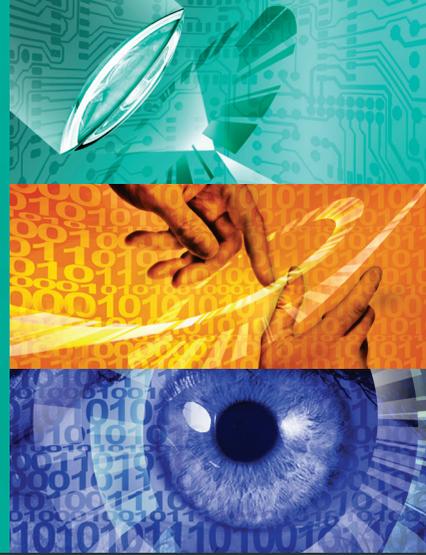


Karlsruher Schriften
zur Anthropomatik

Band 38



Miriam Ruf

**Geometrie und Topologie von
Trajektorienoptimierung für
vollautomatisches Fahren**

Miriam Ruf

**Geometrie und Topologie von Trajektorienoptimierung
für vollautomatisches Fahren**

Karlsruher Schriften zur Anthropomatik

Band 38

Herausgeber: Prof. Dr.-Ing. habil. Jürgen Beyerer

Eine Übersicht aller bisher in dieser Schriftenreihe
erschienenen Bände finden Sie am Ende des Buchs.

Geometrie und Topologie von Trajektorienoptimierung für vollautomatisches Fahren

von
Miriam Ruf

Dissertation, Karlsruher Institut für Technologie
KIT-Fakultät für Informatik

Tag der mündlichen Prüfung: 08. Februar 2018
Gutachter: Prof. Dr.-Ing. Jürgen Beyerer, Prof. Dr.-Ing. Bodo Rosenhahn

Impressum



Karlsruher Institut für Technologie (KIT)
KIT Scientific Publishing
Straße am Forum 2
D-76131 Karlsruhe

KIT Scientific Publishing is a registered trademark
of Karlsruhe Institute of Technology.
Reprint using the book cover is not allowed.

www.ksp.kit.edu



*This document – excluding the cover, pictures and graphs – is licensed
under a Creative Commons Attribution-Share Alike 4.0 International License
(CC BY-SA 4.0): <https://creativecommons.org/licenses/by-sa/4.0/deed.en>*



*The cover page is licensed under a Creative Commons
Attribution-No Derivatives 4.0 International License (CC BY-ND 4.0):
<https://creativecommons.org/licenses/by-nd/4.0/deed.en>*

Print on Demand 2018 – Gedruckt auf FSC-zertifiziertem Papier

ISSN 1863-6489
ISBN 978-3-7315-0832-8
DOI 10.5445/KSP/1000085281

Geometrie und Topologie von Trajektorienoptimierung für vollautomatisches Fahren

zur Erlangung des akademischen Grades eines
Doktors der Ingenieurwissenschaften

der KIT-Fakultät für Informatik
des Karlsruher Instituts für Technologie (KIT)

genehmigte

Dissertation

von

Miriam Ruf

aus Stuttgart – Bad Cannstatt

Tag der mündlichen Prüfung: 08. Februar 2018

Erster Gutachter: Prof. Dr.-Ing. Jürgen Beyerer
Karlsruher Institut für Technologie

Zweiter Gutachter: Prof. Dr.-Ing. Bodo Rosenhahn
Leibniz Universität Hannover

*Für meine Eltern,
Brigitte und Jürgen*

Kurzfassung

Die Arbeit mit dem Titel *Geometrie und Topologie von Trajektorienoptimierung für vollautomatisches Fahren* hat zum Ziel, allgemeine Aussagen über das Themenfeld der Bewegungsplanung für vollautomatisches Fahren zu entwickeln, um ein umfassendes Problemverständnis unabhängig von Einschränkungen auf konkrete algorithmische oder sensorische Gegebenheiten zu erlangen. Hierfür wird zunächst eine intuitive Problemformulierung aus der Domäne der Variationsrechnung abgeleitet, woraus sich das *Euler-Lagrange-Modell zur Trajektorienplanung* (ELM) ergibt, das durch gängige iterative Optimierungsmethoden gelöst werden kann.

Aufgrund der bekannten Nachteile iterativer Optimierung wird eine Korrespondenz von ELM mit speziellen probabilistischen Graphenmodellen beschrieben und damit das *Hidden-Markov-Modell zur Trajektorienplanung* (HMM) hergeleitet. Die so erschlossene globale Optimierung wird zusammen mit einer erschöpfenden Generierung von Starttrajektorien zur *topologischen Analyse des Lösungsraums* der Trajektorienoptimierung anhand synthetisierter Räume und realer Beispielsituationen eingesetzt.

Für die *geometrische Analyse des Trajektorienraums* wird eine probabilistische Beschreibung der Umgebung des Ego-Fahrzeugs, der initialen Situation und ihrer Prädiktion in die Zukunft hergeleitet. Damit können Unsicherheiten über Sensorik oder Verhaltensweisen anderer Verkehrsteilnehmer in einer gemeinsamen Bewertungsfunktion vereint werden mit intrinsischen Trajektorieneigenschaften, die beispielsweise Insassenkomfort über Beschleunigungen, aber auch die Einhaltung von Geschwindigkeitsbegrenzungen berücksichtigen. Zur Beschreibung der Fahrzeuggeometrie wird das inverse C^2 -Modell herleitet und simulativ sowie anhand realer Testfahrten mit den VERTEX-Versuchsträgern des Fraunhofer IOSB evaluiert.

Die Ergebnisse der geometrischen und topologischen Analyse zeigen eine hohe Komplexität des Trajektorienraums realen Verkehrsgeschehens, mit einer Vielzahl an lokalen Optima deutlich unterschiedlicher Güte, und geben damit Aufschluss über Anforderungen an zukünftige Trajektorienplanungsverfahren.

Das aus probabilistischer Situationsbeschreibung und intuitiver Modellierung der Trajektorienplanungsaufgabe resultierende neuartige Trajektorienplanungskonzept *Situation Prediction and Reaction Control (SPARC)* wird beispielhaft auf mehrspurige Straßen, zur Generierung von Notfalltrajektorien sowie mit einer Erweiterung auf interaktive Verhaltensmodelle angewendet.

Inhaltsverzeichnis

	Kurzfassung	I
<hr/>		
	Symbole und Abkürzungen	VII
<hr/>		
1	Einführung	1
<hr/>		
	1.1 Von der Motivation zur Fragestellung	1
<hr/>		
	1.2 Stand der Forschung	4
<hr/>		
	1.2.1 Bewegungsplanungsebene	5
	1.2.2 Verhaltensentscheidungsebene	13
	1.2.3 Fahrzeugmodellierung	16
	1.2.4 Interaktionsmodelle	18
	1.3 Über diese Arbeit	20
<hr/>		
	1.3.1 Projektkontext der Arbeit	20
	1.3.2 Eigene Beiträge zum Stand der Forschung	22
	1.3.3 Gliederung der Arbeit	25

2	Mathematische Grundlagen	29
2.1	Motivation der mathematischen Modelle	29
2.2	Grundbegriffe der Variationsrechnung	32
2.3	Grundbegriffe Wahrscheinlichkeitstheorie und probabilistische graphische Modelle	40
3	Herleitung der Trajektorienplanungsverfahren	53
3.1	Penalty-Lagrangefunktion und Nebenbedingungen	53
3.2	Das Euler-Lagrange-Modell zur Trajektorienplanung	59
3.3	Korrespondenz zwischen Euler-Lagrange- und Hidden-Markov-Modell	61
3.4	Das Hidden-Markov-Modell zur Trajektorienplanung	68
3.5	Umsetzung der Trajektorienplanungsverfahren	71
3.5.1	Planungsräume	71
3.5.2	Umsetzung des Euler-Lagrange-Modells	72
3.5.3	Umsetzung des Hidden-Markov-Modells	77
4	Geometrie des Trajektorienraums	81
4.1	Geometrie des Ego-Fahrzeugs	81
4.1.1	Das C^2 -Modell	81

4.1.2	Evaluation des C^2 -Modells anhand von Simulationen	88
4.1.3	Evaluation des C^2 -Modells anhand realer Testfahrten	106
4.1.4	Zusammenfassung der Evaluation des C^2 -Modells	114
4.2	Geometrie der Situation	116

4.2.1	Beschreibung der initialen Situation des Ego-Fahrzeugs	116
4.2.2	Prädiktion der initialen Situation	124
4.3	Von der Geometrie zur Trajektorienplanung – SPARC	136

5	Topologie des Trajektorienraums	143

5.1	Notation und Vergleichsmetriken	145

5.2	Betrachtung anhand synthetisierter Trajektorienräume	149

5.2.1	Generierung synthetisierter Rauschfelder	149
5.2.2	Analyse der synthetisierten Rauschfelder	151
5.3	Betrachtung anhand realer Beispielsituationen	158

5.3.1	Auswahl und Beschreibung der Beispielsituationen	159
5.3.2	Analyse der Beispielsituationen	165
5.4	Schlussfolgerungen aus den topologischen Betrachtungen	171

6	Beispielanwendungen der Trajektorienplanungsverfahren	175
6.1	Zyklischer Gesamtprozess SPARC	175
6.2	Globale Trajektorienplanung für mehrspurige Straßen	182
6.3	Notfalltrajektorienplanung	188
6.4	Interaktion mit Verkehrsteilnehmern – PITRA	191
7	Zusammenfassung und Ausblick	199
G	Glossar	205
A	Abbildungsverzeichnis	223
T	Tabellenverzeichnis	227
E	Eigene Publikationen	229
B	Betreute Arbeiten	231
L	Literaturverzeichnis	233

Symbole und Abkürzungen

Symbol	Beschreibung
MATHEMATISCHE SYMBOLE	
$ \cdot $	Betrag
$\ \cdot\ $	euklidische Norm
$\det[\cdot]$	Determinante
$\langle \cdot \cdot \rangle$	Skalarprodukt
$\sphericalangle(\cdot, \cdot)$	Winkel
∇	Gradient
H	Hessematrix
$\arctan_2(\cdot, \cdot)$	auf vier Quadranten erweiterter Arkustangens nach [73]
$\text{SPACE}(\cdot)$	Raumkomplexitätsklasse von Algorithmen nach [7, 189]
$\text{TIME}(\cdot)$	Zeitkomplexitätsklasse von Algorithmen nach [7, 189]

GRIECHISCHE SYMBOLE

$\delta_{t, t_{\text{end}}}$	Kronecker-Delta der Target-Penalty
$\delta, \delta_l, \delta_r$	mittlerer Einschlagwinkel sowie Einschlagwinkel an den Vorderrädern links und rechts
$\delta_1^{\text{gt}}, \delta_r^{\text{gt}}$	Referenzeinschlagwinkel aus CARMAKER
$\tilde{\delta}_l, \tilde{\delta}_r$	über C^2 -Modell geschätzter Einschlagwinkel links und rechts aus Referenzdaten

Symbol	Beschreibung
δ_{lenk}^{sim}	Ergebnislenkradwinkel bei simulierten C^2 -Modellgeschätzten Stellbefehlen
δ_{lenk}^{CAN}	Referenzlenkradwinkel aus CAN-Daten
δ_τ	Vektor innerhalb des Penalty-Viterbi-Algorithmus mit besten Vorgänger-HMM-Zuständen des τ -ten Zeitschritts
Δt	Diskretisierungszeit
$\Delta \xi$	infinitesimal kleine Änderungen der Trajektorie
$\Delta \xi_{hl}$	infinitesimal kleine Änderungen der Position des hinteren linken Radmittelpunkts
$\zeta^x, \zeta^y, \zeta^s,$ $\zeta^{\dot{x}}, \zeta^{\dot{y}}, \zeta^s, \dots$ $\zeta_t^x, \zeta_t^y, \zeta_t^s, \dots$	skalare HMM-Zustandskomponenten skalare HMM-Zustandskomponenten zum Zeitpunkt t
ζ, ζ_t	HMM-Zustandsvektor, sowie zum Zeitpunkt t
$\zeta_{t_{start}}, \zeta_{t_{end}}$	Start-, Endzustandsvektor des HMM
$\dot{\zeta}, \dot{\zeta}_t$	HMM-Zustandsänderungsvektor, sowie zum Zeitpunkt t
ζ^{Sp}	Spurzustand des HMM für mehrspurige Straßen
ζ^{We}	Wechselzustand des HMM für mehrspurige Straßen
$\bar{\zeta}^{We}$	deterministische Kette an Wechselzuständen
$\bar{\zeta}^*$	optimale HMM-Zustandsfolge
Θ	Menge an Ereignissen \mathcal{E}
κ	skalare Krümmung der Trajektorie
$\mathbf{\kappa}$	Krümmungsvektor der Trajektorie
$\lambda, \lambda_0, \lambda_i$	Lagrange-Multiplikatoren
λ	Vektor der Lagrange-Multiplikatoren

Symbol	Beschreibung
μ	mittlerer Fehler innerhalb C^2 -Modell-Evaluation
ξ_x, ξ_y, ξ_s	skalare Komponenten der Trajektorie
$\dot{\xi}_x, \dot{\xi}_y, \ddot{\xi}_x, \dots$	skalare Komponenten der Geschwindigkeit und Beschleunigung der Trajektorie
$\xi_x(t), \dots$	skalare Komponenten der Trajektorie zum Zeitpunkt t
ξ	Trajektorie
$\xi(t)$	Trajektorie zum Zeitpunkt t
$\dot{\xi}, \ddot{\xi}, \ddot{\ddot{\xi}}$	Geschwindigkeit, Beschleunigung, Ruck der Trajektorie ξ
$\bar{\xi}$	Pfad einer Trajektorie, parametrisiert über longitudinalen Raumparameter s
ξ^{gt}	Referenztrajektorie aus Simulation
$\tilde{\xi}^{\text{sim}}$	Ergebnstrajektorie der Simulation einer reinen Steuerung über C^2 -Modell-Stellbefehle
ξ^{GPS}	Referenztrajektorie aus Gps-Daten
ξ_{Emerg}	Notfalltrajektorie
$\xi_{\text{ELM}}^{(k)}$	k -te Starttrajektorie der iterativen ELM-Optimierung
ξ_{ELM}^k	k -te ELM-Ergebnstrajektorie beginnend mit $\xi_{\text{ELM}}^{(k)}$
ξ_{ELM}^*	beste iterative ELM-Ergebnstrajektorie
ξ_{HMM}	Ergebnstrajektorie aus HMM-Optimierung
$\xi_{\text{HMM}}^{\text{low}}$	HMM-Trajektorie mit grober Rasterung des Zustandsraums
$\xi_{\text{HMM}}^{\text{high}}$	HMM-Trajektorie mit feiner Rasterung des Zustandsraums
$\xi_{\text{ELM}}^{\text{HMM}}$	iterative ELM-Ergebnstrajektorie mit ξ_{HMM} als Startlösung
$\xi_{\text{ELM}}^{(k)} \rightsquigarrow \xi_{\text{ELM}}^k$	Beschreibung des iterativen ELM-Optimierungsvorgangs von Starttrajektorie $\xi_{\text{ELM}}^{(k)}$ zu Ergebnstrajektorie ξ_{ELM}^k

Symbol	Beschreibung
$\ \dot{\xi}_{\text{Rad}}^{\text{CAN}}\ $	Radmittelpunktsgeschwindigkeiten aus CAN-Daten als Referenzdaten
$\ \dot{\xi}_{\text{Rad}}\ $	über C^2 -Modell geschätzte Radmittelpunktsgeschwindigkeiten aus Referenzdaten
\mathbb{E}	Trajektorienraum, Menge zulässiger Trajektorien
$\dot{\rho}_{\text{vl}}, \dot{\rho}_{\text{vr}}, \dot{\rho}_{\text{hl}}, \dot{\rho}_{\text{hr}}$	Rollgeschwindigkeiten der Vorder- und Hinterräder links und rechts
$\dot{\rho}_{\text{vl}}^{\text{gt}}, \dot{\rho}_{\text{vr}}^{\text{gt}}, \dot{\rho}_{\text{hl}}^{\text{gt}}, \dot{\rho}_{\text{hr}}^{\text{gt}}$	Rollgeschwindigkeiten der Vorder- und Hinterräder links und rechts aus Simulation als Referenzdaten
$\dot{\check{\rho}}_{\text{vl}}, \dot{\check{\rho}}_{\text{vr}}, \dot{\check{\rho}}_{\text{hl}}, \dot{\check{\rho}}_{\text{hr}}$	über C^2 -Modell geschätzte Rollgeschwindigkeiten
σ	Standardabweichung innerhalb C^2 -Modell-Evaluation
τ	Zeitparameter in Penalty-Viterbi-Algorithmus
τ_{δ}	Lenkperiode innerhalb der Evaluation des C^2 -Modells mit Sinuslenkung
\mathcal{T}	Prädiktionsschritte
ψ	Fahrzeugorientierung
$\dot{\psi}$	Gierrate
Ω	Funktionenraum

LATEINISCHE SYMBOLE

a, a_{long}	longitudinale Beschleunigung
a_{lat}	laterale Beschleunigung
\tilde{a}	über C^2 -Modell geschätzte Beschleunigung aus Referenzdaten
a^{gt}	Referenzbeschleunigung aus Simulation

Symbol	Beschreibung
A_δ	Lenkamplitude bei der Evaluation des C^2 -Modells mit Sinuslenkung
A, B, C, ...	Verkehrsteilnehmer
C^n	Differentiationsklasse
$\bar{e}_{\xi_{\text{end}}}$	mittlerer Endpunktfehler bezogen auf Segmentlänge innerhalb C^2 -Modell-Evaluation
E_ν, E_δ	Fehlerkurven innerhalb der Evaluation des C^2 -Modells mit Sinuslenkung
$\mathcal{E}, \mathcal{E}_A, \mathcal{E}_1, \mathcal{E}_{x^{\text{W}}}^{\text{Bel}}, \dots$	probabilistisches Ereignis
\mathcal{E}	Erwartungswert
f	Funktion
f_{lenk}	Lenkübersetzungsfunktion des VW eGOLF VII
f_δ	Lenkfrequenz bei der Evaluation des C^2 -Modells mit Sinuslenkung
f_X	Wahrscheinlichkeitsdichteverteilung
f_Y	multivariate Wahrscheinlichkeitsdichteverteilung
F_X	kumulierte Verteilungsfunktion
F_Y	multivariate kumulierte Verteilungsfunktion
S1, S2, ...	Fahrstreifen
g	Funktion
G_ν	Voronoi-Graph
h	halbe Spurbreite als halber Abstand zweier Räder auf derselben Achse
H_R	2D-Feld aus Orts- und Zeitkomponente für Voronoi-Betrachtungen

Symbol	Beschreibung
i_{lenk}	linearer Lenkübersetzungsfaktor in Simulation
I_{ELM}^*	Anzahl an Iterationen von $\xi_{\text{ELM}}^{(*)} \rightsquigarrow \xi_{\text{ELM}}^*$
$I_{\text{ELM}}^{\text{HMM}}$	Anzahl an Iterationen von $\xi_{\text{HMM}} \rightsquigarrow \xi_{\text{ELM}}^{\text{HMM}}$
$I_{\text{ELM}}^{\text{min}}, I_{\text{ELM}}^{\text{max}}$	minimale und maximale Anzahl an Iterationen von $\xi_{\text{ELM}}^{(k)} \rightsquigarrow \xi_{\text{ELM}}^k$ über alle k Optimierungsvorgänge
$I_{\text{ELM}}^{\text{mean}}, I_{\text{ELM}}^{\text{med}}$	arithmetisches Mittel und Median der Anzahl an Iterationen von $\xi_{\text{ELM}}^{(k)} \rightsquigarrow \xi_{\text{ELM}}^k$ über alle k Optimierungsvorgänge
J_{S}	Informationen aus Sensordaten
$J_{\text{ELM}}^{\text{P}}$	Sprungmetrik als Metrik für die Komplexität und Verteilung lokaler Optima
$J_{\text{ELM}}^{\text{end}}$	Vorhersagbarkeitsmetrik als Metrik der Vorhersagbarkeit einer Ergebnistrajektorie anhand seiner Starttrajektorie
k	Laufparameter der iterativen ELM-Optimierungen
K	Kosten innerhalb der Erwartungswertmodellierung
K^{W}	Weltkoordinatensystem
l	Achsabstand als Abstand der Vorder- und Hinterachse
\mathcal{L}	Funktional
L	Lagrangefunktion
m	Steigung als lineare Approximation über die Methode der kleinsten Quadrate bei C^2 -Modell-Evaluation
M_z	Kreismittelpunkt zur Krümmungsberechnung
n	Nordrichtung
N	Normalenvektor, Normale

Symbol	Beschreibung
$o_{\text{lenk}}^{\text{gt}}, o_{\text{gas}}^{\text{gt}}, o_{\text{brems}}^{\text{gt}}$	Lenk-, Gas-, Brems-Steuerbefehle als Referenzdaten
$\tilde{o}_{\text{lenk}}, \tilde{o}_{\text{gas}}, \tilde{o}_{\text{brems}}$	über C^2 -Modell geschätzte Lenk-, Gas-, Brems-Steuerbefehle aus Schätzung über C^2 -Modell
$p(\cdot)$	Wahrscheinlichkeit
$p(\cdot \cdot)$	bedingte Wahrscheinlichkeit
$p_C(\mathcal{E}_{\mathbf{x}^W}^{\text{Bel}} t)$	Belegungswahrscheinlichkeit der Zelle an Position \mathbf{x}^W resultierend aus Aufenthaltswahrscheinlichkeit des Verkehrsteilnehmers C an \mathbf{x}^W zum Zeitpunkt t
$p_{n\%}^{\mathcal{P}}$	Wahrscheinlichkeit der iterativen ELM-Optimierung über die Penaltywerte-Verteilung einen n -prozentig schlechteren Penaltywert als jenen der HMM-Lösung zu erhalten
\mathcal{P}_L	Penalty-Lagrangefunktion
\mathcal{P}_{in}	Inner-Penaltys
$\mathcal{P}'_{\text{out}}$	Primary-Outer-Penaltys
$\mathcal{P}''_{\text{out}}$	Secondary-Outer-Penaltys
$\mathcal{P}_{\text{target}}$	Target-Penaltys
$\mathcal{P}_{\text{emerg}}$	Penalty-Funktion für Bewertung des Endzustands einer Notfalltrajektorie
\mathcal{P}	Pre-Penalty-Volumen
\mathcal{P}^{ζ_t}	Pre-Penalty-Volumen des HMM-Zustands ζ_t zur Einbeziehung von Interaktion in PITRA
$\mathcal{P}[\cdot]$	Penalty-Funktional
\mathcal{P}_{HMM}	Penaltywert von ξ_{HMM}
$\mathcal{P}_{\text{ELM}}^k$	Penaltywert der k -ten ELM-Ergebnistrajektorie ξ_{ELM}^k

Symbol	Beschreibung
$\mathcal{P}_{\text{ELM}}^{\text{HMM}}$	Penaltywert von $\xi_{\text{ELM}}^{\text{HMM}}$
$\mathcal{P}_{\text{ELM}}^{\min}, \mathcal{P}_{\text{ELM}}^{\max}$	minimaler sowie maximaler Penaltywert von $\mathcal{P}_{\text{ELM}}^k$ über alle k ELM-Optimierungsergebnisse
$\mathcal{P}_{\text{ELM}}^{\text{mean}}, \mathcal{P}_{\text{ELM}}^{\text{med}}, \mathcal{P}_{\text{ELM}}^{\sigma}$	arithmetisches Mittel, Median sowie Standardabweichung der Penaltywerte-Verteilung aller k ELM-Optimierungsergebnisse
\mathcal{P}_{τ}	Vektor in Penalty-Viterbi-Algorithmus mit minimalen Penaltys der HMM-Zustände aus τ -tem Zeitschritt
\mathcal{P}'_{τ}	Matrix in Penalty-Viterbi-Algorithmus mit Penaltys aller HMM-Zustandskombinationen aus τ -tem Zeitschritt
q^{gt}	Beispiel einer Größe als Referenz
\tilde{q}	Beispiel einer Größe als C^2 -Modell-geschätzte Größe
\tilde{q}^{sim}	Beispiel einer Größe als Ergebnis der Simulation einer C^2 -Modell-geschätzten Größe
r_v, r_h	Reifenradius vorne und hinten
R_z	Radius zur Krümmungsberechnung
$R_{vl}, R_{vr}, R_{hl}, R_{hr}$	Bewegungsradien der Vorderräder links und rechts sowie Hinterräder links und rechts
R_i	Menge an Reaktionen anderer Verkehrsteilnehmer zur Einbeziehung von Interaktion in PITRA
s	Longitudinaler Raumparameter entlang des Pfads
s_H	Longitudinaler Raumparameter entlang des Hockenheimrings
S^W, X^W, Y^W	Raum der Weltpositionen

Symbol	Beschreibung
\mathcal{S}_t	prädizierte Situation zum Zeitpunkt t
$\mathcal{S}_{\text{start}}$	initiale Situation zum Zeitpunkt $t_{\text{start}} = t_{\text{real}}$
\mathcal{S}^{ζ_t}	prädizierte Situation ausgehend von HMM-Zustand ζ_t zur Einbeziehung von Interaktion in PITRA
t	Zeitparameter der Trajektorienplanung
t_{real}	Zeitparameter realer Vorkommnisse (in Abgrenzung zur geplanten Trajektorie mit Zeitparameter t)
t_{eval}	Zeitparameter für Evaluationen in Simulation und realen Testfahrten
$t_{\text{start}}, t_{\text{end}}$	Start- und Endzeit der Trajektorie
$t_{\text{We,Start}}, t_{\text{We,End}}$	Start- und Endzeit des Fahrspurwechsels
T, T_d	Zeitintervall, diskretes Zeitintervall
T_p	Prädiktionszeitraum
T_{We}	Fahrspurwechselintervall
\mathbf{T}	Tangentialvektor, Tangente
$\dot{\mathbf{T}}$	zeitliche Änderung der Tangente
v, v_{long}	longitudinale Geschwindigkeit
v_{lat}	laterale Geschwindigkeit
v^{gt}	Referenzgeschwindigkeit aus Simulation
\tilde{v}	über C^2 -Modell geschätzte Geschwindigkeit aus Referenzdaten
\tilde{v}^{sim}	Geschwindigkeit des Simulationsergebnisses von über C^2 -Modell geschätzten Stellbefehlen
v^{CAN}	Referenzgeschwindigkeit aus CAN-Daten

Symbol	Beschreibung
V	Voronoi-Diagramm
w_i	Gewichtungsfaktoren der Penalty-Funktionen in Penalty-Lagrangefunktion
\mathbf{w}	Westrichtung
x	Variable einer Funktion
x_1, x_2	Intervallgrenzen einer Funktion
x, y	Raumparameter
\mathbf{x}^W	realweltliche Position bestehend aus x, y -Komponente
$\dot{\mathbf{x}}^W, \ddot{\mathbf{x}}^W$	realweltliche Geschwindigkeit sowie Beschleunigung
X^W, Y^W, S^W	Raum der Weltpositionen
y_1, y_2, \dots	Komponenten des Vektors \mathbf{y}
$\mathbf{y}, \hat{\mathbf{y}}$	Vektor
Z	HMM-Zustandsraum
\dot{Z}	HMM- Zustandsübergangsraum

Abkürzung	vollständige Bezeichnung
Acv	Automobil-Club Verkehr
BAST	Bundesanstalt für Straßenwesen
BFGS	Broyden-Fletcher-Goldfarb-Shanno Verfahren
BMW	Bayerische Motoren Werke
CAN	Controlled Area Network
DARPA	Defense Advanced Research Projects Agency
ELM	Euler-Lagrange-Modell zur Trajektorienplanung
FPS	Frames per Second / Bilder pro Sekunde
GPS	Global Positioning System
GPU	Graphics Processing Unit / Graphikkarte
gt	Ground Truth / Referenz
HMM	Hidden-Markov-Modell zur Trajektorienplanung
IOSB	Institut für Optronik, Systemtechnik und Bildauswertung
KIT	Karlsruher Institut für Technologie
opt.	optimal
PITRA	Progressively Interacting Trajectories
pxl	Pixel als Einheit
RMSE	Root Mean Square Error / Wurzel des mittleren quadratischen Fehlers
RRT	Rapidly-Exploring Random Tree
RTK	Real-Time Kinematic
SPARC	Situation Prediction and Reaction Control
VERTEX	Versuchsfahrzeuge für Technologie-Experimente
vs.	versus
Vw	Volkswagen

1

Einführung

1.1 Von der Motivation zur Fragestellung

Die starke gesamtgesellschaftliche Relevanz des Themenfelds rund um *autonome Mobilität* zeigt sich nicht zuletzt in den fortwährenden Anstrengungen von Politik und Wissenschaft, Weiterentwicklungen im gesamten Bereich des automatisierten Fahrens zu unterstützen, mit beispielsweise der Förderung von Testarealen wie dem »Testfeld Autonomes Fahren Baden-Württemberg« in Karlsruhe und Umgebung mit einer Fördersumme von 2,5 Millionen Euro [126]. Auch die Einberufung einer »Ethik-Kommission« zur Erarbeitung von gesellschaftlichen Regulationsinstrumenten [40] stellt dabei einen wichtigen Impuls hin zur autonomen Mobilität dar.

Das hohe Interesse an dem Thema begründet sich durch die Vision, die die autonome Mobilität zu zeichnen vermag: Die Fortführung einer Entwicklung, die eine Erhöhung der Mobilität verbindet mit einer Minderung von Unfällen und Umweltbelastung. Etwa geht die kontinuierliche Abnahme an Verkehrstoten mit Todesfolge – seit etwa 1970 um 84 Prozent – bei einem gleichzeitigen Anstieg des Fahrzeugbestands wesentlich auf eine stetige Erhöhung der technischen Fahrzeugausstattung zurück [164]. So starben nach einer Studie des »Statistischen Bundesamts« bezogen auf je 100.000 Fahrzeuge im Jahr 2012 in mindestens 15 Jahre alten Fahrzeugen 5,2 Menschen im Gegensatz zu lediglich 3,5 Fahrzeuginsassen in jüngeren Fahrzeugen [163]. Gleichwohl zeichnet sich ab, dass die Grenzen dieser Entwicklung in absehbarer Zeit erreicht sein werden, sofern man den Menschen selbst nicht in der Fahrverantwortung ersetzt.

Auch in diesem Sinne kann die neue Form der Mobilität Antworten auf den demographischen Wandel bieten, der derzeit mit einer Erhöhung der Unfallzahlen von Verkehrstoten ab dem Lebensalter von 65 Jahren einhergeht. Die Statistik zeigt einen Anstieg der im Verkehr verunglückten Senioren von knapp 17 Prozent im Jahr 1991 auf 33 Prozent im Jahr 2015, bei gleichzeitigem Anstieg von 31 Prozent auf 42 Prozent der darin enthaltenen Todesfälle von Senioren als Fahrzeuginsassen im Gegensatz zu Fußgänger-, Fahrrad- und Kraftradunfällen [164]. Autonome Mobilität kann einer alternden Gesellschaft die Möglichkeit von bleibender, sicherer und verfügbarer Fortbewegung im Sinne eines Individualverkehrs anbieten, und dies insbesondere auch in ländlichen Regionen.

Neben den Sicherheitsaspekten wächst bei vielen Menschen zudem der Wunsch nach einer komfortablen Individualmobilität, die dem Computer die Fahraufgabe überlässt, um sich während des Fahrens Arbeits- oder Freizeitaktivitäten zu widmen. Laut einer repräsentativen Studie des Automobil-Club Verkehr (Acv) wären 2015 bereits 34 Prozent der Befragten bereit, vollautomatische Fahrzeuge zu nutzen. Dabei nennen die Befragten als wichtige Vorteile fahrerlosen Fahrens unterschiedliche Komfortaspekte, wie beispielsweise eine Stressverringerung im Straßenverkehr oder Erleichterungen bei langen oder unbekanntem Fahrten [1, 115]. Auch sind nach [82] insgesamt 75 Prozent der dortigen Befragungsteilnehmer aus Deutschland, den USA und Japan bereit, für Dienstleistungen zur Gestaltung der »freien Fahrtzeit« zu zahlen, was auf eine hohe Akzeptanz und den Wunsch auf eine komfortable Fortbewegung schließen lässt.

Weiterhin hat die autonome Mobilität das Potenzial, das heutige Städtebild grundlegend zu verändern. Laut einer McKinsey-Studie mit einer Befragung von mehr als 30 internationalen Experten führt eine Auslagerung von Parkplätzen in Außenbezirke in Kombination mit einer Verringerung der Parkplatzgröße um 15 Prozent in den USA zu einer Parkraumeinsparung in Innenstädten von 25 Prozent [20, 123]. Weitere Einsparungen ergeben sich durch den Car-Sharing-Gedanken als individuelles Taxi [76].

Trotz der zu erwartenden enormen positiven Auswirkungen auf alle Lebensbereiche und der seit den 80er Jahren begonnenen Entwicklungstätigkeiten zum vollautomatischen Fahren existieren bis heute keine vollständigen Systeme zur

zuverlässigen Bewältigung der gestellten Aufgabe. Als eines der prominentesten Negativbeispiele gilt das »Tesla Model S«, dessen als »Autopilot« beworbene Fahrfunktion bereits mehrere Unfälle auch mit Todesfolge verursacht hat [31] und in einem internen Gutachten der »Bundesanstalt für Straßenwesen« (Bast) laut [169] als »erhebliche Verkehrsgefährdung« eingestuft wird. Angegeben wird hierfür unter anderem eine unzureichende Sensorabdeckung für Überholmanöver sowie eine »unzureichende Performance« des Notbremssystems. Derzeit käufliche Systeme mit Eingriff in die Fahrzeugaktuatorik beschränken sich daher auf eine Einordnung in die in Abbildung 1.1 dargestellten Automatisierungsstufen »SAE Level« 1 bis 2 als »assistierte« oder »teilautomatisierte« Fahrfunktionen [154], die eine ununterbrochene Überwachung durch den Fahrer voraussetzen und oftmals lediglich Teile der Fahraufgabe automatisieren, wie beispielsweise Notbremss- und Spurhalteassistenten sowie (adaptive) Geschwindigkeitsregelungen. Während die Kombination solcher Funktionen in der Tat in der Lage ist, ein Fahrzeug über längere Strecken auch durch Verkehr und Kurven zu führen, ist eine Vergleichbarkeit mit menschlichen Fähigkeiten nicht annähernd gegeben, obwohl vereinzelt Vermarktungsstrategien dies gezielt nahelegen.

	Steuerung	Systembereich	Verantwortung	Stufe und VDA-Name (SAE-Name)
				0 klassisch (no automation)
z.B. Spurhaltesystem		spezifizierte Anwendungsfälle		1 assistiert (driver assistance)
z.B. Notbremssystem, Distanzregelung (ACC)				2 teilautomatisiert (partial automation)
z.B. Teslas »Autopilot«				3 hochautomatisiert (conditional automation)
				4 vollautomatisiert (high automation)
				5 fahrerlos (full automation)
		überall		

Abbildung 1.1: Automatisierungsstufen nach SAE International Standard J3016.

Die wissenschaftlichen Erfolge der letzten Jahre zeigen enorme Weiterentwicklungen und lassen die Vision der autonomen Mobilität zum Greifen nah erscheinen. Dennoch weisen auch diese Systeme derzeit einen starken Entwick-

lungszuschnitt auf die entsprechenden Anwendungsfälle auf und lassen sich in dieser Weise nicht auf den allgemeinen Straßenverkehr generalisieren. So war die Fahrt auf der »Bertha Benz Memorial Route« zwischen den Städten Mannheim und Pforzheim im Jahr 2013 eines der Großereignisse von Forschung und Industrie im Hinblick auf die Darstellung der technologischen Fähigkeiten auf dem Weg zur autonomen Mobilität und war doch gleichsam geprägt von hochdetaillierten, manuell bearbeiteten Karten und einer Vielzahl an vereinfachenden Annahmen zur Modellierung des Verkehrsgeschehens [192]. Trotz immenser Entwicklungsanstrengungen von Forschung und Automobilindustrie, aber auch von Technologieunternehmen wie Google, existiert derzeit eine deutliche Forschungslücke im Bereich des vollumfänglichen Verständnisses des Verkehrsgeschehens.

Die vorliegende Arbeit hat daher zum Ziel, diese Forschungslücke anhand geometrischer und topologischer Betrachtungen zu adressieren und ein darauf basierendes neuartiges Gesamtkonzept zur Situationsmodellierung und Manöverplanung zu entwickeln.

1.2 Stand der Forschung

Der Themenkomplex der »Bewegung vollautomatischer Fahrzeuge« setzt sich aus vier Ebenen zusammen, bestehend aus einer *Routenplanung* auf einem Straßennetz, einer *Verhaltensentscheidungsebene* als Entscheidungsinstanz für eine Fahraufgabe, einer *Bewegungsplanungsebene* zur Generierung einer Bewegungsfunktion und einer *Regelungsebene* zur Ansteuerung der Aktuatorik [135].

Die mit den Wettbewerben *Grand-* und *Urban Challenges* der Abteilung »Defense Advanced Research Projects Agency« (DARPA) des US-amerikanischen Verteidigungsministeriums in den Jahren 2004, 2005 und 2007 beginnende großflächige Forschungsaktivität um unbemannte, selbstfahrende Fahrzeuge war zunächst geprägt von den Methoden der Robotik, die in einer starken Fokussierung auf Zustandsautomaten resultierte sowie einer Trennung der Bewegungsplanung in longitudinale und laterale Subsysteme. Weiterhin wurden mit den ersten Verfahren rein räumliche *Pfadplanungsprobleme* beschrieben, ohne gleichzeitige Betrachtung der zeitlichen Komponente, die im Nachgang wiederum von anderen

Subsystemen behandelt wurde. Durch die hohe Komplexität dynamischer Situationen bei gleichzeitiger Erhöhung der verfügbaren Rechenkapazitäten finden in den letzten Jahren jedoch vermehrt *Trajektorienplanungsverfahren* Einzug in das Feld der Bewegungsplanung vollautomatischer Fahrzeuge, die beide Komponenten – Zeit und Raum – gleichzeitig einbeziehen.

Im Weiteren wird aufgrund der Einordnung des vorgeschlagenen Ansatzes vornehmlich auf Verfahren der Bewegungsplanung eingegangen, mit Fokus auf numerischen Methoden. Aufgrund einiger Teilaufgaben des Ansatzes, die klassischerweise der Entscheidungsebene zugeordnet werden, folgt ein kurzer Überblick auf Verfahren, die ähnliche Aufgaben als Entscheidungsinstanz übernehmen. Innerhalb des vorgestellten Verfahrens erweist sich die übliche Trennung der beiden Ebenen als mitunter hinderlich aber überwindbar.

1.2.1 Bewegungsplanungsebene

Seit den Wettbewerben der DARPA existiert eine Vielzahl an Algorithmen zur Bewegungsplanung vollautomatische Fahrzeuge, die nach [67] in vier Gruppen gemäß ihrer algorithmischen Grundprinzipien eingeteilt werden können: *Graphensuchbasierte Planungsalgorithmen*, *Sampling-Methoden*, *Kurveninterpolationsalgorithmen* und *numerische Optimierungsalgorithmen*. Daneben existieren weitere Mischformen der vier Grundkategorien sowie die in [67] nicht behandelte Methode der elastischen Bänder, als auch die seit jüngster Zeit prominent werdende Verwendung von modellprädiktiven Regelungen, die sich beide in die letzte Kategorie einordnen lassen. Mit Ausnahme der numerischen Optimierungsalgorithmen und einiger spezieller auf die Zeitkomponente erweiterter Methoden, weisen die in [67] betrachteten Kategorien vornehmlich Ansätze für Pfadplanungsalgorithmen zur rein örtlichen Planung auf. Die Raum-Zeit-Planung der Fahrzeug-Trajektorie ergibt sich in diesen Fällen aus der Kombination mit weiteren Subsystemen, die die Generierung von Geschwindigkeitsprofilen zur Aufgabe haben.

Graphensuchbasierte Planungsalgorithmen

Zu graphensuchbasierten Algorithmen zählen *Dijkstra*- und Derivate des *A*-Algorithmus*, die mitunter in der Urban Challenge bei mehreren Teams zur Generierung von Wegpunkten bei Blockaden [23,127] und unstrukturierten Parkplätzen [9, 93, 194] in unterschiedlichen Ausprägungen Verwendung fanden, wie beispielsweise der *Anytime Dynamic A*-Algorithmus* [48] zur recheneffizienten Neuplanung. Eine mehrfache Anwendung des Dijkstra-Algorithmus in einer Multi-Ebenen-Architektur in Kombination mit B-Splines zur Hindernisvermeidung bei maximaler zulässiger Geschwindigkeit wird in [92] vorgestellt. Eine Erweiterung auf die Zeitkomponente mit einer dynamischen Anpassung der Grid-Auflösung auf die Fahrzeuggeschwindigkeit wird in [24] beschrieben. In [55] werden unterschiedliche graphensuchbasierte Algorithmen auf die Planung kooperativer Manöver zur Vermeidung von Gefahrensituationen angewendet und in [56] mit numerischen Optimierungsmethoden verglichen.

State Lattice Algorithmen – erstmals beschrieben in [141] – stellen die Kombination aus graphensuchbasierten Verfahren und aus mithilfe von Sampling-Methoden aufgebauten Graphen dar, deren einzelne Knoten durch deterministisches Sampling des Konfigurationsraums entstehen, sodass die Kanten fahrbare, geometrische Pfade beschreiben. Neben Erweiterungen auf *Adaptive State-Time Lattices* im Bereich der Robotik [137] existieren erfolgreiche Anwendungen für vollautomatisches Fahren sowohl in unstrukturierten Umgebungen und Blockadesituation in der DARPA Urban Challenge [118] als auch im Kontext strukturierter Fahrsituationen [124, 176, 193].

Samplingbasierte Planungsalgorithmen

Klassische Sampling-Planungsmethoden produzieren Baumstruktur-Graphen durch stichprobenhafte – auf sampling basierende – Erschließung von Pfaden, die bei der Robotik-Bewegungsplanung seit den Anfängen zum Einsatz kommen [94, 111, 112] und noch heute Erweiterungen erfahren [3, 8, 88, 158]. Im Gegensatz zu graphensuchbasierten Verfahren resultiert das Erreichen der Zielregion oftmals in der Terminierung des Bewegungsplanungsprozesses, ohne die Suche einer weiteren, besseren Lösung. Vornehmliche Verwendung im Bereich

der selbstfahrenden Fahrzeuge findet die Methode *Rapidly-Exploring Random Tree* (RRT), die in ihrer allgemeinen Form kinematische Beschränkungen integriert und zunächst mit einer Begrenzung der *Zweige* in der DARPA Grand Challenge [27] Verwendung fand. Die Betrachtung des Systems als geschlossener Regelkreis durch ein Sampling aus Stellbefehlen wurde im MIT-Fahrzeug »Talos« in der DARPA Urban Challenge [106] eingesetzt sowie in der im Jahr 2010 ausgerichteten *Hyundai-Kia Autonomous Vehicle Competition* [153]. Andere Erweiterungen ergeben sich aus der Einbeziehung von Unsicherheiten der Umgebung und zugehöriger Risikobewertung [6], der Verwendung von RRTs innerhalb der Planung kooperativer Manöver mehrerer vollautomatischer Fahrzeuge [91] oder der Anpassungen auf fahrdynamisch anspruchsvolle Fahrsituationen [89].

Kurveninterpolationsalgorithmen

Kurveninterpolationsalgorithmen stellen eine weitere prominente Methode zur Planung von Bewegungen automatischer Fahrzeuge dar, die berechnete Knoten oder Wegpunkte unter Berücksichtigung des Fahrzeugumfelds und kinematischer Nebenbedingungen in glatte Pfade transformieren. Neben der Kombination von *Linien-* und *Kreissegmenten* [81, 146] werden zumeist komplexere Kurvengeometrien zur Bewegungsplanung eingesetzt.

Ein Beispiel hierfür stellen *Klothoiden* dar, die durch eine lineare Krümmungsänderung zu glatten Kurven an Segment-Verbindungsstücken führen und oftmals zur Bewegungsplanung verwendet werden, beispielsweise im Bereich der Robotik in [51]. Neben der erfolgreichen Anwendung von Klothoiden bei der *VisLab Intercontinental Autonomous Challenge* [33] – eine automatische Fahrt von etwa 16.000 km in 100 Tagen durch 9 Länder – werden die speziellen Kurven in [58] für maximale Kurveneinfahrts- und -ausfahrtsgeschwindigkeiten im fahrdynamischen Grenzbereich eingesetzt.

Im Gegensatz zu Klothoiden bieten *polynomielle Kurven* weitere Freiheitsgrade zur Beschreibung der Pfadgeometrie. So verwendet beispielsweise [140] quartische Polynome zweifacher geometrischer Stetigkeit zur Interpolation eines allgemeinen Pfadverlaufs oder [138] kubische Polynome für die Beschreibung eines in drei Stufen eingeteilten Überholmanövers. Eine Kombination der State

Lattice Methode aus [124] zur Generierung rein ortsbezogener Knoten mit quartischen Polynomen als Kanten zusammen mit der Berechnung von Geschwindigkeitsprofilen als kubische, über Bogenlänge parametrisierte Polynome wird in [186] vorgestellt.

Stückweise polynomielle Kurven mit definierten Glattheitsbedingungen an Segment-Verbindungspunkten werden als *Splines* bezeichnet und wurden bereits bei der DARPA Urban Challenge zur Generierung von Referenzpfaden innerhalb eines Fahrstreifens und zur Überquerung von Kreuzungen eingesetzt [9]. Weitere Beispiele der Spline-Verwendung sind in [161] die Bewegungsplanung auf unebenem Terrain und in [17] eine Hindernisumfahrung für Bergbaufahrzeuge auf straßenähnlichem Gelände.

Eine spezielle Form der Kurveninterpolation sind die *Bézierkurven*, die an jedem Stützpunkt zusätzliche Kontrollpunkte – in der Regel abseits der Kurve – zur Formbestimmung nutzen. Unterschiedliche Eigenschaften ergeben sich durch die Anzahl an Kontrollpunkten, beschrieben als die Ordnung der Bézierkurven beginnend mit Ordnung 1 als lineare Verbindung zwischen Start- und Endpunkt. So werden beispielsweise zur Planung von Hindernisumfahrungen in [74] Bézierkurven 4-ter Ordnung, und in [66] Bézierkurven der Ordnung 3 oder 4 in Abhängigkeit von weiteren Nebenbedingungen verwendet. Dabei kann die Bestimmung der Kontrollpunkte unter Berücksichtigung von Straßen- und Fahrzeuggeometrien geschehen und so bereits während der Kurvengenerierung eine Vorauswahl geeigneter Ergebniskurven getroffen werden [145]. Ein Vergleich zwischen kubischen Splines, trigonometrischen Splines und der Kombination von Geradensegmenten, Kreisen und Klothoiden über eine simulative Evaluation eines Pkw-ähnlichen Fahrzeugs wird in [107] gegeben.

Numerische Optimierungsmethoden

Durch immer leistungsfähigere Fahrzeughardware, wie beispielsweise die auf Fahrzeug-Anwendungen spezialisierte Grafikkarte NVIDIA DRIVE PX [133], nehmen auch rechenintensive Ansätze Einzug in die Bewegungsplanung vollautomatischer Fahrzeuge. Vor allem in den letzten Jahren gehen diese Ansätze von einer Pfadplanung in eine Trajektorienplanung über.

Numerische Optimierungsverfahren können einerseits zur Glättung von bereits generierten nicht-glatten Pfaden verwendet werden, wie beispielhaft in [41], dessen mit einem A*-Algorithmus gefundener Pfad in einem zweistufigen Prozess unter Einhaltung der Kollisionsfreiheit über das iterative *konjugierten Gradientenverfahren* [78] in einer glatten Kurve resultiert. Andererseits können numerische Optimierungsmethoden zur direkten Bewegungsplanung eingesetzt werden, wovon erste Einsätze bereits während der DARPA Grand Challenge Anwendung fanden, jedoch aufgrund begrenzter Rechenkapazität mit einer starken Reduktion der Optimierungsparameter, wie beispielhaft in [37] auf eine reduzierte Optimierung der Parameter eines quadratischen Splines zur lateralen Planung und linearen Splines zur longitudinalen Planung. Das Gewinnerfahrzeug »Boss« der DARPA Urban Challenge der Carnegie Mellon University verwendete zur Bewegungsplanung in strukturierten Umgebungen einen *modellprädiktiven Ansatz* zur numerischen Generierung von Spline-Kandidatentrjektorien unter Berücksichtigung fahrdynamischer Nebenbedingungen [173], der zur Reduktion der notwendigen Rechenkapazität mit einer situationsabhängigen Auswahl aus vier Geschwindigkeitsprofilen und einer Lookup-Tabelle an Startlösungen kombiniert wurde [49].

Die ursprünglich in der Robotik zur Pfadplanung unter lokaler Hindernisvermeidung verwendete *Methode der elastischen Bänder* – beispielsweise erstmalig in [144] sowie weiter in [32, 97, 139, 143] – basiert auf der Modellierung des Pfads als Feder-Masse-System einzelner Stützpunkte innerhalb eines Potenzialfelds, dessen Gleichgewicht über iterative Optimierungsverfahren berechnet wird. Anwendungen im Automotive-Bereich sind beispielsweise die Planung von Notfallmanövern über die Optimierung eines einzelnen elastischen Bands [80] sowie mehrerer elastischer Bänder [156] und die Planung von Folgefahrtsituationen mit geschwindigkeitsabhängigen Potentialfeldern zur Erhöhung des Sicherheitsabstands für hohe Fahrtgeschwindigkeiten [60].

