 1, 2, \dots, n$. Es wird vorausgesetzt, dass die Werte x_i äquidistant verteilt sind, d. h. $x_i = x_0 + i \cdot h$.

In jedem Intervall i , definiert durch $x_i \leq x \leq x_{i+1}$ wird der Werteverlauf zwischen den beobachteten Punkten interpoliert durch ein Polynom dritten Grades:

$$f_i(x) = a_i + b_i \cdot (x - x_i) + c_i \cdot (x - x_i)^2 + d_i \cdot (x - x_i)^3 \quad (\text{A.2.1})$$

Die Steigung und Krümmung der Splinefunktion ergeben sich als erste bzw. zweite Ableitung von A.2.1 bzgl. des variablen Parameters x .

$$f'_i(x) = b_i + 2 \cdot c_i \cdot (x - x_i) + 3 \cdot d_i \cdot (x - x_i)^2 \quad (\text{A.2.2})$$

$$f''_i(x) = 2 \cdot c_i + 6 \cdot d_i \cdot (x - x_i)$$

Von der gesuchten Splinefunktion wird gefordert, dass sie die beobachteten Daten interpoliert. Insbesondere bedeutet dies, dass sie die Daten in den Stützstellen exakt beschreibt. Damit ergeben sich an den Stützstellen $x = x_i$ folgende Bedingungen für die Koeffizienten des kubischen Polynoms im Intervall i :

$$f_i(x_i) = y_i = a_i \quad f'_i(x_i) = b_i \quad f''_i(x_i) = 2 \cdot c_i \quad (\text{A.2.3})$$

Analog hierzu lassen sich die Koeffizienten des i -ten Polynoms der Splinefunktion in Beziehung zu den beobachteten Daten an der Stützstelle $x_{i+1} = x_i + h$ setzen.

$$f_i(x_{i+1}) = y_{i+1} = a_i + b_i \cdot h + c_i \cdot h^2 + d_i \cdot h^3 \quad (\text{A.2.4})$$

$$f'_i(x_{i+1}) = b_i + 2 \cdot c_i \cdot h + 3 \cdot d_i \cdot h^2$$

$$f''_i(x_{i+1}) = 2 \cdot c_i + 6 \cdot d_i \cdot h$$

Die Auswertung des $(i+1)$ -ten Polynoms an der Stützstelle $x_{i+1} = xi + h$ führt zu folgenden Bedingungen für die Koeffizienten a_{i+1} , b_{i+1} sowie c_{i+1} :

$$f_{i+1}(x_{i+1}) = a_{i+1} \quad f'_{i+1}(x_{i+1}) = b_{i+1} \quad f''_{i+1}(x_{i+1}) = 2 \cdot c_{i+1} \quad (\text{A.2.5})$$

Die Idee der Interpolation mit Splinefunktionen besteht darin, einen glatten Funktionsverlauf durch die beobachteten Daten zu realisieren. Mathematisch wird dieser Idee dadurch Rechnung getragen, dass der Funktionswert, die Steigung und die Krümmung benachbarter Polynome in den Stützstellen stetig verlaufen.

Angewendet auf die Krümmung der gesuchten Splinefunktion im Punkt x_{i+1} folgt daraus der Zusammenhang:

$$\begin{aligned} f''_i(x_{i+1}) &= 2 \cdot c_i + 6 \cdot d_i \cdot h \stackrel{!}{=} 2 \cdot c_{i+1} = f''_{i+1}(x_{i+1}) & (\text{A.2.6}) \\ \Rightarrow d_i &= \frac{c_{i+1} - c_i}{3 \cdot h} \end{aligned}$$

Die Forderung nach stetigem Verlauf der Funktionswerte im Punkt x_{i+1} ergibt:

$$\begin{aligned} f_i(x_{i+1}) &= a_i + b_i \cdot h + c_i \cdot h^2 + d_i \cdot h^3 \stackrel{!}{=} a_{i+1} = f_{i+1}(x_{i+1}) & (\text{A.2.7}) \\ \Rightarrow b_i &= \frac{a_{i+1} - a_i}{h} - c_i \cdot h - d_i \cdot h^2 \end{aligned}$$

Analog liefert die Forderung nach stetiger Steigung im Punkt x_{i+1} die Identität:

$$\begin{aligned} f'_i(x_{i+1}) &= b_i + 2 \cdot c_i \cdot h + 3 \cdot d_i \cdot h^2 \stackrel{!}{=} b_{i+1} = f'_{i+1}(x_{i+1}) & (\text{A.2.8}) \\ \Rightarrow a_{i+2} - 2 \cdot a_{i+1} + a_i &= \frac{h^2}{3} \cdot (c_{i+2} + 4 \cdot c_{i+1} + c_i) \\ \Leftrightarrow \frac{1}{h} \cdot (a_{i+2} - 2 \cdot a_{i+1} + a_i) &= \frac{h}{3} \cdot (c_{i+2} + 4 \cdot c_{i+1} + c_i) \end{aligned}$$

Als Randbedingungen für die beiden verbleibenden Freiheitsgrade werden die Bedingung eines natürlichen Splines an den beiden äußeren Stützstellen c_0 und c_n gesetzt:

$$c_0 = c_n = 0 \quad (\text{A.2.9})$$

Als Vorbereitung für eine kompakte Darstellung von A.2.8 in Matrix-Notation werden die Matrizen L und Q eingeführt:

$$Q = \frac{h}{3} \cdot \begin{pmatrix} 4 & 1 & 0 & \cdots & \cdots & \cdots \\ 1 & 4 & 1 & \ddots & \ddots & \ddots \\ 0 & \ddots & \ddots & \ddots & \ddots & \ddots \\ \vdots & \ddots & \ddots & \ddots & \ddots & \ddots \\ \vdots & \ddots & \ddots & 1 & 4 & 1 \\ \vdots & \ddots & \ddots & \ddots & 1 & 4 \end{pmatrix} \in \mathbb{R}^{(n-1) \times (n-1)} \quad (\text{A.2.10})$$

$$L = \frac{1}{h} \cdot \begin{pmatrix} 1 & 0 & \cdots & \cdots & \cdots \\ -2 & 1 & \ddots & \ddots & \ddots \\ 1 & -2 & 1 & \ddots & \ddots \\ 0 & \ddots & \ddots & \ddots & \ddots \\ \vdots & \ddots & 1 & -2 & 1 \\ \vdots & \ddots & \ddots & 1 & -2 \\ \vdots & \ddots & \ddots & \ddots & 1 \end{pmatrix} \in \mathbb{R}^{(n+1) \times (n-1)} \quad (\text{A.2.11})$$

Somit lässt sich Gleichung A.2.8 mit den Definitionen A.2.10 und A.2.11 schreiben als:

$$Q \cdot \mathbf{c} = L^T \cdot \mathbf{y}, \quad \mathbf{c} = (c_1, c_2, \dots, c_{n-1})^T \quad (\text{A.2.12})$$

Die Koeffizientenvektoren \mathbf{b} und \mathbf{d} können durch Einsetzen der c_i in Gleichung A.2.7 bzw. A.2.6 berechnet werden. A.2.3 liefert die Identität $\mathbf{a} = \mathbf{y}$.

A.2.2 Spline-Approximation

Es gelten weiterhin die Voraussetzungen des Kapitels A.2.1. Betrachtet werde eine Punktmenge $\mathbf{x} = (x_i, y_i)^T$, $i = 0, 1, 2, \dots, n$. Ferner wird vorausgesetzt, dass die Werte x_i äquidistant verteilt sind, d. h. $x_i = x_0 + i \cdot h$.