Erweiterungen der klassischen Methodik ergeben sich über die Einbeziehung der Fahrzeugdynamik in Form von zusätzlichen internen Kräften zwischen Stützpunkten [77] oder einer Kombination mit anderen Verfahren, wie beispielsweise im Rahmen des Projekts »Stadtpilot« der Technischen Universität Braunschweig, in dem eine Verbindung von elastischen Bändern zur Minimierung der

Krümmungsmaxima mit mehrfachen Spline-Interpolationen eingesetzt wurde, um minimale Krümmungseigenschaften des Pfads zu erzielen [185]. Die Einführung von Knotenübergangszeiten führt zur *Timed Elastic Bands*-Methode [148], die für Folgefahrtverhalten im Projekt »AutoNOMOS Labs« der Freien Universität Berlin zur Methode der *Stable Timed Elastic Bands with loose Ends* weiterentwickelt wurde [172]. Hierbei wird die Vorgabe eines festen Endpunkts aufgehoben und ersetzt durch Anziehungskräfte hin zur Trajektorie eines vorausfahrenden Fahrzeugs. Daneben wird die Methode der elastischen Bänder in [52–54] auf die Bewegungsplanung kooperativer Fahrmanöver zur Generierung von Trajektorien mehrerer, sich in einer kooperativen Gruppe nach [57] befindlicher Fahrzeuge, zur Auflösung von Gefahrensituationen erweitert.

Eine weitere numerische Methode der Bewegungsplanung ergibt sich bei Verwendung der *Optimalsteuertheorie*, die unter Berücksichtigung eines Fahrzeugmodells und Nebenbedingungen optimale Stellbefehle findet, gegeben einer Zielfunktion zur Qualitätsbewertung. Zur Lösung der Trajektorienplanungsaufgabe wird in [182] eine Vielzahl unrestringierter Optimalsteuerprobleme – also ohne Berücksichtigung harter Nebenbedingungen – zur Minimierung des quadratischen Rucks gelöst, die in einem anschließenden Schritt auf die Einhaltung der physikalischen Nebenbedingungen, sowie Kollisionsfreiheit hin geprüft werden. Eine Separierung von longitudinaler und lateraler Bewegung führt zusammen mit einem an State Lattices orientierten Sampling von zugelassenen Endpositionen in [181] zu zwei Sätzen an longitudinalen und lateralen Teil-Trajektorien, die in unkritischen Situationen und für hohe Geschwindigkeiten kombinatorisch verbunden eine Menge an Optimaltrajektorien (des reduzierten Problems) ergeben, aus der schließlich die beste zulässige Trajektorie als Planungsergebnis ausgewählt werden kann. Dabei beschreiben unterschiedliche Berechnungsformeln der Endzustände unterschiedliche longitudinale Fahrmodi – wie beispielsweise Folgen, Stoppen, Einscheren – mit einer Verhaltensentscheidungsinstanz mittels *Override Control*-Methode nach [65], die gemäß eines Minimum-Operators den initialen Longitudinal-Ruck über alle zulässigen Lösungstrajektorien der Fahrmodi minimiert.

Andere Ansätze des Optimalsteuerproblems integrieren Reifenmodelle für fahrdynamisch anspruchsvolle Manöver [19], verwenden Fahrzeugmodelle mit Ge-

wichtsverteilung [150], kombinieren Optimalsteuerprobleme mit Potenzialfeldmethoden zur Beschreibung von Hindernissen [12, 39] oder ergänzen das Optimalsteuerproblem mit einer unterliegenden Regelung auf die Trajektorie über Entkopplung und Linearisierung des als Mehrgrößensystem modellierten Fahrzeugs [159]. In [59] wird eine Anwendung auf »automatisiertes Kolonnenfahren« hinter menschlichen Fahrern mit teilweise kommunizierenden Fahrzeugen beschrieben. Eine longitudinal und lateral kombinierte Trajektorienplanung über ein nichtlineares Optimalsteuerproblem wird in [157] für Autobahnfahrten vorgestellt, in der eine Sampling-Strategie zur echtzeitfähigen Berechenbarkeit angewendet wird basierend auf der Vermeidung von Samples in potentiell zukünftig belegten Regionen, deren Berechnung über eine probabilistische Prädiktion anderer Verkehrsteilnehmer geschieht.

Auf zyklische Neuplanung mit begrenztem und sich mitbewegendem Planungshorizont angepasste Optimalsteuerprobleme führen zu den verbreiteten Methoden *modellprädiktiver Regelungen*, die beispielsweise verwendet werden innerhalb [18,21,44,46,130,187,188]. Dabei ergeben sich die Unterschiede in den einzelnen Ansätzen durch unterschiedliche Fahrzeugmodelle und gegebenenfalls Linearisierungen zur Vorwärtssimulation des Bewegungsverhaltens, unterschiedliche Bewertungsterme innerhalb der Zielfunktion, der Integrationsweise von physikalischen Nebenbedingungen und der Berücksichtigung des Fahrzeugumfelds. Beispielsweise wird in [129] die Integration von Unsicherheiten durch eine Modellierung sowohl der eigenen Fahrzeugposition, als auch anderer dynamischer Hindernisse über »(Extended-)Kalman Filter« realisiert und über eine Ellipsendarstellung in deterministische Nebenbedingungen transformiert. Weitere Ansätze ergeben sich durch Kombinationen mit anderen Methoden, beispielsweise mit der Methode der elastischen Bänder in [149] oder durch eine aufeinander aufbauende modellprädiktive Regelung für longitudinale und laterale Bewegungen [171].

In [119] werden zwei unterschiedliche modellprädiktive Planungsalgorithmen für die Lateralbewegung in Kombination mit einem Geschwindigkeitsprofilgenerator für Transport-Nutzfahrzeuge vorgeschlagen. Die Verwendung eines *Clothoid-based Model Predictive Controller* mit der Beschreibung der Fahrzeugbewegung über die Krümmungsänderung ermöglicht dabei ein langes Prädik-

tionsintervall bei gleichzeitiger geringer Rechenlast, indem die Optimierung der Fahrzeugparameter lediglich an einigen wenigen Wegpunkten notwendig wird. Weiterhin wird ein *Economic Model Predictive Controller* beschrieben, der die Bewertungsfunktion durch eine Minimierung der ersten beiden Krümmungsableitungen zu linearen Krümmungen und damit wiederum zu klothoid-ähnlichen Bewegungsprofilen überführt.

Zur Berücksichtigung von Aktuatorunsicherheiten wird in [116] ein stochastisch-dynamisch-zeitdiskretes Fahrzeugmodell vorgeschlagen, das zusammen mit der Modellierung von stochastischen Nebenbedingungen für die Beschreibung von Sensorunsicherheiten von Objekten als *Chance Constraint Stochastic Model Predictive Controller* bezeichnet und in [96] mit einem konservativen Verfahren ohne Unsicherheitsbetrachtungen verglichen wird.

Eine Verknüpfung von kontinuierlichen und logischen Nebenbedingungen wird in [142] zur Modellierung der Trajektorienplanungsaufgabe als *Mixed-Integer Quadratic Program* vorstellt. Dabei werden beispielsweise Verkehrsregeln, aber auch Objekte als boolesche lineare Bedingungen einer Zustandsvariablen beschrieben. Die Lösung ergibt sich durch die Verwendung eines quadratischen Bewertungsfunktional mit linearen Nebenbedingungen als global optimale Trajektorie.

Die Berücksichtigung von dynamischen Objekten als zeitvariante Nebenbedingungen resultiert in einem *Linear Time-Varying Model Predictive Controller* und wird in [70] für laterale und in [72] für longitudinale Bewegungsplanung eingesetzt. Dabei wird die Kombination beider Bewegungsanteile als Ausblick in [71] gegeben, indem mehrere lokal-optimale Längsbewegungen als Geschwindigkeitsprofile kombinatorisch zusammengeführt werden sollen mit einer darauf basierenden Optimierung der Querbewegung. Innerhalb desselben Verfahrens ermöglicht die Verwendung von Schlupfvariablen eine Beeinflussung der Trajektorienform, um einen optimalen Kompromiss zwischen Sicherheit und Komfort der Fahrzeuglängsbewegung zu bewirken [25].

Im Gegensatz zu Optimalsteuerproblemen und modellprädiktiven Regelungen – die über die Optimierung der Stellbefehle indirekt eine optimale Fahrzeugbewegung generieren – kann mittels der *Variationsrechnung* eine direkte Optimierung der Bewegung geschehen. Die Euler-Lagrange-Gleichung der Varia-

tionsrechnung ermöglicht dabei die analytische Berechnung des Gradienten zur numerischen, iterativen Optimierung der Trajektorie, wie ausführlich in Kapitel 2 beschrieben wird. Die Trajektorienplanungsaufgabe wird dabei über die Minimierung eines Funktionals modelliert, das zur Bewertung der Trajektorie dient. Das in 2013 auf der etwa 100 km langen »Bertha Benz Memorial Route« zwischen den Städten Mannheim und Pforzheim erfolgreich eingesetzte Verfahren modelliert als sogenanntes *Energiefunktional* eine gewichtete Summe quadratischer Bewertungsterme für den Abstand zum rechten und linken Fahrbahnrand, der Fahrzeug-Geschwindigkeit, -Beschleunigung und des -Rucks sowie der Orientierung [190]. Interne Nebenbedingungen begrenzen die maximale Krümmung und gemäß des *kammschen Kreises* aus [134] die maximal zulässige Beschleunigung in laterale und longitudinale Bewegungsrichtung. *Externe Nebenbedingungen* resultieren aus der Fahrzeugumgebung, die aus einem Fahrkorridor, einer Offline-Karte und relevanten Objekten bestehen. Dabei werden die Hindernisse als Polygone modelliert und von einer Entscheidungsinstanz einem der beiden Fahrbahnränder zugeordnet, sodass die Problemformulierung zusammen mit der quadratischen Bewertungsfunktion ein einziges – globales – Optimum enthält. Aufgrund der Limitationen, die sich durch die spezielle Problemformulierung ergeben, wird zusätzlich laut [190] eine kombinatorische Entscheidungsinstanz nötig, die Lösungen für komplexe Verkehrssituationen, wie beispielsweise »Engpass-« und »Einfädelsituationen« liefert.

Abschließend wird in [75] ein neuartiges Zielfunktional vorgeschlagen, das neben der Hindernisvermeidung und Komfortoptimierung eine Bewertung des Sichtbereichs in die Planung integriert und damit zusätzlich die Umgebungswahrnehmung eines Fahrzeugs optimiert.

1.2.2 Verhaltensentscheidungsebene

Wie bereits beschrieben, zeigte sich in den Anfängen der DARPA Challenges ein starker Fokus der Verhaltensentscheidungsebene auf die Modellierung mit Zustandsautomaten. So navigierte das Fahrzeug »Stanley« der Stanford University als Gewinner der ersten erfolgreich zum Abschluss gebrachten DARPA Grand Challenge 2005 zwar noch mit einem minimalistischen Zustandsautomaten innerhalb eines einzigen Fahrzustands durch die Wüste Nevadas [168];

für die anschließende DARPA Urban Challenge machten die Herausforderungen des urbanen Verkehrs jedoch eine Erweiterung des bestehenden Zustandsautomaten auf weitere Fahrzustände für konkrete Fahrsituationen notwendig, wie beispielsweise Kreuzungsüberquerung, Stoppzeichenbehandlung und Vorwärtsfahrt [127]. Damit erreichte das Stanford-Team mit »Junior« den zweiten Platz. Neben dem drittplatzierten »Odin« der Virginia Polytechnic Institute and State University [9] sowie zahlreichen anderen Wettbewerbsteilnehmern [34, 180] verwendete auch das Gewinnerteam der Carnegie Mellon University mit Fahrzeug »Boss« einen Zustandsautomaten als Entscheidungsinstanz für die Wahl geeigneter Bewegungsziele.

Die Verwendung von Zustandsautomaten in der Verhaltensentscheidungsebene zur Strukturierung des komplexen Verkehrsgeschehens besitzt durch die notwendige manuelle Festlegung einer festen Menge an Situationsklassen jedoch deutliche Limitationen und führte in den letzten Jahren zur Etablierung neuer, zustandsautomatenfreier Ansätze zur Entscheidungsfindung.

Zustandsautomatenfreie Verhaltensentscheidungsebene

Zur zustandsautomatenfreien Entscheidungsplanung longitudinaler Fahrstrategien wird in [85] ein Ansatz vorgeschlagen, der über einen heuristikgeleiteten A^* -Algorithmus ein Bewertungsfunktional minimiert, dessen Schrittkosten sich aus der Durchführung einer Beschleunigungsaktion in einem Zustand, Geschwindigkeitskosten und Umgebungskosten – modelliert über Events, die eine Ort-Zeit-Kombination bestrafen – zusammensetzen. Der Verhaltensentscheidungsplaner resultiert in einer longitudinalen Langzeitfahrstrategie von über 10 Sekunden, deren erste 3 Sekunden dem Bewegungsplaner aus [182] zur numerischen Berechnung der optimalen Trajektorie übergeben werden. Dabei ergeben sich für die Verhaltens- und Bewegungsplanungsebene unterschiedliche Optimierungskriterien. Über die probabilistische Modellierung von Fahrzeug- und Verkehrsteilnehmerzuständen ergibt sich eine Erweiterung des Ansatzes auf Mess- und Verhaltensunsicherheiten als *Partially Observable Markov Decision Process* mit einem *Naive Bayes Classifier* in [86].

Ausgehend von der Annahme vollständigen Wissens wird in [28] zur Handhabung unsicheren zukünftigen Verhaltens anderer Verkehrsteilnehmer die Modellierung der Entscheidungen als *Markov Decision Process* mit symbolischen Zuständen eines *Dynamic Bayesian Networks* als Transitionsmodell vorgeschlagen. Dabei führt die Kombination von Offline-Planungen üblicher Standardsituationen mit konkreten Online-Entscheidungsberechnungen zu einem echtzeitfähigen Algorithmus. Die Erweiterung in [30] auf unvollständiges Wissen führt wiederum zu einem Partially Observable Markov Decision Process mit einer kontinuierlichen Situationsbeschreibung basierend auf den Zuständen anderer Verkehrsteilnehmer und ist effizient mit [29] berechenbar. Das Prozessmodell – modelliert als *hierarchisches bayessches Modell* nach [63] – besteht aus dem Verhalten und der Interaktion der anderen Verkehrsteilnehmer sowie der Fahrtdynamik und vorhandenem Hintergrundwissen, beispielsweise aus Kartendaten.

Eine, auf der Identifikation von kombinatorischen »Manövervarianten« basierende Entscheidungsinstanz wird in [14] vorgeschlagen, die iterativen Planungsverfahren zur Generierung von Startlösungen dienen kann. Hierfür wird über die Methode der Mittelachsentransformation nach [114] ein »Freiraumskelett« des Raum-Zeit-Planungsvolumens erschlossen, dessen Liniensegmente den Planungsraum mit maximaler Distanz zu Hindernissen durchtrennen und damit die einzelnen Manövervarianten darstellen. Weiterführend wird in [15] eine kombinatorische Beschreibung der einzelnen Manövervarianten unter Anwendung einer Heuristik zur Lösungsraumbegrenzung eingeführt, die zur Modellierung von Nebenbedingungen und zur Begrenzung des Planungsvolumens dient.

In [102] wird das Verkehrsgeschehen und dessen Evolution ontologie- und geometrie-basiert als *semantischer Zustandsraum* innerhalb eines Graphen mit gegenseitigen Relationen und Bedingungen modelliert, was über Graphensuchalgorithmen in einer Kette an High-Level-Manövern als Vorgabe für eine Bewegungsplanungsinstanz resultiert. Die in [103] beschriebene Erweiterung auf fahrphysikalische Betrachtungen ergibt sich über die Verwendung eines *Sichtbarkeitsgraphen* zur Geschwindigkeitsprofilberechnung nach [90] in einer Pfad-Zeit-Beschreibung der Situation.

1.2.3 Fahrzeugmodellierung

Fahrzeugmodelle sind für die Einhaltung realisierbarer Bewegungen innerhalb der Planung notwendig. Sie können je nach Anwendungsbereich und gewünschten Freiheitsgraden in Einspurmodell, Zweispurmodell und Mehrkörpersysteme eingeteilt werden [160]. Dabei beschreibt das *Zweispurmodell* die Bewegung des Fahrzeugs im dreidimensionalen Raum mit sechs Freiheitsgraden, deren translatorischer Anteil über den Impulserhaltungssatz modelliert wird [87]. Durch Trägheitsmomente können Wank-, Nick- und Gierbewegungen in das Fahrzeugmodell integriert werden. Im Gegensatz dazu ergibt sich das *Einspurmodell* aus der Vereinfachung der Zweispurmodellierung über eine Transformation in ein ebenes Problem auf Fahrbahnebene mit einer Projektion der Hinter- und Vorderräder auf jeweils ein mittleres Rad [87]. Daraus resultiert ein Modell mit drei Freiheitsgraden unter Vernachlässigung von Wank- und Nick-Bewegungen, wobei oftmals unterschieden wird zwischen dem *kinematischen Einspurmodell* für die Modellierung der Querdynamik und dem *dynamischen Einspurmodell* unter Verwendung von Reifenmodellen zur Beschreibung des Reifen-Fahrbahn-Kontakts für die Längsdynamikmodellierung. *Mehrkörpersysteme* beschreiben das Fahrzeugverhalten als kinematische Kette mehrerer Starrkörperkomponenten, die über reale und virtuelle Gelenke miteinander verbunden sind und stellen damit die komplexesten und rechenintensivsten Fahrzeugmodelle dar, die üblicherweise in Spezialanwendungen eingesetzt werden, wie beispielsweise Unfallsimulationen [160].

Bei der Auswahl eines geeigneten Fahrzeugmodells ist entsprechend zwischen benötigtem Detaillierungsgrad und resultierendem Rechenaufwand abzuwägen. Aufgrund der begrenzten Rechenkapazität werden innerhalb der Bewegungsplanung vollautomatischer Fahrzeuge im Allgemeinen Varianten des Einspurmodells verwendet. Eine Ausnahme stellt [35] mit einem Zweispurmodell zur modellprädiktiven Regelung dar.

Simple Einspurmodelle mit kinematischen und dynamischen Nebenbedingungen werden beispielsweise innerhalb Graphensuch- oder Sampling-Algorithmen zur Bewegungsplanung ausgewählt [106,168] sowie zur Prädiktion von Bewegungen anderer Verkehrsteilnehmer, beispielsweise über einen »Unscented-

Kalmanfilter-Ansatz« in [11]. Dabei werden Einspurmodelle selbst für fahrdynamisch anspruchsvolle Manöver verwendet, die zur Erhöhung der Simulationsgenauigkeit detailliert Reifenmodelle integrieren, wie beispielhaft in [13, 58, 80]. Unterschiede in den verwendeten Modellen, die auf den Vereinfachungen des Einspurmodells basieren, ergeben sich bei der Modellierung als lineares oder nichtlineares System, der Art der Linearisierung und der verwendeten Regel- und Zustandsparameter. Ein nichtlineares Einspurmodell wird beispielsweise in [157] verwendet, wohingegen um den Operationspunkt linearisierte Modelle in [45, 187] zur Bewegungsplanung vorgeschlagen werden. Eine linearisierte Beschreibung der Fahrzeugbewegung in Bezug auf den Referenzpfad über einen Abstands- und Orientierungsfehler wird in [99] hergeleitet. Die Modellierung der Fahrzeugbewegung als *lineares zeitvariantes Systemmodell* mit der Geschwindigkeit als zeitlich variierendem Parameter in einem erweiterten Einspurmodell wird in [70] zur modellprädiktiven Bewegungsplanung aufgestellt. Als Regelparameter wird dabei die Krümmungsänderung gewählt, wie auch in [116] in Kombination mit der Beschleunigung als zweite Stellgröße. Eine Erweiterung des Einspurmodells auf die Berücksichtigung der Gewichtsverteilung für Wank- und Nickbewegungen wird in [150] vorgestellt.

Abschließend wird in [4] ein aussagekräftiges und gleichzeitig rechenaufwandsarmes Fahrzeugmodell für fahrdynamische Grenzmanöver hergeleitet, das über eine samplingbasierte Approximation eines vorwärtssimulierten Zweispurmodells mit entsprechend gewählten Randbedingungen eines *Doppelintegratorsystems* zu einem detaillierten Fahrzeugmodell führt.

Inverse Fahrzeugmodelle

Die im vorherigen Abschnitt vorgestellten Modelle stellen allesamt Fahrzeugmodelle zur Vorwärtssimulation dar, die den Einfluss von Regelgrößen auf den Fahrzeugzustand modellieren. Sie werden üblicherweise eingesetzt für eine Bewertung der zukünftigen Fahrzeugbewegung hinsichtlich Kollisionsfreiheit und Komforteigenschaften. Innerhalb modellprädiktiver Planungsverfahren wird die Optimierung der Fahrzeugbewegung dabei über die Vorwärtssimulation mit einer Vielzahl an unterschiedlichen Stellbefehlen durchgeführt und so die optimale

Trajektorie berechnet. Dieser rechenintensive Prozess durch multiple Vorwärtssimulationen macht daher üblicherweise die Verwendung einfacher und rechenaufwandsarmer Fahrzeugmodelle notwendig.

Im Gegensatz dazu geht die Bewegungsplanung auf Basis der Variationsrechnung den umgekehrten Weg, indem eine direkte Optimierung der Trajektorie unter Berücksichtigung der Regelparameter als Nebenbedingungen durchgeführt wird. Zur Berechnung der Regelparameter wird dabei ein *inverses Fahrzeugmodell* nötig, das entsprechende Größen aus der Trajektorie über differentialgeometrische Beziehungen extrahiert. Neben den Regelparametern können über das inverse Fahrzeugmodell weitere Trajektorieneigenschaften berechnet werden, die beispielsweise eine Bewertung des Komforts über den Beschleunigungsverlauf ermöglichen. Die Einsparung der Vorwärtssimulation resultiert in Bezug auf die Fahrzeugmodellierung in einem rechenaufwandsarmen Planungsprozess.

Aus der Fokussierung der derzeitigen Forschungsentwicklungen auf Verfahren der modellprädiktiven Regelung existiert wenig Literatur im Bereich der inversen Fahrzeugmodellierung, was die ausführliche Herleitung des C^2 -Modells in Abschnitt 4.1 begründet. Eine Ausnahme findet sich dabei in [190] aufgrund der Verwendung der Variationsrechnung zur Bewegungsplanung, sodass dort die für das konkrete Bewertungsfunktional notwendigen Geometriebeziehungen beschrieben werden, jedoch ohne Diskussion des dahinterstehenden inversen Fahrzeugmodells mit resultierenden vereinfachenden Annahmen.

1.2.4 Interaktionsmodelle

Heutiges Verkehrsgeschehen ist geprägt von menschlichem Fahrverhalten, das eine direkte Beeinflussung der Situation durch eigene Handlungen vorsieht, wie beispielsweise das Ausparken in den fließenden Verkehr ohne eine ausreichende Lücke für die ungehinderte Durchführung des vollständigen Manövers abzuwarten, sondern damit eine Interaktion mit anderen Verkehrsteilnehmern zu erzwingen. Die Einbeziehung solcher Mechanismen in die Bewegungsplanung vollautomatischer Fahrzeuge beschreibt ein bis dato wenig beachtetes Forschungsfeld der Trajektorienplanung.

Eine Ausnahme stellt dabei [43] dar, in der eine Trajektorienplanung beschrieben wird, die Reaktionen anderer Verkehrsteilnehmer auf das eigene geplante Verhalten berücksichtigt. Durch die Vorwärtssimulation einer Vielzahl an Kandidatentrajektorien ohne Interaktionsbetrachtungen wird in einem daran anschließenden Schritt das Fahrverhalten anderer Verkehrsteilnehmer als Reaktion auf die einzelnen Kandidatentrajektorien prädiziert und die sich ergebenden Situationen gemäß Sicherheits- und Komfortkriterien bewertet, um die beste interaktive Trajektorie zu erhalten.

Ansonsten beschränken sich Interaktionsmodelle des derzeitigen Stands der Forschung typischerweise auf die Beschreibung menschlichen Fahrverhaltens unter Berücksichtigung des Verkehrsgeschehens und ergeben sich aus einer *reinen Beobachterperspektive* ohne Gestaltungsanspruch und lediglich zum Zweck der Verhaltensprädiktion. Beispiele modellieren oftmals Teilverhalten, wie das über Differentialgleichungen beschriebene longitudinale Folgeverhalten der prominenten Modelle von »Wiedemann« [184] oder »Gipps« [64], die Geschwindigkeitsanpassungen basierend auf vorausfahrenden Fahrzeugen abbilden. Erweiterungen basieren auf der Betrachtung mehrerer vorausfahrender Fahrzeuge [117] und der Berücksichtigung kooperativer Systeme [36].

Weitere Verhaltensmodelle ergeben sich über die Modellierung von *intelligenten Agenten* für Spurwechselerhalten in [79], deren Entscheidungen sich aus dem erwarteten Sicherheitsabstand zum Ende des Manövers ableiten, oder der Verwendung probabilistischer Netze in [38,62] unter Berücksichtigung lokaler Kontextparameter wie relativer Abstand und Geschwindigkeit. Auf eine Prädiktion der Interaktion von Fußgängern angewendete *Social Force Models* [113] werden in [5,84,104] auf die Einbeziehung von Fahrzeugen generalisiert und in [151] mit Modellen der Spieltheorie für Einfädelentscheidungen kombiniert. Das bekannte auf *zellulären Automaten* basierende »Nagel-Schreckenberg-Modell« [131] zur Beschreibung von Fahrerverhalten auf Schnellstraßen findet schließlich Erweiterungen in [109,121].

1.3 Über diese Arbeit

1.3.1 Projektkontext der Arbeit

Die Dissertation entstand im Rahmen des von »Valeo Schalter und Sensoren GmbH« von Mitte 2012 bis Mitte 2016 geförderten Dissertationsprojekts »V50« zur Erforschung vollautomatischen Fahrens. Neben dem Fraunhofer Iosb waren weitere Partner aus Deutschland, Frankreich und Irland beteiligt.

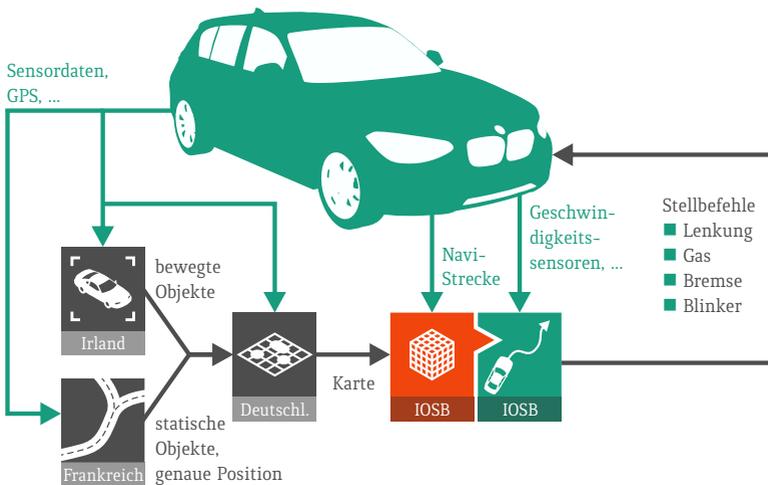


Abbildung 1.2: Technischer Projektüberblick des Dissertationsprojekts »V50«. Basierend auf einer dynamischen Karte hatte das Iosb Situationsinterpretation, Manöverplanung und Regelung zur Aufgabe.

Das Projekt hatte zum Ziel, neue Ansätze aus dem gesamten Gebiet vollautomatischen Fahrens zu erforschen, beginnend mit der visuellen Erfassung anderer Verkehrsteilnehmer (Irland) und der Eigenlokalisierung, Aufbereitung von Verkehrsregeln und Straßeninformationen vornehmlich im Kreuzungsbereich (Frankreich). Eine Fusion dieser und weiterer Daten in eine detaillierte *dynamische Karte* (Deutschland) sollte dem Iosb zur Situationsinterpretation, Manöverplanung und Regelung des Fahrzeugs dienen. Neben der wissenschaftlichen Weiterentwicklung der einzelnen Teilgebiete sollte eine gemeinsame Demons-

tration in einem Versuchsträger stattfinden. Abbildung 1.2 gibt einen thematischen Projektüberblick.

Aufgrund der begrenzten Verfügbarkeit und Bereitstellung von Spezifikationen, Sensordaten sowie Versuchsträgern wurde am Ende des dritten Projektjahres in Abstimmung mit Valeo eine Neuausrichtung der Arbeit auf eine theoretische Analyse der Problemmodellierung vollautomatischen Fahrens beschlossen.



Abbildung 1.3: Versuchsfahrzeug für Technologie-Experimente (VERTEX) des Fraunhofer Iosb. Versuchsfahrzeug zur Evaluation des in Abschnitt 4.1 hergeleiteten inversen C²-Modells.

Über das daran anschließende Projekt »Profilregion Mobilitätssysteme Karlsruhe«¹ zusammen mit der Bereitstellung einer Investition aus dem zentralen Strategiefonds der Fraunhofer-Gesellschaft wurde die Umrüstung von insgesamt zwei Versuchsträgern zur Erforschung unterschiedlicher Aspekte vollautomatischen Fahrens am Iosb finanziert. Die seit September 2017 zur Verfügung stehenden »Versuchsfahrzeuge für Technologie-Experimente« (VERTEX) besitzen zum Zeitpunkt der Fertigstellung dieser Arbeit keine hinreichende Prozessierungskette zur Umfeldwahrnehmung, sodass die praktische Erprobung des Trajektorienplanungskonzepts im Realbetrieb sich lediglich im Ausblick auf

¹ Gefördert aus Mitteln des Ministeriums für Wirtschaft, Arbeit und Wohnungsbau Baden-Württemberg und als nationales Leistungszentrum aus Mitteln der Fraunhofer-Gesellschaft.

kommende Arbeiten wiederfindet. Die Evaluation des in Abschnitt 4.1 hergeleiteten C^2 -Modells mit Realdaten wurde jedoch mit dem ersten Versuchsträger – einem Vw eGOLF VII gezeigt in Abbildung 1.3 – durchgeführt.

1.3.2 Eigene Beiträge zum Stand der Forschung

Die Arbeit hat zum Ziel, allgemeine Aussagen über das Themenfeld der Bewegungsplanung für vollautomatisches Fahren zu entwickeln, um ein umfassendes Problemverständnis unabhängig von Einschränkungen aufgrund sensorischer oder algorithmischer Gegebenheiten zu erlangen. Dabei liegen die wesentlichen Beiträge der Arbeit in der Analyse der \hookrightarrow topologischen und \hookrightarrow geometrischen Eigenschaften des Trajektorienraums sowie in der Entwicklung eines darauf basierenden neuartigen Trajektorienplanungskonzepts namens \hookrightarrow Situation Prediction and Reaction Control Konzept (SPARC).

Situation Prediction and Reaction Control Konzept (SPARC)

Im Gegensatz zu den in Abschnitt 1.2 beschriebenen Ansätzen, die die Bewegung vollautomatischer Fahrzeuge hierarchisch in einzelne Ebenen durch spezialisierte *Subsysteme* aufteilen, reicht das in dieser Arbeit vorgeschlagene Konzept zur Trajektorienplanung über mehrere Ebenen hinweg. Neben der Möglichkeit, Steuerbefehle direkt auf die Fahrzeugaktuatorik zu geben, kombiniert das vorgeschlagene SPARC-Konzept die Verhaltensentscheidungs- und Bewegungsplanungsebene durch eine ganzheitliche Beschreibung der Situation innerhalb der Trajektorienplanung unter Berücksichtigung von Unsicherheiten, die üblicherweise innerhalb der Verhaltensentscheidungsebene betrachtet werden [135].

Die verbleibende Aufgabe einer übergeordneten Instanz zur Operationalisierung des SPARC-Konzepts besteht dabei ausschließlich in der Generierung von informationstragenden Wegpunkten – beispielsweise Sollgeschwindigkeit an *Ampelwegpunkten* für die Ampelzustände »Grün« und »Rot« – ohne jegliche Entscheidungslogik. Alternativ ist eine detaillierte Karte von High-Level-Informationen denkbar, wie beispielsweise verwendet auf der »Bertha Benz Memorial Route«, dort in Kombination mit einer Verhaltensentscheidungs- und Bewegungsplanungs-Instanz [191, 192]. Im Gegensatz zu dieser Demonstration ist mit einer

gleichwertigen High-Level-Karte bei der Verwendung des SPARC-Konzepts keine weitere übergeordnete Instanz unmittelbar erforderlich.

Daneben ergibt sich durch den beschriebenen Korrespondenznachweis zwischen Variationsrechnung und Hidden-Markov-Modellen die Möglichkeit zur Kombination der Vorteile beider Domänen, die durch ziel- und bewertungserhaltende Modelltransformationen über eine »geschickte Zusammenfügung« unterschiedlicher Verfahren – wie beispielhaft in [26,108] – hinaus geht. Somit wird eine an eine physikalische Modellierung angelehnte Problembeschreibung bei gleichzeitiger globaler Optimierung möglich.

Zusammengefasst hat das SPARC-Konzept folgende Eigenschaften:

- Intuitive, flexible und aussagekräftige Modellierung der Planungsaufgabe der Fahrzeugbewegung
- Keine Klassifikation der Situation oder der Fahraufgabe, und damit keine Notwendigkeit eines Situationsverständnisses auf High-Level-Ebene oder diskreter Zustandstransitionen zwischen einzelnen definierten Fahrmodi
- Multikriterielle Optimierung aller Ziele², wie beispielsweise Navigationsanweisungen, Verkehrsregeln, Sicherheits-, Komfortaspekte
- Einbeziehung von Unsicherheiten unterschiedlicher Quellen über eine durchgehende probabilistische Modellierung
- Aufeinander abgestimmtes Konzept von multikriterieller Optimierung und probabilistischer Modellierung

Geometrie und Topologie des Trajektorienraums

Als Entwicklungsgrundlage des SPARC-Konzepts dient eine ausführliche geometrische und topologische Analyse des mit der Problembeschreibung aufgespannten \hookrightarrow Trajektorienraums, die einen grundlegenden Beitrag zum derzeitigen Forschungsstand darstellt, dessen Fortschritt in den vergangenen Jahre stark von einer schnellen Realerprobung geprägt war, mit den zwangsläufig daraus resul-

² Im Sinne einer skalarisierten Optimierung als gewichtete Linearkombination einzelner Ziele [189]

tierenden Notwendigkeiten vereinfachender Modellierung des Verkehrsgeschehens zur Einhaltung von Rechenkapazitäten. Die vorliegende Arbeit befasst sich im Gegensatz dazu mit grundsätzlichen, theoretischen Betrachtungen, die verbreitete Annahmen detailliert analysiert, wohingegen die Erprobung der daraus abgeleiteten praktischen Empfehlungen im Realbetrieb noch in anschließenden Arbeiten zu erbringen ist.

Ursprünglich zum Flächen- und Längenvergleich entwickelt, befasst sich die \hookrightarrow Geometrie mit der Vermessung von Räumen [16]. Übertragen auf die Trajektorienplanungsaufgabe ergibt sich eine Modellierung bestehend einerseits aus der Geometrie des modellierten Fahrzeugs und andererseits aus der Geometrie des Fahrzeugumfelds, der initialen Situation und ihrer Evolution in die nahe Zukunft. Die geometrischen Betrachtungen führen zu einer durchgängigen probabilistischen Situationsmodellierung, die Unsicherheiten über Sensorik oder Verhaltensweisen anderer Verkehrsteilnehmer in einer gemeinsamen Bewertung mit intrinsischen Trajektorieneigenschaften über ein hergeleitetes inverses Fahrzeugmodell vereint.

Im Gegensatz dazu werden über \hookrightarrow topologische Betrachtungen im Allgemeinen Nachbarschaftsbeziehungen analysiert, die durch Deformationen des Raums erhalten bleiben [122]. Wiederum übertragen auf die Trajektorienplanungsaufgabe erweisen sich vor allem die (lokalen und globalen) Optima als invariant gegenüber geometrischen Raumänderungen, wie beispielsweise die Verzerrung einer Weltkoordinate durch eine asymmetrische Auflösungsänderung oder Anpassungen an die Geometrie eines vollautomatischen Motorrads. Die topologischen Betrachtungen ergeben sich durch eine globale Optimierung in Kombination mit einer iterativen Abtastung des Trajektorienraums durch eine erschöpfende Anzahl an Startlösungen und basieren sowohl auf synthetisierten Räumen als auch realen Beispielsituationen.

1.3.3 Gliederung der Arbeit

Das an die Einführung anschließende Kapitel 2 dient dem besseren Verständnis der Arbeit. Beginnend mit einer Motivation der ausgewählten Modelle in Abschnitt 2.1, die die intuitive Modellierung des Trajektorienproblems beschreibt, werden in den Abschnitten 2.2 und 2.3 verwendete mathematische Grundbegriffe eingeführt.

Beginnend mit der \hookrightarrow Penalty-Lagrange-Funktion in Abschnitt 3.1 beschreibt Kapitel 3 die Herleitung und Umsetzung der verwendeten Modelle zur Trajektorienplanung, bestehend aus einer intuitiven Euler-Lagrange-Modellierung und einer korrespondierenden Beschreibung als Hidden-Markov-Modell. Die Herleitungen des \hookrightarrow Euler-Lagrange-Modells zur Trajektorienplanung (ELM) und des \hookrightarrow Hidden-Markov-Modells zur Trajektorienplanung (HMM) werden in den Abschnitten 3.2 und 3.4 gegeben, verbunden mit einer Diskussion der Korrespondenz der Modelle in Abschnitt 3.3. Die Umsetzung der Verfahren folgt in Abschnitt 3.5 zusammen mit einer Einführung in die verwendeten \hookrightarrow Planungsräume in Abschnitt 3.5.1.

In Kapitel 4 werden die zur Trajektorienplanung notwendigen \hookrightarrow geometrischen Betrachtungen zusammengefasst. Zur Beschreibung der \hookrightarrow Fahrzeuggeometrie wird das inverse \hookrightarrow C^2 -Modell in Abschnitt 4.1 hergeleitet und anhand von Simulationen in Abschnitt 4.1.2 sowie realen Testfahrten in Abschnitt 4.1.3 evaluiert. Der zweite Teil der geometrischen Betrachtungen ergibt sich unter Berücksichtigung von Unsicherheiten aus der probabilistischen Modellierung der initialen Situation in Abschnitt 4.2.1 und dessen Prädiktion in die Zukunft in Abschnitt 4.2.2 und führt zu einer ganzheitlichen Beschreibung der \hookrightarrow Situationsgeometrie in einem \hookrightarrow Pre-Penalty-Volumen. Zusammen mit den Trajektorienplanungsverfahren ergibt sich mit der Geometriemodellierung das Gesamtkonzept SPARC, das zusammen mit der Diskussion der Modellannahmen abschließend in Abschnitt 4.3 eingeführt wird.

Unter Verwendung der Vergleichsmetriken in Abschnitt 5.1 beleuchtet Kapitel 5 die \hookrightarrow Topologie des resultierenden, hochdimensionalen \hookrightarrow Trajektorienraums zunächst in Abschnitt 5.2 anhand synthetisierter Rauschfelder, die aus brownischem Rauschen in Abschnitt 5.2.1 generiert werden. Daran anschließend folgt

in Abschnitt 5.3 eine topologische Analyse des Trajektorienraums mit alltäglichen Beispielsituationen des realen Verkehrsgeschehens. Das Kapitel schließt mit einer Zusammenfassung der Erkenntnisse in Abschnitt 5.4.

Trotz der Fokussierung der Arbeit auf eine theoretische Analyse der Trajektorienplanung werden in Kapitel 6 zur Überprüfung der generellen Anwendbarkeit der Trajektorienplanungsverfahren einige Beispielanwendungen vorgestellt und über reale, aus (Luft-)Bildern stammende Verkehrssituationen evaluiert. Die Beispiele reichen von einer Analyse des zyklischen SPARC-Prozesses in Abschnitt 6.1 über die Anwendung auf mehrspurigen Straßen in Abschnitt 6.2 hin zur Planung von Notfallmanövern ohne Rechenzeiterhöhung in Abschnitt 6.3. Angeregt von wiederholten Anfragen auf Konferenzen und in Diskussionen, innerhalb des Planungsalgorithmus Interaktionen zur aktiven Beeinflussung des Verkehrsgeschehens durch gezielte Handlungen zu berücksichtigen, gibt Abschnitt 6.4 einen Ausblick auf eine Erweiterung des SPARC-Konzepts auf das \hookrightarrow Progressively Interacting Trajectories Konzept (PITRA) ohne jedoch eine Analyse des tatsächlichen Nutzens gegenüber klassischen Methoden durchzuführen. Kapitel 7 gibt eine Zusammenfassung der geometrischen und topologischen Betrachtungen des Trajektorienraums und schließt mit einem Ausblick auf weiterführende Themenbereiche.

\hookrightarrow In der Arbeit werden wichtige Begriffe hervorgehoben und innerhalb des Glossars in Anhang G zusammengefasst.

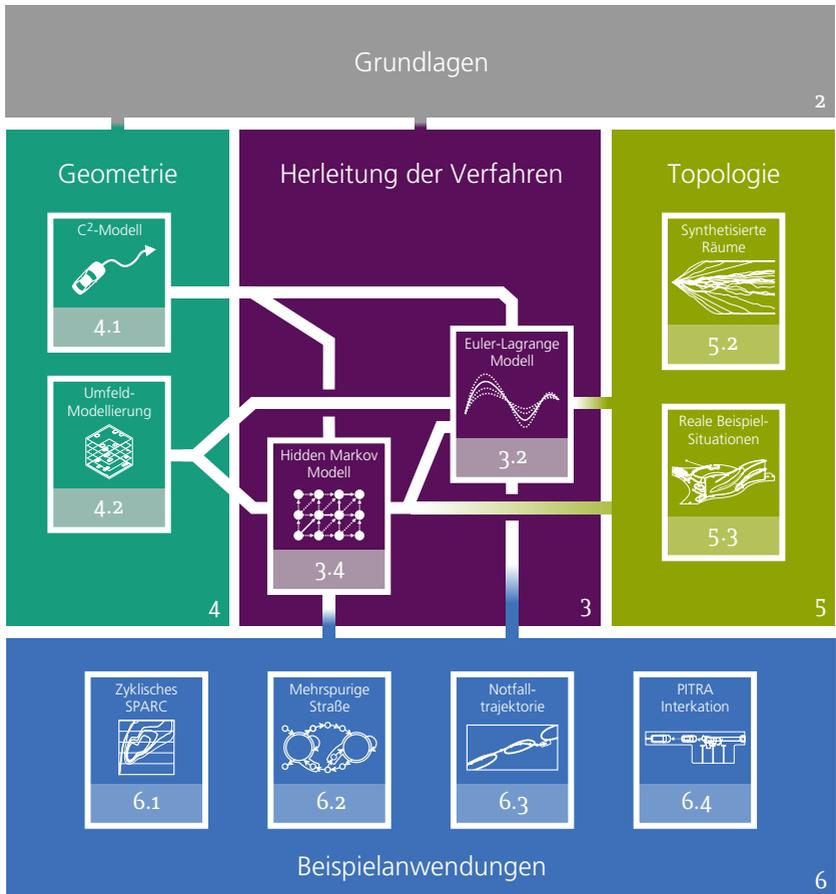


Abbildung 1.4: Gliederung der Arbeit.

2

Mathematische Grundlagen

2.1 Motivation der mathematischen Modelle

Die Bewegung eines Fahrzeugs kann als eine mehrdimensionale Funktion in einem Raum über die Zeit interpretiert werden. Die Position im Raum kann dabei über x, y -Komponenten bezogen auf ein frei wählbares Weltkoordinatensystem K^W beschrieben werden, für die gilt, dass

$$\mathbf{x}^W = \begin{bmatrix} x \\ y \end{bmatrix} \quad \text{mit} \quad x \in X^W \subseteq \mathbb{R} \quad \text{und} \quad y \in Y^W \subseteq \mathbb{R}. \quad (2.1)$$

Die Zeitkomponente t und das betrachtete Zeitintervall T wird definiert über

$$t \in \mathbb{R} \quad \text{mit} \quad T = [t_{\text{start}}, t_{\text{end}}] = \{ t \in \mathbb{R} \mid t_{\text{start}} \leq t \leq t_{\text{end}} \}. \quad (2.2a)$$

Für ein diskretes Zeitintervall mit $(\mathcal{T} + 1)$ Zeitschritten und $\mathcal{T} \in \mathbb{N}$ gilt mit einer Diskretisierung mit $\Delta t \in \mathbb{R}$, dass

$$\begin{aligned} T_d &= \{t_{\text{start}}, t_{\text{start}} + \Delta t, \dots, t_{\text{start}} + \mathcal{T} \cdot \Delta t = t_{\text{end}}\} \\ T_d &= \{t_0, t_1, \dots, t_{\mathcal{T}}\}. \end{aligned} \quad (2.2b)$$

Die mehrdimensionale Bewegungsfunktion des Fahrzeugs wird als \hookrightarrow Trajektorie beschrieben durch

$$\begin{aligned}\xi &: T \rightarrow X^W \times Y^W \\ \xi(t) &= \begin{bmatrix} \xi_x(t) \\ \xi_y(t) \end{bmatrix}.\end{aligned}\tag{2.3}$$

Die *Geschwindigkeit* und *Beschleunigung* der (in beiden Komponenten) zweimal stetig differenzierbaren Trajektorie ergeben sich dabei zu

$$\begin{aligned}\dot{\xi} &: T \rightarrow \dot{X}^W \times \dot{Y}^W \\ \dot{\xi}(t) &= \frac{d}{dt} \xi(t) = \begin{bmatrix} \dot{\xi}_x(t) \\ \dot{\xi}_y(t) \end{bmatrix}\end{aligned}\tag{2.4}$$

und

$$\begin{aligned}\ddot{\xi} &: T \rightarrow \ddot{X}^W \times \ddot{Y}^W \\ \ddot{\xi}(t) &= \frac{d^2}{dt^2} \xi(t) = \begin{bmatrix} \ddot{\xi}_x(t) \\ \ddot{\xi}_y(t) \end{bmatrix}.\end{aligned}\tag{2.5}$$

Weiterhin kann ein \hookrightarrow Pfad

$$\begin{aligned}\bar{\xi} &: S^W \rightarrow X^W \times Y^W \\ \bar{\xi}(s) &= \begin{bmatrix} \bar{\xi}_x(s) \\ \bar{\xi}_y(s) \end{bmatrix}\end{aligned}\tag{2.6}$$

definiert werden, der die x, y -Bewegung der Trajektorie ξ entlang eines longitudinalen Raumparameters $s \in S^W$ beschreibt, der beispielsweise als Bogenlänge der Straße definiert werden kann. Wird dieser Raumparameter wiederum als Funktion über die Zeit t betrachtet

$$s : T \rightarrow S^W\tag{2.7}$$

so ergibt sich daraus der \hookrightarrow zeitlichen Positionsverlauf (das »Timing«) der Trajektorie. Dabei ist der Zusammenhang von Trajektorie ξ , Pfad $\tilde{\xi}$ und zeitlichem Positionsverlauf s

$$\xi(t) = \tilde{\xi}(s(t)). \quad (2.8)$$

Die vorliegende Aufgabe der \hookrightarrow Trajektorienplanung besteht in der Berechnung einer geeigneten Trajektorie ξ , die mittels entsprechender Stellbefehle auf die Aktuatorik eines \hookrightarrow Ego-Fahrzeugs abgefahren werden kann. Um dabei zu bestimmen, ob eine berechnete Trajektorie den an sie gestellten Anforderungen genügt, muss diese bewertet werden. Eine solche Bewertung einer Funktion wird in der Mathematik als *Funktional* bezeichnet, das einer Funktion einen Wert zuordnet. Wird die Bewertung der Trajektorie über eine Vergabe von *Strafen* modelliert, so wird die optimale Trajektorie $\xi^* \in \Xi$ innerhalb eines \hookrightarrow Trajektorienraums Ξ an validen Lösungstrajektorien über das Minimum des Bewertungsfunktionals \mathcal{P} beschrieben¹. Es gilt

$$\xi^* = \arg \min_{\xi \in \Xi} \mathcal{P}[\xi]. \quad (2.9)$$

Die mathematische Disziplin der Minimierung von Funktionalen ist die Variationsrechnung, sodass sich die Anwendung im Bereich der Trajektorienplanung durch eine so erschlossene, intuitive Problemformulierung als Variationsproblem auf natürliche Weise ergibt. Durch die in Abschnitt 3.3 aufgezeigte Korrespondenz kann die gewählte Trajektorienplanung der Variationsrechnung in die Disziplin der probabilistischen graphischen Modelle überführt werden, woraus sich eine Vielzahl an Vorteilen ergibt, wie im Weiteren ausführlich diskutiert.

Daher werden in diesem Kapitel zunächst Grundbegriffe der Variationsrechnung in Abschnitt 2.2 sowie der Wahrscheinlichkeitstheorie und stochastischer graphischer Modelle in Abschnitt 2.3 eingeführt. Die mathematischen Grundlagen werden hierbei anwendungsunabhängig beschrieben und anschließend in Kapitel 3 auf die Problemstellung der Trajektorienplanung angewendet.

¹ Bei der Vergabe von *Belohnungen* läge die optimale Trajektorie im Maximum des Bewertungsfunktionals, und damit im Minimum des negierten Funktionals: $\xi^* = \arg \max(\mathcal{P}) = \arg \min(-\mathcal{P})$. Siehe hierzu beispielsweise [170].

2.2 Grundbegriffe der Variationsrechnung

Aufgrund ihrer weitreichenden Anwendbarkeit in der Physik [136], der analytischen Mechanik [147], der Bildauswertung [22], aber auch in der Regelungstechnik [170], wird die Variationsrechnung von einer Vielzahl an Literatur behandelt, die das Themengebiet auf unterschiedliche Weisen beschreibt. Im Folgenden wird auf die für die Arbeit wesentlichen Grundlagen eingegangen und für einen tieferen Einblick auf entsprechende Literatur verwiesen [50, 120, 174, 178]. Die Anwendung der Variationsrechnung auf die Problemdomäne der Trajektorienplanung wird in Abschnitt 3.2 gegeben.

Wie in [120] einleitend beschrieben, kann die Variationsrechnung als ein Teilgebiet der Optimierung interpretiert werden. Im Unterschied zur Optimierung von Funktionen mit mehreren Variablen, deren Extrema durch Vektoren in \mathbb{R}^n beschrieben werden, beschäftigt sich die Variationsrechnung mit der Suche nach extremalen Funktionen. Die als Lösung *zugelassenen Funktionen* müssen üblicherweise Randbedingungen und Glattheitsbedingungen genügen und werden in einem *Funktionsraum* Ω zusammengefasst.

Durch die unterschiedlichen *Lösungsräume* der beiden mathematischen Disziplinen – Funktionsraum Ω bei der Variationsrechnung im Gegensatz zu \mathbb{R}^n der klassischen Vektoroptimierung – ergeben sich auch unterschiedliche Methoden der Problemlösung. Dennoch können in der Variationsrechnung die zugelassenen Funktionen – die *Vergleichskurven* – als einzelne »Punkte« der Menge Ω interpretiert werden, was zu einer Suche nach einem extremalen, unendlich-dimensionalen Punkt führt [50]. Durch die zur numerischen Berechnung notwendige Diskretisierung des kontinuierlichen Funktionsparameters x hin zu einem diskreten Index in $\{1, 2, \dots, n\}$ wird das analytische Variationsproblem über Ω zu einem klassischen Optimierungsproblem im \mathbb{R}^n . Ein Nachweis der Äquivalenz des diskreten Variationsproblems mit der Vektoroptimierung wird in [E10] beschrieben.

Ein *Funktional* \mathcal{L} beschreibt die Abbildung eines Funktionenraums Ω auf die reellen Zahlen, sodass

$$\mathcal{L} : \Omega \rightarrow \mathbb{R}. \quad (2.10)$$

In der Variationsrechnung wird das Funktional üblicherweise als Integral über die *Lagrangefunktion* L beschrieben, deren Abhängigkeiten sich aus der Integrationsvariablen $x \in [x_1, x_2]$, der zu bewertenden Funktion $f(x)$ an der Stelle x sowie dessen n -te Ableitungen $C^n([x_1, x_2])$ ergeben, über

$$\mathcal{L}[f] = \int_{x_1}^{x_2} L\left(x, f(x), \frac{df(x)}{dx}, \dots, \frac{d^n f(x)}{dx^n}\right) dx. \quad (2.11)$$

Zulässige Funktionen $f: [x_1, x_2] \rightarrow \mathbb{R}$ müssen im Intervall (x_1, x_2) überall n -mal stetig differenzierbar sein, also zur *Differentiationsklasse* $C^n([x_1, x_2])$ gehören.

Die Variationsrechnung beschäftigt sich in der Regel mit der Suche nach jener *optimalen* (oder *extremalen*) Funktion f^* , die das Funktional \mathcal{L} aus Gl. (2.11) minimiert, dass

$$f^* = \arg \min_{f \in \Omega} \mathcal{L}[f]. \quad (2.12)$$

Aufgrund der Äquivalenz zur Vektoroptimierung wird im Folgenden zur Definition der Begrifflichkeiten für *Extremale* auf das Gebiet der Optimierung von Funktionen mehrerer Variablen $g(\mathbf{y})$ mit einem Vektor

$$\mathbf{y} = [y_1, y_2, \dots, y_m]^T \in Y \subseteq \mathbb{R}^m \quad (2.13)$$

zurückgegriffen.

Die Funktion $g : Y \rightarrow \mathbb{R}$ über einer Menge $Y \subseteq \mathbb{R}^m$ besitzt ein *globales Minimum* auf Y an der Stelle $\mathbf{y} \in Y$, wenn gilt

$$g(\mathbf{y}) \leq g(\hat{\mathbf{y}}) \quad \forall \hat{\mathbf{y}} \in Y. \quad (2.14)$$

Analog besitzt die Funktion $g : Y \rightarrow \mathbb{R}$ ein *globales Maximum* bei $\mathbf{y} \in Y$, wenn gilt

$$g(\mathbf{y}) \geq g(\hat{\mathbf{y}}) \quad \forall \hat{\mathbf{y}} \in Y. \quad (2.15)$$

Nun beschreibe der Vektor $\hat{\mathbf{y}}$ einen Punkt in einer ϵ -Umgebung mit $\epsilon > 0$ um \mathbf{y} , sodass gilt

$$B(\mathbf{y}; \epsilon) = \left\{ \hat{\mathbf{y}} \in \mathbb{R}^m \mid |\hat{y}_1 - y_1|^2 + \dots + |\hat{y}_m - y_m|^2 < \epsilon^2 \right\}. \quad (2.16)$$

Die Funktion $g : Y \rightarrow \mathbb{R}$ besitzt ein *lokales Minimum* in \mathbf{y} , wenn eine solche ϵ -Umgebung $B(\mathbf{y}; \epsilon)$ mit $\epsilon > 0$ existiert, für die gilt

$$g(\mathbf{y}) \leq g(\hat{\mathbf{y}}) \quad \forall \hat{\mathbf{y}} \in B(\mathbf{y}; \epsilon) \subseteq Y. \quad (2.17)$$

Die Funktion $g : Y \rightarrow \mathbb{R}$ besitzt ein *lokales Maximum* in \mathbf{y} , wenn eine solche ϵ -Umgebung $B(\mathbf{y}; \epsilon)$ mit $\epsilon > 0$ existiert, für die gilt

$$g(\mathbf{y}) \geq g(\hat{\mathbf{y}}) \quad \forall \hat{\mathbf{y}} \in B(\mathbf{y}; \epsilon) \subseteq Y. \quad (2.18)$$

Ist die Funktion $g : Y \rightarrow \mathbb{R}$ in jeder Komponente von \mathbf{y} einmal stetig differenzierbar in $Y \subseteq \mathbb{R}^m$, gehört also zur Differentiationsklasse $C^1(Y)$ und hat einen *stationären Punkt* (ein lokales Minimum, ein lokales Maximum oder einen Sattelpunkt) im Punkt $\mathbf{y} \in Y$, so gilt

$$\nabla g|_{\mathbf{y}} = \mathbf{0} \quad (2.19)$$

mit dem *Gradienten* von g an der Stelle \mathbf{y} , also der ersten partiellen Ableitung, definiert als

$$\nabla g = \left[\frac{\partial g}{\partial y_1} \quad \frac{\partial g}{\partial y_2} \quad \dots \quad \frac{\partial g}{\partial y_m} \right]^T. \quad (2.20)$$

Gleichung (2.19) stellt also lediglich eine notwendige Bedingung für ein *Extremum* (Minimum oder Maximum) dar. Die Prüfung der zweiten partiellen Ablei-

tion einer Funktion $g : Y \rightarrow \mathbb{R}$ kann zur Bestimmung des Extrempunkts \mathbf{y} herangezogen werden, sofern die Funktion ferner in C^2 liegt.

Ist die *Hessematrix*

$$\mathbf{H}_g = \begin{bmatrix} \frac{\partial^2 g}{\partial y_1 \partial y_1} & \frac{\partial^2 g}{\partial y_1 \partial y_2} & \cdots & \frac{\partial^2 g}{\partial y_1 \partial y_m} \\ \frac{\partial^2 g}{\partial y_2 \partial y_1} & \frac{\partial^2 g}{\partial y_2 \partial y_2} & \cdots & \frac{\partial^2 g}{\partial y_2 \partial y_m} \\ \vdots & \vdots & \ddots & \vdots \\ \frac{\partial^2 g}{\partial y_m \partial y_1} & \frac{\partial^2 g}{\partial y_m \partial y_2} & \cdots & \frac{\partial^2 g}{\partial y_m \partial y_m} \end{bmatrix} \quad (2.21)$$

am Extrempunkt \mathbf{y} positiv definit, gilt also $\mathbf{z}^T \mathbf{H}_g \mathbf{z} > 0 \quad \forall \mathbf{z}$, so ist \mathbf{y} ein lokales Minimum der Funktion g . Ist \mathbf{H}_g hingegen negativ definit an der Stelle \mathbf{y} , gilt also $\mathbf{z}^T \mathbf{H}_g \mathbf{z} < 0 \quad \forall \mathbf{z}$, dann ist das Extremum ein Maximum. Ist die Hessematrix an der Stelle \mathbf{y} positiv oder negativ semidefinit, gilt entsprechend $\mathbf{z}^T \mathbf{H}_g \mathbf{z} \geq 0$ oder $\mathbf{z}^T \mathbf{H}_g \mathbf{z} \leq 0$, so kann mit der ersten und zweiten partiellen Ableitung an der Stelle \mathbf{y} allein kein Extremum bestimmt werden. Ist die Hessematrix am Extrempunkt \mathbf{y} weder positiv noch negativ definit oder semidefinit – also indefinit – so stellt \mathbf{y} einen Sattelpunkt dar.

Zur Übertragung der Begrifflichkeiten aus den Gleichungen (2.14) bis (2.21) in den Bereich der analytischen Variationsrechnung wird eine Funktion \hat{f} definiert, die in einer ϵ -Umgebung um die extremale Funktion f existiert. Sei das Funktional $\mathcal{L} : \Omega \rightarrow \mathbb{R}$ definiert auf dem Funktionenraum Ω mit einer geeigneten Norm $\|\cdot\|$ und sei $\|\hat{f} - f\| < \epsilon$, dann existiert eine *Perturbationsfunktion* $\eta \in \Omega$, für die gilt

$$\hat{f} = f + \epsilon \eta. \quad (2.22)$$

Das Funktional $\mathcal{L} : \Omega \rightarrow \mathbb{R}$ besitzt ein *lokales Minimum* f , wenn ein $\epsilon > 0$ existiert, sodass gilt

$$\mathcal{L}[f] \leq \mathcal{L}[\hat{f}] \quad \forall \hat{f} \in \Theta(f; \epsilon) \quad (2.23)$$

mit

$$\Theta(f; \epsilon) = \{ \hat{f} \in \Omega \mid \| \hat{f} - f \| < \epsilon \}. \quad (2.24)$$

Das Funktional $\mathcal{L} : \Omega \rightarrow \mathbb{R}$ besitzt ein *lokales Maximum* f , wenn entsprechend ein $\epsilon > 0$ existiert, sodass gilt

$$\mathcal{L}[f] \geq \mathcal{L}[\hat{f}] \quad \forall \hat{f} \in \Theta(f; \epsilon). \quad (2.25)$$

Das Funktional $\mathcal{L} : \Omega \rightarrow \mathbb{R}$ besitzt ein *globales Minimum* f , wenn gilt

$$\mathcal{L}[f] \leq \mathcal{L}[\hat{f}] \quad \forall \hat{f} \in \Omega. \quad (2.26)$$

Das Funktional $\mathcal{L} : \Omega \rightarrow \mathbb{R}$ besitzt ein *globales Maximum* f , wenn gilt

$$\mathcal{L}[f] \geq \mathcal{L}[\hat{f}] \quad \forall \hat{f} \in \Omega. \quad (2.27)$$

Gegeben sei ein Funktional $\mathcal{L} : C^2[x_1, x_2] \rightarrow \mathbb{R}$ der speziellen Form

$$\mathcal{L}[f] = \int_{x_1}^{x_2} L(x, f, f') \, dx \quad (2.28)$$

mit $x_1 < x_2$, dessen Lagrangefunktion L zweimal stetig differenzierbar ist bezüglich ihrer Parameter x , $f = f(x)$ und $f' = (d/dx) f(x)$. Seien y_1 und y_2 der Start- und Endpunkt aller betrachteten Funktionen f und

$$S = \{ f \in C^2[x_1, x_2] \mid f(x_1) = y_1 \text{ und } f(x_2) = y_2 \}, \quad (2.29)$$

so wird das Funktional \mathcal{L} als *stationär* bezeichnet und hat ein Extremum (oder einen Sattelpunkt) in $f \in S$, wenn die \leftrightarrow Euler-Lagrange-Gleichung

$$\frac{d}{dx} \left(\frac{\partial L}{\partial f'} \right) - \frac{\partial L}{\partial f} = 0 \quad (2.30)$$

für alle x erfüllt ist. Die Euler-Lagrange-Gleichung ist ein zentraler Bestandteil der Variationsrechnung, die erfüllt ist, wenn die *erste Variation* – also die erste Ableitung von L – in jede Richtung verschwindet und damit das Pendant zum Gradienten in Gl. (2.20) der Vektoroptimierung bildet. Analog dazu stellt eine verschwindende erste Variation lediglich eine notwendige Bedingung eines Extremals dar. Die *zweite Variation* – also die zweite Ableitung von L – kann wiederum gleichbedeutend zur Hessematrix in Gl. (2.21) Aufschluss über die Art des Extremums geben. Aufgrund der im Weiteren notwendigen Problem-diskretisierung und der sich daraus ergebenden Möglichkeit zur Verwendung von Vektoroptimierungsmethoden wird in diesem Abschnitt nicht weiter auf die zweite Variation eingegangen. Eine ausführliche Herleitung der ersten und zweiten Variation ist beispielsweise in [174] zu finden, eine Reihe von Methoden zur Prüfung auf eine Minimalstelle in [170].

Gleichung (2.30) beschreibt die Lösung für Variationsprobleme mit festen Start- und Endpunkten y_1 und y_2 und einem Funktional mit einer Lagrangefunktion L , die die Funktion f und deren erste Ableitung f' – jeweils ausgewertet an der Stelle x – enthält. Für variable Start- und Endpunkte der Funktion f müssen zusätzlich zu Gl. (2.30) die *natürlichen Randbedingungen*² gelten, dass

$$\left. \frac{\partial L}{\partial f'} \right|_{x_1} = 0 \quad (2.31a)$$

$$\left. \frac{\partial L}{\partial f'} \right|_{x_2} = 0. \quad (2.31b)$$

² Diese Bedingungen ergeben sich nicht aus dem Problemverständnis, sondern resultieren aus der Formulierung des Problems als Variationsproblem. Dies ist der Grund für die Auswahl des Namens »natürliche Randbedingungen« (engl. »natural boundary conditions«) [174].

Durch die Äquivalenz der numerischen Optimierung von Funktionalen – durch Diskretisierung des Parameters der Funktion f – und der Vektoroptimierung kann die Euler-Lagrange-Gleichung in iterativen Optimierungsverfahren zur Gradientenberechnung eingesetzt werden. Beispielsweise kann sie im *Gradientenabstiegsverfahren* zur Verbesserung der vorangegangenen Iteration i zusammen mit einer Schrittbreite h_i und beginnend mit einer Startlösefunktion f^0 zur iterativen Lösung des Problems verwendet werden, wobei gilt

$$f^{(i+1)} := f^i - h_i \cdot \delta f^i, \quad (2.32)$$

mit der Euler-Lagrange-Gleichung aus Gl. (2.30) als Gradient zur Berechnung der (negativen) Abstiegsrichtung

$$\delta f = \frac{d}{dx} \left(\frac{\partial L}{\partial f'} \right) - \frac{\partial L}{\partial f} \quad (2.33)$$

und einem geeigneten Abbruchkriterium, wie beispielsweise $\|f^{i+1} - f^i\| < c$ mit geeignet gewähltem Abbruchparameter c .

Bei der Berücksichtigung \hookrightarrow harter Nebenbedingungen – also Bedingungen, die nicht verletzt werden dürfen – werden die Vorteile, die sich durch die Äquivalenz zur Vektoroptimierung ergeben, besonders deutlich. Die klassische Variationsrechnung bietet die Methode der *Lagrange-Multiplikatoren* zur Einbeziehung harter Nebenbedingungen³ der Form

$$\mathbf{g}(f, x) = \mathbf{0} \quad (\text{»holonome Nebenbedingung«}) \quad (2.34a)$$

$$\mathbf{g}(f, f', x) = \mathbf{0} \quad (\text{»nichtholonome Nebenbedingung«}) \quad (2.34b)$$

mit $\mathbf{g} \in \mathbb{R}^m$ und $m \in \mathbb{N}$, indem die Euler-Lagrange-Gleichung mit der um die Nebenbedingungen erweiterten Lagrangefunktion

$$L_{\mathbf{g}} = \lambda_0 L - \boldsymbol{\lambda}^T \mathbf{g} \quad (2.35)$$

³ Angepasst an die Problemdomäne beschreibt eine holonome Bedingung beispielsweise die Abhängigkeit von der Position einer Trajektorie. Nichtholonome Bedingungen sind von der Position und der Geschwindigkeit abhängig, also von der Form, wie die Position erreicht wird, wie beispielsweise die Orientierung des Ego-Fahrzeug an einem bestimmten Ort.

gelten muss. Der Vektor $\boldsymbol{\lambda} = [\lambda_1, \lambda_2, \dots, \lambda_m]^\top$ beinhaltet für jede Nebenbedingungsgleichung g_i in \boldsymbol{g} einen Lagrange-Multiplikator $\lambda_i \in \mathbb{R}$. Für holonome Nebenbedingungen gilt für $\lambda_0 = 1$, ansonsten ist $\lambda_0 \in \{0, 1\}$, wobei $\lambda_0 = 0$ als *nicht normale Lösung* bezeichnet wird, da in diesem Fall die ursprüngliche Lagrange-Gleichung L nicht mehr in die Lösung einfließt. Die Aufgabe besteht dann neben der Bestimmung der Extremalfunktion $f^* \in \Omega$ noch zusätzlich in der Bestimmung der Lagrange-Multiplikatoren $\lambda_0, \boldsymbol{\lambda}$. Eine ausführliche Behandlung von Variationsproblemen mit holonomen und nichtholonomen Nebenbedingungen bietet beispielsweise [98].

Der aufwendigen analytischen Berechnung der Lagrange-Multiplikatoren innerhalb der Variationsrechnung (und ebenso der klassischen, analytischen Vektroptimierung) steht der Teilbereich der numerischen Optimierung entgegen, der eine Vielzahl an Optimierungsmethoden bietet, die zudem die Einhaltung von Nebenbedingungen sicherstellen, indem der Lösungsraum auf zulässige Funktionen begrenzt wird. Beispiele hierfür sind eine *Rückprojektion* der Funktion in den Lösungsraum, *Barriere-Methoden*, *Innere-Punkte-Methoden* oder *Active-Set-Methoden*. Eine ausführliche Erläuterung der Algorithmen bieten [61, 132].

Aufgrund der breiten Vorteile der Optimierung von mehrdimensionalen Funktionen werden die Erkenntnisse der Variationsrechnung in die Domäne der Optimierung überführt und im Folgenden entsprechende Vektroptimierungsmethoden zur Trajektorienplanung verwendet. In Abschnitt 3.5.2 wird die Umsetzung beschrieben. Dabei erfolgt die Problemmodellierung weiterhin im Gebiet der Variationsrechnung und wird in Abschnitt 3.2 auf Lagrange-Funktionen mit zweiter Ableitung f'' der Form

$$\mathcal{L}[f] = \int_{x_1}^{x_2} L(x, f, f', f'') \, dx \quad (2.36)$$

erweitert. Die in [195] ausführlich hergeleitete resultierende Euler-Lagrange-Gleichung folgt dabei zu

$$\frac{\partial L}{\partial f} - \frac{d}{dx} \left(\frac{\partial L}{\partial f'} \right) + \frac{d^2}{(dx)^2} \left(\frac{\partial L}{\partial f''} \right) = 0. \quad (2.37)$$

Sind die Start- und Endpunkte einer Lagrangegleichung mit zweiter Ableitung variabel, so erweitern sich die natürlichen Randbedingungen aus Gl. (2.31) mit

$$\left. \frac{\partial L}{\partial f''} \right|_{x_1} = 0, \quad \left. \frac{\partial L}{\partial f''} \right|_{x_2} = 0, \quad (2.38a)$$

$$\left. \frac{d}{dx} \frac{\partial L}{\partial f''} \right|_{x_1} = 0, \quad \left. \frac{d}{dx} \frac{\partial L}{\partial f''} \right|_{x_2} = 0. \quad (2.38b)$$

Innerhalb der Vektoroptimierung müssen geltende natürliche Randbedingungen an den Start- und Endpunkten zusätzlich mitoptimiert werden.

2.3 Grundbegriffe Wahrscheinlichkeitstheorie und probabilistische graphische Modelle

Probabilistische graphische Modelle und stochastische Prozesse basieren auf wahrscheinlichkeitstheoretischen Betrachtungen der zu modellierenden Gegebenheiten, sodass im Folgenden zunächst wichtige Grundbegriffe der Wahrscheinlichkeitstheorie eingeführt werden. Auch dieses Gebiet der Mathematik besitzt eine vielfältige Literatur, die zur ausführlichen Einführung in die Materie geeignet ist [100,155,162,166,175] und der die weiteren Erläuterungen folgen.

Es sei eine Menge Θ an Ereignissen gegeben, die bei einem *Zufallsexperiment* auftreten können. Die *Wahrscheinlichkeit*, dass ein Ereignis $\mathcal{E} \in \Theta$ eintritt, wird beschrieben als

$$p(\mathcal{E}). \quad (2.39)$$

Die Wahrscheinlichkeit, dass zwei Ereignisse $\mathcal{E}_A, \mathcal{E}_B \in \Theta$ gleichzeitig eintreten, wird als *Verbundwahrscheinlichkeit* bezeichnet und wird beschrieben als

$$p(\mathcal{E}_A, \mathcal{E}_B). \quad (2.40)$$

Gilt für eine Menge Θ von Ereignissen, dass diese *paarweise disjunkt* sind, also

$$p(\mathcal{E}_A, \mathcal{E}_B) = 0 \quad \forall \mathcal{E}_A, \mathcal{E}_B \in \Theta, \quad \mathcal{E}_A \neq \mathcal{E}_B, \quad (2.41)$$

so ergibt sich durch die *Additivität der Wahrscheinlichkeiten* die Wahrscheinlichkeit der Vereinigung der Ereignisse als Summe der Einzelwahrscheinlichkeiten – also entsprechend für die Wahrscheinlichkeit, dass eines der Ereignisse eintritt

$$p(\mathcal{E}_\Theta) = \sum_{\mathcal{E} \in \Theta} p(\mathcal{E}) \quad \text{für} \quad \mathcal{E}_\Theta = \bigcup_{\mathcal{E} \in \Theta} \mathcal{E}. \quad (2.42)$$

Die Wahrscheinlichkeit des Eintretens eines Ereignisses \mathcal{E}_A unter der Annahme, dass ein Ereignis \mathcal{E}_B bereits eingetreten ist, wird als *bedingte Wahrscheinlichkeit* von \mathcal{E}_A gegeben \mathcal{E}_B beschrieben. Unter der Voraussetzung, dass gilt $p(\mathcal{E}_B) > 0$, ergibt sich für die bedingte Wahrscheinlichkeit, dass

$$p(\mathcal{E}_A | \mathcal{E}_B) = \frac{p(\mathcal{E}_A, \mathcal{E}_B)}{p(\mathcal{E}_B)}. \quad (2.43)$$

Seien die Ereignisse in Θ paarweise disjunkt, gelten also die Gleichungen (2.41) und (2.42) und seien die Ereignisse eine *vollständige Zerlegung* von \mathcal{E}_A [128], gilt also

$$\mathcal{E}_A = \bigcup_{\mathcal{E} \in \Theta} \mathcal{E} \quad (2.44)$$

so ergibt sich mit Gl. (2.43) die *vollständige Wahrscheinlichkeit* des Auftretens von \mathcal{E}_A zu

$$p(\mathcal{E}_A) = \sum_{\mathcal{E} \in \Theta} p(\mathcal{E}_A, \mathcal{E}) = \sum_{\mathcal{E} \in \Theta} p(\mathcal{E}_A | \mathcal{E}) p(\mathcal{E}). \quad (2.45)$$

Zwei Ereignisse \mathcal{E}_A und \mathcal{E}_B werden als *stochastisch unabhängig* bezeichnet, wenn für die Verbundwahrscheinlichkeit aus Gl. (2.40) und für die bedingten Wahrscheinlichkeiten aus Gl. (2.43) gilt, dass

$$p(\mathcal{E}_A, \mathcal{E}_B) = p(\mathcal{E}_A) \cdot p(\mathcal{E}_B) \quad (2.46a)$$

$$p(\mathcal{E}_A | \mathcal{E}_B) = p(\mathcal{E}_A) \quad (2.46b)$$

$$p(\mathcal{E}_B | \mathcal{E}_A) = p(\mathcal{E}_B). \quad (2.46c)$$

Eine der zentralen Regeln der Wahrscheinlichkeitstheorie ist der *Satz von Bayes*

$$p(\mathcal{E}_A | \mathcal{E}_B) = \frac{p(\mathcal{E}_B | \mathcal{E}_A) p(\mathcal{E}_A)}{p(\mathcal{E}_B)}, \quad (2.47)$$

der den Zusammenhang zwischen bedingten Wahrscheinlichkeiten unter Vertauschung von Ereignis und Vorbedingung herstellt und somit eine Umrechnungsvorschrift zwischen bekanntem und unbekanntem Wissen darstellt, die für viele praktische Anwendungen der Stochastik relevant ist.

Zur Herleitung der *Kettenregel der Verbundwahrscheinlichkeiten* werden zunächst drei, nicht unabhängige Ereignisse \mathcal{E}_A , \mathcal{E}_B und \mathcal{E}_C betrachtet. Mit der Definition eines neuen Ereignisses \mathcal{E}_D , das das Eintreten von \mathcal{E}_B und \mathcal{E}_C beschreibt, lässt sich die Verbundwahrscheinlichkeit mit zweimaliger Anwendung von Gl. (2.43) bestimmen als

$$\begin{aligned} p(\mathcal{E}_A, \mathcal{E}_B, \mathcal{E}_C) &= p(\mathcal{E}_A, \mathcal{E}_D) \\ &= p(\mathcal{E}_A | \mathcal{E}_D) \cdot p(\mathcal{E}_D) \\ &= p(\mathcal{E}_A | \mathcal{E}_B, \mathcal{E}_C) \cdot p(\mathcal{E}_B, \mathcal{E}_C) \\ &= p(\mathcal{E}_A | \mathcal{E}_B, \mathcal{E}_C) \cdot p(\mathcal{E}_B | \mathcal{E}_C) \cdot p(\mathcal{E}_C). \end{aligned}$$

Verallgemeinert ergibt sich die Kettenregel der Verbundwahrscheinlichkeit für m Ereignisse \mathcal{E}_m mit $m \in \mathbb{N}$ demnach zu

$$p(\mathcal{E}_1, \mathcal{E}_2, \dots, \mathcal{E}_m) = \left(\prod_{i=1}^{m-1} p(\mathcal{E}_i | \mathcal{E}_{i+1}, \dots, \mathcal{E}_m) \right) \cdot p(\mathcal{E}_m). \quad (2.48)$$

Eine *Zufallsvariable* X ordnet jedem möglichen Ausgang eines Zufallsexperiments mit Ereignismenge Θ einen Wert x zu. Der Ausgang eines Zufallsexperiments, bei dem die Zufallsvariable X den Wert x_0 oder geringer annimmt, kann dabei als Ereignis \mathcal{E}_A mit Eintrittswahrscheinlichkeit

$$p(\mathcal{E}_A) = p(X \leq x_0) \quad (2.49)$$

beschrieben werden. Auf diese Weise können die Erkenntnisse aus Gl. (2.39) bis Gl. (2.48) über eine geeignete Definition von Ereignissen \mathcal{E} auf die Beschreibung von Zufallsexperimenten mit Zufallsvariablen X erweitert werden. Beschreibt beispielsweise das Ereignis \mathcal{E}_B ein Zufallsexperiment, bei dem die m Zufallsvariablen X_m die m Werte x_m mit $m \in \mathbb{N}$ annehmen, gilt also für das Ereignis

$$\mathcal{E}_B = \{X_1 = x_1, X_2 = x_2, \dots, X_m = x_m\},$$

so ergibt sich die Verbundwahrscheinlichkeit aus Gl. (2.40), dass die m Zufallsvariablen X_i entsprechende Werte x_i annehmen, zu

$$\begin{aligned} p(\mathcal{E}_B) &= p(X_1 = x_1, X_2 = x_2, \dots, X_m = x_m) \\ &= p(x_1, x_2, \dots, x_m). \end{aligned} \quad (2.50)$$

Der zweite Ausdruck wird zur kompakteren Darstellung in den anschließenden Kapiteln verwendet.

Für eine Zufallsvariable X mit reellwertiger Wertemenge $x \in \mathbb{R}$ ist die (*kumulierte*) *Verteilungsfunktion* definiert als

$$F_X(x) = p(X \leq x) \quad (2.51)$$

und ergibt sich zu

$$F_X(x) = \int_{-\infty}^x f_X(\tau) d\tau. \quad (2.52)$$

Die Funktion f_X beschreibt dabei die *Wahrscheinlichkeitsdichteverteilung* der Zufallsvariablen X .

Für die *Wahrscheinlichkeitsmassenfunktion* f_X einer diskret verteilten Zufallsvariable X und damit abzählbaren Werten x_i mit $i \in I \subseteq \mathbb{N}$ gilt

$$f_X(x_i) = p(X = x_i). \quad (2.53)$$

Die zugehörige kumulierte Verteilungsfunktion F_X einer diskret verteilten Zufallsvariable ergibt sich dabei zu

$$F_X(x) = \sum_{\substack{i \in I, \\ x_i \leq x}} f_X(x_i). \quad (2.54)$$

Die *multivariate (kumulierte) Verteilungsfunktion* einer Zufallsvariablen Y , die wiederum aus m Zufallsvariablen X_i mit $m \in \mathbb{N}$ und zugehörigen reellen Werten $x_i \in \mathbb{R} \forall x_i$ besteht, ist definiert als

$$F_Y(x_1, \dots, x_m) = \int_{-\infty}^{x_m} \dots \int_{-\infty}^{x_1} f_Y(\tau_1, \dots, \tau_m) d\tau_1 \dots d\tau_m. \quad (2.55)$$

Die Funktion f_Y beschreibt die *multivariate Wahrscheinlichkeitsdichteverteilung*.

Der *Erwartungswert* einer Zufallsvariablen X mit reellen Werten $x \in \mathbb{R}$ ist definiert als

$$\mathcal{E}(X) = \int_{-\infty}^{\infty} x \cdot f_X(x) dx. \quad (2.56)$$

Für eine diskret verteilte Zufallsvariable X mit abzählbaren, reellen Werten x_i mit $i \in I \subseteq \mathbb{N}$ gilt

$$\mathcal{E}(X) = \sum_{i \in I} x_i \cdot p(X = x_i). \quad (2.57)$$

Vertreter der \hookrightarrow probabilistischen graphischen Modelle können zur Darstellung multivariater Wahrscheinlichkeitsverteilungen aus Gl. (2.55) dienen. Die Knoten beschreiben dabei die einzelnen Zufallsvariablen X_i , die über Kanten miteinander verbunden sind und die den probabilistischen Relationen zwischen den Knoten entsprechen. Durch die graphische Darstellung von Abhängigkeiten der Zufallsvariablen können multivariate Wahrscheinlichkeiten in einfachere Darstellungen transformiert werden, die eine Teilmenge der ursprünglichen Freiheitsgrade enthalten [162].

Unterschiedliche Probleme werden durch unterschiedliche Strukturen modelliert, die gemäß ihrer Eigenschaften benannt werden können. *Gerichtete Graphen* beschreiben beispielsweise Zusammenhänge, die eine Richtungsabhängigkeit darstellen. Im Gegensatz dazu werden symmetrische Zusammenhänge mit *ungerichteten Graphen* modelliert. Die Darstellung von zeitlichen Abhängigkeiten wird in *dynamischen Graphen* modelliert, die Beschreibung von Zufallsvariablen zu einem bestimmten Zeitpunkt in *statischen Graphen*. Enthalten gerichtete Graphen Zyklen oder Kreise, so wird der Graph als *gerichteter zyklischer Graph* bezeichnet. Das Gegenstück bilden *gerichtete azyklische Graphen*, die entsprechend keine Kreise enthalten. Im Weiteren werden lediglich jene Graphenstrukturen beschrieben, die in der Arbeit weitere Verwendung finden. Eine allgemeine Einführung in die unterschiedlichen Arten probabilistischer graphischer Modelle geben beispielsweise [162, 166].

Das \hookrightarrow bayessche Netz ist ein bekannter Vertreter probabilistischer Modelle und stellt einen (statischen) gerichteten azyklischen Graphen dar, der bedingte Abhängigkeiten – und vor allem Unabhängigkeiten – zwischen Zufallsvariablen auf kompakte Weise beschreibt. Hierfür werden für jede Zufallsvariable entsprechende *Eltern* bestimmt, die deren Wahrscheinlichkeit direkt beeinflussen. Die Wahrscheinlichkeit der Zufallsvariablen X_i einen Wert x_i anzuneh-

men, gegeben ihrer Eltern $\text{Pa}(X_i)$ wird über die bedingte Wahrscheinlichkeit $p(X_i = x_i | \text{Pa}(X_i))$ beschrieben. Mit der Kettenregel aus Gl. (2.48) ergibt sich für die Verbundwahrscheinlichkeit von m Zufallsvariablen X_i mit $i = \{1, 2, \dots, m\}$ entsprechend

$$p(X_1 = x_1, X_2 = x_2, \dots, X_m = x_m) = \prod_{i=1}^m p(X_i = x_i | \text{Pa}(X_i)). \quad (2.58)$$

Hauptziel eines bayesschen Netzes ist die Vereinfachung der Verbundwahrscheinlichkeit, indem bei der Bestimmung der Eltern $\text{Pa}(X_i)$ oftmals Unabhängigkeiten als Modellvereinfachungen eingeführt werden. Dadurch entsteht ein vereinfachtes Netz, dessen bedingte Wahrscheinlichkeiten aus Gl. (2.58) einfach modellierbar und/oder innerhalb des Netzes wiederkehrend sind und entsprechend die minimale Anzahl an Eltern $\text{Pa}(X_i)$ besitzen. Bayessche Netze werden in dieser Arbeit in Abschnitt 4.2.2 für die Verhaltensmodellierung von Interaktionen menschlicher Fahrer verwendet.

Ein \hookrightarrow stochastischer Prozess besteht aus einer Menge an zeitabhängigen Zufallsvariablen X_t mit $t \in T$. Für zeitdiskrete stochastische Prozesse gilt dabei $T = T_d \subseteq \mathbb{N}_0$, für zeitkontinuierliche stochastische Prozesse $T \subseteq \mathbb{R}_+ = [0, \infty)$.

Zeitdiskrete stochastische Prozesse können als dynamische gerichtete Graphen modelliert werden, deren Zufallsvariablen X_t der einzelnen Zeitpunkte t probabilistisch voneinander abhängen. Im allgemeinen Fall hängt bei komplexen stochastischen Prozessen eine Zufallsvariable X_t zum Zeitpunkt t von allen *Vorgängerzufallsvariablen* $\{X_{t-1}, X_{t-2}, \dots, X_0\}$ ab.

Ist die Zufallsvariable X_t eines zeitdiskreten stochastischen Prozesses lediglich abhängig von der direkten Vorgängerzufallsvariablen X_{t-1} , so wird ein solcher Prozess \hookrightarrow Markov-Kette erster Ordnung genannt. Die zugrundeliegende Eigenschaft der auf den Vorgänger begrenzten Abhängigkeit wird als \hookrightarrow Markov-Eigenschaft bezeichnet. Die Wahrscheinlichkeit, dass die Zufallsvariable X_t den Wert $x_t \in I$ aus einer Menge an möglichen Werten I annimmt, ist – für den Fall

das X_{t-1} gegeben ist – somit nicht mehr abhängig von $\{X_{t-2}, \dots, X_0\}$. Daraus ergibt sich die Modellvereinfachung

$$\begin{aligned} p(X_t = x_t | X_{t-1} = x_{t-1}, \dots, X_0 = x_0) \\ = p(X_t = x_t | X_{t-1} = x_{t-1}). \end{aligned} \quad (2.59)$$

Mit dieser Vereinfachung und der Kettenregel aus Gl. (2.48) lässt sich die Wahrscheinlichkeit einer zeitlichen Abfolge einer Markov-Kette ausschließlich durch deren *Anfangswahrscheinlichkeit*

$$p(X_0 = x_0) \quad (2.60)$$

und deren *Zustandsübergangswahrscheinlichkeiten* von einem Zeitpunkt zum darauffolgenden

$$p(X_t = x_t | X_{t-1} = x_{t-1}) \quad (2.61)$$

beschreiben. Für die Verbundwahrscheinlichkeit einer zeitlichen Folge von Zufallsvariablen gilt entsprechend

$$\begin{aligned} p(X_t = x_t, X_{t-1} = x_{t-1}, \dots, X_0 = x_0) \\ = \left(\prod_{i=1}^t p(X_i = x_i | X_{i-1} = x_{i-1}) \right) \cdot p(X_0 = x_0). \end{aligned} \quad (2.62)$$

Markov-Ketten höherer Ordnung beschreiben Abhängigkeiten von mehr als einem Vorgänger. So berechnet sich die bedingte Wahrscheinlichkeit einer allgemeinen \hookrightarrow Markov-Kette n -ter Ordnung zu

$$\begin{aligned} p(X_t = x_t | X_{t-1} = x_{t-1}, \dots, X_0 = x_0) \\ = p(X_t = x_t | X_{t-1} = x_{t-1}, \dots, X_{t-n} = x_{t-n}). \end{aligned} \quad (2.63)$$

Eine Markov-Kette n -ter Ordnung lässt sich jedoch einfach in eine Markov-Kette erster Ordnung durch die Definition einer neuen Zufallsvariable Y_t mit

$$Y_t = [X_t, X_{t-1}, \dots, X_{t-n}]^T \quad (2.64)$$

transformieren, sodass für die resultierende Zufallsvariable Y_t wieder die Markov-Eigenschaft aus Gl. (2.59) mit allen resultierenden Vereinfachungen gilt.

Sind die Verteilungen zeitunabhängig, so wird die Markov-Kette als *homogen* bezeichnet. Es gilt also für alle $i, j \in I$ und für alle $t \in T$

$$p(X_t = i | X_{t-1} = j) = \text{konstant für alle } t. \quad (2.65)$$

Nimmt eine Zufallsvariable X_t zum Zeitpunkt t den Wert $j \in I$ an, so befindet sich die Markov-Kette zum Zeitpunkt t im *Zustand* $s_j = j$. Abbildung 2.1a zeigt eine beispielhafte homogene Markov-Kette mit drei Zuständen $A, B, C \in I$.

Ein \leftrightarrow Hidden-Markov-Modell ist definiert als eine Markov-Kette, deren einzelne Zustände s_i zusätzlich beobachtbare *Emissionen* $e_j \in O$ aus einer endlichen Symbolmenge O mit einer *Emissionswahrscheinlichkeit*

$$p(Y_t = e_j | X_t = s_i) = p(e_j | s_i) \quad (2.66)$$

emittieren, wobei der Emissionsprozess einen weiteren Zufallsprozess mit der Zufallsvariablen Y_t darstellt. Dabei sind die Emissionen e_j lediglich vom emittierenden Zustand s_i abhängig. Es gilt entsprechend für die bedingte Wahrscheinlichkeit, dass

$$\begin{aligned} p(Y_t = e_j | X_t = s_i, \dots, X_0 = s_m, Y_{t-1} = e_n, \dots, Y_0 = e_l) \\ = p(Y_t = e_j | X_t = s_i). \end{aligned} \quad (2.67)$$

Die Emissionen werden zur Modellierung zusätzlicher Informationen verwendet, die die Wahrscheinlichkeit eines Zustands unabhängig von den modellierten Zustandsübergangswahrscheinlichkeiten in Abhängigkeit des Zeitpunkts beeinflussen, wie in Abbildung 2.1b dargestellt wird. Mit einer unterliegenden

homogenen Markov-Kette können somit sowohl zeitunabhängige als auch zeitabhängige Systemeigenschaften innerhalb eines Hidden-Markov-Modells modelliert werden.

Neben der Erweiterung der Markov-Kette auf die Ausgabe von Emissionen e_i werden die Zustände s_i eines Hidden-Markov-Modells üblicherweise als nicht beobachtbar betrachtet, sodass eine übliche Aufgabe darin besteht, aus einer beobachtbaren *Emissionsfolge*

$$\bar{e}_t = [e_0, \dots, e_t] \quad (2.68)$$

auf die *Zustandsfolge* der unbeobachtbaren Zustände

$$\bar{s}_t = [s_0, \dots, s_t] \quad (2.69)$$

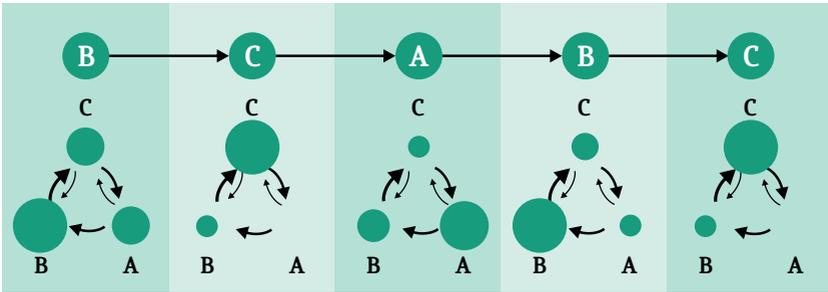
zu schließen. Die als *Dekodierung* bezeichnete Aufgabe sucht somit die wahrscheinlichste Zustandsfolge $\bar{s}_t^* \in S$ unter allen möglichen Zustandsfolgen \bar{s}_t der Menge S , gegeben einer emittierten Emissionsfolge \bar{e}_t , sodass

$$\bar{s}_t^* = \arg \max_{\bar{s}_t \in S} p(\bar{s}_t | \bar{e}_t). \quad (2.70)$$

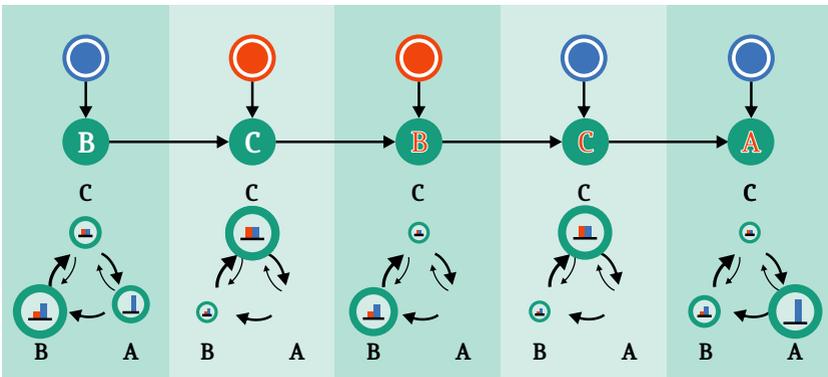
Unter Anwendung von Gl. (2.43) kann die Verbundwahrscheinlichkeit zur Lösung der Dekodierungsaufgabe eingesetzt werden. Damit ergibt sich Gl. (2.70) zu

$$\begin{aligned} \bar{s}_t^* &= \arg \max_{\bar{s}_t \in S} \left(\frac{p(\bar{s}_t, \bar{e}_t)}{p(\bar{e}_t)} \right) \\ &= \arg \max_{\bar{s}_t \in S} p(\bar{s}_t, \bar{e}_t). \end{aligned} \quad (2.71)$$

Aufgrund der Unabhängigkeit der Emissionswahrscheinlichkeit $p(\bar{e}_t)$ von der Zustandsfolge \bar{s}_t ist diese bei der Suche des *Arguments des Maximums* über \bar{s}_t (entsprechend der »arg max-Funktion«) nicht relevant und muss daher nicht betrachtet werden.



(a) Markov-Kette.



(b) Kette eines Hidden-Markov-Modells mit unterliegender Markov-Kette aus (a).

Abbildung 2.1: *Markov-Kette und Hidden-Markov-Modell.* Drei Zustände (grüne Kreise) mit $A, B, C \in I$. Die Zustandsübergangswahrscheinlichkeiten sind über die Größe der Pfeile dargestellt und für Markov-Kette und Hidden-Markov-Modell identisch. Wahrscheinlichkeiten für Verbleib in einem Zustand sind als gering angenommen und nicht dargestellt. Die Emissionswahrscheinlichkeiten der Emissionen (rote und blaue Kreise) sind als Balken innerhalb der Zustände beschrieben. Die Größe der Zustände gibt Aufschluss über die aktuellen Auftrittswahrscheinlichkeiten. Es liegt eine Anfangswahrscheinlichkeitsverteilung vor, die B die höchste Wahrscheinlichkeit zuweist. Durch die Emissionen ergibt sich ab dem 3. Schritt eine von der Markov-Kette abweichende Zustandsfolge. (Größen nicht maßstabsgetreu.)

Die gesuchten Verbundwahrscheinlichkeiten aus Gl. (2.71) können unter Berücksichtigung der Markov-Eigenschaft aus Gl. (2.59) und einer geschickten Faktorisierung der Kettenregel aus Gl. (2.48) berechnet werden und ergeben sich schließlich als eine Kombination aus (als bekannt angenommenen) Anfangs-, Emissions- und Zustandsübergangswahrscheinlichkeiten aus den Gleichungen (2.60), (2.61) und (2.66). Zum besseren Verständnis ergibt sich die Verbundwahrscheinlichkeit einer konkreten Emissionsfolge $\bar{e}_2 = [e_0, e_1, e_2]$ und den konkreten Zuständen $\bar{s}_2 = [s_0, s_1, s_2]$ beispielhaft zu

$$\begin{aligned}
 p(\bar{s}_2, \bar{e}_2) &= p(s_2, s_1, s_0, e_2, e_1, e_0) \\
 &= p(e_2 | s_2, s_1, s_0, e_1, e_0) \cdot p(s_2, s_1, s_0, e_1, e_0) \\
 &= p(e_2 | s_2) \cdot p(s_2 | s_1, s_0, e_1, e_0) \cdot p(s_1, s_0, e_1, e_0) \\
 &= p(e_2 | s_2) \cdot p(s_2 | s_1) \cdot p(e_1 | s_1, s_0, e_0) \cdot p(s_1, s_0, e_0) \\
 &= p(e_2 | s_2) \cdot p(s_2 | s_1) \cdot p(e_1 | s_1) \cdot p(s_1 | s_0, e_0) \cdot p(s_0, e_0) \\
 &= p(e_2 | s_2) \cdot p(s_2 | s_1) \cdot p(e_1 | s_1) \cdot p(s_1 | s_0) \cdot p(e_0 | s_0) \cdot p(s_0).
 \end{aligned}$$

Verallgemeinert auf eine Emissions- und Zustandsfolge der Länge t berechnet sich die Verbundwahrscheinlichkeit des Hidden-Markov-Modells aus Gl. (2.71) über

$$\begin{aligned}
 p(\bar{s}_t, \bar{e}_t) &= p(X_t = s_t, \dots, X_0 = s_0, Y_t = e_t, \dots, Y_0 = e_0) \\
 &= \left(\prod_{i=1}^t p(Y_i = e_i | X_i = s_i) \cdot p(X_i = s_i | X_{i-1} = s_{i-1}) \right) \cdot (2.72) \\
 &\quad \cdot p(Y_0 = e_0 | X_0 = s_0) \cdot p(X_0 = s_0).
 \end{aligned}$$

Abbildung 2.1b zeigt ein Hidden-Markov-Modell im direkten Vergleich mit einer Markov-Kette.

Die Dekodierungsaufgabe kann mithilfe des \hookrightarrow Viterbi-Algorithmus gelöst werden. Der Viterbi-Algorithmus nutzt hierfür das *Optimalitätsprinzip von Bellman* der \hookrightarrow dynamischen Programmierung, das besagt, dass die optimale Lösung eines in Teilprobleme zerlegbaren Gesamtproblems sich wiederum aus der Zu-

sammensetzung der optimalen Lösungen jener Teilprobleme ergibt [125]. Gemäß dessen werden alle Zustände $s_\tau^k \in I$ des Zustandsraums I eines Zeitschritts $\tau \in T$ betrachtet, beginnend mit dem ersten Zeitschritt $\tau = t_0$. Für jeden Zustand s_τ^k wird jener Vorgängerzustand $s_{\tau-1}^v$ gesucht, der die Verbundwahrscheinlichkeit der Zustandsfolge gemäß Gl. (2.71) bis zum Zeitpunkt τ und terminierend im Zustand s_τ^k maximiert. Die maximale Verbundwahrscheinlichkeit und der zugehörige Vorgänger werden für jeden Zustand s_τ^k für alle k, τ bestimmt und gespeichert. Für den letzten Zeitpunkt $\tau = t$ liegt dann für alle Endzustände die wahrscheinlichste Zustandsfolge \bar{s}_t vor, die im entsprechenden Endzustand s_t^i terminiert. Das *Backtracking* – beginnend vom Endzustand mit maximaler Verbundwahrscheinlichkeit – kann aufgrund der jeweiligen gespeicherten Vorgänger die gesamte optimale Zustandsfolge \bar{s}_t^* vom Ende bis zum Anfang Schritt für Schritt rekonstruieren. Der beschriebene Vorgang entspricht dem Viterbi-Algorithmus, der in Abschnitt 3.5.3 auf die Problemstellung der Trajektorienplanung angepasst und als Pseudocode in Algorithmus 3.1 gegeben ist.

3

Herleitung der Trajektorienplanungsverfahren

3.1 Penalty-Lagrangefunktion und Nebenbedingungen

Wie bereits in Abschnitt 2.1 motiviert, bietet die Variationsrechnung eine intuitive Problemformulierung der Trajektorienplanungsaufgabe. Sie besteht aus der Bewertung einer Funktion über ein Funktional, das Eigenschaften der Funktion an einzelnen Funktionsstellen über eine Lagrangefunktion auswertet, über alle *lokalen Lagrangeergebnisse* integriert und somit eine Aussage über die Güte der gesamten Funktion erhält. Bezogen auf die Problemdomäne der Trajektorienplanung beschreibt die zeitabhängige Trajektorie ξ aus Gl. (2.3) die zu bewertende Funktion, die über die \hookrightarrow Penalty-Lagrangefunktion \mathcal{P}_L zu den einzelnen Zeitschritten t bewertet wird. Die Minimierung des \hookrightarrow Penalty-Funktional \mathcal{P} aus Gl. (2.9) liefert dann die optimale Trajektorie ξ^* .