Weiterhin sei nun jedoch angenommen, dass die beobachteten Daten x_i mit einer Unsicherheit behaftet sind. Von der gesuchten Splinefunktion S wird gefordert, dass sie die Ungenauigkeiten in den Beobachtungen ausgleicht. Als Optimierungskriterium wird ein expliziter Ausgleich zwischen der Annäherung der Daten und der Glattheit der Kurve konstruiert:

$$S = S(\lambda) = \frac{\|\mathbf{a} - \mathbf{y}\|^2}{\sigma_n^2} + \lambda \cdot \int_{x_0}^{x_n} [f''(x)]^2 \cdot dx \rightarrow \min \quad (\text{A.2.13})$$

Das Verhältnis zwischen der Annäherung der Daten und der Glattheit der Kurve wird durch den Regressionsparameter $\lambda \in \mathbb{R}^+$ bestimmt. Für jedes Intervall x_i bis x_{i+1} berechnet sich die Krümmung numerisch zu (vgl. A.2.2)

$$\begin{aligned} \int_{x_i}^{x_{i+1}} [f_i''(x)]^2 \cdot dx &= \int_{x_i}^{x_{i+1}} [2 \cdot c_i + 6 \cdot d_i \cdot (x - x_i)]^2 \cdot dx & (\text{A.2.14}) \\ &= \int_{x_i}^{x_{i+1}} [4 \cdot c_i^2 + 24 \cdot c_i \cdot d_i \cdot (x - x_i) + 36 \cdot d_i^2 \cdot (x - x_i)^2] \cdot dx \\ &= \left[4 \cdot c_i^2 \cdot x + \frac{24 \cdot c_i \cdot (c_{i+1} - c_i)}{2 \cdot 3 \cdot h} \cdot (x - x_i)^2 + \frac{36 \cdot (c_{i+1} - c_i)^2}{3 \cdot 9 \cdot h^2} \cdot (x - x_i)^3 \right]_{x_i}^{x_{i+1}} \\ &= 4 \cdot c_i^2 \cdot h + \frac{4 \cdot (c_i \cdot c_{i+1} - c_i^2)}{h} \cdot h^2 + \frac{4 \cdot (c_{i+1}^2 - 2 \cdot c_{i+1} \cdot c_i + c_i^2)}{3 \cdot h^2} \cdot h^3 \\ &= \frac{4}{3} \cdot h \cdot (3 \cdot c_i^2 + 3 \cdot c_i \cdot c_{i+1} - 3 \cdot c_i^2 + c_{i+1}^2 - 2 \cdot c_{i+1} \cdot c_i + c_i^2) \end{aligned}$$

Die Bestimmungsgleichung für die numerische Krümmung der Splinefunktion im Intervall x_i bis x_{i+1} ergibt sich damit zu

$$\int_{x_i}^{x_{i+1}} [f_i''(x)]^2 \cdot dx = \frac{4}{3} \cdot h \cdot (c_{i+1}^2 + c_{i+1} \cdot c_i + c_i^2) \quad (\text{A.2.15})$$

Die Randbedingungen des natürlichen Splines gelten weiterhin, vgl. A.2.9. Betrachtet man die Splinefunktion auf ihrem gesamten Definitionsbereich x_0 bis x_n , berechnet sich die numerische Krümmung zu

$$\int_{x_0}^{x_n} [f''(x)]^2 \cdot dx = \frac{4}{3} \cdot h \cdot (c_0^2 + c_0 \cdot c_1 + c_1^2 + c_1^2 + c_1 \cdot c_2 + c_2^2 + \dots + c_{n-2}^2 + c_{n-2} \cdot c_{n-1} + c_{n-1}^2 + c_{n-1}^2 + c_{n-1} \cdot c_n + c_n^2) \quad (\text{A.2.16})$$

$$= 2 \cdot \mathbf{c}^T \cdot \mathbf{Q} \cdot \mathbf{c}$$

Die numerische Berechnung des Residuenvektors $\|\mathbf{a} - \mathbf{y}\|^2$ erfolgt mit

$$\|\mathbf{a} - \mathbf{y}\|^2 = \mathbf{a}^T \cdot \mathbf{a} + 2 \cdot \mathbf{a}^T \cdot \mathbf{y} + \mathbf{y}^T \cdot \mathbf{y} \quad (\text{A.2.17})$$

A.2.17 und das Ergebnis der Berechnung A.2.16 werden eingesetzt in A.2.13. Das numerische Optimierungsproblem hat damit folgende Gestalt:

$$\frac{1}{\sigma_n^2} \cdot (\mathbf{a}^T \cdot \mathbf{a} + 2 \cdot \mathbf{a}^T \cdot \mathbf{y} + \mathbf{y}^T \cdot \mathbf{y}) + \tilde{\lambda} \cdot 2 \cdot \mathbf{c}^T \cdot \mathbf{Q} \cdot \mathbf{c} \rightarrow \min \quad (\text{A.2.18})$$

Die Konstante $\tilde{\lambda}$ wird hier als temporäre Substitution für die Konstante λ aus Gleichung A.2.13 vereinbart. Sie ist definiert als $\tilde{\lambda} = 1/\lambda$. Im weiteren Verlauf der Rechnung wird sich zeigen, dass diese Definition vorteilhaft für die kompakte Darstellung des Ergebnisses ist (vgl. Gleichung A.2.21, Zeile 3).

Als Nebenbedingung aus der Spline-Interpolation gilt weiterhin (vgl. A.2.12 und A.2.3)

$$\mathbf{Q} \cdot \mathbf{c} = \mathbf{L}^T \cdot \mathbf{a}, \quad \mathbf{c} = (c_1, c_2, \dots, c_{n-1})^T \quad (\text{A.2.19})$$

A.2.19 eingesetzt in A.2.18 liefert die Darstellung des Optimierungskriteriums in Abhängigkeit vom gesuchten Koeffizientenvektor \mathbf{a} .

$$\mathbf{a}^T \cdot \mathbf{a} + 2 \cdot \mathbf{a}^T \cdot \mathbf{y} + \mathbf{y}^T \cdot \mathbf{y} + 2 \cdot \tilde{\lambda} \cdot \sigma_n^2 \cdot \mathbf{L} \cdot \mathbf{Q}^{-1} \cdot \mathbf{a}^T \cdot \mathbf{L}^T \cdot \mathbf{a} \rightarrow \min \quad (\text{A.2.20})$$

Die Ableitung von A.2.20 bzgl. des gesuchten Koeffizientenvektors \mathbf{a} führt auf das zu lösende Gleichungssystem.

$$\begin{aligned} \mathbf{a} - \mathbf{y} + \tilde{\lambda} \cdot \sigma_n^2 \cdot \mathbf{L} \cdot \mathbf{Q}^{-1} \cdot \mathbf{L}^T \cdot \mathbf{a} &\stackrel{!}{=} 0 && (\text{A.2.21}) \\ \Leftrightarrow \left(\mathbf{I} + \tilde{\lambda} \cdot \sigma_n^2 \cdot \mathbf{L} \cdot \mathbf{Q}^{-1} \cdot \mathbf{L}^T \right) \cdot \mathbf{a} = \mathbf{y} &&& \left| \cdot \lambda \cdot \mathbf{L}^T \right. \\ \left(\lambda \cdot \mathbf{L}^T + \lambda \cdot \tilde{\lambda} \cdot \sigma_n^2 \cdot \mathbf{L}^T \cdot \mathbf{L} \cdot \mathbf{Q}^{-1} \cdot \mathbf{L}^T \right) \cdot \mathbf{a} = \lambda \cdot \mathbf{L}^T \cdot \mathbf{y} &&& \left| \lambda \cdot \tilde{\lambda} = 1 \right. \\ \Leftrightarrow \left(\lambda \cdot \mathbf{I} + \sigma_n^2 \cdot \mathbf{L}^T \cdot \mathbf{L} \cdot \mathbf{Q}^{-1} \right) \cdot \mathbf{L}^T \cdot \mathbf{a} = \lambda \cdot \mathbf{L}^T \cdot \mathbf{y} &&& \left| \mathbf{L}^T \cdot \mathbf{a} = \mathbf{Q} \cdot \mathbf{c} \right. \\ \Leftrightarrow \left(\lambda \cdot \mathbf{Q} + \sigma_n^2 \cdot \mathbf{L}^T \cdot \mathbf{L} \right) \cdot \mathbf{c} = \lambda \cdot \mathbf{L}^T \cdot \mathbf{y} \end{aligned}$$