Hierbei wird in dieser Arbeit bewusst der englische Begriff \hookrightarrow Penalty für konkret modellierte Strafen einer Trajektorie verwendet, um eine Abgrenzung der konkreten Problemformulierung der Trajektorienplanungsaufgabe zu den allgemeinen Erläuterungen in Kapitel 2 zu verdeutlichen. Variablen, Funktionen und Konstrukte, die sich auf die Penaltys beziehen, erhalten zur Verdeutlichung entsprechend daran angelehnte Bezeichner.

Die Güte einer geplanten Trajektorie ξ ist maßgeblich gekennzeichnet durch

- die Position der Trajektorie $\xi(t)$ nach Gl. (2.3),
- die Geschwindigkeit der Trajektorie $\dot{\xi}(t)$ nach Gl. (2.4) und
- die Beschleunigung der Trajektorie $\ddot{\xi}(t)$ nach Gl. (2.5).

Bewertungen der Geschwindigkeit und Beschleunigung stehen im Zusammenhang mit Insassenkomfort, zügigem Erreichen eines Zielpunkts und harten Nebenbedingungen, wie beispielsweise physikalische Grenzen des Fahrzeugs. Die Position des Fahrzeugs ist relevant zur Kollisionsvermeidung. Weitere Bewertungskriterien ergeben sich aus ökologischen Betrachtungen, die beispielsweise in [68, 69] ausführlich modelliert werden.

Der Einbezug weiterer, höherer Ableitungen, wie beispielsweise dem Ruck als dritte Ableitung $\ddot{\xi} = d^3/dt^3 \xi$, sind in der Problemformulierung prinzipiell möglich. Es existieren auch Quellen, die dem Ruck eine Komfortrelevanz zuschreiben [83]. Da jedoch bei der Verwendung von Hidden-Markov-Modellen zur Trajektorienplanung – wie in Abschnitt 3.4 hergeleitet wird – die Hinzunahme höherer Ableitungen zu einer exponentiellen Erhöhung des Zustandsraums führt, muss die Aussagekraft eines so erweiterten Modells gegen eine signifikante Rechenzeiterhöhung abgewogen werden. Aufgrund fehlender allgemeingültiger Aussagen zu »Ruckempfinden« wird die Penalty-Lagrangefunktion daher im Rahmen der Arbeit auf Positions-, Geschwindigkeits- und Beschleunigungsbewertungen beschränkt.

Die Bewertung der Trajektorie ist maßgeblich abhängig von der initialen Situation zum Startzeitpunkt t_{start} und der Prädiktion der initialen Situation in die nahe Zukunft bis zum Endzeitpunkt der Trajektorie t_{end} . Abschnitt 4.2 führt hierfür eine ganzheitliche Beschreibung der Umgebung des Ego-Fahrzeugs und deren Evolution ein – das \hookrightarrow Pre-Penalty-Volumen \wp . Das Pre-Penalty-Volumen dient der Penalty-Lagrangefunktion als nichtoptimierbare Vorbedingung, die alle relevanten Gegebenheiten der Situation und Prädiktion beinhaltet und für die Bewertung der Trajektorie zur Verfügung stellt. Zur Verdeutlichung von Abhängigkeiten und Vorbedingungen im Gegensatz zu Optimierungsparametern wird

im Folgenden die in der Stochastik übliche Darstellung von Bedingungen (siehe Abschnitt 2.3) verwendet. Es gilt

$$p(\text{Ereignisse|Bedingungen}) \leftrightarrow \mathcal{P}(\text{dynamische Größen|Vorbedingungen}).$$

Die Penalty-Lagrangefunktion \mathcal{P}_L bestimmt sich aus unterschiedlichen \hookrightarrow Penalty-Funktionen, die die Eigenschaften der Trajektorie zu den Zeitpunkten $t \in T_d \subseteq T$ bewerten. Für sie gilt

$$\begin{aligned} \mathcal{P}_L(\xi, \dot{\xi}, \ddot{\xi}, t | \mathcal{P}) \\ = \underbrace{\mathcal{P}_{\text{in}}(\dot{\xi}, \ddot{\xi})}_{L_{\text{in}}(\dot{\xi}, \ddot{\xi})} + \underbrace{\mathcal{P}'_{\text{out}}(\xi, \dot{\xi}, t | \mathcal{P}) + \mathcal{P}''_{\text{out}}(\xi, \dot{\xi}, t | \mathcal{P}) + \mathcal{P}_{\text{target}}(\xi, t | \mathcal{P})}_{L_{\text{out}}(t, \xi, \dot{\xi})}. \end{aligned} \quad (3.1)$$

Die *Inner-Penalty*s $\mathcal{P}_{\text{in}}(\dot{\xi}, \ddot{\xi})$ beschreiben Eigenschaften, die sich unabhängig von einer konkreten Situation ergeben, wie beispielsweise Geschwindigkeiten oder Beschleunigungen. Die *Outer-Penalty*s bewerten die Umgebung des Ego-Fahrzeugs und beinhalten als *Primary-Outer-Penalty*s $\mathcal{P}'_{\text{out}}(\xi, \dot{\xi}, t | \mathcal{P})$ die Kollisionsrisiken mit anderen Verkehrsteilnehmern und als *Secondary-Outer-Penalty*s $\mathcal{P}''_{\text{out}}(\xi, \dot{\xi}, t | \mathcal{P})$ weitere von Kollisionsrisiken unabhängige Penalty's, die sich durch die Situation ergeben, wie beispielsweise Geschwindigkeitsbegrenzungen. Entgegen der klassischen Modellierung von Variationsproblemen mit festen Start- und Endwerten in Abschnitt 2.2 werden in der Problemformulierung für Trajektorienplanung feste Endwerte aufgegeben, um somit erzwungene Kollisionen an diesen Stellen zu verhindern. Dadurch gelten die natürlichen Randbedingungen für Endwerte aus Gl. (2.38). Um dennoch das Erreichen von Endpositionen in kollisionsarmen Gebieten zu belohnen, wird eine *Target-Penalty* $\mathcal{P}_{\text{target}}(\xi, t | \mathcal{P})$ in die Penalty-Lagrangefunktion eingeführt, die Abweichungen des Trajektorien-Endpunkts $\xi(t_{\text{end}})$ von der Endposition $\mathbf{x}_{\text{end}}^W$ nach Gl. (2.1) bestraft. Somit kann über die Penalty-Lagrangefunktion eine Abwägung zwischen einer Endpunktverfehlung und einem an diesem Ort möglicherweise auftretenden Kollisionsrisiko durch eine Gewichtung der einzelnen Penalty-Funktionen geschehen.

Modellierte Penalty-Lagrangefunktion

Die konkrete Modellierung der Penalty-Lagrangefunktion hängt maßgeblich von den Systemeigenschaften des Ego-Fahrzeugs ab. Einerseits ist genaue Kenntnis über das Aussehen und die Qualität der verfügbaren Sensordaten notwendig sowie Genauigkeit und Totzeiten der zur Regelung des Ego-Fahrzeugs eingesetzten Aktuatorik, um geplante Trajektorien mit der realen Ausführbarkeit in Verbindung zu bringen. Aufgrund der vorgeschlagenen probabilistischen Modellierung des Verkehrsgeschehens in Abschnitt 4.2 sind zudem stochastische Verhaltensmodelle anderer Verkehrsteilnehmer für die konkrete Ausgestaltung der Penalty-Funktionen notwendig. Durch eine Gewichtung der einzelnen Penalty-Funktionen zueinander mit Gewichtungsfaktoren

$$w_i \in \mathbb{R} \quad \text{mit} \quad i = \{\text{in}, \text{out}_1, \text{out}_2, \text{target}\}$$

ergeben sich weiterhin ethische Fragestellungen, die im Rahmen einer Arbeit im Bereich der Ingenieurwissenschaften nicht beantwortet werden können.

Aufgrund der eingangs beschriebenen Beschränkung an Realdaten dient die im Folgenden vorgeschlagene Penalty-Lagrangefunktion primär dem theoretischen Verständnis der beschriebenen Trajektorienplanungsverfahren. Weitere Arbeiten zur Validierung der Tauglichkeit des Gesamtsystems, wie auch der konkreten Ausgestaltung der Penalty-Lagrangefunktion müssen dieser Arbeit folgen.

Die Outer-Penaltys bewerten einerseits das Kollisionsrisiko an den einzelnen Positionen der Trajektorie $\xi(t)$, das mithilfe der Informationen im Pre-Penalty-Volumen \mathcal{P} , wie beispielhaft in Abschnitt 4.3 gezeigt, berechnet wird, und führen andererseits Bestrafungsterme für Abweichungen von der Geschwindigkeitsbegrenzung v_{Begr} ein, die wiederum aus \mathcal{P} hervorgeht. Für die Primary-Outer-Penaltys und Secondary-Outer-Penaltys kann für den Moment zur Veranschaulichung angenommen werden, dass

$$\mathcal{P}'_{\text{out}}(\xi(t), \dot{\xi}(t), t | \mathcal{P}) = w_{\text{out}_1} \cdot \mathcal{P}(\xi(t), t) \quad (3.2a)$$

$$\mathcal{P}''_{\text{out}}(\xi(t), \dot{\xi}(t), t | \mathcal{P}) = w_{\text{out}_2} \cdot \left(\|\dot{\xi}(t)\| - v_{\text{Begr}} \right)^2. \quad (3.2b)$$

Dabei stellt Gl. (3.2b) durch die quadratische Bestrafung der Geschwindigkeitsabweichung eine vereinfachte Penalty-Funktion dar. In Abschnitt 4.2.1 und Abbildung 4.21 wird eine komplexere Penalty-Funktion diskutiert, die von unterschiedlichen Verkehrszonen abhängt.

Situationsunabhängige Trajektorieneigenschaften werden innerhalb der Inner-Penalty betrachtet. Zur Bewertung des Komforts wird eine Bestrafung der longitudinalen und lateralen Beschleunigungen vorgeschlagen, wobei durch die Verwendung der Norm eine Gleichgewichtung der beiden Beschleunigungsrichtungen erreicht wird. Es gilt

$$\mathcal{P}_{\text{in}}(\dot{\xi}(t), \ddot{\xi}(t)) = w_{\text{in}} \cdot \|\ddot{\xi}(t)\|^2. \quad (3.2c)$$

Penalty, die eine Abweichung des Endpunkts $\xi(t_{\text{end}})$ von einer definierten Endposition in Weltkoordinaten $\mathbf{x}_{\text{end}}^{\text{W}}$ bewerten, werden über die Target-Penalty miteinbezogen als

$$\mathcal{P}_{\text{target}}(\xi(t), t | \mathcal{P}) = w_{\text{target}} \cdot \|\xi(t_{\text{end}}) - \mathbf{x}_{\text{end}}^{\text{W}}\|^2 \cdot \delta_{t, t_{\text{end}}}. \quad (3.2d)$$

Die quadratische Bestrafung des *euklidischen Abstands* stellt dabei wieder einen einfachen Bestrafungsterm dar, der durch das *Kronecker-Delta*

$$\delta_{t, t_{\text{end}}} = \begin{cases} 1 & \text{wenn } t = t_{\text{end}} \\ 0 & \text{sonst} \end{cases} \quad (3.3)$$

lediglich auf die Bewertung des letzten Zeitschritts t_{end} Einfluss nimmt. In [S15] wird eine komplexere Target-Penalty-Funktion hergeleitet. In einigen Beispielen in dieser Arbeit wird auf die Target-Penalty gänzlich verzichtet.

Die Gewichtungsfaktoren w_i der Penalty-Funktionen in Gl. (3.2) definieren die einzelnen Prioritäten und beschreiben damit unterschiedliche Fahrstile. Eine geringe Bestrafung von Beschleunigungen über eine geeignete Wahl von w_{in} mit $w_{\text{in}} \ll w_i$ resultiert beispielsweise in einem »sportlichen« Fahrstil, wohingegen ein großes w_{out1} mit $w_i \ll w_{\text{out1}}$ einen »vorsichtigen« Fahrstil definiert. Ohne Kenntnisse über reale Sensordaten, Unsicherheiten, Verhaltensmodelle, aber auch ohne ein allgemeines Verständnis über vorherrschende Verkehrs-

situationen, ist eine geeignete Wahl dieser Gewichtungsfaktoren nicht möglich, da innerhalb jedes Fahrstils die maximale Verkehrssicherheit in kritischen Situationen gewährleistet sein muss. Die Analyse und Definition geeigneter Penalty-Funktionen inklusive Gewichtungsfaktoren w_i stellt daher eine wichtige Weiterentwicklung der in dieser Arbeit entwickelten Trajektorienplanungsverfahren dar.

Modellierte harte Nebenbedingungen

Innerhalb der Trajektorienplanung existieren einige harte Nebenbedingungen, die bei der Berechnung beachtet werden müssen. Auch bei der Definition der Nebenbedingungen sind wiederum weitreichende Kenntnisse des Gesamtsystems notwendig, um eine abschließende Modellierung anzugeben. Im Weiteren werden die Begrenzung der minimalen und maximalen Geschwindigkeit

$$\begin{aligned} v_{\min} \leq v \leq v_{\max} & & v_{\max} > 0 & (3.4a) \\ & & v_{\min} = 0 & \end{aligned}$$

der maximalen longitudinalen und lateralen Be- und Entschleunigung

$$\begin{aligned} a_{\text{long},\min} \leq a_{\text{long}} \leq a_{\text{long},\max} & & a_{\text{long},\max} > 0 & (3.4b) \\ & & a_{\text{long},\min} < 0 & \end{aligned}$$

$$|a_{\text{lat}}| \leq a_{\text{lat},\max} \quad a_{\text{lat},\max} > 0 \quad (3.4c)$$

sowie eine Begrenzung der *Trajektorienkrümmung*

$$|\kappa| \leq \kappa_{\max} \quad \kappa_{\max} > 0 \quad (3.4d)$$

vorgeschlagen. Zur Berechnung der Größen aus der Trajektorie ξ wird das in Abschnitt 4.1.1 hergeleitete $\hookrightarrow C^2$ -Modell verwendet.

Daneben stellen Startposition und Startgeschwindigkeit der zu optimierenden Trajektorie harte Nebenbedingungen dar, die sich aus der aktuellen Position und

Geschwindigkeit des Ego-Fahrzeugs bestimmen lassen. Für eine Trajektorienplanungsrate von 10 Hz kann beispielsweise eine ausreichend genaue Extrapolation der Ego-Fahrzeugbewegung der kommenden 100 Millisekunden vorausgesetzt werden. Es gilt

$$\begin{aligned} \xi(t_{\text{start}}) &= \mathbf{x}_{\text{ego}}^{\text{W}}(t_{\text{real}}) + \dot{\mathbf{x}}_{\text{ego}}^{\text{W}}(t_{\text{real}}) \cdot 100 \text{ ms} \\ &\quad + 0,5 \cdot \ddot{\mathbf{x}}_{\text{ego}}^{\text{W}}(t_{\text{real}}) \cdot (100 \text{ ms})^2 \end{aligned} \quad (3.4e)$$

$$\dot{\xi}(t_{\text{start}}) = \dot{\mathbf{x}}_{\text{ego}}^{\text{W}}(t_{\text{real}}) + \ddot{\mathbf{x}}_{\text{ego}}^{\text{W}}(t_{\text{real}}) \cdot 100 \text{ ms}. \quad (3.4f)$$

Dabei beschreibt t_{real} den aktuellen Zeitpunkt, t_{start} den Startzeitpunkt des kommenden Planungszyklus und $\mathbf{x}_{\text{ego}}^{\text{W}}$ die aktuelle Ego-Fahrzeugposition, $\dot{\mathbf{x}}_{\text{ego}}^{\text{W}}$ die Ego-Fahrzeuggeschwindigkeit sowie $\ddot{\mathbf{x}}_{\text{ego}}^{\text{W}}$ die Ego-Fahrzeugbeschleunigung.

3.2 Das Euler-Lagrange-Modell zur Trajektorienplanung

Das \hookrightarrow Euler-Lagrange-Modell zur Trajektorienplanung (ELM) basiert – wie der Name vermuten lässt – auf der Verwendung der Euler-Lagrange-Gleichung. Die in Abschnitt 2.1 dargestellte intuitive Problembeschreibung der Trajektorienplanungsaufgabe als Variationsproblem führt zu einer Bewertung einer Trajektorie ξ zu diskreten Zeitschritten $t \in T_d$ mit Δt nach Gl. (2.2) und davon ausgehend zu einem diskreten Penalty-Funktional der Form

$$\mathcal{P}[\xi] = \sum_{t \in T_d} \rho_L(\xi(t), \dot{\xi}(t), \ddot{\xi}(t), t | \rho) \cdot \Delta t. \quad (3.5)$$

Wie in Gl. (2.33) eingeführt, kann die Euler-Lagrange-Gleichung innerhalb diskreter Optimierungsmethoden als Gradient verwendet werden. Mit der Penalty-Lagrangefunktion aus Gl. (3.1) ergibt sich die \hookrightarrow Penalty-Euler-Lagrange-Gleichung mit zweifacher Ableitung aus Gl. (2.37) zu

$$\frac{\partial \rho_L}{\partial \xi} - \frac{d}{dt} \left(\frac{\partial \rho_L}{\partial \dot{\xi}} \right) + \frac{d^2}{dt^2} \left(\frac{\partial \rho_L}{\partial \ddot{\xi}} \right) =: \delta \xi. \quad (3.6)$$

Die einzelnen Terme aus der Penalty-Euler–Lagrange-Gleichung mit den Penalty-Funktionen aus Gl. (3.2) ergeben sich zu

$$\frac{\partial \mathcal{P}_L}{\partial \xi} = w_{\text{out1}} \cdot \nabla \mathcal{P} + 2 \cdot w_{\text{target}} \cdot \|\xi_{\text{end}} - \mathbf{x}_{\text{end}}^W\| \cdot \delta_{t, t_{\text{end}}} \quad (3.7a)$$

$$\begin{aligned} -\frac{d}{dt} \left(\frac{\partial \mathcal{P}_L}{\partial \dot{\xi}} \right) &= -\frac{d}{dt} \left(2 \cdot w_{\text{out2}} \cdot \left(\|\dot{\xi}(t)\| - v_{\text{Begr}} \right) \right) \\ &= -2 \cdot w_{\text{out2}} \cdot \left(\|\ddot{\xi}(t)\| - \dot{v}_{\text{Begr}} \right) \end{aligned} \quad (3.7b)$$

sowie

$$\begin{aligned} \frac{d^2}{dt^2} \left(\frac{\partial \mathcal{P}_L}{\partial \ddot{\xi}} \right) &= \frac{d^2}{dt^2} \left(2 \cdot w_{\text{in}} \cdot \|\ddot{\xi}(t)\| \right) \\ &= 2 \cdot w_{\text{in}} \cdot \|\ddot{\ddot{\xi}}(t)\|. \end{aligned} \quad (3.7c)$$

Dabei beschreibt $\nabla \mathcal{P}$ die partielle Ableitung des Pre-Penalty-Volumens, entsprechend den lokalen Gradienten in Ortsrichtung

$$\nabla \mathcal{P} = \frac{\partial \mathcal{P}(\xi(t), t)}{\partial \xi}. \quad (3.8)$$

Weiterhin müssen aufgrund der aufgehobenen Fixierung der Endpunkte die natürlichen Randbedingungen aus den Gleichungen (2.31) und (2.38) gelten, sodass

$$\left. \frac{\partial \mathcal{P}_L}{\partial \dot{\xi}} \right|_{t_{\text{end}}} = 2 \cdot w_{\text{out2}} \cdot \dot{\xi}(t_{\text{end}}) = 0 \quad (3.9a)$$

$$\left. \frac{\partial \mathcal{P}_L}{\partial \ddot{\xi}} \right|_{t_{\text{end}}} = 2 \cdot w_{\text{in}} \cdot \ddot{\xi}(t_{\text{end}}) = 0 \quad (3.9b)$$

$$\left. \frac{d}{dt} \frac{\partial \mathcal{P}_L}{\partial \ddot{\xi}} \right|_{t_{\text{end}}} = 2 \cdot w_{\text{in}} \cdot \ddot{\ddot{\xi}}(t_{\text{end}}) = 0. \quad (3.9c)$$

3.3 Korrespondenz zwischen Euler-Lagrange- und Hidden-Markov-Modell

In Abschnitt 2.1 wird die Variationsrechnung als intuitive Modellierung von Trajektorienplanungsaufgaben hergeleitet. Durch die Äquivalenz zur Domäne der Optimierung von Funktionen mehrerer Variablen können iterative Methoden zur Lösung angewendet werden. Die Verwendung iterativer Lösungsverfahren bedeutet jedoch einige Nachteile, die andere Verfahren überwinden. Um jedoch die intuitive Problemmodellierung zu erhalten und dennoch die Vorteile anderer Verfahren zu nutzen, wird im Folgenden die in [E10] hergeleitete Korrespondenz zwischen Variationsproblemen und Hidden-Markov-Modellen gegeben. In Abschnitt 3.4 folgt die Anwendung auf die konkrete Trajektorienplanungsaufgabe.

Werden die Bewertungen der Funktion der Variationsrechnung als *Energien* interpretiert, kann die *Boltzmann-Verteilung* der Thermodynamik für die Korrespondenz zwischen Variationsproblemen und Hidden-Markov-Modellen verwendet werden. Die Boltzmann-Verteilung stellt einen Zusammenhang zwischen Wahrscheinlichkeiten eines Zustands und der Energie desselben Systems auf. Die Wahrscheinlichkeit $p(x)$ des Zustands x ergibt sich aus der Gesamtenergie $E(x)$ des Zustands x (mit Normierungskonstanten Z , β) über [100] als

$$p(x) = \frac{1}{Z} \cdot \exp\left(-\beta \cdot E(x)\right). \quad (3.10)$$

Mit der Erweiterung der Zustandswahrscheinlichkeit eines Zustands $p(x)$ auf eine Zustandssequenz, kann der probabilistische Teil der Boltzmann-Verteilung mit der Verbundwahrscheinlichkeit $p(\bar{s}_\tau, \bar{e}_\tau)$ eines Hidden-Markov-Modells aus Gl. (2.72) in Zusammenhang gebracht werden über

$$p(x) \rightarrow p(s_0) p(e_0|s_0) \cdot \prod_{i=1}^{\tau} p(e_i|s_i) p(s_i|s_{i-1}). \quad (3.11)$$

Der energetische Teil der Boltzmann-Verteilung wird mit der (Energie-)Bewertung einer Funktion in der Variationsrechnung über das Funktional $\mathcal{L}(f)$ aus Gl. (2.28) in Verbindung gebracht. Zur Herleitung der Korrespondenz wird weiterhin eine in zwei Teile *separierbare* Lagrangefunktion der kontinuierlichen Form

$$L(x, f(x), f'(x)) = L_1(x, f(x)) + L_2(f(x), f'(x)) \quad (3.12)$$

angenommen, deren erster Teilterm L_1 von der höchsten auftretenden Ableitung unabhängig ist und deren zweiter Teilterm L_2 vom Funktionsparameter x . Da es sich bei Hidden-Markov-Modellen um diskrete Modelle handelt, müssen die Funktionswerte x des Variationsproblems auch aus einer endlichen Menge stammen, um in einen endlichen Zustandsraum des Hidden-Markov-Modells transformiert zu werden. Mit einer Diskretisierung mit

$$c_i = x_1 + i \cdot \Delta x, \quad f(c_i) = y_i \quad \text{und} \quad f'(c_i) = \frac{y_i - y_{i-1}}{\Delta x}$$

ergibt sich dann der Zusammenhang zur Boltzmann-Verteilung als

$$E(x) \rightarrow \sum_{i=0}^{\tau} \left(L_1(c_i, y_i) + L_2\left(y_i, \frac{y_i - y_{i-1}}{\Delta x}\right) \right). \quad (3.13)$$

Damit ergibt sich für die Boltzmann-Verteilung aus Gl. (3.10) unter Vernachlässigung der Startwerte sowohl auf der probabilistischen, als auch auf der energetischen Seite

$$\begin{aligned} & \prod_{i=1}^{\tau} p(e_i | s_i) p(s_i | s_{i-1}) \\ &= \frac{1}{Z} \cdot \exp\left(-\beta \cdot \sum_{i=1}^{\tau} \left(L_1(c_i, y_i) + L_2\left(y_i, \frac{y_i - y_{i-1}}{\Delta x}\right) \right)\right) \quad (3.14) \\ &= \prod_{i=1}^{\tau} \frac{1}{Z_1} \exp\left(-\beta \cdot L_1(c_i, y_i)\right) \cdot \frac{1}{Z_2} \exp\left(-\beta \cdot L_2\left(y_i, \frac{y_i - y_{i-1}}{\Delta x}\right)\right). \end{aligned}$$

Durch die Separierung der Lagrangefunktion in L_1 und L_2 hängt der zweite Exponentialterm lediglich vom Funktionswert y_i und dessen Vorgänger y_{i-1} ab und beschreibt damit einen Zusammenhang zwischen zwei Zuständen. Der erste Exponentialterm enthält hingegen alleinig den Funktionswert y_i und eine Abhängigkeit des Laufparameters c_i und beschreibt somit einen Zustand unter Berücksichtigung weiterer Parameter. Der Parameter β bewirkt eine Skalierung der Energiewerte – beziehungsweise im Wahrscheinlichkeitsraum einen schärferen Abfall der Wahrscheinlichkeit mit zunehmenden Energiewerten – wohingegen die (von β abhängenden) Parameter Z_1 und Z_2 zur Wahrung korrekter Wahrscheinlichkeiten notwendig sind. Keine dieser Transformationen beeinflussen die Lage der Optima, sodass unter Vernachlässigung der Interpretation als »echte« Wahrscheinlichkeiten für die Parameter $Z_1 = Z_2 = \beta = 1$ angenommen werden kann.

Die Umformung eines Variationsproblems in ein korrespondierendes Hidden-Markov-Modell ist somit nach Gl. (3.14) über den Zusammenhang

$$p(e_i | s_i) \propto \exp\left(-L_1(c_i, y_i)\right) \quad \forall i = [1, \tau] \quad (3.15a)$$

$$p(s_i | s_{i-1}) \propto \exp\left(-L_2\left(y_i, \frac{y_i - y_{i-1}}{\Delta x}\right)\right) \quad \forall i = [1, \tau] \quad (3.15b)$$

gegeben. Die Summe der Einzelbewertungen der Variationsrechnung geht dabei in eine Multiplikation der Wahrscheinlichkeiten über.

Hinsichtlich der Transformationen von Start- und Endwerten ergeben sich je nach Anwendungsfall unterschiedliche Korrespondenzen, die vollständig in [E10] angegeben sind. Für die Anwendung als Trajektorienplanung vollautomatischer Fahrzeuge gelten für die Variationsrechnung feste Startwerte, die sich in ein Hidden-Markov-Modell zu einer Anfangswahrscheinlichkeit des sicheren Zustands mit $p(s_0) = 1$ transformieren. Durch das sichere Eintreten von s_0 wird die Anfangsemissionswahrscheinlichkeit $p(e_0 | s_0)$ irrelevant, da sich durch e_0 keine neuen Informationen ergeben, die das Eintreten von s_0 beeinflussen würden. Die natürlichen Randbedingungen freier Endpunkte in der Trajektorienplanung finden ihr Pendant in der Ausführung des Backtrackings des verwendete-

ten Viterbi-Algorithmus, der für freie Endpunkte mit jenem Zustand s_t^* maximaler Wahrscheinlichkeit begonnen wird. Spezielle Bewertungsterme aus Abschnitt 3.1, die lediglich auf den Endzustand wirken, können dabei bei der Wahl des Backtracking-Startzustands berücksichtigt werden.

Eigenschaften der Variationsrechnung und Hidden-Markov-Modelle

Durch die Korrespondenz zwischen Variationsproblemen und Hidden-Markov-Modellen können entsprechende Problemmodellierungen ineinander transformiert und damit die jeweiligen Vorteile der einzelnen Methoden ausgenutzt werden. Tabelle 3.1 fasst die Eigenschaften der beiden Modelle kompakt zusammen. In Kapitel 5 wird ein ausführlicher Vergleich innerhalb der Anwendung auf den Bereich der Trajektorienplanung gegeben, sodass im Weiteren lediglich auf die Kernaspekte eingegangen wird.

Der große Vorteil der Hidden-Markov-Modelle ist die Berechnung der global optimalen Lösung mittels dynamischer Programmierung. Im Gegensatz dazu kann bei der Verwendung der Variationsrechnung durch die iterative Problemlösung im Allgemeinen lediglich von einer lokalen Lösung ausgegangen werden. Innerhalb der iterativen Optimierung sind harte Nebenbedingungen schwer zu integrieren. Demgegenüber steht eine einfache Einbeziehung der harten Nebenbedingung durch eine entsprechende Definition des Hidden-Markov-Zustandsraums. Weiterhin muss bei einer iterativen Optimierung neben der Diskretisierung in Zeitschritte eine Startlösung, eine Optimierungsschrittweite und ein Abbruchkriterium bestimmt werden. Diese Parameter sind im Wesentlichen unabhängig von der eigentlichen Problemmodellierung und besitzen daher keine (physikalische) Anschauung, die eine geeignete Bestimmung erleichtern würde. Im Gegensatz dazu ist bei einer Hidden-Markov-Modellierung neben der Zeitdiskretisierung – die identisch zur Diskretisierung des Variationsproblems gewählt werden kann – lediglich eine Diskretisierung des Zustandsraums Z und des Zustandsübergangsraums \dot{Z} zu spezifizieren, was direkt der Ortsauflösung und Geschwindigkeitsauflösung entspricht und somit eine physikalisch deutbare Interpretation besitzt.

	Variationsproblem (ELM)	Hidden-Markov-Modell (HMM)
<i>Optimierungsmethode</i>	Gradienten-/Newton-Verfahren (iterativ)	Dynamische Programmierung (generativ)
<i>Wahl der Domäne</i>	Zeit diskret und begrenzt, Zustandsraum kontinuierlich	Zeit und Zustandsraum diskret und begrenzt
<i>Zu spezifizierende Parameter</i>	Startlösung, Schrittweite, Abbruchkriterium, Zeitdiskretisierung	Zustandsraum-diskretisierung (Ortsauflösung), Zeitdiskretisierung
<i>Optimierungsziel</i>	Sattelpunkt oder lokales Minimum	Globales Minimum
<i>Nebenbedingungen</i>	Schwierig zu handhaben	Einfach durch geeignete Definition des Zustandsraums
<i>Speicherbedarf</i>	$\text{SPACE}(T_d)$	$\text{SPACE}(T_d \cdot Z)$
<i>Rechenzeit</i>	TIME gegebenenfalls unendlich	$\text{TIME}(T_d \cdot Z \cdot Z')$
<i>Parallelisierungsmöglichkeiten</i>	Zeit parallel berechenbar, Iterationen seriell	Zustandsraum parallel berechenbar, Zeit seriell

Tabelle 3.1: Gegenüberstellung Euler-Lagrange- und Hidden-Markov-Modell. $\text{SPACE}(f)$ und $\text{TIME}(f)$ werden zur Beschreibung der Platz- und Zeitkomplexität von Algorithmen verwendet und beziehen sich auf Entscheidungsprobleme, die auf einer deterministischen Turingmaschine mit Zeit- beziehungsweise Platzbedarf in $O(f)$ im Sinne der Landau-Symbolik lösbar sind [7, 189].

Die großen Nachteile der Hidden-Markov-Modelle liegen in der schlechten Skalierung von Rechenzeit und Speicherbedarf. Der Speicherbedarf des Hidden-Markov-Modells ist abhängig von der Anzahl an Zeitschritten $|T_d|$ nach Gl. (2.2) und der Größe des Zustandsraums $|Z|$, wohingegen der Speicherbedarf der Variationsrechnung lediglich mit den Zeitschritten $|T_d|$ skaliert. Hinsichtlich der Rechenzeiten ist für die Variationsrechnung aufgrund der iterativen Methoden keine Aussage zu treffen und ist im schlechtesten Fall einer Divergenz unendlich. Im Gegensatz dazu ist die Rechenzeit des Hidden-Markov-Modells für eine feste Problemgröße konstant und skaliert mit der Zeit $|T_d|$, dem Zustandsraum $|Z|$ und dem Zustandsübergangsraum $|Z'$. Parallelisierungsmöglichkeiten ergeben sich bei Variationsproblemen über die einzelnen Zeitschritte, wobei die einzelnen Iterationen lediglich seriell ausführbar sind. Im Gegensatz dazu sind innerhalb der Hidden-Markov-Modelle alle Zustandsraumberechnungen innerhalb eines Zeitschritts parallelisierbar, jedoch die Berechnung der einzelnen Zeitschritte lediglich seriell ausführbar.

Anwendungsgebiete der Hidden-Markov-Modelle

Für die Aufgabe der Trajektorienplanung ist die Transformation der als Variationsproblem beschriebenen Problemformulierung in ein Hidden-Markov-Modell geeignet, da gerade eine garantierte Konvergenz innerhalb eines bekannten und konstanten Berechnungszeitraums für sicherheitskritische Anwendungen essenziell ist und daher iterative Lösungen der Variationsrechnung ein hohes Risiko darstellen. Im Wesentlichen ergeben sich folgende Anwendungsgebiete:

- *Hidden-Markov-Modell zur Trajektorienplanung:* Für eine Trajektorienplanung wird der Hidden-Markov-Zustandsraum Z über die notwendige Ortsauflösung aufgebaut und besitzt daher eine große Anzahl an Zuständen, deren Berechnungen sich jedoch innerhalb eines Planungszeitschritts $t \in T_d$ vollständig parallelisieren lassen. Die seriellen Berechnungsschritte ergeben sich durch die Anzahl an Planungsschritten, die in der vorliegenden Problemformulierung etwa 10 Zeitschritte betragen, sodass eine Echtzeitfähigkeit mit geeigneter Hardware realisierbar ist, wie am Beispiel einer NVIDIA GeForce GTX TITAN Grafikkarte in [S8] nachgewiesen wird.

- *Hidden-Markov-Modell zur Generierung von Startlösungen:* Das Hidden-Markov-Modell kann Startlösungen für die iterative Optimierung in einer niedrigen Ortsauflösung generieren, sodass iterative Verfahren in der Nähe einer global optimalen Lösung beginnen und die Startlösung kontinuierlich glätten. Durch die Korrespondenz zur Variationsrechnung sind die Optimierungskriterien gleich. Ist sichergestellt, dass auch die grobe globale Lösung des Hidden-Markov-Modells eine akzeptable Trajektorie beschreibt, so kann bei einer Divergenz des iterativen Algorithmus (oder dem Terminieren in einem schlechteren lokalen Optimum wie in Kapitel 5 diskutiert) zumindest diese Trajektorie für den nachfolgenden Zeitschritt verwendet werden.
- *Hidden-Markov-Modell als Qualitätsmaß:* Das Hidden-Markov-Modell kann im Sinne einer offline berechneten, qualitativ hochwertigen global optimalen *Benchmark-Lösung* bei der Entwicklung von einfacheren Methoden verwendet werden, da selbst eine hohe Anzahl an Starttrajektorien das Finden der global optimalen Lösung über iterative Methoden nicht garantieren, wie in Kapitel 5 diskutiert wird.

3.4 Das Hidden-Markov-Modell zur Trajektorienplanung

Mit der in Abschnitt 3.3 beschriebenen Korrespondenz kann das in Abschnitt 3.2 aufgestellte ELM in ein korrespondierendes \hookrightarrow Hidden-Markov-Modell zur Trajektorienplanung (HMM) transformiert werden. Die Penalty-Lagrangefunktion aus Gl. (3.1) ist separierbar in $L_{\text{in}}(\xi, \ddot{\xi})$ und $L_{\text{out}}(t, \xi, \dot{\xi})$ und modelliert die Trajektorienplanungsaufgabe bis einschließlich einer Bewertung von Beschleunigungen $\ddot{\xi}$, sodass zur Erhaltung der Markov-Eigenschaft der Zustand des HMMs gemäß Gl. (2.64) neben der Trajektorie ξ selbst, auch die Geschwindigkeit $\dot{\xi}$ beinhalten muss. Mit den Gleichungen (2.3) und (2.4) gilt für den HMM-Zustand

$$\zeta : T \rightarrow X^W \times Y^W \times \dot{X}^W \times \dot{Y}^W$$

$$\zeta_t = \begin{bmatrix} \xi(t) \\ \dot{\xi}(t) \end{bmatrix} = \begin{bmatrix} \xi_x(t) \\ \xi_y(t) \\ \dot{\xi}_x(t) \\ \dot{\xi}_y(t) \end{bmatrix} = \begin{bmatrix} \zeta_t^x \\ \zeta_t^y \\ \zeta_t^{\dot{x}} \\ \zeta_t^{\dot{y}} \end{bmatrix}. \quad (3.16)$$

Damit geht die Beschleunigung $\ddot{\xi}$ der Trajektorie über die Zustandsänderung $\dot{\zeta}$ ein, für die mit Gl. (2.5) gilt, dass

$$\dot{\zeta} : T \rightarrow \dot{X}^W \times \dot{Y}^W \times \ddot{X}^W \times \ddot{Y}^W$$

$$\dot{\zeta}_t = \frac{\zeta_t - \zeta_{t-1}}{\Delta t} = \begin{bmatrix} \dot{\xi}(t) \\ \ddot{\xi}(t) \end{bmatrix} = \begin{bmatrix} \zeta_t^{\dot{x}} \\ \zeta_t^{\dot{y}} \\ \zeta_t^{\ddot{x}} \\ \zeta_t^{\ddot{y}} \end{bmatrix}. \quad (3.17)$$

Mit den Transformationsvorschriften aus Gl. (3.15) ergeben sich die Zustandsübergangs- und Emissionswahrscheinlichkeiten mit der separierbaren Penalty-

Lagrangefunktion aus Gl. (3.1) und für die Parameter $Z_1 = Z_2 = \beta = 1$ unter Vernachlässigung der Interpretation als echte Wahrscheinlichkeiten zu

$$\begin{aligned} p(\zeta_t | \zeta_{t-1}) &\propto \exp\left(-L_{\text{in}}(\xi, \dot{\xi})\right) \\ &\propto \exp\left(-\mathcal{P}_{\text{in}}(\xi, \dot{\xi})\right) \end{aligned} \quad (3.18a)$$

$$\begin{aligned} p(\boldsymbol{\rho}(t) | \zeta_t) &\propto \exp\left(-L_{\text{out}}(t, \xi, \dot{\xi})\right) \\ &\propto \exp\left(-\mathcal{P}'_{\text{out}}(\xi, \dot{\xi}, t | \boldsymbol{\rho}) - \mathcal{P}''_{\text{out}}(\xi, \dot{\xi}, t | \boldsymbol{\rho}) - \mathcal{P}_{\text{target}}(\xi, t | \boldsymbol{\rho})\right). \end{aligned} \quad (3.18b)$$

Durch die Transformation wird deutlich, dass die Inner-Penalty's aus Gl. (3.18a) in die Übergangswahrscheinlichkeiten transformiert werden und damit dem zeit- und ortsinvarianten Mechanismen der Fahrzeugphysik entsprechen, also der – auf immer gleiche Weise beschreibbaren – Änderung des Ego-Fahrzeug-Zustands. Daneben zeigt die Korrespondenz in Gl. (3.18b) die Bedeutung des Pre-Penalty-Volumens als Emissionen, die entsprechend die Zeitabhängigkeiten der Situation und Prädiktion des Ego-Fahrzeugs modellieren¹. Die so interpretierbaren Korrespondenzen werden in Abbildung 3.1 nochmals dargestellt.

Über die Maximierung von Gl. (2.71) kann nun die wahrscheinlichste Zustandsfolge $\bar{\zeta}_{t_{\text{end}}}^* = [\zeta_{t_{\text{start}}}, \dots, \zeta_{t_{\text{end}}}]$ nach (2.69) erhalten werden, deren erste beiden Komponenten über Gl. (3.16) die »wahrscheinlichste« – und damit die optimale – Trajektorie ξ^* beschreiben. Hierbei bietet die folgende Anschauung eine intuitive Interpretation der Trajektorienplanung mittels HMM:

Zum besseren Verständnis wird eine umgekehrte Wahrnehmung eingenommen, die den Betrachter an das Ende des Prädiktionszeitraums zum Zeitpunkt $t_{\text{real}} = t_{\text{end}}$ versetzt und »in die Vergangen-

¹ Obwohl üblicherweise eine endliche Menge an Emissionssymbolen angenommen wird, ist für die betrachtete Anwendung eine unendliche Menge an emittierbaren Pre-Penalty-Volumen ohne praktische Probleme möglich.

heit« bis zum Startzeitpunkt t_{start} schauen lässt. Gesucht wird nun jene Trajektorie $\xi = \xi^*$ des Ego-Fahrzeugs, die die in der Vergangenheit beobachteten Situationen – gespeichert im Pre-Penalty-Volumen \mathcal{p} – als Emissionen erzeugt hat. Daraus ergeben sich zu den einzelnen Zeitpunkten t jene Positionen $\xi^*(t)$, an denen sich das Ego-Fahrzeug zur Zeit t am wahrscheinlichsten befunden hat, damit die beobachtete Situation sich zur Zeit t entsprechend gestaltet hat.

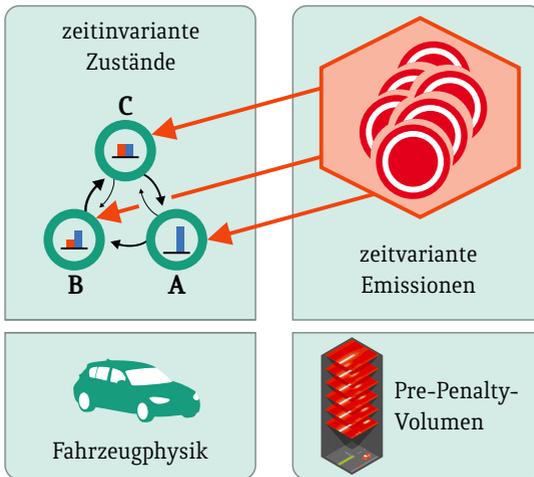


Abbildung 3.1: Anpassungen des Hidden-Markov-Modells zur Trajektorienplanung. Die zeitinvarianten Zustände beschreiben die Fahrzeugphysik, die Emissionen zu einzelnen Zeitschritten t die Ebenen des Pre-Penalty-Volumens.

3.5 Umsetzung der Trajektorienplanungsverfahren

3.5.1 Planungsräume

Die Modellierung der Welt ergibt sich gemäß Gl. (2.1) aus $x \in X^W$ und $y \in Y^W$ mit einem frei wählbaren Koordinatensystem K^W . Durch die betrachtete Situationsprädiktion – dargestellt als Pre-Penalty-Volumen – wird die Problemformulierung um eine zeitliche Komponente $t \in T_d$ erweitert. Der Lösungsraum einer Optimierung der Parameter x und y über t wird daher als $\hookrightarrow xyt$ -Planungsraum bezeichnet und stellt die allgemeinste Form der Optimierung in dieser Arbeit dar.

Zur besseren Veranschaulichung der Optimierungsergebnisse wird an einigen Stellen dieser Arbeit auf eine Optimierung im $\hookrightarrow st$ -Planungsraum zurückgegriffen, da sich bereits in diesem vereinfachten Planungsraum typische Herausforderungen der Optimierung finden, diese jedoch noch anschaulich darstellbar sind. Hierfür wird entsprechend Gl. (2.6) der geplante Pfad $\tilde{\xi}(s)$ des Ego-Fahrzeugs betrachtet und damit die räumliche Komponente auf eine Dimension abgebildet. Zusammen mit dem zeitlichen Positionsverlauf aus Gl. (2.7) ergibt sich daraus eine Optimierung des Raumparameters $s \in S^W$ über die Zeit t .

Die Reduktion der Raumkomponente kann als ein *Schnitt* durch das Pre-Penalty-Volumen entlang des Pfades $\tilde{\xi}(s)$ unter Beibehaltung aller Prädiktionszeiten t betrachtet werden, sodass sich – ein 3D-Pre-Penalty-Volumen vorausgesetzt – eine 2D-Darstellung des Pre-Penalty-Volumens ergibt. Abbildung 3.2 zeigt einen beispielhaften Schnitt.

Die Reduktion des vollständigen xyt -Planungsraums auf eine st -Planung stellt eine Vereinfachung des Lösungsraums dar. Die Ergebnisse dieser Arbeit in Kapitel 5 zeigen jedoch bereits bei einer reduzierten st -Planung entsprechende Defizite der iterativen Optimierung des ELM-Trajektorienplanungsverfahrens auf, sodass die Ergebnisse als *untere Qualitätsschranke* der xyt -Planung aufgrund der damit einhergehenden Komplexitätserhöhung übertragbar sind. Tatsächlich ist der Straßenverkehr durch seine Ausrichtung an (potentiell mehreren) Fahr-

spuren einer st -Planung strukturell ähnlicher als einer freien Planung durch einen beliebigen xyt -Raum. Dieser Umstand wird in Abschnitt 6.2 zur (reduzierten) xyt -Planung auf mehrspurigen Straßen ausgenutzt. Wo immer sinnvoll, werden vollständige Beschreibungen im xyt -Planungsraum gegeben.

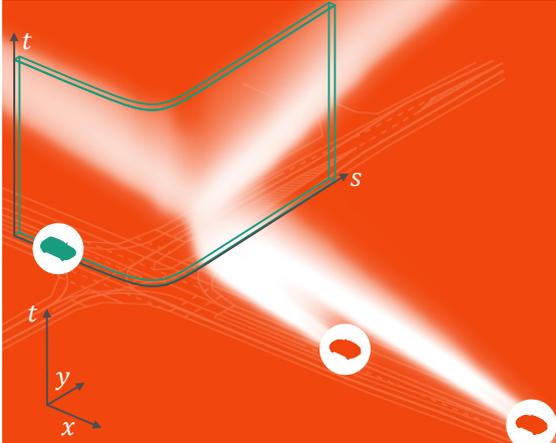


Abbildung 3.2: Schnitt durch 3D-Pre-Penalty-Volumen. Dargestellt ist das einfache Linksabbiegermanöver (Beispielsituation ①) aus Abbildung 5.8.

3.5.2 Umsetzung des Euler-Lagrange-Modells

Um bestmögliche Vergleichbarkeit der beiden Trajektorienplanungsverfahren zu gewährleisten, wird für die iterative Optimierung des ELM-Algorithmus die von MATLAB bereitgestellte Funktion *fmincon* für beschränkte Optimierungsprobleme verwendet. Sie stellt einen gängigen Algorithmus zur numerischen Lösung des nichtlinearen Optimierungsproblems bereit, basierend auf dem Broyden-Fletcher-Goldfarb-Shanno (BFGS) Verfahren, einem Quasi-Newton-Verfahren mit einer Approximation der inversen Hesse-Matrix. Als Gradient wird der Funktion die Penalty-Euler-Lagrange-Gleichung aus Gl. (3.6) mit Gl. (3.7) übergeben sowie die Nebenbedingungen aus Gl. (3.4) und die natürlichen Randbedingungen aus Gl. (3.9). Neben der Verwendung von Liniensuchverfahren werden in der Funktion zur Einhaltung der harten Nebenbedingungen sowohl Active-

Set-Methoden als auch Innere-Punkte-Verfahren angewendet. Eine ausführliche Erläuterung der Methoden ist in [61, 132] zu finden.

Die ELM-Iterationsergebnisse können daher als »hochwertige« iterative Lösungen angesehen werden, da es sich bei dem verwendeten MATLAB-Löser um einen Optimierungsalgorithmus handelt, der in professionellen Anwendungen verbreitet genutzt wird und in den betrachteten Evaluationen großzügig Rechenzeit für die Terminierung der Optimierung eingeräumt wird. Weniger weit entwickelte Löser – wie beispielsweise ein zum Vergleich implementierter Gradientenabstieg unter Verwendung der Penalty-Euler-Lagrange-Gleichung – terminieren erwartungsgemäß in weiteren lokalen Optima und weisen Probleme bei der Einhaltung der Nebenbedingungen auf, und erzielen demnach weitaus schlechtere Ergebnisse.

Die iterative ELM-Optimierung gehört zu den lokalen Optimierungsverfahren, die beginnend von einer Startlösung $\xi_{\text{ELM}}^{(k)}$ eine Ergebnistrajektorie ξ_{ELM}^k generieren. Da es sich bei dem so gefundenen Optimum um ein einziges lokales Minimum handelt, wird der Trajektorienraum mit mehreren ELM-Optimierungen basierend auf unterschiedlichen Startlösungen abgetastet, um in einem anschließenden Vergleich der Penaltywerte aller Optimierungsergebnisse jenes lokale Minimum mit dem geringsten Wert auszuwählen.

Durch den iterativen Charakter des ELM-Algorithmus kann keine Konvergenz in endlicher Zeit garantiert werden. Jeder ELM-Optimierungsvorgang besitzt daher ein Abbruchkriterium in Form einer maximalen Anzahl an Iterationsschritten. Die Kriterien, die eine erfolgte Konvergenz des Optimierungsprozesses bestimmen, werden dem *fmincon*-Löser überlassen.

Starttrajektorien aus Voronoi-Diagrammen

Eine qualitativ gute Starttrajektorie bietet der iterativen Lösungsmethode einen möglichst direkten Weg in ein lokales Minimum, das im Wert dem globalen Minimum möglichst ähnlich ist. Die tatsächliche Nähe zum globalen Optimum kann dabei ein Indiz sein, ist aber weitaus weniger signifikant, als gemeinhin – beispielsweise in [14, 15] – angenommen. Dies zeigt sich in der topologischen Analyse in Kapitel 5.

Ein geeigneter Algorithmus zur Starttrajektoriengenerierung ermöglicht daher eine gute Ausgangslage des Optimierungsalgorithmus – unter Verwendung einer geringen Anzahl an Starttrajektorien – sodass Echtzeitschranken des gesamten Trajektorienplanungssystems eingehalten werden können. Die Generierung unter Berücksichtigung des Fahrzeugumfelds erscheint als vielversprechender Ansatz zur intelligenten Berechnung einer geringen Anzahl an potentiellen Starttrajektorien. Hierfür schlägt [14] eine *Skelettierung* des Freiraums vor, die im Zweidimensionalen topologisch dem Voronoi-Diagramm entspricht. Dieser Ansatz ist jedoch mit einigen Problemen verbunden, die im Folgenden entlang der Erkenntnisse aus [E1] in verkürzter Form diskutiert werden. Da diese Arbeit im Gegensatz zu [14] keine binärwertige Situationsbeschreibung (belegt gegenüber frei) voraussetzt, muss zunächst eine Menge an positiven Punkten definiert werden. Dennoch sind die im Weiteren gewonnenen Aussagen über methodische Herausforderungen des Ansatzes zur Starttrajektoriengenerierung analog auf die Methode in [14] übertragbar.

Das Voronoi-Diagramm V eines 2D-Felds aus einer Orts- und Zeitkomponente $H_R : X \times T \mapsto \mathbb{R}$ ergibt sich aus einer (im Vorhinein) festgelegten Anzahl an auf lokalen Maxima liegenden Zentren, wobei alle Punkte des 2D-Felds gemäß dem euklidischen Distanzmaß entsprechend ihrem nächstgelegenen Maximumszentrum zugeordnet werden. Die Voronoi-Kanten ergeben sich aus der Verbindung aller Punkte, die zu mehreren Zentren zugeordnet werden und damit in der Mitte zweier Maximumszentren liegen. Sie korrelieren somit mit den Minima des 2D-Felds. Transformiert in eine Graphenstruktur G_V ergeben sich aus den ursprünglichen Voronoi-Kanten durch Graphensuchalgorithmen einzelne Voronoi-Pfade P_V , die als Grundlage zur Startlösungsgenerierung verwendet werden.

Durch die Verwendung der Voronoi-Diagramme ergeben sich jedoch folgende Probleme der so generierten Starttrajektorien, die – wenn überhaupt – zunächst durch eine aufwendige Nachprozessierung korrigiert werden müssen [E1]:

- Der aufgespannte Graph G_V enthält im Allgemeinen nicht die Ego-Fahrzeug-Position, sodass eine Verbindung zwischen der Startposition und dem Pfad P_V generiert werden muss, was in der Voronoi-

Modellanschauung nicht begründet werden und potentiell unerwünschte Trajektorieneigenschaften wie Komfort- oder Sicherheitsverluste einbringen kann.

- Das Voronoi-Diagramm V betrachtet rein geometrische Aspekte und unterscheidet nicht zwischen solchen, und zeitlichen Abhängigkeiten, sodass sich Pfade P_V entgegen der Zeitrichtung ergeben können. Diese können nachträglich herausgefiltert werden, was jedoch potentiell mit einem Verlust möglicher Pfadvarianten einhergeht, die nicht strikt Teil des Voronoi-Diagramms sind und dennoch vorwärts durch die Zeit führen.
- Die geometrische Betrachtungsweise bedeutet weiterhin eine Austauschbarkeit der Dimensionen des Risikofelds H_R , sodass die Rasterung von Zeit- und Ortsachse als gleichwertig betrachtet werden. Es wird jedoch in [E1] gezeigt, dass das Verhältnis der Achsen einen signifikanten Einfluss auf das Ergebnis hat, dieses dabei jedoch keiner physikalischen Bedeutung entspricht und somit ein Raum-Zeit-Umrechnungsfaktor als weiterer Parameter in die Problemmodellierung einfließt.
- Das Voronoi-Diagramm V und die sich ergebenden Pfade P_V hängen lediglich vom Risikofeld H_R ab, und nicht von anderen relevanten Parametern der Problemmodellierung, wie beispielsweise der Fahrdynamik oder dem Fahrzeugzustand zum Zeitpunkt $t = t_{\text{start}}$. Die sich als Voronoi-Pfad P_V ergebenden Starttrajektorien beschreiben somit bestenfalls die Nähe von rein auf der Umgebung des Ego-Fahrzeugs basierenden lokalen Optima, stellen aber *keine* vollständige Aufzählung der tatsächlichen lokalen Optima der vollständigen Problembeschreibung dar.

Die Ergebnisse in Kapitel 5 zeigen, dass rein geometrische Betrachtungen zur Lösung des Trajektorienproblems nicht ausreichend sind, weshalb die Verwendung von Voronoi-Diagrammen (oder ähnlichen Verfahren) zur Trajektorienplanung als nicht geeignet eingeschätzt wird.

Starttrajektorien konstanter Geschwindigkeit

Als Alternative zu der beschriebenen selektiven und mit Problemen behafteten Generierung von Starttrajektorien über Voronoi-Diagramme wird im Weiteren ein »Brute-Force-Ansatz« – im Sinne des Versuchs einer erschöpfenden Starttrajektorien-generierung – gewählt. Hierfür wird der Trajektorienraum mit einer großen Zahl an Startlösungen abgetastet, um allgemeine Aussagen über den ELM-Algorithmus hinsichtlich Ergebnisqualität und Konvergenzverhalten treffen zu können. Dabei ist ein solcher Ansatz *nicht* geeignet zur echtzeitfähigen Trajektorienplanung für vollautomatische Fahrzeuge und soll vielmehr zur möglichst umfassenden Evaluation des iterativen ELM-Planungsalgorithmus dienen, um methodische Eigenschaften zu analysieren. Im Allgemeinen ergeben sich durch die Trajektorienplanungsaufgabe Echtzeitanforderungen bei gleichzeitiger begrenzter Rechenkapazität, die für die Evaluation der ELM-Trajektorienplanungsmethode jedoch außer Acht gelassen werden. Die im Folgenden beschriebene dichte Abtastung des Trajektorienraums ist für den Einsatz einer ELM-Trajektorienplanung in einem ressourcenbegrenzten Echtzeitsystem nicht realisierbar, sodass weitere Arbeiten hinsichtlich guter Startlösungsgenerierungen notwendig sind.

Die topologischen Analysen des ELM-Algorithmus in Kapitel 5 basieren auf einem st -Planungsraum. Eine Evaluation bei einer xyt -Planung ist in [S15] gegeben. Für eine möglichst erschöpfende Betrachtung wird ein dichter Fächer an Starttrajektorien für $t \in [t_{\text{start}}, t_{\text{end}}]$ und $s \in [s_{\text{min}}, s_{\text{max}}]$ mit identischem Startpunkt s_{start} und unterschiedlichen, konstanten Geschwindigkeiten aufgespannt. Für die k -te Starttrajektorie $\xi_{\text{ELM}}^{(k)}$ gilt mit $\dot{\xi}_k$ als das k -te Element der Menge $M_{\dot{\xi}} = \{\dot{\xi}_{\text{min}}, \dot{\xi}_{\text{min}} + \Delta\dot{\xi}, \dots, \dot{\xi}_{\text{max}}\}$ mit $k \in \{1, \dots, |M_{\dot{\xi}}|\}$

$$\xi_{\text{ELM}}^{(k)}(t) = \begin{cases} s_{\text{min}}, & \text{wenn } s_{\text{start}} + \dot{\xi}_k \cdot t \leq s_{\text{min}} \\ s_{\text{max}}, & \text{wenn } s_{\text{start}} + \dot{\xi}_k \cdot t \geq s_{\text{min}} \\ s_{\text{start}} + \dot{\xi}_k \cdot t, & \text{sonst.} \end{cases} \quad (3.19)$$

Die Abbildungen 5.3a und 5.9d zeigen beispielhafte Teilmengen an generierten Starttrajektorien.

3.5.3 Umsetzung des Hidden-Markov-Modells

Die Suche nach der wahrscheinlichsten Trajektorie, dargestellt als Zustandsfolge des HMMs, kann – wie in Abschnitt 2.3 beschrieben – durch den Viterbi-Algorithmus gelöst werden, indem die Problemformulierung der Variationsrechnung über die Korrespondenz in Gl. (3.15) in ein korrespondierendes HMM transformiert wird.

Alternativ ist eine Anpassung des Viterbi-Algorithmus auf die Problemformulierung der Variationsrechnung möglich. Hierfür ergeben sich folgende Korrespondenzen der einzelnen Viterbi-Berechnungsschritte anhand der Herleitung in Abschnitt 3.3:

- Die Multiplikation der Wahrscheinlichkeiten einzelner Zeitschritte geht in eine Summation der Penaltys einzelner Zeitschritte über. (Siehe Korrespondenz: Gl. (3.14))
- Die Maximierung der Verbundwahrscheinlichkeit geht in eine Minimierung des Funktionals über. (Vergleiche Grundlagen: Gl. (2.12), Gl. (2.70))

Aus den Anpassungen ergibt sich der im Weiteren verwendete \hookrightarrow Penalty-Viterbi-Algorithmus aus Algorithmus 3.1.

Zur Aufstellung des *HMM-Zustandsraums* ist eine Diskretisierung aller Zustandskomponenten aus den Gleichungen (3.16) und (3.17) notwendig. Wie bereits bei der Diskretisierung der Zeit in Gl. (2.2b) gilt für die betrachteten Größen c mit $c \in \{x, y, \dot{x}, \dot{y}, \ddot{x}, \ddot{y}\}$, sowie die dazugehörigen Mengen $C \in \{X, Y, \dot{X}, \dot{Y}, \ddot{X}, \ddot{Y}\}$ und deren Intervalle $[c_{\min}, c_{\max}]$ bei Wahl einer Anzahl an jeweiligen Diskretisierungsschritten $N_c \in \mathbb{N}$ (beziehungsweise deren Weite $\Delta c = (c_{\max} - c_{\min}) / N_c$)

$$\zeta^c \in C \subset C^W$$

$$C = \{c_{\min}, c_{\min} + \Delta c, \dots, c_{\min} + (N_c - 1) \cdot \Delta c, c_{\max}\}. \quad (3.20)$$

Der HMM-Zustandsraum Z des Zustands ζ aus Gl. (3.16) und der HMM-Zustandsübergangsraum \dot{Z} des Zustandsübergangs $\dot{\zeta}$ aus Gl. (3.17) ergeben sich dann als

$$Z = X \times Y \times \dot{X} \times \dot{Y} \quad (3.21a)$$

$$\dot{Z} = \dot{X} \times \dot{Y} \times \ddot{X} \times \ddot{Y}. \quad (3.21b)$$

Durch eine entsprechende Wahl der Intervalle $[c_{\min}, c_{\max}]$ können die harten Nebenbedingungen aus Gl. (3.4) direkt in den HMM-Zustandsraum integriert werden. Daraus ergibt sich ein minimales HMM zur Trajektorienplanung, deren Lösungen in allen Fällen valide Trajektorien ergeben. Die Zustandsräume in Gl. (3.21) zeigen jedoch deutlich, dass eine wohlüberlegte Wahl der Diskretisierung zur Wahrung der Echtzeitbedingungen notwendig ist. Entsprechend wird in Abschnitt 6.2 eine weitere Möglichkeit zur Zustandsraumreduktion vorgestellt. Die Festlegung von Startposition und Geschwindigkeit aus Gl. (3.4f) geschieht durch Wahl der Penaltys der ersten Zustände ζ_0 als unendlich mit Ausnahme des gewünschten Zustands. Die natürlichen Randbedingungen werden gemäß den Erläuterungen in Abschnitt 3.3 durch das Backtracking eingebunden.

Der Penalty-Viterbi-Algorithmus aus Algorithmus 3.1 berechnet für jeden Zeitschritt $\tau \in \mathbb{N}$ eine Matrix $\mathcal{P}'_\tau(\zeta_\tau, \zeta_{\tau-1})$ der Größe $Z \times \dot{Z}$, die die Auswertungsergebnisse der Penalty-Lagrangefunktion \mathcal{p}_L aus Gl. (3.1) mit Gl. (3.2) aller modellierten Zustandsübergänge von $\zeta_{\tau-1}^i$ nach $\zeta_\tau^j \forall i, j \in \mathbb{N}$ enthält. Eine anschließende Suche nach den minimalen Penaltys in $\mathcal{P}'_\tau(\zeta_\tau, \zeta_{\tau-1})$ für jeden Zustand ζ_τ^i resultiert in zwei Vektoren jeweils der Dimension Z , die die minimale Penalty in $\mathcal{P}_\tau(\zeta_\tau)$ mit zugehörigem Vorgängerzustand $\zeta_{\tau-1}^*$ in $\delta_\tau(\zeta_\tau)$ zur weiteren Verwendung speichern.

Für den Normalbetrieb wird das Backtracking von jenem Zustand ζ_N^* begonnen, der den minimalen Penalty-Eintrag in $\mathcal{P}_N(\zeta_N)$ aufweist und damit die global optimale Trajektorie ξ^* enthält. Zudem wird ein weiterer Backtrackingprozess für die in Abschnitt 6.3 beschriebene Notfalltrajektorienplanung von einem optimalen Notfalltrajektorienzustand ζ_N^{Emerg} begonnen, der sich aus einer von der Target-Penalty-Funktion $\mathcal{p}_{\text{target}}$ abweichenden Bewertung des Endzustands ergibt. Diese Notfall-Penalty-Funktion $\mathcal{p}_{\text{emerg}}$ bewertet nicht das Erreichen eines Zielorts, sondern vielmehr den Stillstand in einem als sicher eingestuftem Bereich, wie beispielsweise auf dem Seitenstreifen.

Eingabe: Anzahl der Zeitschritte \mathcal{T} , Zeitintervall $[t_{\text{start}}, t_{\text{end}}]$,
 Zustandsraum Z , Zustandsübergangsraum \check{Z} ,
 Penalty-Lagrangefunktion \mathcal{P}_L , Penalty-Funktion für
 Notfallbetrieb $\mathcal{P}_{\text{emerg}}$, Startzustand $[\mathbf{x}_{\text{start}}^W, \dot{\mathbf{x}}_{\text{start}}^W]^T$

Ausgabe: Global optimale Trajektorie ξ_{HMM} oder Notfalltrajektorie ξ_{Emerg}

Beginn

$\Delta t \leftarrow (t_{\text{end}} - t_{\text{start}}) / \mathcal{T};$

für jedes $\zeta_0 \in Z$ **tue**

$$\mathcal{P}_0(\zeta_0) \leftarrow \begin{cases} 0 & \text{wenn } \zeta_0 = [\mathbf{x}_{\text{start}}^W \ \dot{\mathbf{x}}_{\text{start}}^W]^T; \\ \infty & \text{sonst} \end{cases};$$

Ende

für $\tau \leftarrow 1$ **bis** \mathcal{T} **tue**

$t \leftarrow t_{\text{start}} + \tau \cdot \Delta t;$

für jedes $\zeta_\tau \in Z$ **tue**

für jedes $\check{\zeta}_\tau \in \check{Z}$ **tue**

$\zeta_{\tau-1} \leftarrow \zeta_\tau - \check{\zeta}_\tau \cdot \Delta t;$

$\mathcal{P}'_\tau(\zeta_\tau, \zeta_{\tau-1}) \leftarrow \mathcal{P}_L(\xi(t), \dot{\xi}(t), \ddot{\xi}(t), t | \mathcal{P}) \Delta t + \mathcal{P}_{\tau-1}(\zeta_{\tau-1});$

Ende

$\mathcal{P}_\tau(\zeta_\tau) \leftarrow \min_{\zeta_{\tau-1} \in Z} \mathcal{P}'_\tau(\zeta_\tau, \zeta_{\tau-1});$

$\delta_\tau(\zeta_\tau) \leftarrow \arg \min_{\zeta_{\tau-1} \in Z} \mathcal{P}'_\tau(\zeta_\tau, \zeta_{\tau-1});$

Ende

Ende

// Trajektorie für Normalbetrieb

$\zeta_N^* \leftarrow \arg \min_{\zeta_N \in Z} \mathcal{P}_N(\zeta_N);$

Backtracken von ξ_{HMM} entlang δ_τ beginnend ζ_N^* ;

// Trajektorie für Notfall

$\zeta_N^{\text{Emerg}} \leftarrow \arg \min_{\zeta_N \in Z} (\mathcal{P}_N(\zeta_N) - \mathcal{P}_{\text{target}}(\zeta_N) + \mathcal{P}_{\text{emerg}}(\zeta_N));$

Backtracken von ξ_{Emerg} entlang δ_τ beginnend ζ_N^{Emerg} ;

Ende

Algorithmus 3.1: Penalty-Viterbi-Algorithmus für Variationsprobleme.

4

Geometrie des Trajektorienraums

Der Trajektorienraum Ξ beschreibt eine Teilmenge eines allgemeinen, unbeschränkten Funktionenraums. Die im Trajektorienraum enthaltenen Funktionen sind dabei die Menge aller validen Trajektorien $\xi \in \Xi$, die sich als gültige Lösungen hinsichtlich modellierter Nebenbedingungen und Problemannahmen ergeben. Die Geometrie des Trajektorienraums besteht dabei aus der Geometrie des Ego-Fahrzeugs in Abschnitt 4.1 und der Geometrie der Situation in Abschnitt 4.2, die die Grundlage zur Modellierung der Inner-Penaltys \mathcal{P}_{in} und Outer-Penaltys \mathcal{P}_{out} der Penalty-Lagrangefunktion \mathcal{P}_L aus Gl. (3.1) bilden.

4.1 Geometrie des Ego-Fahrzeugs

4.1.1 Das C^2 -Modell

Das in [E3] hergeleitete $\hookrightarrow C^2$ -Modell definiert ein *analytisches Fahrzeugmodell*, das zur Beschreibung relevanter Größen des *Ego-Fahrzeug-Zustands* dient. Die Berechnungen des Modells lassen sich vollständig auf eine gegebene Trajektorie ξ und \hookrightarrow Konstruktionsparameter des Ego-Fahrzeugs zurückführen und ergeben dadurch ein schlankes, einfach zu berechnendes Fahrzeugmodell, das dennoch ein Modell ausreichender Güte für die Aufgabe der Trajektorienplanung darstellt, wie anhand Simulationen und realen Testfahrten gezeigt wird.

Die Einfachheit des C^2 -Modells ermöglicht eine effiziente Einbeziehung geometrischer Betrachtungen des Ego-Fahrzeugs in die Trajektorienoptimierung in

Form von Nebenbedingungen und Bewertungstermen innerhalb der Penalty-Lagrangefunktion ohne die Notwendigkeit einer *Vorwärtssimulation* eines – möglicherweise rechenintensiven – Simulationsmodells des Ego-Fahrzeugs. Daneben kann das C^2 -Modell, das sowohl als Ein- als auch als Mehrspurmodell parametrisiert werden kann, zur Berechnung der nächsten Stellbefehle aus der optimalen Trajektorie ξ^* verwendet werden.

Neben der Trajektorienplanung kann das C^2 -Modell weiterhin zur Rekonstruktion intrinsischer Fahrzeugparameter anderer Verkehrsteilnehmer über deren aufgezeichnete Trajektorien – beispielsweise aus Luftbildern – dienen. Daraus ergeben sich Rückschlüsse auf Fahrerverhalten und Verkehrsstatistiken, die für die Modellierung der \hookrightarrow Situationsgeometrie im folgenden Abschnitt 4.2 genutzt werden können.

Die über das Datenblatt eines Fahrzeugs gegebenen, für eine C^2 -Modellierung notwendigen Konstruktionsparameter sind:

- Achsabstand l : Abstand der Vorder- und Hinterachse
- Halbe Spurbreite h : Hälfte des Abstands zweier Räder einer Achse
- Reifenradius vorne r_v und hinten r_h : Radien der Räder an Vorder- und Hinterachse, wobei identische Radradien an derselben Achse angenommen werden. (Für eine genauere Modellierung können statische Reifenradien über die Tabelle in [160] verwendet werden.)

Die kompakte Modellierung des Ego-Fahrzeug-Zustands geht mit einigen vereinfachenden Annahmen einher, die es jedoch ermöglichen, unter der ausschließlichen Betrachtung der Trajektorie ξ auf den Zustand des Ego-Fahrzeugs zu schließen. Hierfür wird angenommen, dass der Ego-Fahrzeug-Zustand eindeutig definiert ist über:

- Position ξ des Ego-Fahrzeugs
- Geschwindigkeit $\dot{\xi}$ des Ego-Fahrzeugs, die immer in Richtung der Fahrzeugorientierung ψ gerichtet ist
- Einschlagwinkel an den Vorderrädern links δ_l und rechts δ_r
- Rollgeschwindigkeiten der Vorderräder links $\dot{\rho}_{vl}$ und rechts $\dot{\rho}_{vr}$ sowie Hinterräder links $\dot{\rho}_{hl}$ und rechts $\dot{\rho}_{hr}$

Relevante vereinfachende Modellannahmen im Vergleich zu komplexeren Fahrzeugmodellen sind dabei:

- Vernachlässigung von lateralem Schlupf (wie in der Literatur üblich, beispielsweise in [70]), sodass die Fahrzeuglängsachse aus Abbildung 4.1 immer tangential an der Trajektorie ausgerichtet ist
- Vernachlässigung von longitudinalem Schlupf, sodass sich Rad-Rollgeschwindigkeiten gemäß der Geschwindigkeit des Ego-Fahrzeugs ergeben
- Vernachlässigung von Roll- und Nickwinkel
- Vereinfachung auf eine zweidimensionale, nicht notwendigerweise ebene Fläche, wie in [S1] beschrieben
- Vereinfachung auf einen statischen Reifenradius unter Vernachlässigung von Reifenverformungserscheinungen

Herleitung des C^2 -Modells

Das C^2 -Modell basiert auf differentialgeometrischen Betrachtungen entsprechend [42, 165] und beschreibt eine in der räumlichen Weltebene $X^W \times Y^W$ planare Trajektorie ξ , die zur Differentiationsklasse $C^2(T)$ aus Abschnitt 2.2 gehört. Die Differenzierbarkeit der zweidimensionalen Funktion ξ – definiert nach Gl. (2.3) – wird dabei als eine Differenzierbarkeit ihrer einzelnen Komponenten definiert. Es gilt

$$\left. \begin{array}{l} \xi_x \in C^2(T) \\ \xi_y \in C^2(T) \end{array} \right\} \Rightarrow \xi \in C^2(T). \quad (4.1)$$

Der Tangential- und Normalenvektor einer Trajektorie ξ sind definiert als

$$\mathbf{T} = \frac{\dot{\xi}}{\|\dot{\xi}\|} \quad \text{und} \quad \mathbf{N} = \begin{bmatrix} 0 & -1 \\ 1 & 0 \end{bmatrix} \cdot \mathbf{T} \quad \text{womit} \quad \|\mathbf{T}\| = \|\mathbf{N}\| = 1. \quad (4.2)$$

Für den Fall eines Ego-Fahrzeug-Stillstands innerhalb eines Intervalls $I \subset T$ mit $\dot{\xi}(t) = 0 \quad \forall t \in I$, kann der Tangentialvektor \mathbf{T} als Fortsetzung eines der existierenden Limits der Tangente \mathbf{T} auf den Rändern des Intervalls I unter Berücksichtigung der Stetigkeitsbedingungen definiert werden. Der mögliche Fall $\dot{\xi}(t) = 0 \quad \forall t \in T$ beschreibt ein zu allen Zeiten stehendes Ego-Fahrzeug und stellt daher keinen praktischen Nutzen für die Anwendung dar.

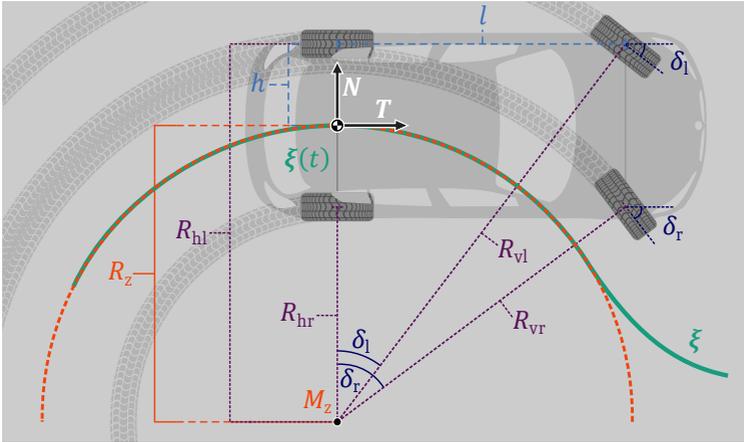


Abbildung 4.1: Geometrische Parameter des C^2 -Modells. Die Trajektorie ξ kann zu jedem Zeitpunkt $t \in T$ über einen Kreis mit Mittelpunkt $M_z(t)$ und Radius $R_z(t)$ approximiert werden. Identisches gilt für die Bewegungsfunktion der einzelnen Radmittelpunkte aufgetragen über t , dessen Radien der beschriebenen Kreise sich zu $R_{vl}(t)$, $R_{vr}(t)$, $R_{hl}(t)$, $R_{hr}(t)$ ergeben. Die Einschlagwinkel der Vorderräder sind als $\delta_r(t)$, $\delta_l(t)$ gegeben.

Mit der Beschreibung des *Fahrzeugkoordinatensystems* nach Abbildung 4.1 mit der Basis (\mathbf{T}, \mathbf{N}) im Mittelpunkt der Hinterachse – und aufgrund der getroffenen Annahme vernachlässigbaren lateralen Schlupfs – lassen sich die absolute Geschwindigkeit v und die Längsbeschleunigung a als Projektionen der ersten

und zweiten Ableitung der Trajektorie ξ auf den Tangentialvektor \mathbf{T} über das Skalarprodukt berechnen und mit Gl. (4.2) vereinfachen, sodass gilt

$$v = \langle \mathbf{T} | \dot{\xi} \rangle = \frac{\langle \dot{\xi} | \dot{\xi} \rangle}{\|\dot{\xi}\|} = \frac{\|\dot{\xi}\|^2}{\|\dot{\xi}\|} = \|\dot{\xi}\| \quad (4.3)$$

$$a = \langle \mathbf{T} | \ddot{\xi} \rangle = \frac{\langle \dot{\xi} | \ddot{\xi} \rangle}{\|\dot{\xi}\|}. \quad (4.4)$$

Gleichung (4.4) verdeutlicht den allgemeinen Zusammenhang $|a| \cong \|\ddot{\xi}\|$, der lediglich bei Geradeausfahrt, also bei parallelen Geschwindigkeits- und Beschleunigungsvektoren aufgrund $|\langle \dot{\xi} | \ddot{\xi} \rangle| = \|\dot{\xi}\| \cdot \|\ddot{\xi}\|$ in die Form $|a| = \|\ddot{\xi}\|$ übergeht. Für die Querbeschleunigung gilt derweil entsprechend $a_{\text{lat}} = \langle \mathbf{N} | \ddot{\xi} \rangle$.

Die Änderung des Tangentialvektors \mathbf{T} entlang der Bogenlänge s beschreibt die Krümmung der Trajektorie ξ . Der Krümmungsvektor $\boldsymbol{\kappa}$ mit

$$\boldsymbol{\kappa} = \frac{d}{ds} \mathbf{T} \quad (4.5)$$

steht wegen $\|\mathbf{T}\| = \text{const.} (= 1)$ immer senkrecht auf der Tangente \mathbf{T} und damit parallel zur Normalen \mathbf{N} . Damit kann die skalare, richtungsabhängige Krümmung κ wegen $\|\mathbf{N}\| = \text{const.} = 1$ aus dem Skalarprodukt des Krümmungsvektors und der Normalen berechnet werden über¹

$$\kappa = \langle \mathbf{N} | \boldsymbol{\kappa} \rangle = \left\langle \mathbf{N} \left| \frac{d}{ds} \mathbf{T} \right. \right\rangle. \quad (4.6)$$

Unter Zuhilfenahme der Umformung

$$\frac{d}{ds} \mathbf{T} = \frac{dt}{ds} \cdot \frac{d}{dt} \mathbf{T} = \frac{1}{\|\dot{\xi}\|} \cdot \dot{\mathbf{T}} \quad \text{mit} \quad \|\dot{\xi}\| = \frac{ds}{dt}$$

¹ Für zwei Vektoren \mathbf{a} , \mathbf{b} mit Winkel $\sphericalangle(\mathbf{a}, \mathbf{b}) = \varphi$ und $\|\mathbf{b}\| = 1$ gilt:
 $\langle \mathbf{a} | \mathbf{b} \rangle = \|\mathbf{a}\| \cdot \|\mathbf{b}\| \cdot \cos(\varphi) = \|\mathbf{a}\| \cdot 1 \cdot 1 = \|\mathbf{a}\|$

berechnet sich die skalare Krümmung schließlich zu²

$$\kappa = \frac{\langle \mathbf{N} | \dot{\mathbf{T}} \rangle}{\|\dot{\boldsymbol{\xi}}\|} = \frac{\det[\mathbf{T}, \dot{\mathbf{T}}]}{\|\dot{\boldsymbol{\xi}}\|^2} = \frac{\det[\dot{\boldsymbol{\xi}}, \ddot{\boldsymbol{\xi}}]}{\|\dot{\boldsymbol{\xi}}\|^3}. \quad (4.7)$$

Die Krümmung κ beschreibt die Approximation jedes Punkts der Trajektorie $\boldsymbol{\xi}$ als einen Kreis, dessen Mittelpunkt M_z in Richtung des Normalenvektors \mathbf{N} im Abstand von $R_z = 1/\kappa$ liegt, wie in Abbildung 4.1 dargestellt. Radius R_z und Krümmung κ sind für Rechtskurven negativ definiert, für Linkskurven positiv.

Die Bewegungsprofile der Räder können ebenso über Kreise um den Fahrzeugbezugspunkt M_z beschrieben werden und ergeben sich entsprechend Abbildung 4.1 als R_{vr} (vorne rechts), R_{vl} (vorne links), R_{hr} (hinten rechts), R_{hl} (hinten links).

Die Einschlagwinkel der beiden Vorderräder ergeben sich aufgrund der konstruktiven Einschränkung $\delta_l, \delta_r \in [-\pi/2, \pi/2]$ über den Arkustangens zu

$$\begin{aligned} \delta_l &= \arcsin\left(\frac{l}{R_{vl}}\right) = \arctan\left(\frac{l}{R_{hl}}\right) = \arctan\left(\frac{l}{R_z + h}\right) \\ \delta_l &= \arctan\left(l \cdot \kappa \cdot \frac{R_z}{R_{hl}}\right) \end{aligned} \quad (4.8a)$$

$$\begin{aligned} \delta_r &= \arcsin\left(\frac{l}{R_{vr}}\right) = \arctan\left(\frac{l}{R_{hr}}\right) = \arctan\left(\frac{l}{R_z - h}\right) \\ \delta_r &= \arctan\left(l \cdot \kappa \cdot \frac{R_z}{R_{hr}}\right). \end{aligned} \quad (4.8b)$$

Die Rollgeschwindigkeit der einzelnen Räder ergibt sich exemplarisch hergeleitet für das linke Hinterrad $\dot{\rho}_{hl}$ über die Betrachtung infinitesimal kleiner Ände-

² Für zwei Vektoren $\mathbf{a} = [a_1, a_2]^T$, $\mathbf{b} = [b_1, b_2]^T \in \mathbb{R}^2$, und $\bar{\mathbf{a}} = [-a_2, a_1]^T \in \mathbb{R}^2$ sodass $\|\bar{\mathbf{a}}\| = \|\mathbf{a}\|$ und $\angle(\mathbf{a}, \bar{\mathbf{a}}) = +\pi/2$, gilt: $\langle \bar{\mathbf{a}} | \mathbf{b} \rangle = a_1 \cdot b_2 - a_2 \cdot b_1 = \det[\mathbf{a}, \mathbf{b}]$

rungen der Trajektorie $\Delta\xi$ und der Position des Radmittelpunkts $\Delta\xi_{\text{hl}}$ über den Zusammenhang

$$\frac{R_z}{\Delta\xi} = \frac{R_{\text{hl}}}{\Delta\xi_{\text{hl}}} \stackrel{\lim_{\Delta \rightarrow 0} \Delta\xi = \|\dot{\xi}\|}{\Rightarrow} \|\dot{\xi}_{\text{hl}}\| = \|\dot{\xi}\| \frac{R_{\text{hl}}}{R_z}. \quad (4.9)$$

Damit gilt für die Rollgeschwindigkeit des linken Hinterrads mit der Radmittelpunktsgeschwindigkeit $\dot{\xi}_{\text{hl}}$

$$\dot{\rho}_{\text{hl}} = \frac{\|\dot{\xi}_{\text{hl}}\|}{r_{\text{h}}} = \frac{\|\dot{\xi}\| \frac{R_{\text{hl}}}{R_z}}{r_{\text{h}}} = \frac{\|\dot{\xi}\|}{r_{\text{h}}} \frac{R_z + h}{R_z}. \quad (4.10a)$$

Identische Herleitungen der weiteren Rollgeschwindigkeiten $\dot{\rho}_{\text{hr}}$, $\dot{\rho}_{\text{vl}}$, $\dot{\rho}_{\text{vr}}$ resultieren in

$$\dot{\rho}_{\text{hr}} = \frac{\|\dot{\xi}\|}{r_{\text{h}}} \frac{R_{\text{hr}}}{R_z} = \frac{\|\dot{\xi}\|}{r_{\text{h}}} \frac{R_z - h}{R_z} \quad (4.10b)$$

$$\dot{\rho}_{\text{vl}} = \frac{\|\dot{\xi}\|}{r_{\text{v}}} \frac{R_{\text{vl}}}{R_z} = \frac{\|\dot{\xi}\|}{r_{\text{v}}} \frac{\sqrt{l^2 + R_{\text{hl}}^2}}{R_z} = \frac{\|\dot{\xi}\|}{r_{\text{v}}} \frac{\sqrt{l^2 + (R_z + h)^2}}{R_z} \quad (4.10c)$$

$$\dot{\rho}_{\text{vr}} = \frac{\|\dot{\xi}\|}{r_{\text{v}}} \frac{R_{\text{vr}}}{R_z} = \frac{\|\dot{\xi}\|}{r_{\text{v}}} \frac{\sqrt{l^2 + R_{\text{hr}}^2}}{R_z} = \frac{\|\dot{\xi}\|}{r_{\text{v}}} \frac{\sqrt{l^2 + (R_z - h)^2}}{R_z}. \quad (4.10d)$$

Die Orientierung ψ beschreibt die Ausrichtung des Ego-Fahrzeugs in der Welt als Winkel zwischen der Tangente \mathbf{T} und einer *Nordrichtung* \mathbf{n} mit $\|\mathbf{n}\| = 1$, die innerhalb des Weltkoordinatensystems K^W aus Abschnitt 2.1 definiert ist. Mit der Projektion der Tangente auf die Nordrichtung als Gegenkathete und der Projektion der Tangente auf die *Westrichtung* \mathbf{w} mit $\|\mathbf{w}\| = 1$ und dem einge-

schlossenen Winkel $\varphi(\mathbf{n}, \mathbf{w}) = +\pi/2$ als Ankathete gilt für die Orientierung mit dem auf vier Quadranten erweiterten Arkustangens entsprechend [73]

$$\begin{aligned}\psi &= \varphi(\mathbf{T}, \mathbf{n}) = \arctan_2(\langle \mathbf{w} | \mathbf{T} \rangle, \langle \mathbf{n} | \mathbf{T} \rangle) \\ &= \arctan_2(\det[\mathbf{n}, \dot{\boldsymbol{\xi}}], \langle \mathbf{n} | \dot{\boldsymbol{\xi}} \rangle).\end{aligned}\quad (4.11)$$

Die Gierrate $\dot{\psi}$ ist die zeitliche Änderung der Tangentenrichtung \mathbf{T} und ergibt sich identisch zur Herleitung der Krümmung in Gl. (4.6) entsprechend parallel zur Normalen \mathbf{N} , sodass die vorzeichenbehaftete Gierrate über das Skalarprodukt

$$\dot{\psi} = \langle \mathbf{N} | \dot{\mathbf{T}} \rangle \quad (4.12)$$

beschrieben werden kann. Mit Gl. (4.7) ergibt sich für die Gierrate $\dot{\psi}$ schließlich

$$\dot{\psi} = \kappa \cdot \|\dot{\boldsymbol{\xi}}\| = \frac{\det[\ddot{\boldsymbol{\xi}}, \dot{\boldsymbol{\xi}}]}{\|\dot{\boldsymbol{\xi}}\|^2}. \quad (4.13)$$

4.1.2 Evaluation des C^2 -Modells anhand von Simulationen

Durch die vereinfachenden Modellannahmen des C^2 -Modells ist eine Evaluation der Güte notwendig, um die Eignung für die Trajektorienplanungsaufgabe zu prüfen. Hierfür wird im Folgenden zunächst ein Vergleich mit dem kommerziellen Fahrzeugsimulationstool *CARMAKER* durchgeführt und im daran anschließenden Abschnitt 4.1.3 mit Realdaten der *VERTEX*-Fahrzeuge des Iosb.

Das Tool *CARMAKER* stellt ein in der Automobilindustrie etabliertes Werkzeug zur detaillierten Fahrzeugphysiksimulation dar. Zur Ansteuerung des Simulationsfahrzeugs bietet *CARMAKER* das Fahrermodell *IPGDRIVER*, das aus Referenzmanövern *Stellbefehle* zur Bewegung des Fahrzeugs generiert. Die verwendeten Stellgrößen Lenkradwinkel σ_{lenk} sowie Gas- und Bremsbefehle $\sigma_{\text{gas}}, \sigma_{\text{brems}}$ bilden die Eingangsgrößen des Systems »Simulationsfahrzeug« ungeachtet der Ansteuerungsform von entweder einer *Regelung* – einer Ansteuerung mit Rückkopplung des Ergebnisses und damit der Möglichkeit zur Kompensation von Modellierungsfehlern und externen Störungen – oder einer *Steuerung* – eine blinde

Ansteuerung ohne zusätzliche Informationen über den Ausgang. Wie auch bei menschlichen Fahrern stellt der IPGDRIVER eine Regelung dar.

Die sich aus der Simulation mit CARMAKER und IPGDRIVER ergebenden Vergleichsparameter werden im weiteren Verlauf als \hookrightarrow Referenzdaten – abgekürzt als »gt« des englischen \hookrightarrow Ground Truth – angenommen. Für die folgende Evaluation wird ein BMW 118i mit Heckantrieb mit einer Rate von 1 kHz simuliert. Die Simulationswerte ergeben sich zu den einzelnen Zeitschritten $t_{\text{eval}} \in \mathbb{R}$.

Das prinzipielle Vorgehen wird in Abbildung 4.2 dargestellt und besteht aus den folgenden Teilen:

- 1** Über manuell eingegebene Referenzmanöver werden von IPGDRIVER Lenkrad-, Gas- und Bremsbefehle generiert und eine Dynamiksimulation mit CARMAKER durchgeführt. Die sich ergebenden Größen bilden die Referenzdaten der Evaluation. — Bezeichnung: q^{gt}
- 2** Unter Verwendung des C^2 -Modells aus Abschnitt 4.1.1 werden die Ego-Fahrzeug-Zustandsgrößen aus der im vorherigen Schritt gegebenen Referenztrajektorie rekonstruiert. — Bezeichnung: \tilde{q}
- 3** Die mit dem C^2 -Modell im vorherigen Schritt aus der Referenztrajektorie geschätzten Größen werden über entsprechende Umwandlungsmodelle in Stellbefehle für das Simulationsfahrzeug transformiert und damit eine gesteuerte – also ohne Rückkopplung – Dynamiksimulation mit CARMAKER durchgeführt. — Bezeichnung: \tilde{q}^{sim}

Die dieser Arbeit zugrundeliegenden Stellgrößenanforderungen des Projektpartners Valeo als Beschleunigung und mittlerer Einschlagwinkel erfordern aufgrund von Limitationen der Software CARMAKER im 3. Schritt zusätzliche Umwandlungen in die für das Simulationsfahrzeug notwendigen Stellgrößen Lenkradwinkel und Gas- und Bremsbefehle. Hierfür wird zur Transformation der Beschleunigung \tilde{a} in Gas- und Bremsbefehle $\tilde{\sigma}_{\text{gas}}$, $\tilde{\sigma}_{\text{brems}}$ ein in CARMAKER als Beispielanwendung mitgelieferter Simulationsblock mit entsprechender Funktionalität verwendet. Zur Umwandlung des mittleren Einschlagwinkels $\tilde{\delta}$ in entsprechenden Lenkradwinkel $\tilde{\sigma}_{\text{lenk}}$ wird eine lineare Übersetzungsfunktion

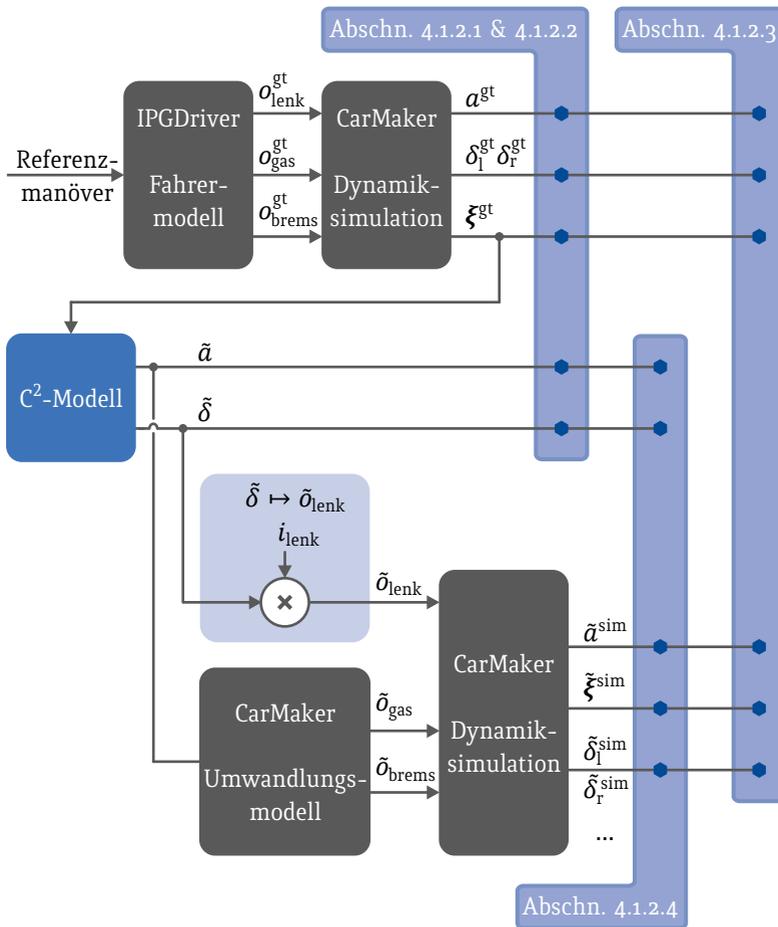


Abbildung 4.2: Überblick über Evaluationen des C^2 -Modells in der Simulation. Die Übersicht gibt eine Auswahl der zur Evaluation herangezogenen Größen, stellt jedoch keine vollständige Liste dar.

mit $i_{\text{lenk}} = 18,4$ experimentell für das verwendete Fahrzeugmodell identifiziert und entsprechend angewendet. Es gilt

$$\tilde{\delta}_{\text{lenk}} = i_{\text{lenk}} \cdot \tilde{\delta} = i_{\text{lenk}} \cdot \left(\frac{\tilde{\delta}_l + \tilde{\delta}_r}{2} \right). \quad (4.14)$$

Die Evaluation besteht einerseits aus der systematischen Analyse unterschiedlicher Lenkradwinkel über die Variation von Lenkfrequenz und Lenkamplitude bei unterschiedlichen Geschwindigkeiten und andererseits aus einer Simulationsfahrt über den fahrdynamisch abwechslungsreichen Hockenheimring. Die Analyse umfasst dabei die folgenden Evaluationen:

- q^{gt} vs. \tilde{q}
Referenzdaten aus 1. Schritt gegenüber geschätzten Größen über C^2 -Modell aus 2. Schritt — Abschnitte 4.1.2.1 und 4.1.2.2
- q^{gt} vs. \tilde{q}^{sim}
Referenzdaten aus 1. Schritt gegenüber Daten aus Simulation mit C^2 -Modell-Stellbefehlen aus 3. Schritt — Abschnitt 4.1.2.3
- \tilde{q} vs. \tilde{q}^{sim}
Geschätzte Größen über C^2 -Modell aus 2. Schritt gegenüber Daten aus Simulation mit C^2 -Modell-Stellbefehlen aus 3. Schritt — Abschnitt 4.1.2.4

Abbildung 4.2 gibt einen umfassenden Überblick über die einzelnen Schritte des Simulationsvorgehens sowie die einzelnen Vergleichsanalysen.

4.1.2.1 Sinusförmige Lenkung mit Geschwindigkeitsvariation: q^{gt} vs. \tilde{q}

Zur Evaluation der C^2 -Modellgüte wird zunächst eine umfangreiche Simulationsserie mit unterschiedlichen konstanten Zielgeschwindigkeiten

$$v^{\text{ref}} = \{6 \text{ km/h}, 30 \text{ km/h}, 50 \text{ km/h}\} \quad (4.15)$$

und einer Variation an sinusförmigen Lenkradwinkeln der Form

$$o_{\text{lenk}}^{\text{gt}} = A_{\delta} \cdot \sin\left(\frac{2\pi t_{\text{eval}}}{\tau_{\delta}}\right) \quad (4.16)$$

innerhalb der Intervalle

$$A_{\delta} \in [0, \pi] \quad \tau_{\delta} = \frac{1}{f_{\delta}} \in [1 \text{ s}, 20 \text{ s}] \quad t_{\text{eval}} \in [0 \text{ s}, 40 \text{ s}]$$

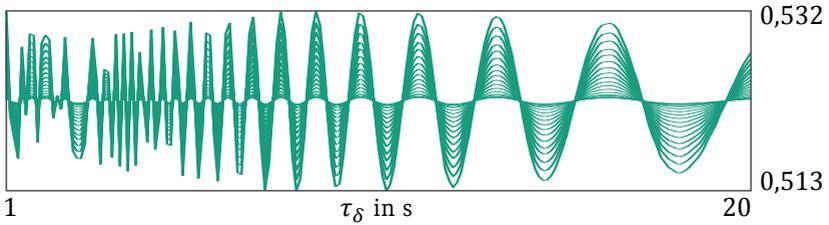
betrachtet. Die Zielgeschwindigkeit aus Gl. (4.15) wird als Referenzmanöver zur Berechnung der notwendigen Gas- und Bremsbefehle an den IPGDRIEVER übergeben. Durch die Regelung innerhalb des IPGDRIEVERS wird ein ausführbares Manöver auch bei hohen Lenkfrequenzen sichergestellt, indem das Simulationsfahrzeug eine geringere Geschwindigkeit als vorgegeben fährt. Diese Geschwindigkeitsverringerung ist jedoch für die Evaluation unerheblich, da lediglich die geschätzten Parameter durch das C²-Modell aus der – zuweilen verlangsamt – Trajektorie betrachtet werden. Der sinusförmige Lenkradwinkel aus Gl. (4.16) wird im Gegensatz dazu direkt an das Simulationsfahrzeug übergeben, um das regulierende Element des IPGDRIEVERS zu umgehen. Die aus der Simulation resultierende Referenztrajektorie ξ^{gt} wird dem C²-Modell im Anschluss zur Berechnung der geschätzten Größen \tilde{q} übergeben.

Zur Evaluation werden die mit dem C²-Modell geschätzten Größen \tilde{q} mit den Referenzwerten q^{gt} aus der Dynamiksimulation anhand der Fehlermetrik

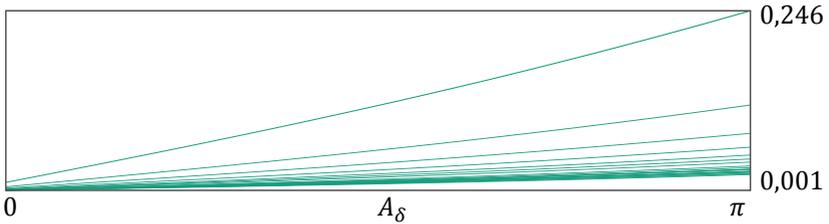
$${}^n E_q = \sqrt{\frac{1}{40 \text{ s}} \int_{t_{\text{eval}}=0 \text{ s}}^{40 \text{ s}} \left({}^n q^{\text{gt}}(t_{\text{eval}}) - {}^n \tilde{q}(t_{\text{eval}}) \right)^2 dt_{\text{eval}}} \quad (4.17)$$

für alle N Simulationsfahrten mit $n \in \{1, \dots, N\}$ betrachtet.

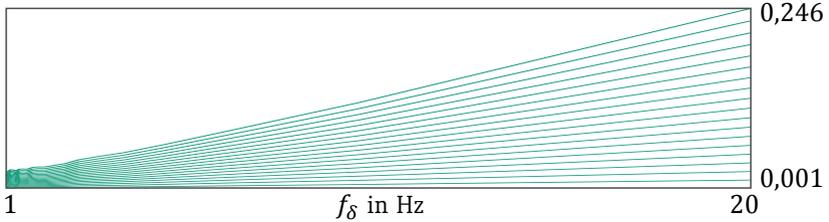
Die über Gl. (4.17) berechneten Geschwindigkeitsfehler E_v und Fehler des mittleren Einschlagwinkels E_{δ} werden für eine Zielgeschwindigkeit $v^{\text{ref}} = 50 \text{ km/h}$ über der Amplitude A_{δ} und Periodendauer τ_{δ} als *Heatmap* in Abbildung 4.4 und als Kurvenschar in Abbildung 4.3 dargestellt. Geringere Geschwindigkeiten ergeben weniger starke Fehlerverläufe und werden daher nicht diskutiert.



(a) Fehlerkurven E_v der Geschwindigkeit in m/s. Die Kurven beschreiben unterschiedliche Lenkradwinkelamplituden A_δ .



(b) Fehlerkurven E_δ des mittleren Einschlagwinkels in rad über der Lenkradwinkelamplitude A_δ . Die Kurven zeigen verschiedene Lenkradwinkelperioden τ_δ .