Mit der abkürzenden Definition $\mathbf{P} := \sigma_n^2 \cdot \mathbf{L}^T \cdot \mathbf{L}$ ergibt sich abschließend folgende Bestimmungsgleichung für den Koeffizientenvektor \mathbf{c} :

$$\mathbf{c} = \left(\mathbf{Q} + \frac{1}{\lambda} \cdot \mathbf{P} \right)^{-1} \cdot \mathbf{L}^T \cdot \mathbf{y} \quad (\text{A.2.22})$$

Das Ergebnis der Berechnung A.2.21 bestimmt in Verbindung mit der Nebenbedingung A.2.19 darüber hinaus die Funktionswerte \mathbf{a} an den Stützstellen \mathbf{x} in Abhängigkeit vom Koeffizientenvektor \mathbf{c} .

$$\begin{aligned} \lambda \cdot \mathbf{Q} \cdot \mathbf{c} + \sigma_n^2 \cdot \mathbf{L}^T \cdot \mathbf{L} \cdot \mathbf{c} = \lambda \cdot \mathbf{L}^T \cdot \mathbf{y} &&& \left| \mathbf{Q} \cdot \mathbf{c} = \mathbf{L}^T \cdot \mathbf{a} \quad (\text{A.2.23}) \right. \\ \Leftrightarrow \lambda \cdot \mathbf{L}^T \cdot \mathbf{a} + \sigma_n^2 \cdot \mathbf{L}^T \cdot \mathbf{L} \cdot \mathbf{c} = \lambda \cdot \mathbf{L}^T \cdot \mathbf{y} &&& \left| \cdot \left(\mathbf{L}^T \right)^{-1} \right. \\ \Leftrightarrow \lambda \cdot \mathbf{a} + \sigma_n^2 \cdot \mathbf{L} \cdot \mathbf{c} = \lambda \cdot \mathbf{y} \\ \Leftrightarrow \mathbf{a} = \mathbf{y} - \frac{\sigma_n^2}{\lambda} \cdot \mathbf{L} \cdot \mathbf{c} \end{aligned}$$

Den Zusammenhang zwischen den Funktionswerten \mathbf{a} der Splinefunktion S und den beobachteten Daten \mathbf{y} an den Stützstellen \mathbf{x} liefert die Identität A.2.22 eingesetzt in A.2.23.

$$\mathbf{a} = \mathbf{y} - \frac{\sigma_n^2}{\lambda} \cdot \mathbf{L} \cdot \left(\mathbf{Q} + \frac{1}{\lambda} \cdot \mathbf{P} \right)^{-1} \cdot \mathbf{L}^T \cdot \mathbf{y} \quad (\text{A.2.24})$$

Maßgeblich für die praktische Anwendbarkeit des Verfahrens ist die Frage, wie der Ausdruck $(\mathbf{Q} + 1/\lambda \cdot \mathbf{P})^{-1}$ berechnet wird. Insbesondere bei großen Werten von n kommt der effizienten Invertierung dieser Matrix entscheidende Bedeutung zu. Sie wird im folgenden Abschnitt diskutiert.

A.3 Effiziente Invertierung pentadiagonaler Matrizen

Pentadiagonale Matrizen sind Bandmatrizen der Bandbreite fünf. Sie treten regelmäßig bei der Ausgleichung fehlerbehafteter Beobachtungen durch approximierende Splinefunktionen auf¹ (vgl. auch Kapitel 3.2.1.1 und 4.4.2) und sind durch folgende Eigenschaften definiert:

Definition A.2 (Bandmatrix) Eine (n, n) -Matrix $\mathbf{A} = (a_{ik})$, $i, k = 1, 2, \dots, n$, heißt Bandmatrix, wenn ihre Elemente außerhalb eines Bandes längs der Hauptdiagonalen verschwinden. Sei m_l die Anzahl der unteren Nebendiagonalen und m_r die der oberen, dann gilt für die Elemente:

$$a_{ik} = 0 \quad \text{für} \quad \begin{cases} i - k > m_l & \text{mit } 0 \leq m_l \leq n-2 \\ k - i > m_r & \text{mit } 0 \leq m_r \leq n-2 \end{cases}$$

Die Größe $m = m_l + m_r + 1$ heißt Bandbreite der Matrix. Es können höchstens m von Null verschiedene Elemente in einer Zeile auftreten. Spezielle Bandbreiten sind:

Diagonalmatrizen mit	$m_l = m_r = 0$,
Bidiagonale Matrizen mit	$m_l = 1, m_r = 0$ oder $m_l = 0, m_r = 1$,
Tridiagonale Matrizen mit	$m_l = 1, m_r = 1$,
Pentadiagonale Matrizen mit	$m_l = 2, m_r = 2$.

¹ Insbesondere ist auch der zu invertierende Ausdruck $(\mathbf{Q} + 1/\lambda \cdot \mathbf{P})^{-1}$ in Gleichung A.2.24 pentadiagonal

In erster Näherung lässt sich der Rechenaufwand eines numerischen Verfahrens über die Anzahl erforderlicher Multiplikationen und Divisionen abschätzen [Eng98]. In Tabelle A.1 ist die Anzahl von Punktoperationen zusammengefasst, die zur Lösung eines quadratischen linearen Gleichungssystems mit n Unbekannten notwendig sind. Ohne Anpassung an spezielle Eigenschaften der Matrix ist die Komplexitätsklasse der Aufgabe $O(n^3)$, vgl. [Pre92a].

Verfahren	Anzahl der Punktoperationen
Cramersche Regel	$(n^2 - 1) \cdot n! + n$
Gauß-Algorithmus	$n/3 \cdot (n^2 + n - 1)$
Cholesky-Verfahren	$n^3/6 + O(n^2)$
Gauß-Jordan-Verfahren	$n/2 \cdot (n^2 + n + 1)$
Singulärwertzerlegung ²	$O(n^2)$
Verfahren für tridiagonale Matrizen	$5 \cdot n - 4$
Verfahren für pentadiagonale Matrizen	$11 \cdot n - 16$

Tabelle A.1: Anzahl erforderlicher Punktoperationen zur Lösung quadratischer linearer Gleichungssysteme mit n Unbekannten.

Dieses Kapitel stellt ein rekursives Verfahren vor, mit dem pentadiagonale Systeme linearer Gleichungen sehr effizient gelöst werden können. Der Algorithmus liegt der Aufwandsabschätzung zur Invertierung pentadiagonaler Matrizen in Tabelle A.1 zugrunde. Die Idee ist aus [Eng98] bekannt.

A.3.1 Allgemeine pentadiagonale Matrizen

Betrachtet werde das System m linearer Gleichungen mit n Unbekannten x_i aus Gleichung A.1.1 und A.1.2 für den Spezialfall $m = n$. A sei eine pentadiagonale Matrix gemäß Definition A.2. Der Vektor δ sei zu Null definiert. Gesucht ist der Vektor x , dessen Komponenten x_i , $i = 1, 2, \dots, n$ jede der n Gleichungen des Systems A.1.2 zu einer Identität werden lassen.

² Der konkrete Aufwand der Invertierung innerhalb der Komplexität $O(n^2)$ hängt davon ab, nach welchem Verfahren die Eigenwerte der Matrix berechnet werden. Grundsätzlich benötigt die Singulärwertzerlegung wahlfreien Zugriff auf die Matrixelemente. Dies ist ein wesentlicher Nachteil des Verfahrens (vgl. [Pre92c])

Die Lösung des Gleichungssystems basiert auf einer Faktorisierung der Matrix \mathbf{A} in eine tridiagonale Subdiagonalmatrix \mathbf{L} und eine normierte Superdiagonalmatrix \mathbf{R} . Die LR-Zerlegung zur Faktorisierung wird als bekannt vorausgesetzt, vgl. bspw. [Mey90], S. 293 ff.