(c) Fehlerkurven E_δ des mittleren Einschlagwinkels in rad über der Lenkradwinkel Frequenz f_δ . Die Kurven zeigen verschiedene Lenkradwinkelamplituden A_δ .

Abbildung 4.3: Fehlerkurven der Sinuslenkung des mittleren Einschlagwinkels und der Geschwindigkeit. Darstellung der Fehlermetriken E_δ und E_v aus Abbildung 4.4 bei einer Zielgeschwindigkeit von $v^{\text{ref}} = 50$ km/h. In (a) ist das periodische Muster über der Periodendauer τ_δ deutlich zu erkennen. (b) und (c) zeigen einen näherungsweise linearen Anstieg des Einschlagwinkelfehlers E_δ bei steigender Amplitude A_δ und Frequenz f_δ . Zur Verdeutlichung der Linearität wird (c) über f_δ dargestellt.

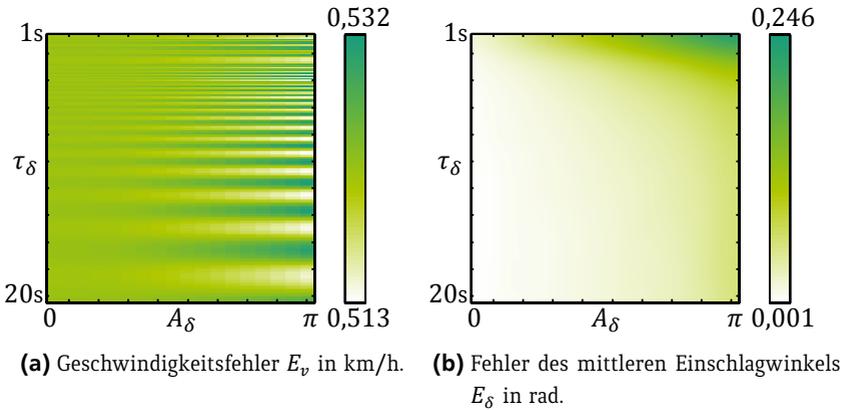


Abbildung 4.4: Fehlermetriken der Sinuslenkung über Amplitude und Frequenz. Geschwindigkeitsfehler E_v und Fehler des mittleren Einschlagwinkels E_δ bei einer Zielgeschwindigkeit von 50 km/h. E_v in (a) zeigt ein mit Rollwinkel korrelierendes periodisches Muster. E_δ zeigt in (b) einen Anstieg bei ansteigender Lenkamplitude A_δ und fallender Lenkperiodendauer τ_δ .

Der Geschwindigkeitsfehler E_v in den Abbildungen 4.4a und 4.3a weist einen periodischen Verlauf mit variierender Periodendauer τ_δ auf, der mit dem Rollwinkelfehler korreliert und lässt sich somit auf die vereinfachende Annahme verschwindenden Rollwinkels des C^2 -Modells zurückführen.

Die Analyse des Fehlers des mittleren Einschlagwinkels E_δ in Abbildung 4.4b zeigt eine Verringerung der Lenkwinkelgenauigkeit bei fallender Periodendauer τ_δ und steigender Amplitude A_δ . Die Betrachtungen der Kurvenscharen über der Amplitude und der Frequenz in den Abbildungen 4.3b und 4.3c verdeutlichen einen linearen Anstieg des Einschlagwinkelfehlers E_δ mit der Frequenz f_δ und eines überproportional ansteigenden Fehlers mit der Amplitude A_δ .

4.1.2.2 Hockenheimerling – Vergleich von Referenz und C^2 -Modell: q^{gt} vs. \tilde{q}

Die Evaluation anhand der sinusförmigen Lenkbefehle in Abschnitt 4.1.2.1 weist auf eine Verschlechterung der C^2 -Modellgüte bei fahrdynamisch anspruchsvol-

len Manövern mit starken Lenkbewegungen hin, die sich am Rande des stabilen Fahrdynamikbereichs befinden, da dort eine offensichtliche Verletzung der vereinfachenden Modellannahmen vorliegt.

Die folgende Evaluation soll entsprechend Aufschluss darüber geben, welche Relevanz der Fahrdynamikgrenzbereich im täglichen Straßenverkehr einnimmt. Um zusätzlich kritische Fahrmanöver, die sich aus Beinaheunfällen ergeben, in der Analyse zu bewerten, wird eine Simulationsfahrt auf dem fahrdynamisch anspruchsvollen Hockenheimring durchgeführt. Der Hockenheimring mit einer Gesamtlänge von 4,574 km ist durch seine Beschaffenheit eine ideale Testumgebung mit insgesamt 17 unterschiedlich engen Kurven (11 Rechts- und 6 Linkskurven), die eine zum Teil sehr geringe Geschwindigkeit und damit eine hohe Ent- und Beschleunigung bewirken. Daneben beinhaltet die Teststrecke einige längere kurvenfreie Abschnitte von bis zu 570 m zur Erzielung hoher Geschwindigkeiten. Durch die Kombination von langen geradlinigen Abschnitten für hohe Geschwindigkeiten mit anschließenden engen Kurven kann die Evaluation des C^2 -Modells im gesamten stabilen Fahrdynamikspektrum geschehen. Abbildung 4.5 zeigt die mit dem IPGDRIVER gefahrene Trajektorie ξ^{gt} in Grün und entspricht aufgrund der dargestellten Größenverhältnisse näherungsweise dem Streckenverlauf des Hockenheimrings.

Zur Erstellung der Referenzdaten wird eine einmalige Simulationsfahrt des Hockenheimrings unter Verwendung des IPGDRIVERS mit einer Zielgeschwindigkeit von $v^{ref} = 200$ km/h durchgeführt. Daraus ergeben sich Referenzdaten mit folgenden Eigenschaften:

- Longitudinale Beschleunigungen von $a \in [-6,3 \text{ m/s}^2, 6,1 \text{ m/s}^2]$
- Geschwindigkeiten von $v \in [0 \text{ km/h}, 170,6 \text{ km/h}]$
- Raddrehgeschwindigkeiten von $\dot{\rho} \in [0 \text{ rad/s}, 168,8 \text{ rad/s}]$
- Einschlagwinkel von $\delta \in [-0,23 \text{ rad}, 0,13 \text{ rad}]$

Die mit der Referenztrajektorie ξ^{gt} über das C^2 -Modell rekonstruierten Fahrzeugparameter werden in den Abbildungen 4.6 und 4.7 als »Punktdiagramme« mit dem Referenzwert auf der Abszissenachse und dem zugehörigen daraus geschätzten C^2 -Modell-Wert auf der Ordinatenachse dargestellt. Der Korrelationszusammenhang von Referenz und Schätzung wird über den mittleren Fehler μ ,

die Standardabweichung σ und die Steigung m der linearen Approximation über die Methode der kleinsten Quadrate analysiert. Entsprechende Diagramme werden daher im Weiteren als *Korrelationsplots* bezeichnet.

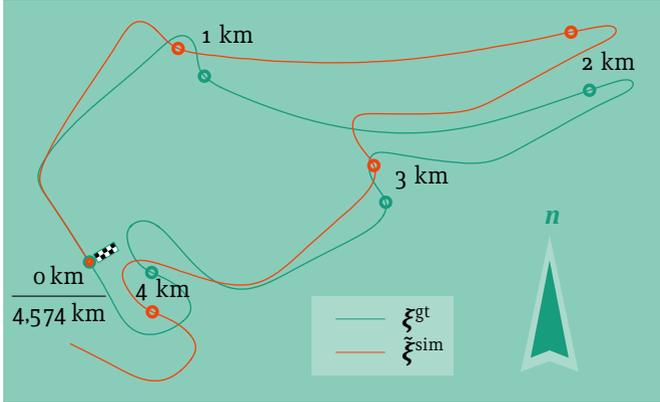


Abbildung 4.5: Hockenheimring mit IPGDRIVER und C^2 -Modell-Steuerung. Die Simulationssahrt des IPGDRIVERS ergibt die Trajektorie ξ^{gt} und ist dargestellt in Grün. Die rote Trajektorie ξ^{sim} resultiert aus der reinen Steuerung des Fahrzeugs mittels C^2 -Modell-Stellbefehlen, die aus ξ^{gt} geschätzt werden. Die Abweichungen resultieren einerseits aus C^2 -Modell-Vereinfachungen und andererseits aus Limitationen der Ansteuermöglichkeiten der Software CARMAKER, die in Abschnitt 4.1.2.4 analysiert werden.

Die Steigung m ergibt sich dabei aus der pseudoinversen Lösung der Gleichung $q^{\text{gt}}(t_{\text{eval}}) \cdot m = \tilde{q}(t_{\text{eval}})$ für eine beliebige Fahrzeugzustandsvariable q über alle Messwerte t_{eval} . Die Metrik beschreibt – konsistent zu Gl. (4.17) – eine Minimierung des Integrals

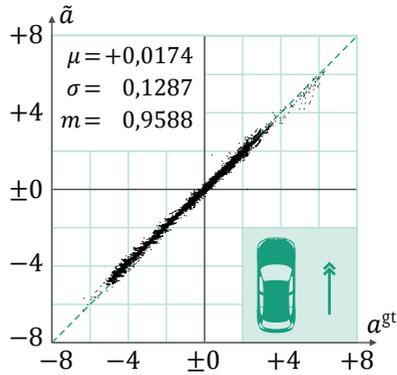
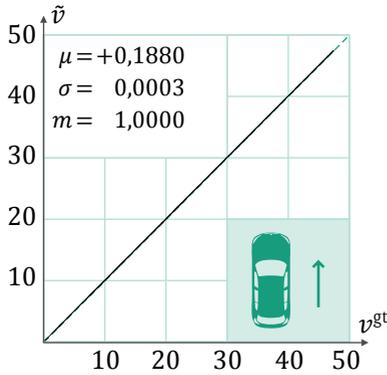
$$\int (q^{\text{gt}}(t_{\text{eval}}) \cdot m - \tilde{q}(t_{\text{eval}}))^2 dt_{\text{eval}} \quad (4.18)$$

und stellt damit ein Maß für einen systematischen Skalierungsfehler dar. Eine perfekte Korrelation der C^2 -Modell-Schätzung mit den Referenzdaten würde $m = 1,0$ – dimensionslos – sowie $\mu = 0,0$ und $\sigma = 0,0$ – in jeweiligen Einheiten der zu vergleichenden Größen – ergeben. Neben der Evaluation über Korrelationsplots werden in den Abbildungen 4.8 bis 4.10 zur weiteren Analy-

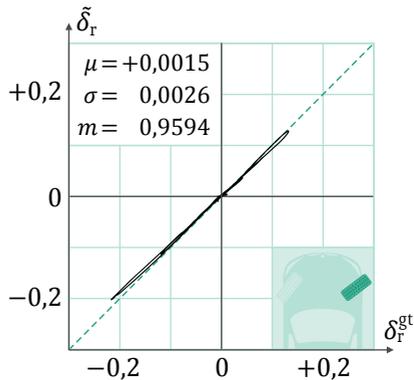
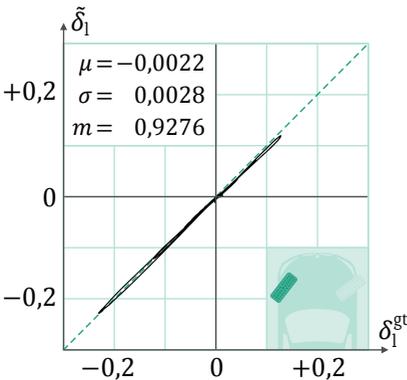
se ausgewählte C^2 -Modell-Schätzparameter mit entsprechenden Referenzdaten über der Hockenheimstrecke $s_H \in [0 \text{ m}, 4574 \text{ m}]$ aufgetragen.

Das C^2 -Modell erzielt sehr gute Schätzergebnisse der Geschwindigkeit \tilde{v} , was sowohl aus der Darstellung als Korrelationsplot in Abbildung 4.6a als auch über dem Streckenparameter in Abbildung 4.8a hervorgeht. Für die Beschleunigung \tilde{a} ergibt sich ebenso eine gute C^2 -Modell-Schätzung in den Abbildungen 4.6b und 4.8b, lediglich mit einer erhöhten Standardabweichung in Form einer Streuung, die durch Tiefpassfilterung reduziert werden kann.

Die Evaluation der Hinterraddrehgeschwindigkeiten $\dot{\hat{p}}_h$ in Abbildungen 4.7c-d zeigt einerseits mit einer Steigung $m \approx 1$ und einem mittleren Fehler $\mu \approx 0$ ein gutes Korrelationsergebnis mit verschwindend geringem systematischen Fehler. Auf der anderen Seite sind Effekte, die sich aus der Vernachlässigung des longitudinalen Schlupfs ergeben, deutlich anhand einiger starker Ausreißer in Form von »horizontalen Spitzen« erkennbar. Diese entstehen bei starken Betätigungen des Gas- oder Bremspedals, die in der Realität und in der Referenzsimulation zu einer nahezu abrupten Änderung der Raddrehgeschwindigkeiten der Antriebsräder – durch die Modellierungen eines Bmw entsprechend die Hinterräder – führen. Aufgrund der begrenzten Haftreibung bewegt sich das Fahrzeug trotz dieser »veränderten« Raddrehgeschwindigkeiten gleichförmig weiter und beschreibt eine Trajektorie mit verzögerter Anpassung der Geschwindigkeit. Durch die C^2 -Modell-Schätzung der Raddrehgeschwindigkeiten anhand der Geschwindigkeit der Trajektorie ergeben sich dadurch Schätzfehler, die in der Abbildung mehrerer Referenzraddrehgeschwindigkeiten auf eine einzige geschätzte Geschwindigkeit resultieren und die entsprechende Spitzen in den Korrelationsplots ergeben. Im Gegensatz dazu werden die Raddrehgeschwindigkeiten der Vorderräder $\dot{\hat{p}}_v$ vornehmlich durch den Rad-Bodenkontakt bestimmt und sind somit direkt an die Fahrzeuggeschwindigkeit gekoppelt. Die zugehörigen Korrelationsplots in den Abbildungen 4.7a-b weisen entsprechend gute Schätzergebnisse des C^2 -Modells auf.

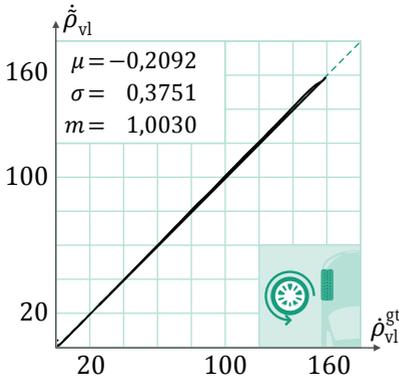


(a) Geschwindigkeiten v^{gt} und \tilde{v} in m/s. (b) Beschleunigungen a^{gt} und \tilde{a} in m/s².

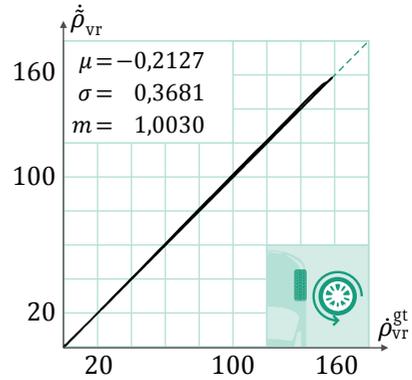


(c) Einschlagwinkel des linken Vorderrads δ_l^{gt} und $\tilde{\delta}_l$ in rad. (d) Einschlagwinkel des rechten Vorderrads δ_r^{gt} und $\tilde{\delta}_r$ in rad.

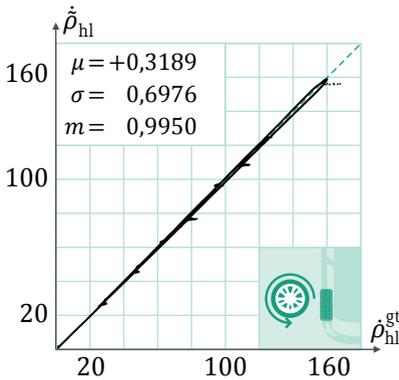
Abbildung 4.6: Korrelationsplots von C^2 -Modell und Referenzdaten – Geschwindigkeit, Beschleunigung, Einschlagwinkel. Korrelation der C^2 -Modellschätzungen mit den Referenzdaten entlang der simulierten Fahrt auf dem Hockenheimring. Metriken: Mittlerer Fehler μ , Standardabweichung σ , Steigung m der linearen Approximation über Methode der kleinsten Quadrate. Die ersten beiden in der jeweiligen Einheit der zu vergleichenden Größen.



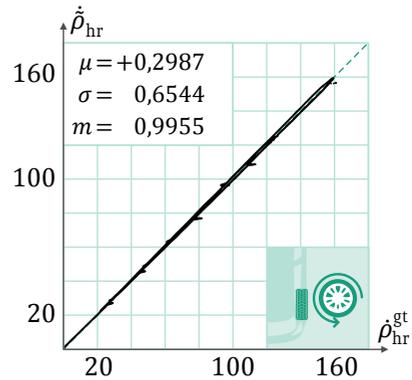
(a) Raddrehgeschwindigkeiten des linken Vorderrads $\dot{\rho}_{vl}^{gt}$ und $\dot{\rho}_{vl}$ in rad/s.



(b) Raddrehgeschwindigkeiten des rechten Vorderrads $\dot{\rho}_{vr}^{gt}$ und $\dot{\rho}_{vr}$ in rad/s.



(c) Raddrehgeschwindigkeiten des linken Hinterrads $\dot{\rho}_{hl}^{gt}$ und $\dot{\rho}_{hl}$ in rad/s.

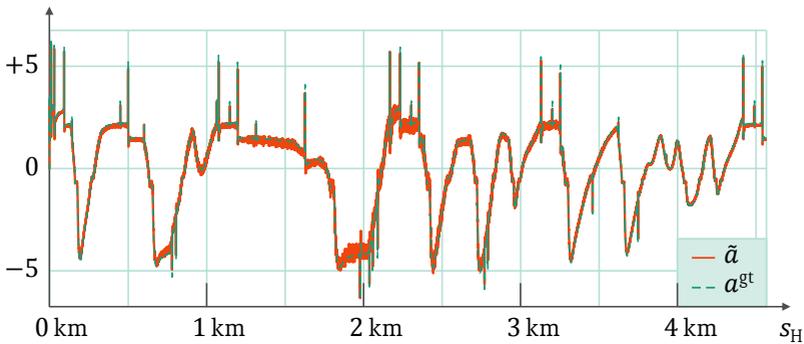


(d) Raddrehgeschwindigkeiten des rechten Hinterrads $\dot{\rho}_{hr}^{gt}$ und $\dot{\rho}_{hr}$ in rad/s.

Abbildung 4.7: Korrelationsplots von C^2 -Modell und Referenzdaten – Raddrehgeschwindigkeiten. Korrelation der C^2 -Modellschätzungen mit den Referenzdaten entlang der simulierten Fahrt auf dem Hockenheimring. Metriken: Mittlerer Fehler μ , Standardabweichung σ , Steigung m der linearen Approximation über Methode der kleinsten Quadrate. Die ersten beiden in der jeweiligen Einheit der zu vergleichenden Größen.



(a) Vergleich der Geschwindigkeiten \tilde{v} und v^{gt} in m/s.



(b) Vergleich der Beschleunigungen \tilde{a} und a^{gt} in m/s^2 .

Abbildung 4.8: Vergleich der C^2 -Modell-geschätzten Parameter mit den Referenzdaten über dem Hockenheim-Streckenverlauf – Geschwindigkeit und Beschleunigung.

In den Korrelationsplots der beiden Einschlagwinkel $\tilde{\delta}_l$, $\tilde{\delta}_r$ in den Abbildungen 4.6c-d ist eine leichte systematische Biegung erkennbar, die aus Fehlern in den Fahrzeugkonstruktionsparametern Achsabstand l und halber Spurbreite h stammen, wie eine experimentelle Variation der Parameter ergibt. Über den Streckenparameter s_H in Abbildung 4.9 dargestellt, wird eine gute Schätzung des mittleren Einschlagwinkels $\tilde{\delta}$ über weite Teile der Strecke deutlich.

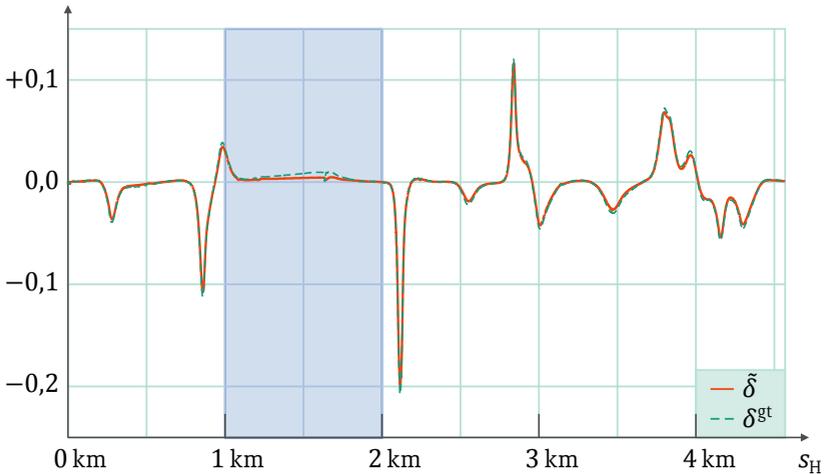
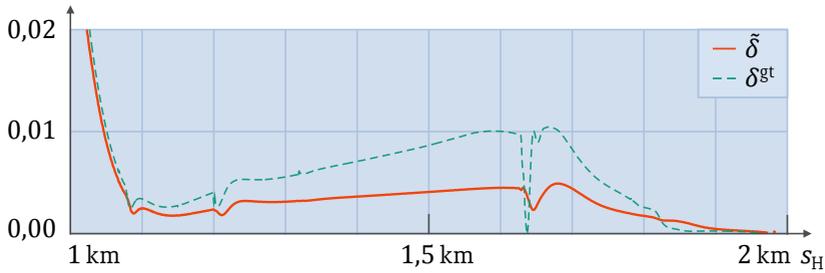
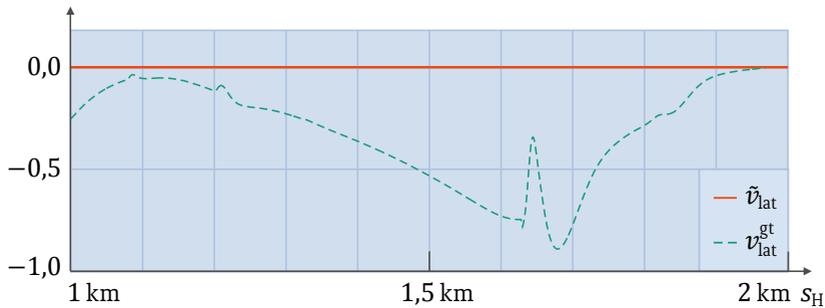


Abbildung 4.9: Vergleich der C^2 -Modell-geschätzten Parameter mit den Referenzdaten über dem Hockenheim-Streckenverlauf – mittlerer Einschlagwinkel. Mittlerer Einschlagwinkel in rad. Eine Vergrößerung des blauen Bereichs ist in Abbildung 4.10 dargestellt.

Lediglich zwischen den Streckenkilometern $s_H = 1$ km und $s_H = 2$ km in Abbildung 4.10a ergibt sich ein deutlicher Schätzfehler. Die vom IPGDRIVER bei der Durchfahrt der dortigen langgestreckten Linkskurve gewählte Geschwindigkeit resultiert in einem Verlust der Haftreibung der Hinterräder bei einer longitudinalen Geschwindigkeit von $v_{\text{long}}^{\text{gt}} \approx 170$ km/h nach Gl. (4.4) bei einer lateralen Geschwindigkeit berechenbar über $v_{\text{lat}}^{\text{gt}} = \langle \mathbf{N} | \dot{\boldsymbol{\xi}} \rangle$ von $v_{\text{lat}}^{\text{gt}} \approx -3$ km/h, dargestellt für den Streckenabschnitt in Abbildung 4.10b. Die durch das seitliche Rutschen notwendigen höheren Einschlagwinkel werden aufgrund der vereinfachenden C^2 -Modellannahme vernachlässigbarer lateraler Geschwindigkeit unterschätzt und beschreiben einen mittleren Einschlagwinkel bei perfekter Haftung der Reifen. Aufgrund der ansonsten guten Schätzergebnisse des mittleren Einschlagwinkels innerhalb der verbleibenden 3,5 km bei dem gegebenen vergleichsweise dynamischen Szenario ist davon auszugehen, dass die Annahme perfekter Haftung innerhalb des C^2 -Modells in typischen Fahrsituationen des gegebenen Anwendungsfalls zu keinen signifikanten Modellfehlern führt.



(a) Vergleich der mittleren Einschlagwinkel $\tilde{\delta}$ und δ^{gt} in rad auf der Teilstrecke.



(b) Vergleich der lateralen Geschwindigkeiten \tilde{v}_{lat} und v_{lat}^{gt} in m/s auf der Teilstrecke.

Abbildung 4.10: Vergleich der C^2 -Modell-geschätzten Parameter mit den Referenzdaten über dem Hockenheim-Streckenverlauf – mittlerer Einschlagwinkel und laterale Geschwindigkeit eines Streckenabschnitts. Die Schätzfehler in diesem Abschnitt resultieren in einer Übersteuerung des Fahrzeugs.

Für hochdynamische Manöver oder bei Bedarf an sehr detaillierten Simulationen ist das Modell hingegen – erwartungsgemäß – nicht geeignet.

4.1.2.3 Hockenheimring – Vergleich von Referenz und C^2 -Modell-Steuerung: ξ^{gt} vs. ξ^{sim}

Im zweiten Schritt der Evaluation werden die mit dem C^2 -Modell geschätzten Parameter unter Verwendung entsprechender Umwandlungsmodelle aus Abbildung 4.2 als Stellbefehle für eine erneute Dynamiksimulation mit CARMAKER verwendet. Das Simulationsfahrzeug wurde dafür in CARMAKER entsprechend blind durch die ermittelten Stellgrößen – Geschwindigkeit und Lenkradwinkel – gesteuert, ohne sonstige Referenz auf den tatsächlichen Verlauf des Hockenheimrings. Hierbei wurden die Lenkradwinkel direkt umgesetzt, die Geschwindigkeiten hingegen über einen in CARMAKER vorhandenen Simulationsblock. Insbesondere letzterer trägt wesentlich zur resultierenden Gesamtabweichung bei, da durch fast sofortige Umsetzung von Bremsungen bei gleichzeitiger merklicher Verzögerung von Beschleunigungsbefehlen, Spitzensollgeschwindigkeiten insbesondere in Kurven systematisch unterschritten werden, wodurch die zeitabhängigen Lenkradwinkel-Einschläge systematisch bereits vor Vollendung der Kurve wieder zurückgenommen werden. Abbildung 4.5 zeigt die Ergebnistrajektorie ξ^{sim} im Vergleich zur Referenztrajektorie ξ^{gt} , die zur Schätzung der C^2 -Modell-Parameter verwendet wurde.

Es zeigen sich deutliche Abweichungen der beiden Trajektorien, die entsprechend dem vorherigen Abschnitt 4.1.2.2 neuerlich Aufschluss über Modellierungsfehler des C^2 -Modells geben. Auf der anderen Seite ergibt sich durch die Limitationen der Ansteuerbarkeit des Simulationswerkzeugs die Notwendigkeit der Umwandlungsmodelle, die wiederum eine Fehlerquelle darstellen, wie im anschließenden Abschnitt 4.1.2.4 analysiert wird. Die Aussagekraft der Evaluationsergebnisse einer reinen Steuerung über die C^2 -Modell-Parameter ist daher begrenzt und stellt vielmehr eine untere Qualitätsschranke dar. Unter Berücksichtigung der Streckenlänge von über 4,5 km erscheinen die Abweichungen jedoch in einem vertretbaren Rahmen. Eine Einteilung des Hockenheimrings in äquidistante Segmentstücke ergibt einen mittleren Endpunktfehler von $\bar{e}_{\xi_{\text{end}}} \approx 3 \text{ cm}/1 \text{ m}$ bezogen auf die Segmentlänge. Die deutlichen Abweichungen der simulierten Trajektorie ξ^{sim} zur Referenz resultieren demnach aus einer Fehlerkumulation, die durch eine Rückkopplung einer entsprechenden Regelung vermindert werden kann.

4.1.2.4 Hockenheimring – Vergleich von C^2 -Modell-Schätzung und C^2 -Modell-Steuerung: \tilde{q} vs. q^{sim}

Ein Vergleich der Schätzparameter des C^2 -Modells mit Simulationsergebnissen, die sich durch eine Dynamiksimulation mit denselben C^2 -Modell-Parametern zur Fahrzeugsteuerung ergeben, weist auf Modellierungsfehler außerhalb des C^2 -Modells hin, die von den notwendigen Umwandlungsmodellen in Abbildung 4.2 herrühren und in verzögerten Stellbefehlen an das Simulationsfahrzeug resultieren.

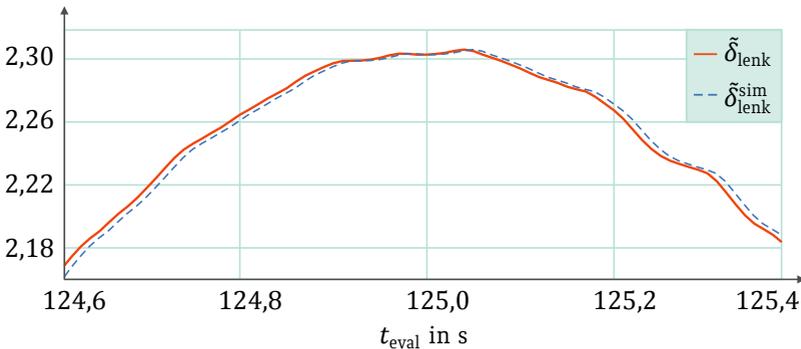
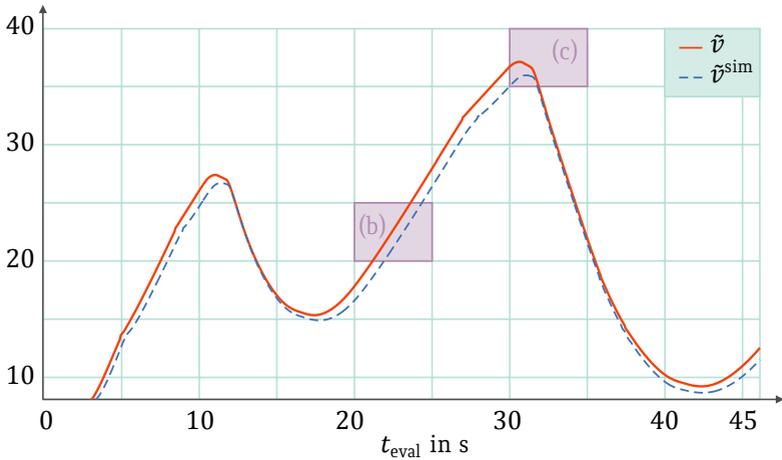
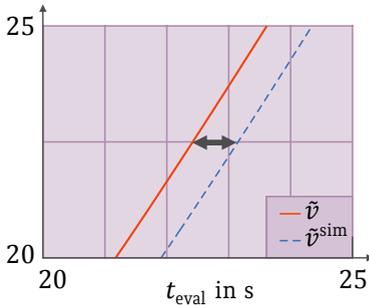


Abbildung 4.11: Vergleich der geschätzten C^2 -Modell-Parameter mit den Simulationsergebnissen selbiger Parameter als Stellbefehle – Lenkradwinkel. Lenkradwinkel dargestellt in rad.

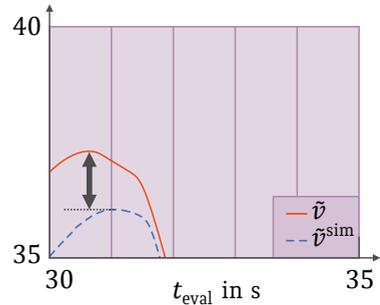
Abbildung 4.11 zeigt eine geringe Verzögerung der Lenkradwinkel δ_{lenk} von maximal 0,01 Sekunde. Im Gegensatz dazu weist die Geschwindigkeit in Abbildung 4.12 eine deutliche Übergabeverzögerung auf, die sich bei Geschwindigkeitserhöhungen zu 0,7 Sekunden und Bremsbewegungen zu 0,1 Sekunde ergibt, dargestellt zu Beginn der Hockenheimstrecke. Das asymmetrische Verzögerungsprofil führt, aufgrund der vorzeitigen Terminierung der Geschwindigkeitserhöhung, zu um 5% verringerten Höchstgeschwindigkeiten, die damit einen signifikanten Einfluss auf das Lenkverhalten haben. Durch die blinde Steuerung des Simulationsfahrzeugs werden Lenkmanöver aufgrund der Durchführung von Kurven mit zu geringer Geschwindigkeit bereits vor dem Ende der Kurve beendet und nicht vollständig ausgefahren, wie in Abbildung 4.5 deutlich zu erkennen ist.



(a) Vergleich der Geschwindigkeiten \tilde{v} und \tilde{v}^{sim} in m/s.



(b) Abweichungen aufgrund von verzögerten Geschwindigkeitserhöhungen. Geschwindigkeiten in m/s.



(c) Abweichung aufgrund von asymmetrischen Verzögerungen von Geschwindigkeitserhöhung und Bremsung. Geschwindigkeiten in m/s.

Abbildung 4.12: Vergleich der geschätzten C^2 -Modell-Parameter mit den Simulationsergebnissen selbiger Parameter als Stellbefehle – Geschwindigkeit. Die Auswirkungen der Verzögerung im Detail sind in (b) und (c) gezeigt.

4.1.3 Evaluation des C^2 -Modells anhand realer Testfahrten

Die Evaluation des C^2 -Modells im vorangegangenen Abschnitt 4.1.2 weist auf eine gute Schätzgenauigkeit in Bezug auf die Simulationsergebnissen von CAR-MAKER hin. Zur Überprüfung der Schätzgüte im realen Testaufbau wurden Testfahrten mit einem der kurzfristig zur Verfügung stehenden VERTEX-Fahrzeuge des Iosb auf dem »Exerzierplatz« des KIT-Campus Ost durchgeführt. Der verwendete Vw eGOLF VII aus Abbildung 1.3 wurde zur Positionsbestimmung mit einem PIXSI MULTI der Firma »Swift Navigation« [167] ausgestattet, das mit der *Real-Time Kinematik* (RTK)-Technik zusammen mit einer *Basisstation* mit GPS³ als geodätisches Bezugssystem [177] eine experimentell während der Stillstandszeiten gemessene Positionsmessungengenauigkeit von einem *Root Mean Square Error*⁴ (RMSE) von etwa 12,5 cm in Ost-West-Richtung und etwa 24,4 cm in Nord-Süd-Richtung in dem Testaufbau erreichte. Die notwendigen Konstruktionsparameter des eGOLFS wurden aus dem offiziellen Vw-Datenblatt entnommen.

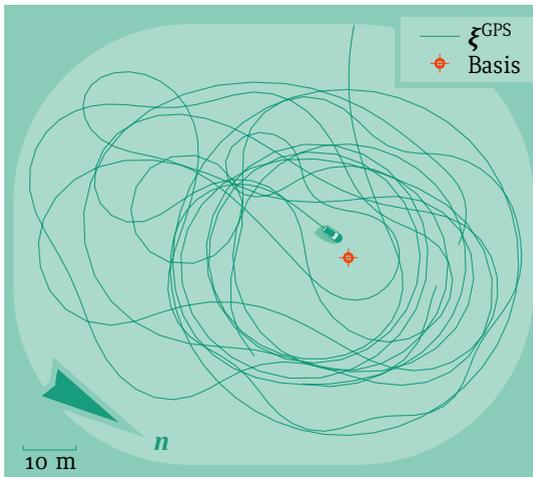


Abbildung 4.13: Testfahrt mit dem VERTEX-Fahrzeug auf dem Exerzierplatz am KIT-Campus Ost. Die grüne Linie zeigt die Gps-Spur ξ^{GPS} der Testfahrten; das rote Kreuz den Aufstellort der Basisstation.

³ Global Positioning System

⁴ Wurzel des mittleren quadratischen Fehlers

Abbildung 4.13 zeigt die Fahrzeugbewegung als GPS-Spur ξ^{GPS} , die im Weiteren zur C^2 -Modell-Schätzung verwendet wird. Um die asynchron aufgenommenen Positions- und Beschleunigungsdaten des P1KSI-GPS-Systems und die ebenfalls asynchron aufgenommenen Daten des fahrzeugeigenen *Controlled Area Network* (CAN)-Datenbus zusammenzuführen, wurden die Daten auf ein 2-Hz-Raster abgebildet und Messwerte innerhalb derselben Rasterzelle gemittelt.

Die CAN-Daten q^{CAN} dienen der Evaluation des C^2 -Modells als korrekt angenommene Referenzdaten⁵ bestehend aus:

- Geschwindigkeit v^{CAN} in km/h
- Lenkwinkel $\delta_{\text{lenk}}^{\text{CAN}}$ in Grad (°)
- Radmittelpunktgeschwindigkeiten $\|\xi_{\text{Rad}}^{\text{CAN}}\|$ der vier Räder in km/h

Anpassungen der C^2 -Modell-Parameter an CAN-Referenzdatenbasis

Da die CAN-Ausgaben teilweise von den hergeleiteten Größen in Abschnitt 4.1.1 abweichen, werden die geschätzten C^2 -Modell-Parameter \tilde{q} auf die Referenzdaten q^{CAN} angepasst. Zur Analyse der Schätzgenauigkeit der Radumdrehungen wird die Geschwindigkeit der Radmittelpunkte $\|\xi_{\text{Rad}}^{\text{CAN}}\|$ verwendet, die über Gl. (4.10) ohne Division durch den Reifenradius erhalten wird. Der Radius fließt somit in die C^2 -Modell-Schätzung nicht ein und bleibt unbestimmt.

Zur Transformation der geschätzten Einschlagwinkel $\tilde{\delta}_l$ und $\tilde{\delta}_r$ in den geschätzten Lenkwinkel $\tilde{\delta}_{\text{lenk}}$ ist eine Übertragungsfunktion f_{lenk} notwendig. In [S18] wird eine Methode zur Ermittlung der Lenkübertragungsfunktion in Kombination mit der FLOR-Unit⁶ aus [E2] vorgestellt, die den Einschlagwinkel in Videoaufnahmen anhand perspektivischer Eigenschaften einer speziell präparierten Radkappe modellbasiert schätzt. Da der eGOLF jedoch über Aluminiumfelgen verfügt, war eine einfache Anbringung des Messsystems nicht möglich. Aus diesem Grund wird der gemessene CAN-Lenkwinkel $\delta_{\text{lenk}}^{\text{CAN}}$ über ein Polynom dritten Grades auf die über das C^2 -Modell mit Gl. (4.8) geschätzten Einschlagwinkel $\tilde{\delta}_l$ und $\tilde{\delta}_r$ abgebildet. Hierzu werden die geschätzten Einschlagwinkel

⁵ Abweichend zur Nomenklatur in Abschnitt 4.1.2 werden die realen Referenzdaten zur besseren Unterscheidung mit q^{CAN} bezeichnet.

⁶ Frequency-labeled offset recording Unit

beider Räder zu einem Datensatz zusammengenommen, da sich aufgrund der vornehmlich gefahrenen Linkskurven hohe Einschlagwinkel hauptsächlich im linken Rad und geringe Einschlagwinkel hauptsächlich im rechten Rad wiederfinden. Abbildung 4.14 zeigt entsprechende Datenpaare des linken Vorderrades in Dunkelgrün und des rechten Vorderrads in Rot, gespiegelt am Ursprung. In Hellgrün ist das mit der MATLAB-Funktion *polyfit* approximierte Polynom dritten Grades der Übertragungsfunktion des linken Vorderrads $\tilde{\delta}_l$ dargestellt und ergibt sich im Bogenmaß zu

$$f_{\text{lenk}}(\tilde{\delta}_l) = -7,37 \cdot \tilde{\delta}_l^3 - 3,68 \cdot \tilde{\delta}_l^2 + 16,24 \cdot \tilde{\delta}_l - 0,01. \quad (4.19)$$

Mit der Lenkübertragungsfunktion des rechten Vorderrads als Ursprungsspiegelung von Gl. (4.19) und einer Mittelung der beiden resultierenden Lenkwinkel, ergibt sich der geschätzte Lenkwinkel $\tilde{\delta}_{\text{lenk}}$ schließlich zu

$$\tilde{\delta}_{\text{lenk}} = \frac{f_{\text{lenk}}(\tilde{\delta}_l) - f_{\text{lenk}}(-\tilde{\delta}_r)}{2}. \quad (4.20)$$

Die in Abbildung 4.14 in Blau dargestellte Linie mit zugehörigen Datenpunkten zeigt eine aus realen Einschlagwinkeln ermittelte Übertragungsfunktion eines nicht für automatisches Fahren umgerüsteten VW VARIANT aus [S18]. Der ähnliche Verlauf zur hellgrünen Kurve des eGOLFS insbesondere bei kleinen Ausschlägen deutet auf eine valide Approximation der Übertragungsfunktion hin. Die bei hohen Lenkwinkeln abweichenden Verläufe lassen sich auf die unterschiedlichen Bauarten der beiden Fahrzeuge zurückführen, da beide Kurven eine vergleichbare Krümmung aufweisen, lediglich an unterschiedlichen Lenkwinkelpositionen.

Evaluation der Testfahrten

Zur Evaluation der Schätzgüte des C^2 -Modells anhand realer Testfahrten werden – angelehnt an Abschnitt 4.1.2 – sowohl einzelne Fahrzeugparameter mit Korrelationsplots in den Abbildungen 4.15 und 4.16 analysiert, als auch Zeitverläufe in den Abbildungen 4.17 und 4.18.

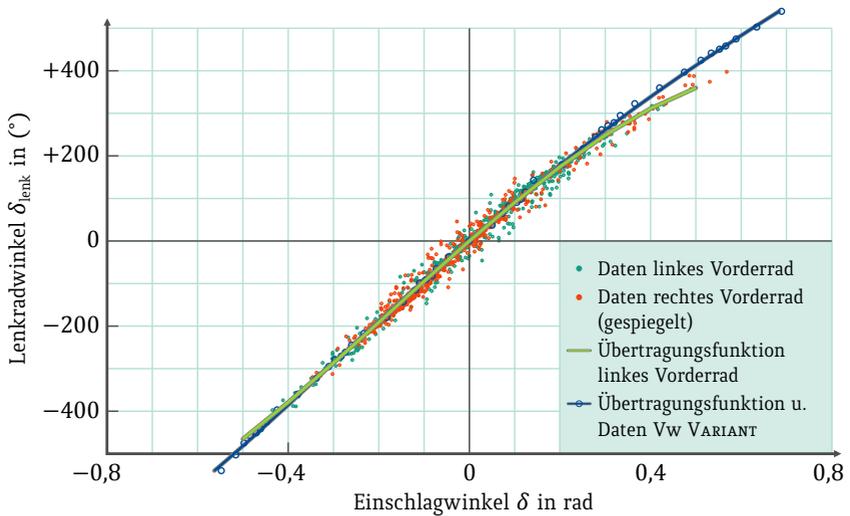


Abbildung 4.14: Daten und approximierte Lenkübertragungsfunktion Vw eGOLF VII. Übertragungsfunktion mit über C^2 -Modell approximierten Einschlagwinkeln. Zum Vergleich sind Messdaten und resultierende Übertragungsfunktion eines Vw VARIANT mit real gemessenen Einschlagwinkeln aus [S18] gegeben.

Abbildung 4.15a zeigt den Vergleich realer Geschwindigkeiten aus dem CAN-BUS und aus der Trajektorie ξ^{GPS} geschätzter Geschwindigkeiten des C^2 -Modells. Entgegen den sehr guten Geschwindigkeitsschätzergebnissen im Vergleich mit den CARMAKER-Simulationen in Abbildung 4.6a zeigt sich eine vergleichsweise hohe Standardabweichung von etwa $\sigma = 0,78$ km/h bei gleichzeitiger Steigung von etwa $m = 0,997$ nahe der perfekten Steigung $m = 1$. Die deutliche Verschlechterung der C^2 -Modell-Ergebnisse im Vergleich zur Simulation bereits in der Geschwindigkeitsschätzung – die nahezu keine spezifischen Modellannahmen des C^2 -Modells enthält, sondern im Wesentlichen die direkten Messungen von Gps- und CAN-Geschwindigkeit vergleicht – zusammen mit der stochastischen Streuung im Gegensatz zu erkennbaren *systematischen* Abweichungen, deutet wesentlich eher auf Messunsicherheiten als Quelle der Abweichungen hin als auf fehlerhafte oder übermäßig vereinfachte Modellannahmen. Diese sind auch für die weiteren Vergleiche zu berücksichtigen, da sich Unsicher-

heiten über die Position des Ego-Fahrzeugs über deren Differentiation in den weiteren Parameterschätzungen fortpflanzen.

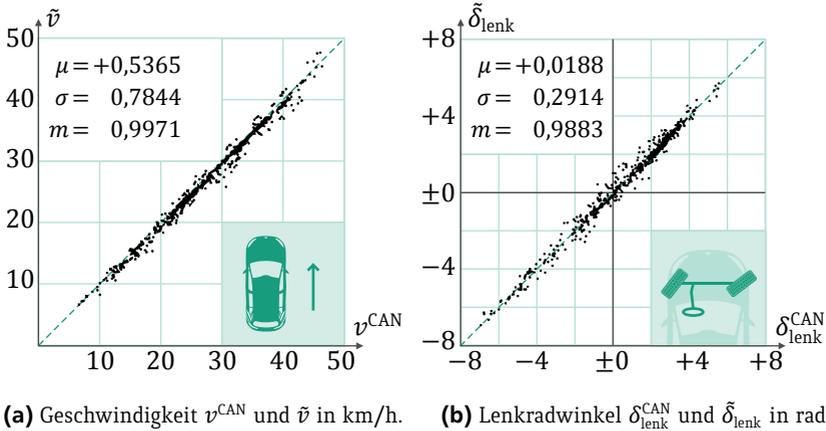
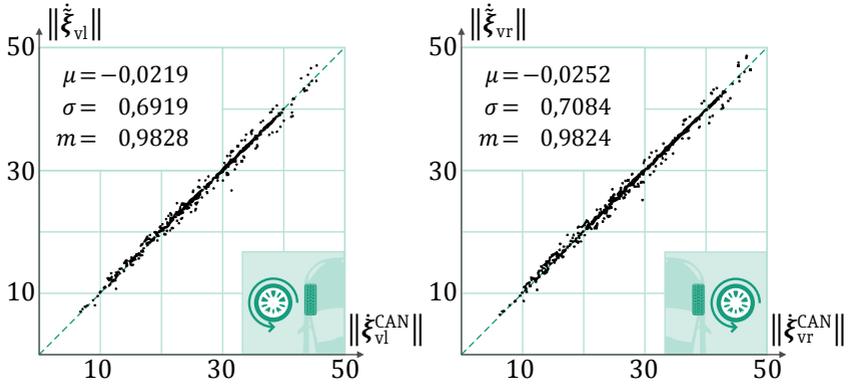


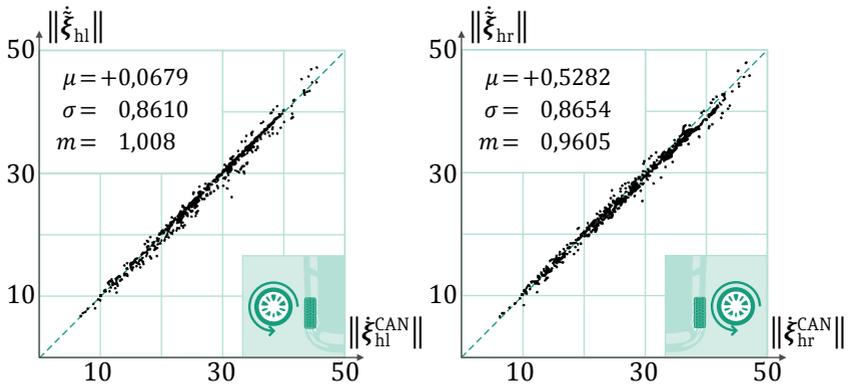
Abbildung 4.15: Korrelationsplots von C^2 -Modell und VERTEX-Daten – Geschwindigkeit und Lenkradwinkel. Korrelation der C^2 -Modellschätzungen mit den CAN-Referenzdaten des VERTEX-Fahrzeugs. Metriken: Mittlerer Fehler μ , Standardabweichung σ , Steigung m der linearen Approximation über Methode der kleinsten Quadrate. Die ersten beiden in der jeweiligen Einheit der zu vergleichenden Größen.

In der Tat finden sich in den Geschwindigkeiten der Radmittelpunkte in Abbildung 4.16 Standardabweichungen in derselben Größenordnung wie bei der Geschwindigkeitskorrelation. Ein Vergleich der Räder untereinander zeigt die höchsten mittleren Fehler μ und Abweichung der Steigung m im rechten Hinterrad, das durch die vornehmlich gefahrenen Linkskurven bei unterschiedlichen Geschwindigkeiten zu erklären ist. Die am hinteren rechten Rad am stärksten auftretenden Kräfte der Rollbewegungen finden durch das Fehlen von Rechtskurven keinen Ausgleich. Dabei resultieren die lange anliegenden Kräfte in einer starken Verformung des Reifens und damit in einer Verringerung des Reifenradius, der fahrzeugintern zur Berechnung der Radmittelpunktgeschwindigkeit aus den Radumdrehungen verwendet wird. Durch die fehlerhafte Schätzung des Reifenradius ergibt sich ein zu hoher Wert für die ausgegebenen CAN-Radmittelpunktgeschwindigkeiten.



(a) Radmittelpunktgeschwindigkeiten des linken Vorderrads $\|\dot{\xi}_{vl}^{\text{CAN}}\|$ und $\|\dot{\xi}_{vl}\|$ in km/h.

(b) Radmittelpunktgeschwindigkeiten des rechten Vorderrads $\|\dot{\xi}_{vr}^{\text{CAN}}\|$ und $\|\dot{\xi}_{vr}\|$ in km/h.