Für die kompakte Darstellung des Algorithmus ist es vorteilhaft, die Bänder der beteiligten Matrizen als Vektoren aufzufassen. Daher wird folgende Benennung der Elemente von \mathbf{A} , \mathbf{L} und \mathbf{R} eingeführt:

$$\mathbf{A} := \begin{pmatrix} d_1 & e_1 & f_1 & 0 & \cdots & \cdots & \cdots \\ c_2 & d_2 & e_2 & f_2 & \ddots & \ddots & \ddots \\ g_3 & c_3 & d_3 & e_3 & f_3 & \ddots & \ddots \\ 0 & \ddots & \ddots & \ddots & \ddots & \ddots & \ddots \\ \vdots & \ddots & g_{n-2} & c_{n-2} & d_{n-2} & e_{n-2} & f_{n-2} \\ \vdots & \ddots & \ddots & g_{n-1} & c_{n-1} & d_{n-1} & e_{n-1} \\ \vdots & \ddots & \ddots & \ddots & g_n & c_n & d_n \end{pmatrix} \quad (\text{A.3.1})$$

$$\stackrel{!}{=}$$

$$\underbrace{\begin{pmatrix} \alpha_1 & 0 & \cdots & \cdots & \cdots & \cdots & \cdots \\ \beta_2 & \alpha_2 & \ddots & \ddots & \ddots & \ddots & \ddots \\ \varepsilon_3 & \beta_3 & \alpha_3 & \ddots & \ddots & \ddots & \ddots \\ 0 & \ddots & \ddots & \ddots & \ddots & \ddots & \ddots \\ \vdots & \ddots & \varepsilon_{n-2} & \beta_{n-2} & \alpha_{n-2} & \ddots & \ddots \\ \vdots & \ddots & \ddots & \varepsilon_{n-1} & \beta_{n-1} & \alpha_{n-1} & \ddots \\ \vdots & \ddots & \ddots & \ddots & \varepsilon_n & \beta_n & \alpha_n \end{pmatrix}}_{:= \mathbf{L}} \cdot \underbrace{\begin{pmatrix} 1 & \gamma_1 & \delta_1 & 0 & \cdots & \cdots & \cdots \\ 0 & 1 & \gamma_2 & \delta_2 & \ddots & \ddots & \ddots \\ \ddots & \ddots & 1 & \gamma_3 & \delta_3 & \ddots & \ddots \\ \vdots & \ddots & \ddots & \ddots & \ddots & \ddots & \ddots \\ \vdots & \ddots & \ddots & \ddots & 1 & \gamma_{n-2} & \delta_{n-2} \\ \vdots & \ddots & \ddots & \ddots & \ddots & 1 & \gamma_{n-1} \\ \vdots & \ddots & \ddots & \ddots & \ddots & \ddots & 1 \end{pmatrix}}_{:= \mathbf{R}}$$

Mit diesen Notationsvereinbarungen lässt sich die Faktorisierung einer pentadiagonalen Matrix \mathbf{A} durch das rekursive Verfahren der Gleichungen A.3.2 bis A.3.4 erreichen.

Die Initialisierung der Elemente mit den Indizes $i = 1, 2$ berechnet sich nach³

³ Bei der praktischen Berechnung ist zu beachten, dass der Wert β_i vor dem korrespondierenden α_i zu bestimmen ist. Aus Gründen der Übersichtlichkeit sind die α_i hier entgegen der Reihenfolge der praktischen Berechnung vor den β_i aufgeführt

$$\begin{aligned}
\alpha_1 &= d_1 & \beta_1 &= 0 & \gamma_1 &= \frac{e_1}{\alpha_1} & \delta_1 &= \frac{f_1}{\alpha_1} & (A.3.2) \\
\alpha_2 &= d_2 - \beta_2 \cdot \gamma_1 & \beta_2 &= c_2 & \gamma_2 &= \frac{e_2 - \beta_2 \cdot \delta_1}{\alpha_2} & \delta_2 &= \frac{f_2}{\alpha_2} \\
\varepsilon_1 &= \varepsilon_2 = 0
\end{aligned}$$

Innerhalb der Rekursion sind für jedes $i = 3, 4, \dots, n-2$ zu bestimmen:

$$\begin{aligned}
\alpha_i &= d_i - g_i \cdot \delta_{i-2} - \beta_i \cdot \gamma_{i-1} & \beta_i &= c_i - g_i \cdot \gamma_{i-2} & (A.3.3) \\
\gamma_i &= (e_{n-1} - \beta_i \cdot \delta_{i-1}) / \alpha_i & \delta_i &= f_i / \alpha_i \\
\varepsilon_i &= g_i
\end{aligned}$$

Als Endkriterien für die Elemente mit den Indizes $i = n-1, n$ ergeben sich

$$\begin{aligned}
\alpha_{n-1} &= d_{n-1} - g_{n-1} \cdot \delta_{n-3} - \beta_{n-1} \cdot \gamma_{n-2} & (A.3.4) \\
\beta_{n-1} &= c_{n-1} - g_{n-1} \cdot \gamma_{n-3} \\
\gamma_{n-1} &= (e_{n-2} - \beta_{n-1} \cdot \delta_{n-2}) / \alpha_{n-1} \\
\alpha_n &= d_n - g_n \cdot \delta_{n-2} - \beta_n \cdot \gamma_{n-1} \\
\beta_n &= c_n - g_n \cdot \gamma_{n-2} \\
\delta_{n-1} &= \delta_n = \gamma_n = 0 \\
\varepsilon_{n-1} &= g_{n-1}, \varepsilon_n = g_n
\end{aligned}$$

Mit den Voraussetzungen dieses Abschnitts (vgl. [A.3.1](#)) und der Faktorisierung [A.3.1](#) lässt sich das Gleichungssystem [A.1.2](#) wie folgt darstellen:

$$A \cdot x = L \cdot R \cdot x = L \cdot r = b \quad \text{mit} \quad r := R \cdot x \quad (A.3.5)$$

Die Lösung \boldsymbol{x} wird in zwei Schritten bestimmt. Zunächst wird der Ausdruck $\boldsymbol{R} \cdot \boldsymbol{x}$ durch einen temporären Vektor \boldsymbol{r} substituiert. Aus dem Koeffizientenvergleich $\boldsymbol{L} \cdot \boldsymbol{r} = \boldsymbol{b}$ ergeben sich die Elemente r_i durch Vorwärtselimination⁴.

$$r_i = (\alpha_i - \varepsilon_i \cdot r_{i-2} - \beta_i \cdot r_{i-1}) / \alpha_i \quad (\text{A.3.6})$$

Als zweite Forderung liefert Gleichung A.3.5 den Zusammenhang $\boldsymbol{R} \cdot \boldsymbol{x} = \boldsymbol{r}$. Diese Identität liefert abschließend nach einer Rückwärtselimination⁵ gemäß Gleichung A.3.7 den gesuchten Lösungsvektor \boldsymbol{x} .

$$x_i = r_i - \gamma_i \cdot x_{i+1} - \delta_i \cdot x_{i+2} \quad (\text{A.3.7})$$

Der Aufwand für die Lösung des pentadiagonalen Gleichungssystems ist mit der Näherung $n \gg 1$ maßgeblich durch die Gleichungen A.3.3, A.3.6 und A.3.7 bestimmt. Da der Aufwand der drei Arbeitsschritte linear mit der Dimension n der Matrix \boldsymbol{A} skaliert, ist auch der Aufwand des gesamten Verfahrens linear von n abhängig.

A.3.2 Symmetrische pentadiagonale Matrizen

Eine weitere Vereinfachung des im Abschnitt A.3.1 beschriebenen Verfahrens ergibt sich, wenn die Matrix \boldsymbol{A} zusätzlich zu den dort aufgeführten Voraussetzungen symmetrisch ist. Insbesondere halbiert sich näherungsweise der benötigte Speicherbedarf. Der Rechenaufwand bleibt im Vergleich zu Abschnitt A.3.1 unverändert. In diesem Fall ist eine Faktorisierung vom Typ

$$\boldsymbol{A} \cdot \boldsymbol{x} = \boldsymbol{R}^T \cdot \boldsymbol{D} \cdot \boldsymbol{R} \cdot \boldsymbol{x} = \boldsymbol{b} \quad (\text{A.3.8})$$

möglich, bei der \boldsymbol{D} eine Diagonalmatrix ist. Für Details zur konkreten Durchführung dieses Verfahrens sei auf [Eng98], Seite 180 ff. verwiesen.

⁴ vgl. Struktur von \boldsymbol{L} in Gleichung A.3.1: Beginnend von Index $i = 1$ werden die r_i sequentiell („vorwärts“) berechnet; für $i = 1, 2$ ist r_{i-2} und im ersten Fall auch r_{i-1} nicht definiert; unter der Annahme endlicher Werte der r_i ist das Ergebnis der Multiplikation jedoch immer Null, da $\varepsilon_1 = \varepsilon_2 = \beta_1$ gilt (vgl. A.3.2)

⁵ vgl. Struktur von \boldsymbol{R} in Gleichung A.3.1: Beginnend von Index $i = n$ werden die r_i sequentiell („rückwärts“) berechnet; für $i = n-1, n$ ist x_{i+2} und im ersten Fall auch x_{i+1} nicht definiert; unter der Annahme endlicher Werte der r_i ist das Ergebnis der Multiplikation jedoch immer Null, da $\delta_{n-1} = \delta_n = \gamma_n$ gilt (vgl. A.3.4)

Abbildungsverzeichnis

1.1	Fahrspur auf der Landstraße und in der Stadt	2
1.2	Ein imaginärer Würfel	4
2.1	Kamera für videobasierte Fahrerassistenzsysteme	8
2.2	Sichtbereiche umfelderfassender Sensoren	9
2.3	Abbildungsgeometrie der idealen Lochkamera	11
2.4	Koordinaten mit Bezug zur Kamera und zur Fahrbahnoberfläche	13
2.5	Zwei Ansichten eines innerstädtischen Verkehrsszenarios	15
2.6	Regionenbasierte Segmentierung der Fahrbahnoberfläche	19
2.7	Histogramm einer Kontrastverteilung	20
2.8	Punktkorrespondenzen im binokularen Kamerasystem	23
2.9	Optisches Flussfeld eines innerstädtischen Szenarios	25
2.10	Rückprojektion von Bildpositionen auf die Fahrbahnebene	27
2.11	Auflösung der Fahrbahnoberfläche im Bild	29
2.12	Einheitsklothoide im Intervall $[-5,5]$	31
2.13	Approximation der Klothoide in kartesischen Koordinaten	33
2.14	Weltbezogene vs. bildbezogene Fahrspurschätzung	35
2.15	Einflussfunktionen zur robusten Parameterschätzung	41
2.16	Integration von Systemwissen und Beobachtungen	43
3.1	Abstraktionsstufen der Modellbildung	49
3.2	Gestaltgesetze der Ähnlichkeit und der Nähe	52
3.3	Eigenschaften der Smoothing Spline-Approximation	57
3.4	Geschätzte Ordnung der approximierenden Splinekurve	61
3.5	Beobachtete Liniensegmente (Vogelperspektive)	63
3.6	Geometrische Ähnlichkeit der Linienelemente	67

3.7	Verteilungsdichte des räumlichen Ursprungs	70
3.8	Mechanisches Modell der Nickwinkelschwingung	73
4.1	Freeman-Code von Bildnachbarschaften	80
4.2	Lokale Maxima der Kontrastverteilung	81
4.3	Konturbasierte Rauschunterdrückung	83
4.4	Parametrische Beschreibung durch Liniensegmente	85
4.5	Räumliche Verfolgung der Fahrspurberandung	87
4.6	Detektion vorausfahrender Fahrzeuge im Nahbereich	89
4.7	Zeitliche Verschiebung der Beobachtung	92
4.8	Aktualisierung der prädierten Splinekurve	93
5.1	Regularisierung der Spline-Approximation	98
5.2	Parameter der Nickwinkelschwingung	99
5.3	Detektion unterschiedlicher Berandungstypen	101
5.4	Unterschiedliche Vorausschauweiten	102
5.5	Approximation von engen Kurvenradien und S-Kurven	104
5.6	Aufspaltung einer Berandungshypothese	105
5.7	Geschwindigkeit und Lenkwinkel des eigenen Fahrzeugs	106
5.8	Projektion der Nickwinkelschwingung in die Bildebene	107
5.9	Trajektorie vorausfahrender Fahrzeuge	109
5.10	Zeitliche Verfolgung einer innerstädtischen Kurve	111
5.11	Verfolgung von Bordsteinkanten	113

Literaturverzeichnis

- [Abr00] S. Abraham: *Kamera-Kalibrierung und metrische Auswertung monokularer Bildfolgen*. Dissertation, Universität Bonn, Shaker Verlag, Aachen, 2000.
- [Apo03] N. Apostoloff und A. Zelinsky: *Robust Vision-Based Lane Tracking Using Multiple Cues and Particle Filtering*. In: *Procs. IEEE Intelligent Vehicles Symposium*, S. 558–563, Columbus, USA, Oktober 2003.
- [Bam98] P. Bamford und B. Lovell: *Bayesian Analysis of Cell Nucleus Segmentation by a Viterbi Search Based Active Contour*. In: *Procs. Int. Conference on Pattern Recognition*, S. 133–135, Brisbane, Australien, August 1998.
- [Bar01] Y. Bar-Shalom, X. R. Li und T. Kirubarajan: *Estimation with Application to Tracking and Navigation*. John Wiley & Sons Inc., New York, USA, 2001.
- [Beh98] R. Behringer und N. Müller: „Autonomous Road Vehicle Guidance from Autobahnen to Narrow Curves“. *IEEE Trans. on Robotics and Automation* **14** (5), S. 810–815, Oktober 1998.
- [Bel62] R. Bellmann und S. Dreyfus: *Applied Dynamic Programming*. Princeton University Press, Princeton, NJ, 1962.
- [Ber98] M. Bertozzi und A. Broggi: „GOLD: A Parallel Real-Time Stereo Vision System for Generic Obstacle and Lane Detection“. *IEEE Trans. on Image Processing* **7** (1), S. 62–81, Januar 1998.
- [Ber00] T. Bertram, M. Hiller, P. Opgen-Rhein, C. Trowitzsch, M. Thiemann und M. Melzig: *Entwicklung einer dynamischen Leuchtweiteregelung mit einem komplexen dreidimensionalen Fahrzeugmodell*. In: *Procs. Konferenz zur Elektronik im Kraftfahrzeug*, Bd. 20, S. 1099–1124, Baden-Baden, Deutschland, 2000.
- [Ber02] M. Bertozzi, A. Broggi, M. Cellario, A. Fascioli, P. Lombardi und M. Porta: „Artificial Vision in Road Vehicles“. *Procs. of the IEEE* **90** (7), S. 1258–1271, Juli 2002.

- [Bis05] R. Bishop: *Intelligent Vehicle Technology and Trends*. Artech House Inc., 2005.
- [Bla98] A. Blake und M. Isard: *Active Contours - The Application of Techniques from Graphics, Vision, Control Theory and Statistics to Visual Tracking of Shapes in Motion*. Springer-Verlag, London, UK, 1998.
- [Bro91] I. N. Bronstein und K. A. Semendjajew: *Taschenbuch der Mathematik*. Teubner Verlagsgesellschaft, Stuttgart, Deutschland, 1991.
- [Büc03] T. Bücher, C. Curio, J. Edelbrunner, C. Igel, D. Kastrup, I. Leefken, G. Lorenz, A. Steinhage und W. von Seelen: „Image Processing and Behaviour Planning for Intelligent Vehicles“. *IEEE Transactions on Industrial Electronics* **90** (1), S. 62–75, 2003.
- [Bux05] B. Buxbaum und B. Hagebeucker: „Dreidimensionale Umfelderkennung - Photomischdetektoren für Assistenz- und Sicherheitssysteme im Auto“. *Elektronik Automotive* **3** (5), S. 77–81, September 2005.
- [Can83] J. Canny: *Finding Edges and Lines in Images*. Techn. Ber., M.I.T. Artificial Intelligence Lab., Cambridge, UK, 1983.
- [Can86] J. Canny: *A Computational Approach to Edge Detection*. In: *Procs. IEEE Conference on Pattern Analysis and Machine Intelligence*, Bd. 8, S. 679–698, Santa Barbara, Kalifornien, USA, November 1986.
- [Cec04] M. Cech, W. Niem, S. Abraham und C. Stiller: *Dynamic Ego-Pose Estimation for Driver Assistance in Urban Environments*. In: *Procs. IEEE Intelligent Vehicles Symposium*, S. 43–48, Parma, Italien, Juni 2004.
- [Cmu03] CMUMC VISION AND AUTONOMOUS SYSTEMS CENTER, ROBOTICS INSTITUTE, CARNEGIE MELLON UNIVERSITY: *Road Image Sequences*, July 2003.
- [Dan06a] T. Dang, C. Hoffmann und C. Stiller: *Self-Calibration for Active Automotive Stereo-Vision*. In: *Procs. of IEEE Intelligent Vehicles Symposium*, S. 364–369, Tokyo, Japan, Juni 2006.
- [Dan06b] T. Dang, S. Kammel, C. Duchow und C. Stiller: *Path Planning for Autonomous Driving based on Stereoscopic and Monoscopic Vision Cues*. In: *Procs. of IEEE Int. Conference on Multisensor Fusion and Integration for Intelligent Systems*, S. 191–196, New York, USA, September 2006.