(c) Radmittelpunktgeschwindigkeiten des linken Hinterrads $\|\dot{\xi}_{hl}^{\text{CAN}}\|$ und $\|\dot{\xi}_{hl}\|$ in km/h.

(d) Radmittelpunktgeschwindigkeiten des rechten Hinterrads $\|\dot{\xi}_{hr}^{\text{CAN}}\|$ und $\|\dot{\xi}_{hr}\|$ in km/h.

Abbildung 4.16: Korrelationsplots von C^2 -Modell und VERTEX-Daten – Radmittelpunktgeschwindigkeit. Korrelation der C^2 -Modellschätzungen mit den CAN-Referenzdaten des VERTEX-Fahrzeugs. Metriken: Mittlerer Fehler μ , Standardabweichung σ , Steigung m der linearen Approximation über Methode der kleinsten Quadrate. Die ersten beiden in der jeweiligen Einheit der zu vergleichenden Größen.

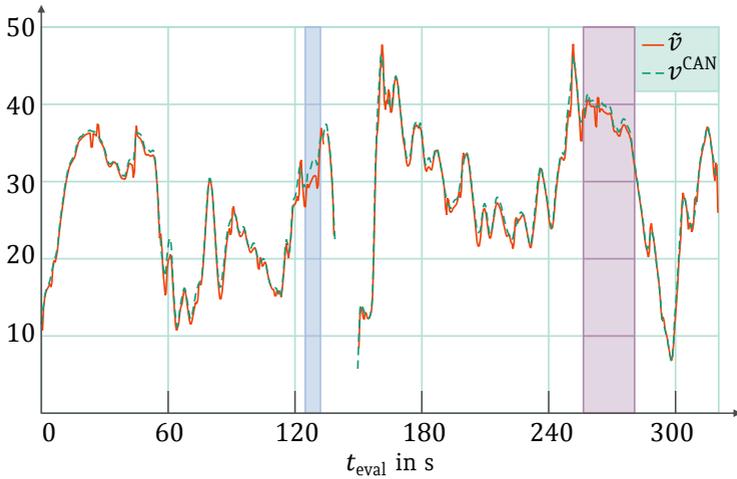
Das Auftreten dieses Effekts ist dabei maximal am rechten Hinterrad zu erkennen, wobei auch das linke Hinterrad durch einen fehlerhaften Reifenradius im Gegensatz zu den Vorderrädern einen erhöhten mittleren Fehler aufweist.

Abschließend zeigt sich in Abbildung 4.15b eine vergleichsweise gute Korrelation der CAN- und C²-Modell-Lenkradwinkel, die sich in einer mit Abbildung 4.15a vergleichbaren Größenordnung aller drei Metriken ausdrückt. Dies deutet auf eine gute Approximation der realen Lenkübertragungsfunktion als Polynom dritten Grades hin.

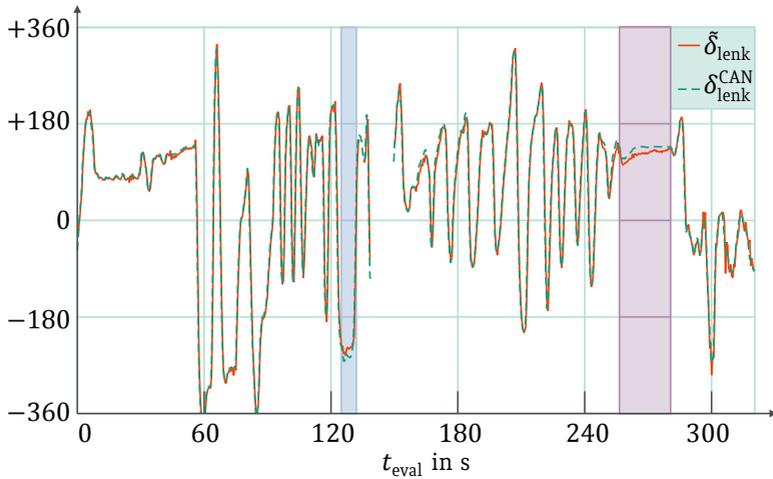
Ein Vergleich der Geschwindigkeiten und Lenkradwinkel über die Fahrzeit ist in Abbildung 4.17 dargestellt. Dabei zeigt sich eine gute Übereinstimmung der geschätzten C²-Modell-Daten mit den als Referenz angenommenen Daten des CAN-Busses mit Ausnahme von zwei farbig gekennzeichneten Intervallen, die sich durch die relativ hohen Geschwindigkeiten auf dem begrenzten Fahrbereich des Exerzierplatzes erklären lassen. Starke Kurveneinschläge bei hohen Geschwindigkeiten führen im Allgemeinen zu Querkraften und einem Verlust der Haftreibung der Reifen. Aufgrund fehlender Sensorik zur Messung der Quergeschwindigkeit wird in Abbildung 4.18 lediglich die geschätzte laterale Beschleunigung \tilde{a}_{lat} aus den GPS-Daten angegeben.

Die erste signifikante Abweichung von Schätzung und Referenz zeigt sich bei der maximalen lateralen Beschleunigung von $\tilde{a}_{\text{lat}} = 7,423 \text{ m/s}^2$ im blauen Bereich, die in einem Schlupfen der Räder mit erhöhter Raddrehzahl resultiert. Da die CAN-Geschwindigkeit fahrzeugintern wiederum aus den Raddrehungen berechnet wird, ergibt sich dadurch eine gegenüber der GPS-Geschwindigkeit fälschlicherweise erhöhte CAN-Geschwindigkeit. Der zur selben Zeit auftretende Fehler in der Lenkwinkelschätzung bestätigt den Schlupf der Reifen, der mit einem Ausbrechen des Hecks einhergeht.

Ähnliches gilt für die Abweichungen im lilanen Bereich, die vor allem in der Lenkradwinkelschätzung Fehler aufweisen. Das Intervall zeigt die Fahrtsituation bei einer Geschwindigkeit v^{CAN} von etwa 35 bis 40 km/h über einen Zeitraum von 24 Sekunden bei einem annähernd konstanten Lenkwinkelschlag von $\delta_{\text{lenk}}^{\text{CAN}} = 110^\circ$. Dies resultiert in einer anhaltenden lateralen Beschleunigung von über $5,5 \text{ m/s}^2$ und resultiert wiederum in einem Haftungsverlust der Reifen und damit einem Ausbrechen des Hecks.



(a) Vergleich der Geschwindigkeiten \tilde{v} und v^{CAN} in km/h.



(b) Vergleich der Beschleunigungen $\tilde{\delta}_{\text{lenk}}$ und $\delta_{\text{lenk}}^{\text{CAN}}$ in ($^{\circ}$).

Abbildung 4.17: Vergleich der C^2 -Modell-geschätzten Parameter mit den VERTEX-Daten – Geschwindigkeit und Lenkradwinkel. Vergleich der C^2 -Modellschätzung mit den CAN-Referenzdaten des VERTEX-Fahrzeugs.

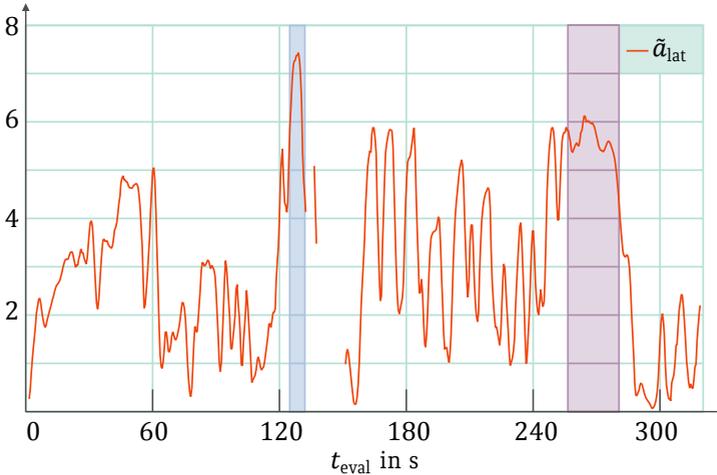


Abbildung 4.18: C^2 -Modell-geschätzte laterale Beschleunigung der realen Testfahrten. Laterale Beschleunigung in m/s^2 .

4.1.4 Zusammenfassung der Evaluation des C^2 -Modells

In den vorangegangenen Abschnitten 4.1.2 und 4.1.3 wurde das C^2 -Modell zunächst anhand von Simulationen mit CARMAKER und daran anschließend mit realen Testfahrten evaluiert. Dabei bieten die Simulationsstudien die Möglichkeit, eine Vielzahl an geschätzten Fahrzeugparametern mit entsprechenden Simulationen ohne Messunsicherheiten zu vergleichen. Da Simulationen die Realität jedoch nur begrenzt abbilden, sind die Real-Testfahrten ein wichtiger Bestandteil bei der Analyse des C^2 -Modells, die jedoch durch vorhandene Messunsicherheiten und dem sensorbedingten Fehlen mancher Fahrzeugparameter wiederum die Simulationserkenntnisse nicht ersetzen können. Entsprechend sind die Ergebnisse beider Evaluationen komplementär zu betrachten.

Beginnend mit der CARMAKER-Simulation weisen die Analysen des C^2 -Modells sehr gute Schätzergebnisse auf dem simulierten Hockenheimring in den Korrelationsplots der Abbildungen 4.6 und 4.7 auf. Lediglich bei Extremsituationen, in denen das Fahrzeug die Haftung verliert, ergeben sich in der C^2 -Modell-Schätzung deutliche Abweichungen, wie gemäß der Modellformulierung zu er-

warten war. Dies zeigt sich einerseits in der Simulation bei einer langgestreckten Linkskurve mit einer Geschwindigkeit von etwa 170 km/h und andererseits in der systematischen Evaluation anhand der variablen sinusförmigen Lenkung in Abschnitt 4.1.2.1, die zu fahrdynamischen Extremsituationen führt.

Die Evaluation der realen Testfahrten mit einem der beiden VERTEX-Versuchsfahrzeuge des Iosb bestätigt die guten Ergebnisse der Simulation hinsichtlich der Schätzgenauigkeit des C^2 -Modells. Zwar weisen entsprechende Korrelationsplots der Testfahrten im Vergleich zu den Ergebnissen der Simulation höhere Standardabweichungen und mittlere Fehler auf, die jedoch zu wesentlichen Teilen aus Messunsicherheiten des Gps-Systems sowie der CAN-Daten und notwendiger Nachprozessierungsschritte herrühren. Dies zeigt sich vor allem anhand der Geschwindigkeitsschätzung der Testfahrten in Abbildung 4.15a im Vergleich zu jenen der Simulation in Abbildung 4.6a, die lediglich aus der Ableitung der Gps-Spur berechnet werden und damit die dort auftretenden Fehler praktisch keine C^2 -Modellierungsfehler abbilden können.

Die in den Geschwindigkeiten resultierenden Fehler als Maß der allgemeinen Messunsicherheit des Testaufbaus annehmend, zeigen alle weiteren Korrelationsplots Fehler in derselben Größenordnung und deuten damit entsprechend auf gute Schätzergebnisse des C^2 -Modells hin. Eine Analyse des Zeitverlaufs bestätigt die Grenzen des C^2 -Modells in fahrphysikalischen Grenzbereichen.

Gegeben der guten Schätzergebnisse sowohl in der Simulation als auch in den Testfahrten und unter der Annahme, dass entsprechende Extremsituationen in physikalischen Grenzbereichen im alltäglichen Straßenverkehr selten auftreten, wird das in Abschnitt 4.1.1 beschriebene C^2 -Modell als geeignet erachtet für die Anwendung der Trajektorienplanungsaufgabe und in Abschnitt 3.1 zur Modellierung der Inner-Penalty der Penalty-Lagrangefunktion sowie zur Beschreibung von harten Nebenbedingungen im selben Abschnitt verwendet.

4.2 Geometrie der Situation

Neben der Geometrie des Ego-Fahrzeugs aus dem vorherigen Abschnitt 4.1 besitzt der Trajektorienraum Ξ eine \hookrightarrow Situationsgeometrie, die aus mehreren Bestandteilen aufgebaut ist, die im Folgenden eingeführt werden und die Grundlage der Outer-Penalty \mathcal{P}_{out} der Penalty-Lagrangefunktion bilden.

4.2.1 Beschreibung der initialen Situation des Ego-Fahrzeugs

Die \hookrightarrow Ego-Umgebung beschreibt die Geometrie der Situation zum aktuellen Zeitpunkt⁷ $t_{\text{real}} = t_{\text{start}} \in T$ nach Gl. (2.2) (die *initiale Situation* $\mathcal{S}(t_{\text{real}}) = \mathcal{S}_{\text{start}}$) und umfasst alle »beobachtbaren« Bestandteile des Fahrzeugumfelds.

Die Beobachtungen beschränken sich dabei nicht nur auf Sensordaten des Ego-Fahrzeugs, sondern können weiterhin aus Online- und Offlinekarten stammen und mittels \hookrightarrow Fahrzeug-zu-X-Kommunikation auch Informationen von anderen Fahrzeugen und geeigneter Infrastruktur beinhalten, um ein erweitertes *Situationsverständnis* zu erlangen. Die Fusion der unterschiedlichen Informationsquellen ermöglicht die Erhöhung der *Glaubwürdigkeit* einzelner Beobachtungen und Minderung von Unsicherheiten.

Die Ego-Umgebung setzt sich zusammen aus

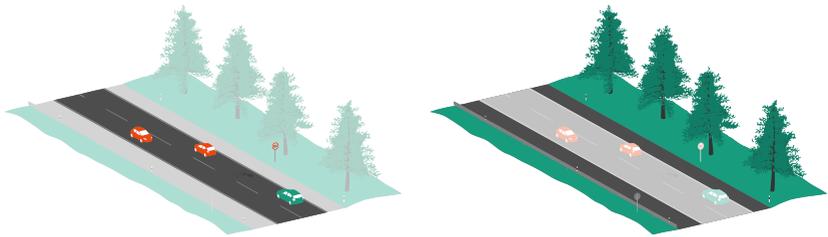
- der Straßengeometrie,
- dem Straßennebenbereich sowie
- anderen Verkehrsteilnehmern.

Die \hookrightarrow Straßengeometrie enthält den für das Ego-Fahrzeug relevanten Teil des umgebenden Straßenverlaufs und die entsprechenden geometrischen Eigenschaften der \hookrightarrow Fahrbahn, die aus einem oder mehreren \hookrightarrow Ego-Fahrstreifen und \hookrightarrow Gegenfahrstreifen besteht. Neben der Anzahl der jeweiligen Fahrstreifen, der Fahrstreifenbreiten und deren Beschaffenheit, zu der beispielsweise Straßenebenenheiten wie Schlaglöcher zählen, werden innerhalb der Straßengeometrie zudem Straßenschilder, Fahrbahnmarkierungen und bauliche Trennungen der

⁷ Der aktuelle (realweltliche) Zeitpunkt wird im Allgemeinen mit t_{real} bezeichnet. Im Kontext der Trajektorienplanung des Ego-Fahrzeugs beschreibt dieser Zeitpunkt den Beginn einer Trajektorie und wird damit mit t_{start} bezeichnet.

entgegengesetzten Fahrtrichtungen modelliert. Ein Beispiel einer Straßengeometrie wird in Abbildung 4.19a dargestellt.

Der \leftrightarrow Straßennebenbereich modelliert an die Fahrbahn angrenzende Bestandteile des Ego-Fahrzeug-Umfelds, wie beispielsweise den nicht mehr zur Fahrbahn gehörigen \leftrightarrow Seitenstreifen, einen Grünstreifen am Fahrbahnrand, Bäume und Leitplanken. Der Straßennebenbereich ist relevant für mögliche Notfallmanöver (beispielsweise in Abschnitt 6.3), die durch Verlassen des Ego-Fahrstreifens aufgelöst werden können. Zudem kann der Straßennebenbereich zur Bewertung eingehender Sensorinformationen verwendet werden, um beispielsweise Sichtbehinderungen an Kreuzungen mit Bäumen zu erkennen und entsprechend eine Anpassung des Ego-Fahrzeug-Fahrverhaltens durchzuführen. Ein beispielhafter Straßennebenbereich ist in Abbildung 4.19b dargestellt.



(a) Straßengeometrie.

(b) Straßennebenbereich.

Abbildung 4.19: Bestandteile der Ego-Fahrzeug-Umgebung. (a) zeigt eine exemplarische Straßengeometrie in Farbe, (b) einen exemplarischen Straßennebenbereich. Das Ego-Fahrzeug ist in Grün dargestellt.

Ein weiterer Bestandteil der Ego-Umgebung sind *andere Verkehrsteilnehmer*, bestehend aus Fahrzeugen, Fahrradfahrern, Fußgängern und Tieren, wobei im Weiteren lediglich andere Fahrzeuge betrachtet werden. Eine Erweiterung der Erkenntnisse auf andere Gruppen von Verkehrsteilnehmern ist bei Kenntnis entsprechender (approximativer) Verhaltensmodelle jedoch einfach möglich.

Verkehrsteilnehmer lassen sich durch eine Reihe an Eigenschaften beschreiben:

- Art des Verkehrsteilnehmers
- Position und gegebenenfalls Orientierung des Verkehrsteilnehmers innerhalb des Weltkoordinatensystems K^W aus Gl. (2.1)
- Geschwindigkeit und Richtung des Verkehrsteilnehmers in K^W
- (für Fahrzeuge) Zustand der Blink-/Bremslichter zur Intensionsübermittlung
- Unsicherheiten der einzelnen Eigenschaften aufgrund von beispielsweise Verhaltens- oder Messunsicherheiten
- weitere beobachtbare Eigenschaften, die zum Verständnis der Situation beitragen

Weitere Eigenschaften wären beispielsweise die Marke eines Fahrzeugs mit entsprechender, validierter Statistik über ein markenabhängiges Fahrverhalten. Ebenso können Gestenerkennung und Blickrichtungsschätzung zur Modellierung von Intentionserkennung bei Fußgängern herangezogen werden [101].

Auswahl eines stochastischen Modells zur Beschreibung der Ego-Umgebung

Die Modellierung von Verkehrssituationen beinhaltet unterschiedliche Quellen an Unsicherheiten, die aus Sensorik und Aktuatorik, aus der Sensorprozessierung und aus Verhaltensunsicherheiten anderer Verkehrsteilnehmer stammen. Zur Betrachtung dieser Unsicherheiten innerhalb der Trajektorienplanung wird eine probabilistische Modellierung des Verkehrsgeschehens vorgeschlagen. Zudem bieten stochastische Modelle eine einfache Validierung zugrundeliegender Modellannahmen über Statistiken – wie beispielsweise die oft genutzte Annahme stochastischer Unabhängigkeit – und ermöglichen die Kombination unterschiedlicher Modelle auf Basis stochastischer Beschreibungen. Durch die Linearität der ELM-Problemformulierung in Abschnitt 3.2 sind vor allem lineare stochastische Modelle geeignet, die eine additive lokale Bewertung von Eigenschaften vornehmen. Prominenteste Vertreter bilden *Log-Lineare Modelle* und eine Modellierung über *Erwartungswerte* [E1]. Eine vertiefende Einführung in stochastische Modelle bieten beispielsweise [2, 175].

Log-lineare Modelle verwenden die Umformung $\log(a \cdot b) = \log(a) + \log(b)$ zur Umwandlung der Multiplikation von Wahrscheinlichkeiten stochastisch unabhängiger Zufallsvariablen $p(X_n = \mathcal{E}_n) = p(\mathcal{E}_n)$ mit $n \in [1, N] \in \mathbb{N}$ nach Gl. (2.46) in eine Addition logarithmierter Wahrscheinlichkeiten

$$\log\left(\prod_{n \in N} p(\mathcal{E}_n)\right) = \sum_{n \in N} \log(p(\mathcal{E}_n)). \quad (4.21)$$

Dabei bleibt bei der Logarithmierung die stochastische Interpretation erhalten, sodass stochastisch beschreibbare Modelle beispielsweise innerhalb solcher Optimierungsmethoden verwendet werden können, die eine lokale Bewertung berechnen die linear in die Gesamtbewertung einfließt, die dann wiederum minimiert oder maximiert wird. Geht die Problemformulierung jedoch über eine Optimierung von Wahrscheinlichkeiten hinaus, stoßen Log-Lineare stochastische Modelle an ihre Grenzen. So besteht die Fahraufgabe nicht nur aus der Minimierung der Eintrittswahrscheinlichkeit eines Verkehrsunfalls. Vielmehr müssen etwa sowohl Komfort- und Verkehrsregelkriterien in die Bewertung miteinbezogen werden, als auch die *Schwere* eines Unfalls, beispielsweise wenn eine Wahl zwischen entweder einem sicheren Auffahrunfall auf das vorausfahrende Fahrzeug ($p(x_A) = 1$) oder einem Ausweichmanöver auf den Gegenfahrstreifen bei potentielltem Gegenverkehr ($p(x_G) = 0,1$) notwendig wird. Durch die hohe Unfallschwere des zweiten Manövers wird der Auffahrunfall üblicherweise dem Ausweichmanöver trotz höherer Eintrittswahrscheinlichkeit vorgezogen, woraus folgt, dass neben Wahrscheinlichkeiten auch andere Größen in der Optimierung berücksichtigt werden sollten, vorzugsweise aber dennoch weiterhin unter konsistenter Berücksichtigung stochastischer Modelle.

Die Entscheidung eines rationalen Fahrers ist folglich geeigneter beschreibbar über das *Risiko* der verfügbaren Manöver, also einer Kombination von Eintrittswahrscheinlichkeit und Unfallschwere im Eintrittsfall, mit der mathematischen Entsprechung als \hookrightarrow Erwartungswert des Schadens. Der gängigste Ansatz, die Wahrscheinlichkeit und die Folgen von Ereignissen geschlossen zu berücksichtigen und zu optimieren, liegt in der statistischen Entscheidungstheorie, beispielsweise nach [10, 110, 152, 183]. Bei einer beispielhaften Beschreibung des

Schadens rein über anfallende Sachkosten ergibt sich für einen leichten Auffahrunfall mit $x_A = 5.000\text{€}$ und einer schweren Kollision mit dem Gegenverkehr mit $x_G = 100.000\text{€}$ der Erwartungswert des Schadens beider Manöver mit Gl. (2.57) zu

$$\mathcal{E}(x_A) = p(x_A) \cdot x_A = 1 \cdot 5.000\text{€} = 5.000\text{€}$$

$$\mathcal{E}(x_G) = p(x_G) \cdot x_G = 0,1 \cdot 100.000\text{€} = 10.000\text{€} .$$

Eine entsprechende Minimierung des Schadenserwartungswerts resultiert in diesem Beispiel in der Wahl des Auffahrmanövers, sodass eine Modellierung über den Erwartungswert die für den Fahrer intuitive Lösung ergibt.

Neben der erfolgreichen Beschreibung des menschlichen Abwägungsprozesses können innerhalb der Modellierung als Schadenserwartungswert sowohl stochastische, als auch deterministische Bewertungen kombiniert werden, indem eine gemeinsame *Bewertungseinheit* des erwarteten Schadens – wie beispielsweise die Währung € – definiert wird. Mit einer entsprechenden \hookrightarrow Penalty-Bewertungseinheit, die sowohl Kollisionsrisiken als auch Komfortbetrachtungen »bepreist«, lassen sich die im Weiteren hergeleiteten *Belegungswahrscheinlichkeiten von Zellen* zugehöriger *Aufenthaltswahrscheinlichkeiten* statischer und dynamischer Objekte, die Teile der Outer-Penaltys \mathcal{P}_{out} bilden, mit den Bewertungen der Trajektorieneigenschaften aus dem vorherigen Abschnitt 4.1 als Grundlage der Inner-Penaltys \mathcal{P}_{in} kombinieren. Durch geeignete Gewichtungsfaktoren w_i entsprechend Abschnitt 3.1 ist zudem eine Priorisierung der unterschiedlichen Penaltys möglich, sodass gemäß der Kritikalität einer Situation entsprechende sicherheitsrelevante Parameter überwiegen.

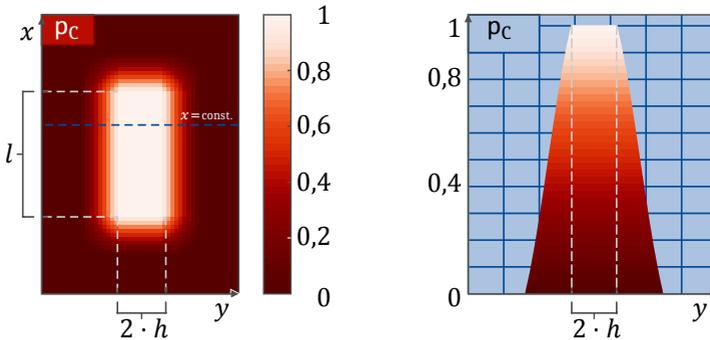
Modellierung der Ego-Umgebung

Die initiale Situation $\mathcal{S}_{\text{start}}$ enthält das beobachtbare Fahrzeugumfeld zum aktuellen Zeitpunkt $t_{\text{real}} = t_{\text{start}} \in T$ und stammt aus unterschiedlichen Quellen, deren Informationen im Allgemeinen mit Unsicherheiten verbunden sind, die in die Modellierung einfließen. Hierzu wird eine zellenbasierte Darstellung der fahrzeugumgebenden Welt mit Koordinaten \mathbf{x}^W aus Gl. (2.1) angenom-

men, deren Zellen Belegungswahrscheinlichkeiten zugewiesen werden, gegeben der Aufenthaltswahrscheinlichkeiten statischer und dynamischer Objekte der Ego-Umgebung. Die Wahrscheinlichkeit eines Verkehrsteilnehmers C zum Zeitpunkt t_{real} mit seiner \hookrightarrow Fahrzeugausdehnung eine bestimmte Zelle um \mathbf{x}^W zu überdecken, resultiert somit in einer Belegungswahrscheinlichkeit dieser Zelle mit den informationsgebenden Sensordaten $\mathcal{I}_S(t_{\text{real}})$ entsprechend

$$p_C(\mathcal{E}_{\mathbf{x}^W}^{\text{Bel}} | t_{\text{start}}) = p_C(\mathcal{E}_{\mathbf{x}^W}^{\text{Bel}} | \mathcal{I}_S(t_{\text{real}})), \quad (4.22)$$

wobei die Größe der Zellen als konstant angenommen wird und $\mathcal{E}_{\mathbf{x}^W}^{\text{Bel}}$ das Ereignis einer belegten Zelle um \mathbf{x}^W darstellt. Dabei beschreibt die Fahrzeugausdehnung des Verkehrsteilnehmers die auf die Bodenebene projizierte reale räumliche Ausdehnung des Verkehrsteilnehmers. Abbildung 4.20 zeigt beispielhaft die resultierende Belegungswahrscheinlichkeit eines Fahrzeugs C mit entsprechenden Sensorunsicherheiten am Fahrzeugrand.



(a) Exemplarische Darstellung als Heatmap. x und y in Längeneinheiten. (b) Entlang $x = \text{const.}$ geschnittene Darstellung. y in Längeneinheit mit Farbkodierung aus (a).

Abbildung 4.20: Aus Aufenthaltswahrscheinlichkeiten eines Fahrzeugs resultierende Belegungswahrscheinlichkeiten. Die Größen h und l stellen die halbe Spurweite und den Achsabstand aus Abschnitt 4.1.1 dar.

Innerhalb der Trajektorienplanung des Ego-Fahrzeugs bedeutet die Belegungswahrscheinlichkeit aus Gl. (4.22) eine Kollisionsgefahr mit dem Verkehrsteil-

nehmer C an der Position \mathbf{x}^W zum Zeitpunkt t_{start} , wenn für die Trajektorie die Eigenschaft $\xi(t_{\text{start}}) = \mathbf{x}^W$ gilt. Dabei muss die \hookrightarrow Ego-Fahrzeug-Ausdehnung in die geometrische Betrachtung miteinbezogen werden, beispielsweise über die Akkumulation aller vom Ego-Fahrzeug abgedeckten Zellen.

Zur Beurteilung eines möglichen Kollisionsereignisses wird der Schadenserwartungswert entsprechend Gl. (2.57) mit Schadenskosten K_C betrachtet, woraus sich jener Teil der Primary-Outer-Penaltys aus Abschnitt 3.1 ergibt, der eine Kollision des Ego-Fahrzeugs mit dem Verkehrsteilnehmer C an der Position \mathbf{x}^W zum Zeitpunkt t_{start} modelliert, sodass

$$p'_{\text{out},C}(\xi(t_{\text{start}}) = \mathbf{x}^W) = K_C \cdot p_C(\mathcal{E}_{\mathbf{x}^W}^{\text{Bel}} | t_{\text{start}}). \quad (4.23)$$

Aufgrund ethischer Implikationen wird in dieser Arbeit auf Vorschläge für eine konkrete Ausgestaltung der Schadensbewertung verzichtet. Vielmehr ist hier ein gesellschaftlicher Konsens vonnöten, der beispielsweise durch eine Weiterführung der Ethik-Kommission entsprechend [40] erarbeitet werden kann. Ausschließlich zu Verdeutlichungszwecken der hergeleiteten Problemformulierung – und auf allgemeine Zeitpunkte t erweitert – ergibt sich beispielhaft eine Penaltyberechnung der Ego-Fahrzeug-Trajektorie über die zu erwartende *kinetische Energie* mit der (geschätzten) Geschwindigkeit des Verkehrsteilnehmers C zum Zeitpunkt t mit v_C zu

$$p'_{\text{out},C}(\xi(t) = \mathbf{x}^W, \|\xi(t)\| = v) \propto (v_C - v)^2 \cdot p_C(\mathcal{E}_{\mathbf{x}^W}^{\text{Bel}} | t).$$

Neben Objekten der Straßengeometrie und des Straßennebenbereichs – wie beispielsweise Bäume oder Leitplanken – können analog zu Gl. (4.23) mittels p''_{out} weiterhin Bereiche modelliert werden, deren Befahrung bestraft, jedoch nicht ausgeschlossen werden soll, beispielsweise das Verweilen auf Fahrstreifenmarkierungen oder das Befahren von Seitenstreifen. In diesem Fall ergibt sich der stochastische Anteil gegebenenfalls aus der Beschreibung von Sensorunsicherheiten. In Notfallsituationen können diese Penaltys vernachlässigt werden.

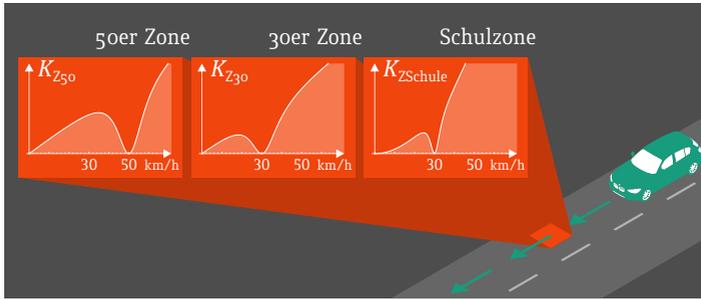


Abbildung 4.21: Geschwindigkeits- und -zonenabhängige Secondary-Outer-Penalty. In Abhängigkeit der Geschwindigkeit und der aktuellen Verkehrszone ergeben sich entsprechende Kosten zur Bewertung der Trajektorie des Ego-Fahrzeugs. Die Kostenfunktionen können zur Modellierung der Secondary-Outer-Penalty $p''_{\text{out}}(\xi, \dot{\xi}, t | p)$ verwendet werden.

Weiterhin lassen sich deterministische Eigenschaften als »unter Erfüllung einer Bedingung mit Sicherheit eintretende Ereignisse« modellieren. Die Wahrscheinlichkeiten eines deterministischen Ereignisses \mathcal{D} an der Position \mathbf{x}^W ergeben sich mit der Bedingung d über

$$p_{\mathcal{D}}(\mathcal{E}_{\mathbf{x}^W}^{\text{Bel}} | d, t_{\text{start}}) = \begin{cases} 1 & \text{wenn } d \\ 0 & \text{sonst.} \end{cases} \quad (4.24)$$

Mit Gl. (4.24) können ortsbezogene, von zusätzlichen Eigenschaften abhängige Penalty modelliert werden, wie beispielsweise eine zonenabhängige Penalty auf die Geschwindigkeit des Ego-Fahrzeugs, dargestellt in Abbildung 4.21. Hierfür werden die Schadenskosten in Abhängigkeit der Umgebung Z und der aktuellen Geschwindigkeit $v = \|\dot{\xi}(t_{\text{start}})\|$ gemäß Gl. (4.4) wie folgt modelliert, sodass

$$\begin{aligned} p''_{\text{out},Z}(\dot{\xi}(t_{\text{start}}) = \mathbf{x}^W, \|\dot{\xi}(t_{\text{start}})\| = v) \\ = p_Z(\mathcal{E}_{\mathbf{x}^W}^{\text{Bel}} | v, t_{\text{start}}) \cdot \begin{cases} K_{Z_{50}}(v) & \text{wenn } 50\text{km/h-Zone} \\ K_{Z_{30}}(v) & \text{wenn } 30\text{km/h-Zone} \\ K_{Z_{\text{Schule}}}(v) & \text{wenn } \text{Schulzone.} \end{cases} \end{aligned} \quad (4.25)$$

4.2.2 Prädiktion der initialen Situation

Die Modellierung der Ego-Umgebung aus dem vorherigen Abschnitt 4.2.1 stellt eine vollständige Beschreibung der geometrischen Eigenschaften der initialen Situation $\mathcal{S}_{\text{start}}$ zum Zeitpunkt $t_{\text{real}} = t_{\text{start}} \in T$ dar. Zur Bewegungsplanung des Ego-Fahrzeugs muss nun in einem nächsten Schritt die initiale Situation in die Zukunft prädiziert werden. Daraus ergeben sich wiederum vollständige *prädizierten Situationen* $\mathcal{S}_t = \mathcal{S}(t|\mathcal{S}_{\text{start}})$ zu den Zeitpunkten $t \in T_p$ für den *Prädiktionszeitraum*

$$\begin{aligned} T_p &= T_d \setminus \{t_{\text{start}}\} \\ &= \{t_{\text{start}} + \Delta t, \dots, t_{\text{start}} + \mathcal{T} \cdot \Delta t = t_{\text{end}}\} \end{aligned} \quad (4.26)$$

mit T_d aus Gl. (2.2), $\Delta t \in \mathbb{R}$ der Diskretisierung und $\mathcal{T} \in \mathbb{N}$ der Anzahl an *Prädiktionszeitschritten*.

Durch die Betrachtung eines Prädiktionszeitraums können zeitabhängige deterministische Ereignisse, die an einem Ort \mathbf{x}^W im Zeitraum $[t_{B_1}, t_{B_2}]$ als Ereignis $\mathcal{E}_{\mathbf{x}^W}$ auftreten, modelliert werden. Gilt für einen Zeitpunkt $t \in T_p$, sodass $\xi(t) = \mathbf{x}^W$, so ergeben sich entsprechende Kosten K_T als Secondary-Outer-Penaltys aus Abschnitt 3.1 mit der Interpretation als sicheres Ereignis $p_T(\mathcal{E}_{\mathbf{x}^W}|t)$ entsprechend Gl. (4.24) als

$$p''_{\text{out},T}(\xi(t) = \mathbf{x}^W) = p_T(\mathcal{E}_{\mathbf{x}^W}|t) \cdot \begin{cases} K_T & \text{wenn } t \in [t_{B_1}, t_{B_2}] \\ 0 & \text{sonst.} \end{cases} \quad (4.27)$$

Beispielsweise ergibt sich eine heruntergesetzte Geschwindigkeitsbegrenzung von 50 km/h auf 30 km/h während der Nachtruhe von 22 Uhr bis 6 Uhr mit zwei Kostenfunktion $K_{\text{Tag}}(v)$ und $K_{\text{Nacht}}(v)$, der Geschwindigkeit des Ego-Fahrzeugs mit Gl. (4.4) als $v(t) = \|\dot{\xi}(t)\|$, dem sicheren Ereignis $p_G(\mathcal{E}_{\mathbf{x}^W}|t)$ entsprechend Gl. (4.24) und der Zeit t definiert als »Stunden : Minuten« zu

$$\begin{aligned} p''_{\text{out},G}(\xi(t) = \mathbf{x}^W, \|\dot{\xi}(t)\| = v) \\ = p_G(\mathcal{E}_{\mathbf{x}^W}|t) \cdot \begin{cases} K_{\text{Tag}}(v) & \text{wenn } t \in (06:00, 20:00) \\ K_{\text{Nacht}}(v) & \text{sonst.} \end{cases} \end{aligned} \quad (4.28)$$

Prädiktion anderer Verkehrsteilnehmer

Das zukünftige Verhalten anderer Verkehrsteilnehmer ist nicht mit Sicherheit vorhersagbar, sodass die prädizierten Situationen \mathcal{S}_t mit $t \in T_p$ diese Unsicherheiten beinhalten müssen. Der in [E5] beschriebene Gesamtprozess wird in Abbildung 4.22 dargestellt und zeigt die einzelnen Schritte der Prädiktion eines Fahrzeugs, die ausgehend von Manöveroptionen eines menschlichen Fahrers zu räumlichen Belegungswahrscheinlichkeiten entsprechend Gl. (4.22) für die prädizierten Zeitpunkte $t \in T_p$ führen. Für die Prädiktion anderer Verkehrsteilnehmer, wie beispielsweise Fußgänger, ergeben sich in Abhängigkeit der abweichenden Verhaltensmodelleigenschaften entsprechende Anpassungen des Gesamtprozesses.

Die zur konkreten Modellierung benötigten Verhaltensstatistiken anderer Verkehrsteilnehmer können über Luftbildaufnahmen gewonnen werden, wie in [E7] anhand einer ausgesuchten Beispielsituation vorgestellt wird. Eine automatisierte Prozessierungskette von Luftbildern zur Gewinnung von Statistiken wird in [S16] vorgestellt, deren vollständige Ausgestaltung und Anwendung jedoch außerhalb dieser Arbeit liegt. Im Folgenden werden die theoretischen Grundlagen der Prädiktionsmodellierung beschrieben.

Aktionsverteilungsfunktion Die Aktionsverteilungsfunktion $p_C(\mathbf{u}_C|t)$ modelliert Handlungsoptionen $\mathbf{u}_C \in \mathcal{U}$ des menschlichen Fahrers C – genauer das Ereignis des Auftretens einer Handlung – dessen Fahrzeugposition zur initialen Situation $\mathcal{S}_{\text{start}}$ über die Belegungswahrscheinlichkeit $p_C(\mathcal{E}_{x^{\text{Bel}}}^{\text{Bel}}|t_{\text{start}})$ gemäß Gl. (4.22) beschrieben wird. Die Menge an modellierten Handlungen \mathcal{U} kann dabei die Stellgrößen an das Fahrzeug enthalten – wie Bremse, Beschleunigung oder Lenkung – oder aber komplexe Manöver beschreiben – wie beispielsweise das Abbiegen an einer Kreuzung. Die möglichen Handlungen \mathbf{u}_C des Verkehrsteilnehmers C sind dabei bestimmt von der initialen Situation, der Straßengeometrie und anderen Verkehrsteilnehmern, deren Einfluss auf C über ein bayessches Netz aus Abschnitt 2.3 modelliert werden kann.



Abbildung 4.22: Einzelne Schritte zur Prädiktion von Aufenthalts- und zugehörigen Belegungswahrscheinlichkeiten.

Dazu wird vereinfachend angenommen, dass das Verhalten des Fahrers C lediglich beeinflusst wird von

- direkt vorausfahrenden Fahrzeugen auf demselben Fahrstreifen,
- Fahrzeugen in nächster Nähe auf benachbarten Fahrstreifen und
- Fahrzeugen, die wegen Vorfahrtsregelungen zu beachten sind.

Durch die Interaktionsbeschränkung ergibt sich das in Abbildung 4.23 beispielhaft dargestellte bayessche Netz für eine Autobahnauffahrt. Mit den Pfeilen als Darstellung der Abhängigkeiten ergibt sich im Beispiel die Wahrscheinlichkeit einer Bremsaktion \mathbf{u}_B^{Br} des Fahrzeugs B, das ausschließlich von den Aktionen des

vordersten Verkehrsteilnehmers **A** abhängt, für den Fall einer Bremsaktion \mathbf{u}_A^{Br} von **A** entsprechend Gl. (2.45) zu

$$p(\mathbf{u}_B^{\text{Br}} | t) = \sum_{\mathbf{u}_A^{\text{Br}}} p(\mathbf{u}_B^{\text{Br}} | \mathbf{u}_A^{\text{Br}}, t) \cdot p(\mathbf{u}_A^{\text{Br}} | t). \quad (4.29)$$

Daneben gilt unter Verwendung der Kettenregel aus Gl. (2.48) und der vollständigen Wahrscheinlichkeit aus Gl. (2.45) sowie unter Berücksichtigung der modellierten Unabhängigkeiten für die Verbundwahrscheinlichkeit einer Bremsung aller Fahrzeuge mit Ausnahme des Verkehrsteilnehmers **G** zum Zeitpunkt t beispielhaft

$$\begin{aligned} & p(\mathbf{u}_F^{\text{Br}}, \mathbf{u}_E^{\text{Br}}, \mathbf{u}_D^{\text{Br}}, \mathbf{u}_C^{\text{Br}}, \mathbf{u}_B^{\text{Br}}, \mathbf{u}_A^{\text{Br}} | t) \\ &= p(\mathbf{u}_F^{\text{Br}} | \mathbf{u}_E^{\text{Br}}, t) \cdot p(\mathbf{u}_E^{\text{Br}} | \mathbf{u}_D^{\text{Br}}, \mathbf{u}_C^{\text{Br}}, \mathbf{u}_B^{\text{Br}}, t) \cdot p(\mathbf{u}_D^{\text{Br}} | \mathbf{u}_B^{\text{Br}}, t) \cdot \\ & \quad p(\mathbf{u}_C^{\text{Br}} | \mathbf{u}_A^{\text{Br}}, t) \cdot p(\mathbf{u}_B^{\text{Br}} | \mathbf{u}_A^{\text{Br}}, t) \cdot p(\mathbf{u}_A^{\text{Br}} | t). \end{aligned} \quad (4.30)$$

Geeignete Wahrscheinlichkeitsmodelle enthalten neben den bereits betrachteten Abhängigkeiten weitere, damit assoziierte Abhängigkeiten, wie beispielsweise den Abstand der einzelnen in Interaktion tretenden Fahrzeuge oder auch Handlungsindikatoren wie Blinker.

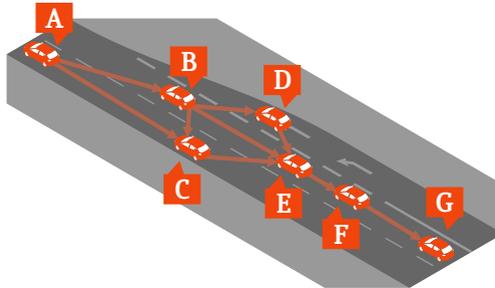


Abbildung 4.23: Bayessches Netz zur Interaktionsmodellierung in der Verhaltensprädiction anderer Fahrzeuge. Vereinfachende Annahmen zur Modellierung von Interaktion zwischen Verkehrsteilnehmern **A** – **G**.

Longitudinale Verteilungsfunktion – Aufbauend auf die Aktionsverteilung wird eine longitudinale Verteilungsfunktion $p_C(\mathcal{E}_s^{\text{Bel}}|t)$ berechnet, die sich entlang eines (prinzipiell) straßenverlaufsunabhängigen Pfades – einem virtuellen Pfad $\tilde{\xi}_{\text{virt}}(s)$ – mit dem longitudinalen Raumparameter s ergibt. Die Verteilung beschreibt die Wahrscheinlichkeit des Fahrzeugs C , sich zum Zeitpunkt t an der Position s zu befinden und kann unter Verwendung der vollständigen Wahrscheinlichkeit aus Gl. (2.45) als Summe aller möglichen zeitlichen Positionsverläufe $s_i(t)$ nach Gl. (2.7) beschrieben werden, die sich aus unterschiedlichen Geschwindigkeiten und Geschwindigkeitswechsellern ergeben. Mit dem Ereignis $\mathcal{E}_s^{\text{Bel}}$ einer belegten Zelle um die Position s gilt

$$p_C(\mathcal{E}_s^{\text{Bel}}|t) = \sum_i p(\mathcal{E}_s^{\text{Bel}}|s_i, t) \cdot p(s_i). \quad (4.31)$$

Dabei ist die Wahrscheinlichkeit, sich an s zum Zeitpunkt t bei gegebenem s_i zu befinden simpel als

$$p(\mathcal{E}_s^{\text{Bel}}|s_i, t) = \begin{cases} 1 & \text{wenn } s_i(t) = s \\ 0 & \text{sonst} \end{cases} \quad (4.32)$$

modellierbar, wohingegen die Aufzählung aller Positionsverlaufsvarianten $p(s_i)$ praktisch bereits für ein Fahrzeug nicht handhabbar ist – selbst wenn diese vereinfachend als endlich angenommen werden. Aus diesem Grund werden im Weiteren zwei mögliche Approximationen zur Beschreibung der longitudinalen Verteilungsfunktion $p_C(\mathcal{E}_s^{\text{Bel}}|t)$ eines Verkehrsteilnehmers C vorgestellt, einerseits basierend auf Geschwindigkeitsverteilungen und andererseits auf der Diffusion mit Faltungskernen.

Eine aus aussagekräftigen Verkehrsstatistiken rührende *kumulierte Geschwindigkeitsverteilung* $p_v(v)$, die Fahrzeuggeschwindigkeiten Wahrscheinlichkeiten zuweist, kann unter der Annahme konstanter (aber unbekannter) Geschwindigkeit in festen Zeitintervallen wie folgt in die longitudinale Belegungswahrscheinlichkeit transformiert werden mit s_{start} als Startposition, über

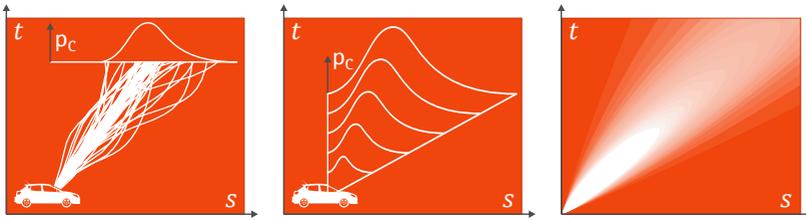
$$p_C(\mathcal{E}_s^{\text{Bel}}|t) = p_v\left(\frac{s - s_{\text{start}}}{t}\right). \quad (4.33)$$

Aufgrund des unbegrenzten Trägers auf $(-\infty, \infty)$ und ihrer symmetrischen Form wird die Normalverteilung zur analytischen Beschreibung von Verkehrsstatistiken in dieser Arbeit als weniger geeignet betrachtet, und damit auch die Verwendung von Prädiktionverfahren, die auf Normalverteilungsannahmen beruhen, wie beispielsweise gängige »Kalmanfilterverfahren«. Im Gegensatz zur Normalverteilung ist die *Kumaraswamyverteilung* aus [105] einerseits einfach zu berechnen und bietet andererseits über die formbestimmenden nicht-negativen Parameter a und b eine hohe Flexibilität. Durch die geschlossene Berechenbarkeit über die Geschwindigkeitsverteilung in Gl. (4.33) kann eine einfache Auswertung der longitudinalen Belegungswahrscheinlichkeit an gezielten Positionen durchgeführt werden, ohne die gesamte Verteilung zu berechnen. Die kumulierte Verteilungsfunktion $p_K(X \leq x)$ einer Kumaraswamy-verteilten Zufallsvariable X ergibt sich als

$$p_K(X \leq x) = \begin{cases} 0 & \text{wenn } x < 0 \\ 1 - (1 - x^a)^b & \text{wenn } x \in [0, 1] \\ 1 & \text{wenn } x > 1. \end{cases} \quad (4.34)$$

Über die Transformation $x = (v - v_{\min}) / (v_{\max} - v_{\min})$ kann die Kumaraswamyverteilung auf das Intervall $v_{\min} \leq v \leq v_{\max}$ erweitert werden. Abbildung 4.24 stellt die so approximierte longitudinale Belegungswahrscheinlichkeit $p_C(\mathcal{E}_s^{\text{Bel}}|t)$ schematisch dar. Abbildung 4.25 zeigt die Approximation von realen Geschwindigkeitsstatistiken aus [95] über eine entsprechende Wahl der Kumaraswamyparameter [E4].

Die wesentliche vorteilhafte Eigenschaft der Approximation über die Kumaraswamyverteilung ergibt sich aus der einfachen Bestimmung der Funktion zu einem beliebigen Zeitpunkt t ohne die gesamte Prädiktion berechnen zu müssen und ist damit vor allem für speicherarm ausgelegte Systeme gut geeignet. Bei der Verwendung eines zellenbasierten Ansatzes wie im vorherigen Abschnitt 4.2.1 beschrieben, ergeben sich jedoch weitere Möglichkeiten zur Modellierung der longitudinalen Verteilungsfunktion, die auf vorherige – gespeicherte – Prädiktionsberechnungen aufbauen.

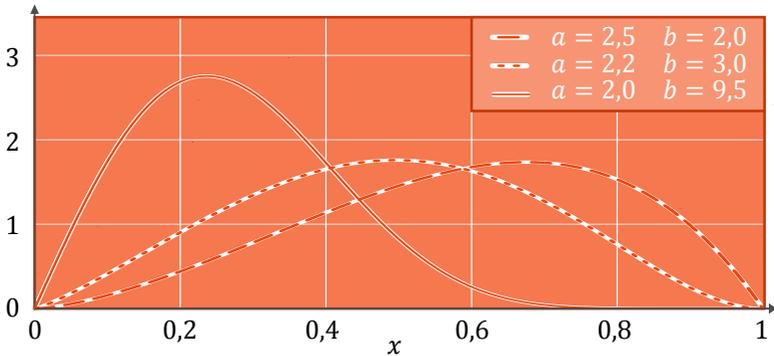


- (a) Zufällig aus Verteilung gezogene zeitliche Positionsverläufe $s_i(t)$. (b) Verteilung zu den Prädiktionszeitpunkten t . (c) Vollständige Verteilung der Aufenthaltswahrscheinlichkeiten.