- [Dan07] T. Dang: *Kontinuierliche Selbstkalibrierung von Stereokameras*. Dissertation, Institut für Mess- und Regelungstechnik, Universität Karlsruhe (TH), Universitätsverlag Karlsruhe, April 2007.
- [dB94] C. de Boor: *A Practical Guide to Splines*. Springer Verlag, New York, 1994.
- [dB02] C. de Boor: *Handbook of Computer Aided Geometry Design*, Kap. 6. Elsevier B.V., 2002.
- [Def05] DEFENSE ADVANCED RESEARCH PROJECTS AGENCY (DARPA): *Grand Challenge*, 2005.
- [Def07a] DEFENSE ADVANCED RESEARCH PROJECTS AGENCY (DARPA): *Finalisten der Urban Challenge 2007*, November 2007.
- [Def07b] DEFENSE ADVANCED RESEARCH PROJECTS AGENCY (DARPA): *Urban Challenge*, November 2007.
- [dG96] P. de Groen: „An Introduction to Total Least Squares“. *Nieuw Archief voor Wiskunde* **14** (2), S. 237–254, 1996.
- [Dic92] E. D. Dickmanns und B. D. Mysliwetz: „Recursive 3-D Road and Relative Ego-State Recognition“. *IEEE Trans. on Pattern Analysis and Machine Intelligence* **14** (2), S. 199–213, Februar 1992.
- [Dou73] D. Douglas und T. Peucker: „Algorithms for the Reduction of the Number of Points required to represent a Digitized Line or its Caricature“. *The Canadian Cartographer* **10** (2), S. 112–122, 1973.
- [Duc05] C. Duchow: *A marking-based, flexible Approach to Intersection Detection*. In: *IEEE International Workshop on Machine Vision for Intelligent Vehicles*, S. 176–181, San Diego, USA, Juni 2005.
- [Duc06] C. Duchow: *A novel, signal model based Approach to Lane Detection for use in Intersection Assistance*. In: *Procs. of IEEE Intelligent Transportation Systems Conference*, S. 1162–1167, Toronto, Kanada, September 2006.
- [Eng98] G. Engeln-Müllges und F. Uhlig: *Numerical Algorithms with C*, Kap. 4. Springer Verlag, Berlin, Deutschland, 1998.
- [Enk97] W. Enkelmann: *Entwicklung von Systemen zur Interpretation von Straßenverkehrsszenen durch Bildfolgenauswertung*. Habilitationsschrift, Universität Karlsruhe (TH), Akademische Verlagsgesellschaft, Berlin, März 1997.

- [Far95] A. A. Faraq und E. J. Delp: „Edge Linking by Sequential Search“. *Pattern Recognition* **28** (5), S. 611–633, Mai 1995.
- [For73] G. D. Forney: „The Viterbi Algorithm“. *Procs. of the IEEE* **61** (3), S. 268–278, März 1973.
- [For93] FORSCHUNGSGESELLSCHAFT FÜR STRASSEN- UND VERKEHRSWESEN: *Richtlinien für die Markierung von Straßen, Teil I: Abmessungen und geometrische Anordnung von Markierungszeichen*, 1993.
- [Fra97] U. Franke, S. Görzig, F. Lindner, D. Mehren und F. Paetzold: *Steps towards an Intelligent Vision System for Driver Assistance in Urban Traffic*. In: *Procs. IEEE Intelligent Transportation Systems Conference*, S. 601–606, Boston (MA), USA, November 1997.
- [Fra98] U. Franke, D. Gavrila, S. Görzig, F. Lindner, F. Paetzold und C. Wöhler: „Autonomous Driving goes Downtown“. *IEEE Intelligent Systems and Their Applications* **13** (6), S. 40–48, Dezember 1998.
- [Fra99] U. Franke, D. Gavrila, S. Görzig, F. Lindner, F. Paetzold und C. Wöhler: „Autonomous Driving approaches Downtown“. *IEEE Intelligent Systems* **13** (6), S. 1–14, 1999.
- [Fra00] U. Franke und A. Joos: *Real-Time Stereo Vision for Urban Traffic Scene Understanding*. In: *Procs. IEEE Intelligent Vehicles Symposium*, S. 273–278, Detroit, USA, Oktober 2000.
- [Fra02] U. Franke und S. Heinrich: „Fast Obstacle Detection for Urban Traffic Scenarios“. *IEEE Trans. on Intelligent Transportation Systems* **3** (3), S. 173–181, September 2002.
- [Gar03] C. S. Garbe: *Motion Estimation from Digital Image Sequences - An Overview with Applications for Intelligent Vehicles*. Literaturstudie, Robert Bosch GmbH and Interdisziplinäres Zentrum für Wissenschaftliches Rechnen, Hildesheim, Heidelberg, Deutschland, Februar 2003.
- [Gau63] K. F. Gauß: *Theoria motus corporum caelestium: Perthes et Besser*, 1809. translated as „*Theory of Motion of the Heavenly Bodies moving about the Sun in Conic Sections*“, New York, Dover, 1963.
- [Geh02] S. K. Gehrig, A. Gern, S. Heinrich und B. Woltermann: *Lane Recognition on Poorly Structured Roads - the Bots Dot Problem in California*. In: *Procs. IEEE Intelligent Transportation Systems Conference*, S. 67–71, Singapur, September 2002.

- [Gem96] D. Geman und B. Jedyak: „An Active Testing Model for Tracking Roads in Satellite Images“. *IEEE Trans. on Pattern Analysis and Machine Intelligence* **18** (1), S. 1–14, Januar 1996.
- [Gol99] J. Goldbeck und B. Hürtgen: *Lane Detection and Tracking by Video Sensors*. In: *Procs. IEEE Intelligent Transportation Systems Conference*, S. 74–79, Tokyo, Japan, Oktober 1999.
- [Gon00] J. P. Gonzalez und Ü. Özgüner: *Lane Detection Using Histogram-Based Segmentation and Decision Trees*. In: *Procs. IEEE Intelligent Transportation Systems Conference*, S. 346–351, Dearborn (MI), USA, Oktober 2000.
- [Grt08] GRTWIKIPEDIA - DIE FREIE ENZYKOPÄDIE: *Nomenklatur der Graphentheorie*, Februar 2008.
- [Grü05] M. Gründig: *3D-Kopfposenschätzung in monochromatischen Videosequenzen geringer Auflösung*. Dissertation, Technische Universität Berlin, Februar 2005.
- [Gui99] A. Guiducci: „Parametric Model of the Perspective Projection of a Road with Applications to Lane Keeping and 3D Road Reconstruction“. *Int. Journal of Image and Vision Computing* **73** (3), S. 414–427, März 1999.
- [Gui00] A. Guiducci: „Camera Calibration for Road Applications“. *Int. Journal of Image and Vision Computing* **79** (2), S. 250–266, August 2000.
- [Ham83] F. M. Ham und R. G. Brown: „Observability, Eigenvalues and Kalman Filtering“. *IEEE Trans. on Aerospace and Electronics Systems* **19** (2), S. 269–273, März 1983.
- [Har03] R. Hartley und A. Zisserman: *Multiple View Geometry in Computer Vision*. Cambridge University Press, Cambridge, UK, 2. Aufl., 2003.
- [Hei00] F. Heimes: *Sichtsystemgestützte Fahrerassistenz im innerstädtischen Verkehr*. Dissertation, Fraunhofer-Institut für Informations- und Datenverarbeitung, Akademische Verlagsgesellschaft, Karlsruhe, Deutschland, Juli 2000.
- [Hei02] F. Heimes und H.-H. Nagel: „Towards Active Machine-Vision-Based Driver Assistance for Urban Areas“. *Int. Journal of Computer Vision* **50** (1), S. 5–34, Oktober 2002.

- [Her96] N. Herrmann: *Spline-Funktionen und ihre Anwendungen*, Kap. 24, S. 185–190. Institut für Angewandte Mathematik, Universität Hannover, Welfengarten 1, Hannover, Deutschland, 1996.
- [Hof04] U. Hofmann: *Zur visuellen Umfeldwahrnehmung autonomer Fahrzeuge*. Dissertation, Universität der Bundeswehr München, Juni 2004.
- [Hof06] C. Hoffmann: *Fahrzeugdetektion durch Fusion monoskopischer Video-merkmale*. Dissertation, Institut für Mess- und Regelungstechnik, Universität Karlsruhe (TH), Universitätsverlag Karlsruhe, Dezember 2006.
- [Hom05] K. Homann: *Wirtschaft und gesellschaftliche Akzeptanz: Fahrerassistenzsysteme auf dem Prüfstand*. In: *Fahrerassistenzsysteme mit maschineller Wahrnehmung*, S. 239–244, Springer Verlag, 2005.
- [Hor81] B. Horn und B. Schunk: „Determining Optical Flow“. *Artificial Intelligence* **17**, S. 185–203, 1981.
- [Hum06] B. Hummel, S. Kammel, T. Dang, C. Duchow und C. Stiller: *Vision based Path Planning in Unstructured Environments*. In: *Procs. of IEEE Intelligent Vehicles Symposium*, S. 176–181, Tokyo, Japan, Juni 2006.
- [Hum07] B. Hummel, W. Thiemann und I. Lulcheva: *A novel, signal model based Approach to Lane Detection for use in Intersection Assistance*. In: *Procs. of Conference on Cognitive Systems with Interactive Sensors (COGIS)*, Stanford University, Kalifornien, USA, 2007.
- [Int78] INTERNATIONAL ORGANISATION FOR STANDARDIZATION: *Road Vehicles - Dimensions of Motor Vehicles and Towed Vehicles - Terms and Definitions*, 1978.
- [Int05] INTEL: *Open Source Computer Vision Library, Version beta 5*, Juli 2005.
- [Isa98] M. Isard und A. Blake: „Condensation - Conditional Density Propagation for Visual Tracking“. *Int. Journal of Computer Vision* **29** (1), S. 5–28, 1998.
- [Jäh02] B. Jähne: *Digitale Bildverarbeitung*. Springer Verlag, Berlin, Heidelberg, New York, 2002.
- [Jäh03] B. Jähne: *Systematische Analyse neuer und bekannter Merkmale, deren Fehler und Leistungsfähigkeit*. In: *Procs. of Heidelberger Bildverarbeitungs-Forum*, Bd. 18, Wiesbaden, Deutschland, März 2003.

- [Jia02] X. Jiang: *Bildanalyse*. Fakultät für Elektrotechnik und Informatik, Technische Universität Berlin, 2002.
- [Kan96a] E. R. Kandel, J. H. Schwartz und T. M. Jessell (Hrsg.): *Essentials of Neural Sciences and Behaviour*, Kap. 21, S. 393–411. Spektrum Akademischer Verlag, Heidelberg, Berlin, Oxford, 1996.
- [Kan96b] D. J. Kang, J. W. Choi und I. S. Kweon: *Finding and Tracking Road Lanes Using Line-Snakes*. In: *Procs. IEEE Intelligent Vehicles Symposium*, S. 189–194, Tokyo, Japan, September 1996.
- [Kan99] D. J. Kang: „A fast and stable Snake Algorithm for Medical Images“. *Pattern Recognition Letters* **20** (5), S. 507–512, Mai 1999.
- [Kas87] M. Kass, A. Witkin und D. Terzopoulos: „Snakes: Active Contour Models“. *Int. Journal of Computer Vision* **1** (4), S. 321–331, 1987.
- [Kas03] V. Kastrinaki, M. Zervakis und M. Kalaitzakis: „A Survey of Video Processing Techniques for Traffic Applications“. *Int. Journal of Image and Vision Computing* **21** (1), S. 359–381, Januar 2003.
- [Klu95] K. Kluge und S. Lakshmanan: *A Deformable-Template Approach to Lane Detection*. In: *Procs. IEEE Intelligent Vehicle Symposium*, S. 54–59, Detroit, USA, September 1995.
- [Köt03a] U. Köthe: *Edge and Junction Detection with an Improved Structure Tensor*. In: *Procs. Deutsche Arbeitsgemeinschaft Mustererkennung Symposium*, S. 25–32, Magdeburg, Deutschland, September 2003.
- [Köt03b] U. Köthe: *Integrated Edge and Junction Detection with the Boundary Tensor*. In: *Procs. Int. Conference on Computer Vision*, S. 424–431, Nizza, Frankreich, Oktober 2003.
- [Kre99] C. Kreucher und S. Lakshmanan: „LANA: A Lane Extraction Algorithm that Uses Frequency Domain Features“. *IEEE Trans. on Robotics and Automation* **15** (2), S. 339–345, April 1999.
- [Mal91] H. Mallot, H. Bulthoff, J. Little und S. Bohrer: „Inverse Perspective Mapping simplifies Optical Flow Computation and Obstacle Detection“. *Biological Cybernetics* **64** (3), S. 177–185, 1991.
- [Mau05] M. Maurer und C. Stiller (Hrsg.): *Fahrerassistenzsysteme mit maschineller Wahrnehmung*. Springer Verlag, Heidelberg, Deutschland, 2005.

- [May79] P. S. Maybeck: *Stochastic Models, Estimation, and Control*. Academic Press, New York, USA, 1979.
- [McC06] J. McCall und M. Trivedi: „Video-Based Lane Estimation and Tracking for Driver Assistance: Survey, System, and Evaluation“. *IEEE Transactions on Intelligent Transportation Systems* **7** (1), S. 20–37, 2006.
- [Mey90] K. Meyberg und P. Vachenhauer: *Höhere Mathematik 1*. Springer Verlag, Berlin, Deutschland, 1990.
- [Mod06] MODWIKIPEDIA - DIE FREIE ENZYKOPÄDIE: *Definitionen des Modellbegriffs*, November 2006.
- [Mrt07] MRTMC INSTITUT FÜR MESS- UND REGELUNGSTECHNIK, UNIVERSITÄT KARLSRUHE: *Homepage Team Annieway*, November 2007.
- [Nie02] W. Niehsen: *Approximation mit natürlichen kubischen Splines*. Robert Bosch GmbH, Robert-Bosch-Str. 200, Hildesheim, Deutschland, 2002.
- [Pae00a] F. Paetzold und U. Franke: „Road Recognition in Urban Environment“. *Int. Journal on Image and Vision Computing* **18** (5), S. 377–387, April 2000.
- [Pae00b] F. Paetzold, U. Franke und W. von Seelen: *Lane Recognition in Urban Environment Using Optimal Control Theory*. In: *Procs. IEEE Intelligent Vehicles Symposium*, S. 221–226, Dearborn(MI), USA, Oktober 2000.
- [Pee08] K. Peeters: *tree.hh: an STL-like C++ tree class*. Max-Planck-Institut für Gravitationsphysik, Am Mühlenberg 1, Potsdam, Deutschland, Februar 2008.
- [Pre92a] W. H. Press, S. A. Teukolsky, W. T. Vetterling und B. P. Flannery: *Numerical Recipes in C: Is Matrix Inversion a N^3 Process?*, Kap. 2.11. Cambridge University Press, Cambridge, Deutschland, 1992.
- [Pre92b] W. H. Press, S. A. Teukolsky, W. T. Vetterling und B. P. Flannery: *Numerical Recipes in C: Robust Estimation*, Kap. 15.7. Cambridge University Press, Cambridge, UK, 1992.
- [Pre92c] W. H. Press, S. A. Teukolsky, W. T. Vetterling und B. P. Flannery: *Numerical Recipes in C: Singular Value Decomposition*, Kap. 2.6. Cambridge University Press, Cambridge, UK, 1992.
- [Rab86] L. R. Rabiner und B. H. Juang: „An Introduction to Hidden Markov Models“. *IEEE Trans. on Acoustics, Speech and Signal Processing* **3** (1), S. 4–16, Januar 1986.

- [Rab89] L. R. Rabiner: „A Tutorial on Hidden Markov Models and Selected Applications in Speech Recognition“. *Proceedings of the IEEE* **77** (2), S. 267–293, Februar 1989.
- [Rei67] C. H. Reinsch: „Smoothing by Spline Functions“. *Numerische Mathematik* **10**, S. 177–183, 1967.
- [Rzs06] RZSWIKIPEDIA - DIE FREIE ENZYKOPÄDIE: *Richtlinien zum Straßenbau*, September 2006.
- [Sor70] H. W. Sorenson: „Least-Squares Estimation: From Gauss to Kalman“. *IEEE Spektrum* **7**, S. 63–68, Juli 1970.
- [Sou98] B. Southall, B. Buxton und J. Marchant: *Controllability and Observability: Tools for Kalman Filter Design*. In: *Procs. British Machine Vision Conference*, S. 164–173, Southampton, UK, September 1998.
- [Sta03] S. Stabrey: *Verbesserung der Spurparameterschätzung durch Integration eines Einspurmodells und zusätzliche Schätzung des Schwimmwinkels*. Robert Bosch GmbH, Daimlerstraße 6, Leonberg, Deutschland, Mai 2003.
- [Ste00] G. P. Stein, O. Mano und A. Shashua: *A Robust Method for Computing Vehicle Ego-Motion*. In: *Procs. IEEE Intelligent Vehicles Symposium*, S. 362–368, Dearborn (MI), USA, Oktober 2000.
- [Ste04] F. Stein: *Efficient Computation of Optical Flow Using the Census Transform*. In: *Procs. of DAGM-Symposium*, S. 79–86, Tübingen, Deutschland, August 2004.
- [Sti05] C. Stiller: *Fahrerassistenzsysteme – Von realisierten Funktionen zum vernetzt wahrnehmenden, selbstorganisierenden Verkehr*. In: *Fahrerassistenzsysteme mit maschineller Wahrnehmung*, S. 3–28, Springer Verlag, 2005.
- [Sun04] Z. Sun, G. Bebis und R. Miller: *On-Road Vehicle Detection Using Optical Sensors: A Review*. In: *Procs. IEEE Intelligent Transportation Systems Conference*, S. 585–590, Washington DC, USA, Oktober 2004.
- [Uns99] M. Unser: „Splines - A Perfect Fit for Signal and Image Processing“. *IEEE Signal Processing Magazine* **16** (6), S. 22–38, November 1999.
- [Vdi03] VDI/VDE INNOVATION + TECHNIK GMBH: *3D-Sensorik für vorausschauende Sicherheitssysteme im Automobil (3D-SIAM)*, Mai 2003.

- [Ver91] D. Vernon: *Machine Vision: Automated Visual Inspection and Robot Vision*, Kap. 5.5.4. Prentice Hall, 1991.
- [Vio01] P. Viola und M. Jones: *Rapid Object Detection Using a Boosted Cascade of Simple Features*. In: *Procs. of IEEE Conference on Computer Vision and Pattern Recognition*, Bd. 1, S. 511–519, Hawaii, USA, Dezember 2001.
- [Vit67] A. Viterbi: „Error bounds for Convolutional Codes and an asymptotically Optimum Decoding Algorithm“. *IEEE Transactions on Information Theory* **13** (2), S. 260–269, April 1967.
- [vW04] G. von Winckel: *Fast Pentadiagonal System Solver*. The Mathworks Company, March 2004.
- [Wan98] Y. Wang, D. Shen und E. K. Teoh: *Lane Detection Using Catmull-Rom Spline*. In: *Procs. IEEE Intelligent Vehicles Symposium*, S. 51–57, Stuttgart, Deutschland, Oktober 1998.
- [Wan00] Y. Wang, D. Shen und E. K. Teoh: „Lane Detection Using Spline Model“. *Pattern Recognition Letters* **21** (6–7), S. 677–689, Juni 2000.
- [Wan04] Y. Wang, E. K. Teoh und D. Shen: „Lane Detection and Tracking using B-Snake“. *Image and Vision Computing* **22** (4), S. 269–280, April 2004.
- [Wel03] G. Welch und G. Bishop: *An Introduction to the Kalman Filter*. Techn. Ber., University of North Carolina, Department of Computer Science, North Carolina, USA, Mai 2003.
- [Wit06] D. Withopf und B. Jähne: *Learning Algorithm for Real-Time Vehicle Tracking*. In: *Procs. of IEEE Intelligent Transportations Systems Conference*, S. 516–521, Toronto, Canada, September 2006.
- [Yag00] Y. Yagi, Y. Kawasaki, M. Yachida und M. Brady: *Active Contour Road Model for Smart Vehicle*. In: *Procs. Int. Conference on Pattern Recognition*, Bd. 3, S. 819–822, 2000.
- [Zha97] Z. Zhang: „Parameter Estimation Techniques: A Tutorial with Application to Conic Fitting“. *Int. Journal on Image and Vision Computing* **15** (1), S. 59–76, Januar 1997.
- [Zio98] D. Ziou und S. Tabbone: „Edge Detection Techniques - An Overview“. *Int. Journal of Pattern Recognition and Image Analysis* **8** (4), S. 537–559, 1998.

Institut für Mess- und Regelungstechnik Universität Karlsruhe (TH)

Umfelderfassende Fahrerassistenzsysteme beurteilen die Situation des eigenen Fahrzeugs anhand seiner Lage innerhalb der Fahrspur und der relativen Position von Objekten entlang der vermuteten Trajektorie. Algorithmen zur Schätzung der vorausliegenden Fahrspurgeometrie sind dabei eine elementare Basiskomponente für viele Assistenzfunktionen. Die konkrete Realisierung ist durch die Abbildungseigenschaften der Fahrspur im Sichtbereich des verwendeten Sensors bestimmt.

In dieser Arbeit wurde ein modellbasierter Schätzer für innerstädtische Fahrspurverläufe in monokularen Bildfolgen entwickelt und im Versuchsfahrzeug implementiert. Ausgangspunkt der Modellbildung ist die Annahme, dass der Beobachtung der Fahrspurberandungen ein Zufallsprozess zugrunde liegt, der räumlichen und zeitlichen Kontinuitätsbedingungen genügt. Als mathematische Werkzeuge werden Markov-Ketten, der Viterbi-Algorithmus und die Approximation mit Splines flexibler Ordnung verwendet.

Im Verlauf der Arbeit werden die Algorithmen zur initialen Detektion und zeitlichen Verfolgung der Fahrspurberandungen aus grundlegenden Annahmen über den Fahrspurverlauf vor dem eigenen Fahrzeug hergeleitet. Die charakteristischen Eigenschaften der Algorithmen werden anhand von visuell und geometrisch anspruchsvollen Szenarien diskutiert. Als Beleg für die Leistungsfähigkeit des Verfahrens werden Schätzergebnisse von Testfahrten in innerstädtischen Umgebungen gezeigt.