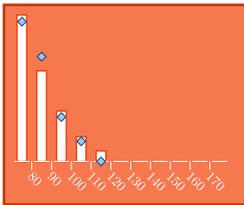
Abbildung 4.24: Schematische Darstellung der per Kumaraswamyverteilung approximierten longitudinalen Aufenthaltswahrscheinlichkeitsverteilung des Verkehrsteilnehmers C zur Berechnung der Belegungswahrscheinlichkeiten.

So kann über eine *Diffusion* der Aufenthaltswahrscheinlichkeiten des vorherigen Prädiktionszeitschritts des Verkehrsteilnehmers C die longitudinale Verteilungsfunktion $p_c(\mathcal{E}_s^{\text{Bel}}|t)$ über den Prädiktionszeitraum T_p schrittweise approximativ berechnet werden. An die Diffusion im Bereich der Bildauswertung anlehnend, beschreibt die Diffusion dabei eine Faltung der Belegungswahrscheinlichkeiten einzelner Zellen mit einem geeigneten *Faltungskern* [22], der eine Zustandsübergangverteilung basierend auf Modellen beschreibt, die aus detaillierten Verkehrsstatistiken gelernt werden können.

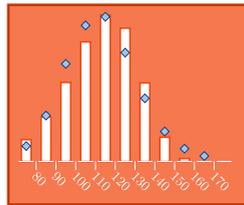
Der wesentliche Vorteil der Diffusion ergibt sich dabei durch die simple Anpassbarkeit des Faltungskerns zu einzelnen Prädiktionszeitpunkten t . Im Gegensatz dazu ist eine Parameteranpassung der Kumaraswamyverteilung lediglich zu Beginn eines Prädiktionsprozesses konsistent möglich. Daraus ergibt sich die Möglichkeit, Interaktionen von Verkehrsteilnehmern einfach über eine Faltungskernanpassung in einem beliebigen Prädiktionszeitschritt t zu inkorporieren. Eine Verkopplung des Diffusionsprozesses mit dem schrittweisen Aufbau des HMM zur Trajektorienplanung ermöglicht weiterhin die Modellierung von Reaktionen auf das eigene Planungsverhalten, das in Abschnitt 6.4 als PTRRA-Modell vorgestellt wird.



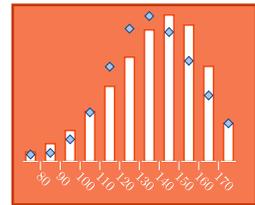
(a) Drei exemplarische Kumaraswamyverteilungen.



(b) $\mathcal{E}(v) = 50 \text{ km/h}$
 $a = 1,7786,$
 $b = 10,577.$



(c) $\mathcal{E}(v) = 110 \text{ km/h}$
 $a = 7,14961,$
 $b = 26,8159.$



(d) $\mathcal{E}(v) = 135 \text{ km/h}$
 $a = 6,23956,$
 $b = 4,35134.$

Abbildung 4.25: Mit Kumaraswamyverteilung approximierte Geschwindigkeitsmassenverteilung. Abbildung (a) zeigt drei Kumaraswamyverteilungen mit unterschiedlichen Parametern. In (b)–(d) werden reale Geschwindigkeitsmassenverteilungen p_v (Balken) über km/h aus [95] mit unterschiedlich parametrisierten Kumaraswamyverteilungen (blaue Raute) über die Fehlerquadratmethode approximiert. Angegeben sind die mittlere Geschwindigkeit, die auf den Geschwindigkeitserwartungswert $\mathcal{E}(v)$ abgebildet wird sowie die Formparameter der Kumaraswamyverteilung a und b .

Pfadabhängige räumliche Verteilungsfunktion Die erhaltene longitudinale Verteilungsfunktion beschreibt Belegungswahrscheinlichkeiten der Zellen entlang eines straßenverlaufsunabhängigen virtuellen Pfads $\bar{\xi}_{\text{virt}}(s)$, sodass die Aufenthaltswahrscheinlichkeiten des Fahrzeugs C im Weiteren auf die konkreten Straßenverläufe $\bar{\xi}_i(s)$ aller $i \in [1, p] \subseteq \mathbb{N}$ Möglichkeiten projiziert werden, unter Berücksichtigung der Fahrzeugausdehnung sowie etwaiger Sensorunsicherheiten gemäß Gl. (4.22). Daraus ergeben sich die p pfadabhängigen räumlichen Verteilungen $p_C(\mathcal{E}_{x^w}^{\text{Bel}} | \bar{\xi}_i, t)$ aller i möglichen Pfade $\bar{\xi}_i(s)$.

Vollständige räumliche Verteilungsfunktion In einem letzten Schritt werden die pfadabhängigen Verteilungsfunktionen mit der diskreten *Pfad-Wahrscheinlichkeitsfunktion* $p_p(\bar{\xi}_i)$ gewichtet, die entsprechende *Befahrungswahrscheinlichkeiten* der einzelnen Pfade $i \in \{1, 2, \dots, p\}$ beschreibt. Die Befahrungswahrscheinlichkeiten lassen sich bestimmen aus:

- Navigationskarten durch eine Einschätzung der Relevanz anhand des entsprechenden Straßentyps
- Statistische Informationen durch Zählungen an Kreuzungen
- Wahrgenommene Handlungsindikatoren des Verkehrsteilnehmers, wie beispielsweise
 - Blinker
 - Spurzugehörigkeit
 - Dynamisches Verhalten (beispielsweise eine Entschleunigung in Vorbereitung einer Ausfahrt)

Die vollständige räumliche Verteilungsfunktion des Fahrzeugs C ergibt sich für die möglichen paarweise verschiedenen Pfade nach Gl. (2.41), beispielhaft dargestellt in Abbildung 4.26, gemäß der vollständigen Wahrscheinlichkeit Gl. (2.45) zu

$$p_C(\mathcal{E}_{x^w}^{\text{Bel}} | t) = \sum_{i=1}^p p_C(\mathcal{E}_{x^w}^{\text{Bel}} | \bar{\xi}_i, t) \cdot p_p(\bar{\xi}_i). \quad (4.35)$$



Abbildung 4.26: Beispiel paarweise verschiedene Pfade ξ_1 bis ξ_4 , entnommen aus [195].

Eine entsprechende Berechnung für alle Verkehrsteilnehmer und Objekte führt zu einer vollständigen Beschreibung der prädizierten Situationen \mathcal{S}_t zu den Zeitpunkten $t \in T_p$. Die Primary-Outer-Penalty ergeben sich dann gemäß Gl. (4.23) erweitert auf den Prädiktionszeitraum $t \in T_p$ mit entsprechenden Kosten K_C , die unter Berücksichtigung der ethischen Implikationen geeignet modelliert werden müssen und daher außerhalb des Fokus dieser Arbeit liegen.

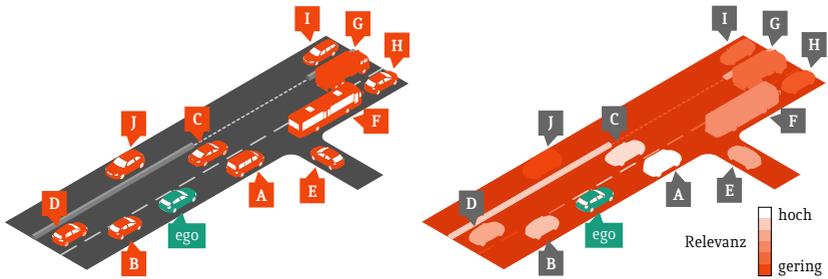
Relevanzgrenzen in der Situationsgeometrie

Neben der in diesem Abschnitt hergeleiteten generellen Möglichkeit der Modellierung anderer Verkehrsteilnehmer und der Prädiktion ihrer Handlungen in die Zukunft stellt sich weiterführend die Frage nach der Relevanzgrenze der Umfeldmodellierung. Dabei ergibt sich die Notwendigkeit der Betrachtung eines konkreten Verkehrsteilnehmers C innerhalb der Umgebungsmodellierung aus seiner Relevanz für die Handlungen des Ego-Fahrzeugs und ist damit abhängig von einer Vielzahl an Parametern, wie beispielsweise der Qualität des zugrundeliegenden Prädiktionsmodells, der Wunschgeschwindigkeit des Ego-Fahrzeugs und dessen physikalischen Eigenschaften, der Sensorgenauigkeiten und -einbaupositionen, den Informationen über Verkehrsdichten, den Updateraten von Sensoren und Trajektorienplanung, sowie deren Prädiktionshorizont, aber auch abhängig von der konkreten Bewertungsfunktion und den darin enthaltenen Sicherheitszielen, dem konkreten Manöver des Ego-Fahrzeugs und nicht zuletzt von den betrachteten Anwendungsfällen. Aufgrund des dieser Arbeit zugrundeliegenden Anspruchs der Entwicklung eines universellen und generischen Konzepts für das gesamte Anwendungsspektrum des vollautomatischen Fahrens ist aufgrund der bestehenden offenen Forschungsfragen keine

abschließende Beantwortung der Relevanzgrenze für die Modellierung der Situationsgeometrie möglich. Die zur Beantwortung dieser Fragestellung erforderlichen Überlegungen sollen – auch um deren Komplexität anzudeuten – im Folgenden anhand einer beispielhaften Situation verdeutlicht werden.

Abbildung 4.27 zeigt eine beispielhafte Situationsgeometrie mit zwei Ego-Fahrstreifen, einer einmündenden Straße von rechts und einem zu Teilen durch eine Barriere abgetrennten Gegenfahrstreifen. Die initiale Situation beinhaltet die Verkehrsteilnehmer A–J, die für das Ego-Fahrzeug in Grün unterschiedliche Relevanz aufweisen, die in Abbildung 4.27b farblich dargestellt ist. Die Fahrzeuge A–D haben dabei eine hohe Relevanz zum dargestellten Zeitpunkt, da eine Kollision mit diesen Verkehrsteilnehmern zum nächsten Zeitschritt physisch möglich ist. Weiterhin besitzen die Fahrzeuge F und G eine Relevanz für das Ego-Fahrzeug, indem sie die mit hoher Relevanz eingestufteten Verkehrsteilnehmer A und C mit ihren Handlungen potentiell beeinflussen. In Abhängigkeit des Detaillierungsgrads des Verhaltensmodells als auch des verwendeten bayessches Netzes zur Modellierung der Beeinflussung kann dem Verkehrsteilnehmer H auch eine geringe Relevanz für das Ego-Fahrzeug über die dazwischenliegenden Verkehrsteilnehmer F, C und A ähnlich zu Abbildung 4.23 zugewiesen werden. Die Fahrzeuge E und I sind zum aktuellen Zeitpunkt nur bedingt relevant, wobei eine Kollision mit beiden Fahrzeugen zu späteren Zeitpunkten möglich ist und damit gegeben eines entsprechenden Prädiktionsmodells Kollisionswahrscheinlichkeiten zu späteren Prädiktionszeitpunkten einfließen können.

Die Relevanz von I und J hängt in der dargestellten Situation maßgeblich von dem geplanten Manöver des Ego-Fahrzeugs und dem für die konkrete Ausprägung des Systems gewählten Prädiktionshorizont ab. Für ein Linksabbiegemanöver beziehungsweise einer Kehrtwende auf den Gegenfahrstreifen und einer geeignet langen Prädiktionszeit erhalten diese beiden Verkehrsteilnehmer zu späteren Prädiktionszeitpunkten eine signifikante Relevanz durch resultierende Kollisionsmöglichkeiten mit dem Ego-Fahrzeug. Zudem ergibt sich bei solch einem Manöver für das Fahrzeug D eine höhere Relevanz durch den dafür notwendigen Fahrstreifenwechsel im Gegensatz zu einem Geradeausmanöver des Ego-Fahrzeugs.



(a) Schematische Darstellung der beispielhaften Situationsgeometrie. (b) Qualitativ farbig dargestellte Relevanz der Situationsgeometrie aus (a).

Abbildung 4.27: Relevanzgrenze der Umgebungsmodellierung anhand einer beispielhaften Situationsgeometrie. Die Situation besteht aus den Verkehrsteilnehmern A–J, die in (b) entsprechend ihrer Relevanz hinsichtlich der Umgebungsmodellierung des Ego-Fahrzeugs qualitativ eingefärbt sind.

Das Beispiel verdeutlicht die hinter der Beantwortung der Relevanzgrenze notwendigen Kenntnisse und Annahmen über das Gesamtsystem. Dabei gilt die Feststellung, dass das in der Arbeit beschriebene generische Gesamtkonzept nicht erst durch die Bereitstellung aller dieser Informationen funktionsfähig wird. Vielmehr ermöglicht eine sinnvolle konsistente probabilistische Modellierung eine korrekte Funktionalität des Gesamtsystems auf Basis eines beliebig geringen Informationsumfangs, da allgemeine Wahrscheinlichkeitsverteilungen zur Substitution fehlender Informationen herangezogen werden können.

So ist bei geringen Geschwindigkeiten – beispielsweise in einer Parkgarage – als Extremauslegung des Systems denkbar, dass keine Informationen außerhalb eines sehr geringen Radius um das Ego-Fahrzeug über die Ultraschallsensoren zur Verfügung stehen. Unter der Annahme eines Penalty-Funktionalis mit stark gewichteten Sicherheitszielen und durch die Generierung von Belegungswahrscheinlichkeiten der Zellen außerhalb des Sensorabdeckungsbereichs gemäß allgemeiner Wahrscheinlichkeitsverteilungen für unbeobachtbare Bereiche wird der Trajektorienplanungsalgorithmus in diesem Fall mit einer entsprechend geringen Geschwindigkeit planen, die eine Vermeidung einer Kollision bei Auftauchen eines Hindernisses am Rand des Sensorabdeckungsbereichs sicherstellt.

Aber auch für die Systemauslegung zur Anwendung auf komplexere Situationen und höhere Geschwindigkeiten ist keine vollständige Informationsbasis notwendig. In Abbildung 4.27 ist beispielsweise bei einer Verdeckung des Verkehrsteilnehmers E durch ein Eckhaus eine Modellierung wiederum über allgemeine Wahrscheinlichkeitsverteilungen unbeobachtbarer Bereiche möglich, oder aber über zur Verfügung stehender statistischer Informationen des Kreuzungsbereichs. So kann auch bei Fehlen der Information über die Existenz von H innerhalb des bayesschen Netzes eine allgemeine Wahrscheinlichkeit für einen Vordermann von F – gegebenenfalls aufgrund vorhandener Verkehrsdichteinformationen – verwendet werden.

Die Beispiele zeigen, dass für eine ideale Serien-Ausprägung des Konzepts zwar alle oben genannten Parameter relevant beziehungsweise wünschenswert sein können, dies jedoch keine Einschränkung der Anwendbarkeit des Verfahrens darstellt, sofern die Modellierung von Unsicherheiten konsistent ist, da innerhalb des Gesamtsystems eine entsprechende Anpassung auf die begrenzte Informationsbasis bei einem geeignet modellierten Penalty-Funktional aus Abschnitt 3.1 geschieht.

4.3 Von der Geometrie zur Trajektorienplanung – Situation Prediction & Reaction Control

Durch die Modellierung der Trajektorieneigenschaften mit Hilfe des C^2 -Modells aus Abschnitt 4.1 und der Beschreibung der initialen und prädizierten Situationen in Abschnitt 4.2 kann eine Trajektorie des Ego-Fahrzeugs über die Penalty-Lagrangefunktion aus Gl. (3.1) in Hinblick auf die unterschiedlichen (oftmals konkurrierenden) Optimierungsziele – beispielsweise Sicherheit, Komfort, Ökologie – bewertet werden. Der sich daraus ergebene Gesamtprozess wird als \hookrightarrow Situation Prediction and Reaction Control (SPARC) bezeichnet und besteht aus der Berechnung der Situationsgeometrie – Situation Prediction – und der daran anschließenden Trajektorienplanung – Reaction Control.

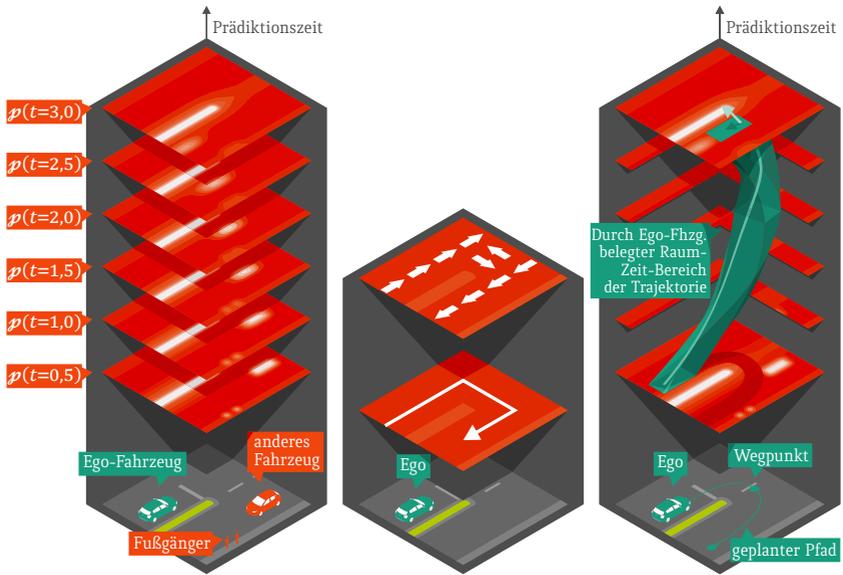


Abbildung 4.28: Das SPARC-Konzept. Links: Das Pre-Penalty-Volumen. Mitte: Navigationsanweisungen und Verkehrsregeln. Rechts: Trajektorie des Ego-Fahrzeugs inklusive Ego-Fahrzeug-Ausdehnung.

Situation Prediction (SP) – Das Pre-Penalty-Volumen

Sowohl die initiale als auch die prädizierten Situationen können als zellenbasierte, räumliche 2D-Darstellung aller für die Penaltyberechnung notwendigen Informationen verstanden werden. Die »Stapelung« aller Situationen entlang der Prädiktionszeit $t \in [t_{\text{start}}, t_{\text{end}}]$ ergibt dabei ein 3D-Raum-Zeit-Volumen – das \hookrightarrow Pre-Penalty-Volumen \mathcal{p} – dessen einzelne *Prädiktionsebenen* hochdimensionale Zelleneinträge beinhalten und alle Informationen über den Ort \mathbf{x}^W zum prädizierten Zeitpunkt t bündeln. Da es sich bei den Zelleneinträgen nicht um konkrete Penaltywerte handelt, sondern vielmehr um die zur Berechnung der Penalties notwendigen Parameter, wird zur Verdeutlichung der Bezeichner »Pre-« verwendet. In Abbildung 4.28 sind die einzelnen Prädiktionsebenen einer Beispielsituation dargestellt.

Reaction Control (RC) – Die Trajektorienplanung und Regelung

Zusammen mit Navigationsanweisungen kann im Weiteren eine Trajektorie über die in Kapitel 3 beschriebenen Methoden durch die einzelnen Prädiktions-ebenen des Pre-Penalty-Volumens geplant werden. Anschließend an die erfolgte Trajektorienplanung werden über das C^2 -Modell aus Abschnitt 4.1 die nächsten Stellgrößen zur Regelung des Ego-Fahrzeugs berechnet und an die Aktuatorik übertragen. Die Trajektorie inklusive der Ego-Fahrzeug-Ausdehnung ist in Abbildung 4.28 als grüner Schlauch durch das Pre-Penalty-Volumen dargestellt.

SPARC – Der zyklische Gesamtprozess

Die zyklische Wiederholung der SP- und RC-Bestandteile resultiert in einem Gesamtprozess, der die Aufgaben Situationsinterpretation und -prädiktion sowie Entscheidungs- und Bewegungsplanung miteinander vereint. Aufgrund fehlender Sensordaten und Spezifikationen des Projektpartners ist eine abschließende Evaluation sowohl geeigneter Prädiktionszeiträume als auch Neuplanungsraten sowie eine abschließende Evaluation des Gesamtsystems im realen Versuchsträger nicht möglich. Entsprechende Literatur [48, 71, 85, 168], sowie Analysen von Situationen, Sensor- und Regelgüten lassen jedoch auf

- einen Prädiktionszeitraum von 5 bis 10 Sekunden mit
- einer Auflösung der diskreten Prädiktionsebenen von 0,5 Sekunden
- und einer Neuplanungsrate von 3 – 10 Hz

als sinnvolle Parameter für eine Systemauslegung schließen.

Die zyklische Wiederholung des Prozesses von SP- und RC-Bestandteilen führt zu einer Regelung des Ego-Fahrzeugs, deren Regelabweichung durch die Generierung einer neuen Trajektorie mit aktualisierter Startposition $\xi(t_{\text{start}})$ korrigiert wird. Durch die zyklische Neuberechnung der Situationsgeometrie werden aktuelle Sensorinformationen in den Prozess mit einbezogen, sodass Sensor- oder Prädiktionsfehler innerhalb eines Zyklus korrigiert werden können.

Vereinfachende Modellannahmen des SPARC-Konzepts

Eine vollständige Problembeschreibung beinhaltet einerseits eine umfassende Modellierung des Ego-Fahrzeugs sowie des Verkehrsgeschehens unter Berücksichtigung aller Abhängigkeiten und andererseits die Berücksichtigung der Rückwirkungen, die sich durch die Ego-Fahrzeug-Trajektorie auf den Verkehr ergeben. Zur Reduktion dieser Komplexität werden einige Vereinfachungen explizit und implizit vorgenommen, die im Hinblick auf die Ego-Fahrzeug-Geometrie in Abschnitt 4.1 diskutiert und evaluiert werden.

Für die Situationsgeometrie eines SPARC-Prozesszyklus – und damit die Generierung eines Pre-Penalty-Volumens zum Zeitpunkt t_{real} – ergeben sich neben vereinfachenden Modellierungen von Sensorik, Aktuatorik und Verhaltensmodellen anderer Verkehrsteilnehmer weiterhin Vereinfachungen in der Modellierung der Belegungswahrscheinlichkeiten und der darauf aufbauenden Trajektorienplanung. Im Weiteren wird zur Verdeutlichung von einer initialen Situation $\mathcal{S}_{\text{start}}$ mit einem Verkehrsteilnehmer C und einer das Ego-Fahrzeug behindernden Mauer O ausgegangen, sowie von einer Penalty-Lagrangefunktion \mathcal{p}_L aus Abschnitt 3.1, die ausschließlich Kollisionsrisiken bewertet.

Der Gesamtprozess SPARC betrachtet den Schadenserwartungswert $\mathcal{E}(\xi(t))$ der Trajektorie, die innerhalb des Prädiktionszeitraums $t \in T_p$ aus Gl. (4.26) die Positionen $\mathbf{x}^W = [x, y]^T \in X^W \times Y^W$ aus Gl. (2.1) passiert. Es gilt

$$\mathcal{E}(\xi) = \sum_{x,y,t} K^{\text{Koll}} \cdot \mathcal{p}(\mathcal{E}_{(x,y,t)}^{\text{Koll}} | \xi, \mathcal{S}_{\text{start}}). \quad (4.36)$$

Die Wahrscheinlichkeit einer Kollision hängt von der geplanten Trajektorie ξ und der initialen Situation $\mathcal{S}_{\text{start}}$ ab, da sich jede prädierte Situation $\mathcal{S}_t \forall t \in T_p$ aus der initialen Situation ergibt, gegeben bekannter Prädiktionsmodelle. Die Wahrscheinlichkeit des Kollisionsereignisses $\mathcal{E}_{(x,y,t)}^{\text{Koll}}$ wird unter Annahme stochastischer Unabhängigkeit nach Gl. (2.46) einerseits beschrieben durch die Wahrscheinlichkeit des Ereignisses $\mathcal{E}_{(x,y,t)}^{\xi_C}$, dass sich der Verkehrsteilnehmer C mit Trajektorie ξ_C an Ort \mathbf{x}^W zum Zeitpunkt t befindet und andererseits der Wahrscheinlichkeit des Ereignisses $\mathcal{E}_{(x,y,t)}^{\xi_{\text{real}}}$, dass sich das Ego-Fahrzeug zum selben Zeitpunkt t am selben Ort \mathbf{x}^W befindet – wobei hier die Unterscheidung

zwischen der *geplanten* Trajektorie ξ und der bei Einwirken entsprechender zu ξ gehöriger Stellbefehle *umgesetzten* Trajektorie ξ_{real} getroffen werden muss. Es gilt für die Kollisionswahrscheinlichkeit

$$p\left(\mathcal{E}_{(x,y,t)}^{\text{Koll}} \mid \xi, \mathcal{S}_{\text{start}}\right) = p\left(\mathcal{E}_{(x,y,t)}^{\xi_{\text{C}}} \mid \xi, \mathcal{S}_{\text{start}}\right) \cdot p\left(\mathcal{E}_{(x,y,t)}^{\xi_{\text{real}}} \mid \xi, \mathcal{S}_{\text{start}}\right). \quad (4.37)$$

Neben der stochastisch unabhängigen Wahl der Position aus Gl. (4.37) wird zur weiteren Komplexitätsreduktion vereinfachend angenommen, dass die zu bewertende Trajektorie ξ wie geplant abgefahren wird und nicht von der initialen Situation $\mathcal{S}_{\text{start}}$ abhängt. Zur Verdeutlichung ist in Abbildung 4.29 der Verkehrsteilnehmer C, die Mauer O und die geplante Trajektorie ξ dargestellt. In der Bewertung der Trajektorie über die Penalty-Lagrangefunktion \mathcal{p}_L ergeben sich Penaltys sowohl für eine Kollision mit O als auch mit C – wie dargestellt in Abbildung 4.29b – wobei unbeachtet bleibt, dass die erste Kollision mit der Mauer das Ego-Fahrzeug zum Stillstand bringen und damit die zweite Kollision mit dem Verkehrsteilnehmer unwahrscheinlich werden lässt. Die Bewertung der Trajektorie findet somit – gemäß der Modellierung über die Euler-Lagrange-Gleichung – für jeden Zeitpunkt unabhängig von anderen Zeitpunkten statt, bezieht also keine Auswirkungen von früheren Ereignissen entlang der Trajektorie auf spätere ein. Eine dahingehende Erweiterung findet sich in Abschnitt 6.4.

Daraus ergibt sich für die Aufenthaltswahrscheinlichkeit des Ego-Fahrzeugs für einen SPARC-Prozesszyklus unter der Annahme gegebener initialer Situation $\mathcal{S}_{\text{start}}$ vereinfachend die Aufenthaltswahrscheinlichkeit des Ego-Fahrzeugs um \mathbf{x}^W als

$$p\left(\mathcal{E}_{(x,y,t)}^{\xi_{\text{real}}} \mid \xi, \mathcal{S}_{\text{start}}\right) = p\left(\mathcal{E}_{(x,y,t)}^{\xi_{\text{real}}} \mid \xi\right) = \begin{cases} 1 & \text{wenn } \xi(t) = \mathbf{x}^W \\ 0 & \text{sonst.} \end{cases} \quad (4.38)$$

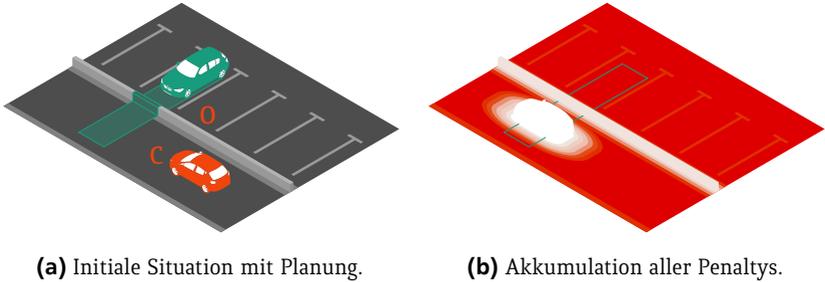


Abbildung 4.29: *Modellvereinfachungen des SPARC-Konzepts.* (a) zeigt die Situation und geplante Trajektorie ξ als Ego-Fahrzeug-Ausdehnung (in Grün) zum initialen Zeitpunkt. (b) zeigt die Akkumulation aller Penaltys über die gesamte Planung wie sie zur Bewertung der Trajektorie herangezogen werden, ungeachtet, dass eine Kollision mit dem Verkehrsteilnehmer C durch die Mauer O (in dieser Form) nicht möglich ist.

Weiterhin werden Interaktionen mit dem Ego-Fahrzeug⁸ innerhalb des originären SPARC-Konzepts vernachlässigt, sodass die Aufenthaltswahrscheinlichkeiten des Verkehrsteilnehmers C unabhängig von der Trajektorie des Ego-Fahrzeugs ξ behandelt werden. Es gilt

$$\begin{aligned} p\left(\mathcal{E}_{(x,y,t)}^{\xi_C} \mid \xi, \mathcal{S}_{\text{start}}\right) &= p\left(\mathcal{E}_{(x,y,t)}^{\xi_C} \mid \mathcal{S}_{\text{start}}\right) \\ &= p_C\left(\mathcal{E}_{x^w}^{\text{Bel}} \mid t\right). \end{aligned} \quad (4.39)$$

Dabei wird wiederum angelehnt an Gl. (4.38) die initiale Situation $\mathcal{S}_{\text{start}}$ für einen Prozesszyklus als gegeben angenommen, sodass sich die in Abschnitt 4.2.1 hergeleiteten Aufenthaltswahrscheinlichkeiten des Verkehrsteilnehmers C aus Gl. (4.35) ergeben.

⁸ Interaktionen von Verkehrsteilnehmern untereinander können über bayessche Netze wie beschrieben in Abschnitt 4.2.2 innerhalb der Prädiktion modelliert werden. Die explizite Berücksichtigung der Interaktion mit dem Ego-Fahrzeug findet sich in Abschnitt 6.4.

Mit den Vereinfachungen aus den Gleichungen (4.37) bis (4.39) ergibt sich die Wahrscheinlichkeit des Kollisionsereignisses $\mathcal{E}_{(x,y,t)}^{\text{Koll}}$ aus Gl. (4.36) schließlich zu

$$p\left(\mathcal{E}_{(x,y,t)}^{\text{Koll}} \mid \xi, \mathcal{S}_{\text{start}}\right) = \begin{cases} p_C\left(\mathcal{E}_{\mathbf{x}^W}^{\text{Bel}} \mid t\right) & \text{wenn } \xi(t) = \mathbf{x}^W \\ 0 & \text{sonst.} \end{cases} \quad (4.40)$$

Aus den Einschränkungen ergibt sich ein defensiver Trajektorienplanungsalgorithmus, der keine Interaktion mit anderen Verkehrsteilnehmern antizipiert und kein »Entgegenkommen« anderer Verkehrsteilnehmer erwartet. Durch die zyklische Neuplanung fließen jedoch indirekt Interaktionen über die Veränderung der Situation ein, die innerhalb der Trajektorienplanung des Ego-Fahrzeugs betrachtet wird. Eine Erweiterung des Trajektorienplanungsraums um Reaktionen anderer Verkehrsteilnehmer auf Handlungen des Ego-Fahrzeugs wird in Abschnitt 6.4 als \hookrightarrow PITRA-Konzept vorgestellt. Durch die Erweiterung auf Interaktion sind jedoch Reduktionen des Planungsraums notwendig, sodass die Eigenschaft der global optimalen Lösung des HMM-Algorithmus aus Abschnitt 3.3 nicht mehr gegeben ist.

5

Topologie des Trajektorienraums

Im folgenden Kapitel werden die topologischen Eigenschaften des in Kapitel 4.2 aus der Geometrie hergeleiteten Trajektorienraums Ξ untersucht, die sich daraus ergebenden Anforderungen an Trajektorienplanungsalgorithmen analysiert und mit den Eigenschaften der in Kapitel 3 vorgestellten Planungsmethoden abgeglichen. Als Motivation der topologischen Betrachtungen des Trajektorienraums wird in Abbildung 5.1 eine einfache Verengungssituation dargestellt, bei der bereits zwei Optima auftreten:

- 1 Das Ego-Fahrzeug wartet, bis das entgegenkommende Fahrzeug die Engstelle passiert hat.
- 2 Das Ego-Fahrzeug passiert die Engstelle noch bevor das entgegenkommende Fahrzeug die Engstelle erreicht hat.

In Abhängigkeit der konkreten Ausprägung der Situation – also entsprechend der konkreten Geometrie der Situation – ergibt sich das globale Optimum als eines der beiden lokalen.

Die Topologieanalyse dieses Kapitels betrachtet die übergeordneten Eigenschaften der Problemmodellierung unter Vernachlässigung konkreter geometrischer Betrachtungen, um generelle Aussagen über Verkehrsgeschehen und die eingehenden Anforderungen an Trajektorienplanungsalgorithmen für vollautomatische Fahrzeuge zu erhalten. Hierfür wird zunächst in Abschnitt 5.2 eine Analyse anhand synthetisierter Pre-Penalty-Volumen durchgeführt, um in Ab-

schnitt 5.3 die allgemeinen Ergebnisse mit beispielhaften realen Situationen zu bestätigen.

Zu Darstellungszwecken und einer intuitiven Interpretation der Ergebnisse wird in den folgenden Abschnitten eine st -Planung aus Abschnitt 3.5.1 gewählt und auf [S15] für eine Anwendung des SPARC-Konzepts auf eine xyt -Planung verwiesen. Die gewonnenen Erkenntnisse der st -Planung sind auf eine xyt -Planung übertragbar, da durch die Komplexitätserhöhung der zusätzlichen Dimension keine Vereinfachungen, sondern weitere Herausforderungen zu erwarten sind. Implementierungsdetails ergeben sich gemäß Abschnitt 3.5.

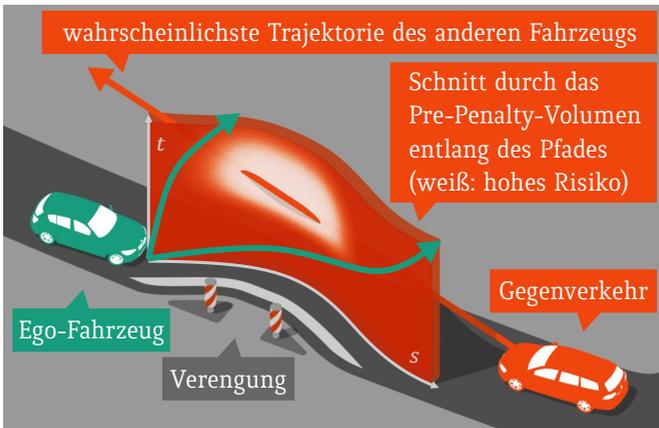


Abbildung 5.1: Beispiel einer einfachen Verkehrssituation mit einer Verengung. Bereits hier existieren zwei lokale Optima in Grün, um diese Situation aufzulösen.

5.1 Notation und Vergleichsmetriken

Zur Evaluation der beiden Trajektorienplanungsverfahren ELM und HMM und zur Analyse der topologischen Eigenschaften der Problemformulierung werden im Folgenden die Notationen und Metriken definiert.

Notationen

Zur Unterscheidung der Start- und Ergebnistrajektorien der unterschiedlichen Optimierungsprozesse ELM und HMM werden folgende Bezeichnungen und Symbole eingeführt:

- $\xi_{\text{ELM}}^{(k)}$ beschreibt die k -te generische Starttrajektorie der iterativen ELM-Optimierung mit $k \in \{1, 2, \dots, K\}$.
- ξ_{ELM}^k beschreibt jene Ergebnistrajektorie, die sich aus der Optimierung der k -ten Starttrajektorie $\xi_{\text{ELM}}^{(k)}$ ergibt.
- $\xi_{\text{ELM}}^{(k)} \rightsquigarrow \xi_{\text{ELM}}^k$ beschreibt den Vorgang der Optimierung der Starttrajektorie $\xi_{\text{ELM}}^{(k)}$ zur Ergebnistrajektorie ξ_{ELM}^k . Der geschwungene Pfeil wurde zur Verdeutlichung der iterativen Eigenschaften des ELM-Algorithmus bewusst ausgewählt.
- ξ_{ELM}^* beschreibt jene Ergebnistrajektorie, die von allen optimierten ELM-Trajektorien zum geringsten Penaltywert \mathcal{P} konvergiert und damit die »optimale« iterative ELM-Lösung darstellt.
- ξ_{HMM} beschreibt jene Ergebnistrajektorie, die sich aus der HMM-Optimierung ergibt und stellt das globale Optimum gegeben der gewählten Diskretisierung des HMM-Zustandsraums Z und des HMM-Zustandsübergangsraums \dot{Z} dar.
- $\xi_{\text{ELM}}^{\text{HMM}}$ beschreibt jene Ergebnistrajektorie aus der iterativen ELM-Optimierung, die sich bei der Verwendung der HMM-trajektorie als Startlösung $\xi_{\text{ELM}}^{(\text{HMM})} = \xi_{\text{HMM}}$ ergibt. Es gilt demnach $\xi_{\text{HMM}} \rightsquigarrow \xi_{\text{ELM}}^{\text{HMM}}$.

Normierung

Zur besseren Vergleichbarkeit unterschiedlicher Evaluationsbeispiele werden folgende Normierungen in Kapitel 5 vorgenommen:

- Die Zeit wird auf $t \in [0, 1]$ normiert.
- Der räumliche Parameter wird auf $s \in [0, 1]$ normiert.
- Der Penaltywert $\mathcal{P}[\xi_{\text{HMM}}]$ der HMM-Ergebnisstrajektorie gilt durch seinen globalen Charakter als Referenzwert und wird daher im Weiteren auf $\mathcal{P}[\xi_{\text{HMM}}] = \mathcal{P}_{\text{HMM}} = 1$ normiert.

Iterative Optimierung

Zur Bewertung der iterativen Optimierung des ELM-Algorithmus werden folgende Metriken verwendet:

- I_{ELM}^* beschreibt die Anzahl an notwendigen Iterationen der Optimierung $\xi_{\text{ELM}}^{(*)} \rightsquigarrow \xi_{\text{ELM}}^*$.
- $I_{\text{ELM}}^{\text{HMM}}$ beschreibt die Anzahl an notwendigen Iterationen der Optimierung $\xi_{\text{HMM}} \rightsquigarrow \xi_{\text{ELM}}^{\text{HMM}}$.
- I_{ELM}^{\min} und I_{ELM}^{\max} beschreiben die minimale und maximale Anzahl an Iterationen der Optimierungen $\xi_{\text{ELM}}^{(k)} \rightsquigarrow \xi_{\text{ELM}}^k$ über alle k Optimierungsvorgänge.
- $I_{\text{ELM}}^{\text{mean}}$ und $I_{\text{ELM}}^{\text{med}}$ beschreiben arithmetisches Mittel und Median der Anzahl an Iterationen der Optimierungen $\xi_{\text{ELM}}^{(k)} \rightsquigarrow \xi_{\text{ELM}}^k$ über alle k Optimierungsvorgänge.

Penaltywerte

Zur Bewertung der Güte einer Trajektorie werden die folgenden Penalty-Metriken eingeführt (normiert auf den Penaltywert der HMM-Lösung $\mathcal{P}[\xi_{\text{HMM}}] = 1$):

- $\mathcal{P}_{\text{ELM}}^k = \mathcal{P}[\xi_{\text{ELM}}^k]$ beschreibt jenen Penaltywert, zu dem die k -te Starttrajektorie $\xi_{\text{ELM}}^{(k)}$ konvergiert.
- $\mathcal{P}_{\text{ELM}}^{\text{HMM}} = \mathcal{P}[\xi_{\text{ELM}}^{\text{HMM}}]$ beschreibt den Penaltywert von $\xi_{\text{ELM}}^{\text{HMM}}$.
- $\mathcal{P}_{\text{ELM}}^{\min}$ und $\mathcal{P}_{\text{ELM}}^{\max}$ beschreiben den minimalen und maximalen Penaltywert von $\mathcal{P}_{\text{ELM}}^k$ über alle k Optimierungsergebnisse $\xi_{\text{ELM}}^{(k)} \rightsquigarrow \xi_{\text{ELM}}^k$.
- $\mathcal{P}_{\text{ELM}}^{\text{mean}}$, $\mathcal{P}_{\text{ELM}}^{\text{med}}$ und $\mathcal{P}_{\text{ELM}}^{\sigma}$ beschreiben das arithmetische Mittel, den Median und die Standardabweichung der Penaltywerte-Verteilung aller k Optimierungsergebnisse $\xi_{\text{ELM}}^{(k)} \rightsquigarrow \xi_{\text{ELM}}^k$ und geben Aufschluss über die Wahrscheinlichkeit, bestimmte Penaltywerte zu erhalten, indem zufällig Starttrajektorien ausprobiert beziehungsweise gezogen werden.
- $\mathfrak{p}_{n\%}^{\mathcal{P}} = \mathfrak{p}(\mathcal{P}_{\text{ELM}} \geq (1 + n/100) \cdot \mathcal{P}_{\text{HMM}})$ beschreibt die Wahrscheinlichkeit des iterativen ELM-Algorithmus über die Penaltywerte-Verteilung einen n -prozentig schlechteren Penaltywert als jenen der HMM-Lösung zu erhalten. Es werden $\mathfrak{p}_{0\%}^{\mathcal{P}}$, $\mathfrak{p}_{10\%}^{\mathcal{P}}$, $\mathfrak{p}_{30\%}^{\mathcal{P}}$, $\mathfrak{p}_{50\%}^{\mathcal{P}}$ und $\mathfrak{p}_{100\%}^{\mathcal{P}}$ betrachtet.

Vorhersagbarkeit der iterativen Lösungen

Zur Bewertung der Vorhersagbarkeit des entsprechenden Optimierungsprozesses $\xi_{\text{ELM}}^{(k)} \rightsquigarrow \xi_{\text{ELM}}^k$ werden folgende Sprung-Metriken definiert:

- $J_{\text{ELM}}^{\mathcal{P}}$ ist ein Maß für Sprünge in den Penaltywerten aufeinanderfolgender Optimierungsvorgänge ($k - 1$) und k . Die Metrik $J_{\text{ELM}}^{\mathcal{P}}$ berechnet sich aus

$$J_{\text{ELM}}^{\mathcal{P}} = \sum_{k=2}^K |\mathcal{P}_{\text{ELM}}^k - \mathcal{P}_{\text{ELM}}^{k-1}|$$

und ist ein Maß für die Komplexität und Verteilung lokaler Optima. Da aufsteigende Indizes k quasi-stetige Änderungen der Startlösungen $\xi_{\text{ELM}}^{(k)}$ gemäß Gl. (3.19) beschreiben, lässt eine Betrachtung entlang k Rückschlüsse auf die Unstetigkeit des Optimierungsproblems zu. Somit weist eine hohe Anzahl an Sprüngen aufeinanderfolgender Starttrajektorien (während aufeinanderfolgender Indizes k) auf eine Vielzahl an lokalen Optima hin, in denen ein iterativer Optimierer terminiert.

- $J_{\text{ELM}}^{\text{end}}$ stellt ein Maß der Vorhersagbarkeit einer Ergebnistrajektorie ξ_{ELM}^k anhand seiner Starttrajektorie $\xi_{\text{ELM}}^{(k)}$ dar. Hierfür wird die Summe der Distanzen aller Sprünge der Endpunkte aufeinanderfolgender Trajektorien $\xi_{\text{ELM}}^k(t_{\text{end}})$ und $\xi_{\text{ELM}}^{k-1}(t_{\text{end}})$ betrachtet und auf die gesamte Ausdehnung der erhaltenen Endpunkte aller k Optimierungsvorgänge normiert, mittels

$$J_{\text{ELM}}^{\text{end}} = \frac{\sum_{k=2}^K \|\xi_{\text{ELM}}^k(t_{\text{end}}) - \xi_{\text{ELM}}^{k-1}(t_{\text{end}})\|}{\max_{m,n \in \{1, \dots, K\}} \|\xi_{\text{ELM}}^m(t_{\text{end}}) - \xi_{\text{ELM}}^n(t_{\text{end}})\|}.$$

Da die meisten lokalen Optima in den Endpunkten variieren, bedeutet ein Endpunktsprung die Existenz eines weiteren Optimums. Da die Starttrajektorien kontinuierlich über den Trajektorienraum verteilt sind, wäre zu erwarten, dass die Summe aller Endpunktdistanzen gleich jener Distanz der beiden zueinander entferntesten Endpunkte entspricht. $J_{\text{ELM}}^{\text{end}} = 1$ bedeutete demnach, dass die iterativen Lösungen entsprechend der Lage ihrer Starttrajektorien variieren und sich »mit der Fächerbewegung« mitbewegen. Je höher $J_{\text{ELM}}^{\text{end}}$ ist, umso mehr springen aufeinanderfolgende Ergebnistrajektorien zwischen unterschiedlichen lokalen Optima hin und her und ergeben sich unabhängig von der Lage der aufeinanderfolgenden Starttrajektorien.

5.2 Betrachtung anhand synthetisierter Trajektorienräume

5.2.1 Generierung synthetisierter Rauschfelder

Zur Analyse allgemeiner Topologieeigenschaften, die unabhängig von konkreten Verkehrssituationen oder Prädiktionsverfahren sind, werden synthetisierte Pre-Penalty-Volumen für eine *st*-Planung mit geeignetem Rauschverhalten generiert. Da Verkehrssituationen in der Regel aus einzelnen, abgegrenzten lokalen Optima bestehen, ist weißes Rauschen für eine allgemeine Analyse weniger geeignet, da sich dort keine intuitiv erkennbaren lokalen Optima ausbilden.

Im Gegensatz dazu besitzt *brownsches Rauschen* durch einen Leistungsdichteabfall mit $1/\omega^2$ im Frequenzbereich entsprechend einen höheren Anteil langwelliger Frequenzanteile und bildet somit große Strukturen aus, die ausgeprägte lokale Optima ergeben [179]. Daneben resultieren hochfrequenten Anteile des brownischen Rauschens in kleinen Details, die die präzise Lage der lokalen Optima beeinflussen und somit eine detaillierte Analyse der Optimierungsmethoden zulassen. Mit ausgeprägten Optima als übergeordnete Einteilung des topologischen Raums in Kombination mit hochfrequenten Eigenschaften zur Beeinflussung kleiner Details kann die Topologie von Verkehrssituationen über brownisches Rauschen nachgebildet und auf allgemeine topologische Eigenschaften – mit Bezug zu Verkehrsgeschehen – hin untersucht werden, ohne sich auf die Analyse einzelner simulierter Beispielverkehrssituationen zu beschränken.

Das im Frequenzraum generierte 2D-Feld von brownischem Rauschen wird in den Ortsraum transformiert und ergibt ein Feld mit lokalen Minima und Maxima wie dargestellt in Abbildung 5.2a. Um die Interpretierbarkeit der Ergebnisse zu unterstützen, werden die Amplituden des 2D-Felds relativ zu einer mittleren Amplitude quadriert, wodurch sich statt punktueller (nulldimensionaler) Minima eindimensionale Täler entlang der entsprechenden Höhenlinien herausbilden. Abbildung 5.2b zeigt das auf einen Penaltywertebereich von $p \in [0, 1]$ normierte Ergebnis in Pixeleinheiten »pxl«.

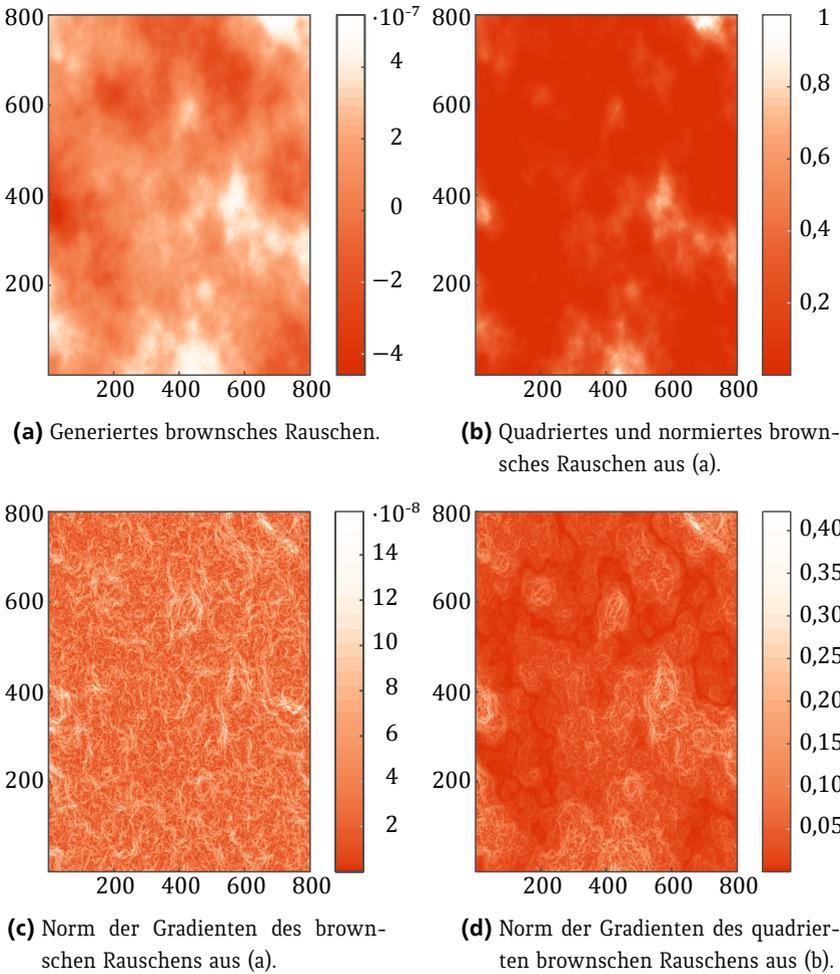


Abbildung 5.2: Generierung synthetisierter Pre-Penalty-Volumen als brownisches Rauschen.

Abbildung (a) zeigt das originale 2D-Feld von generiertem brownischem Rauschen im Ortsraum. Die zugehörige Gradientenverteilung in (c) verdeutlicht das Fehlen zusammenhängender eindimensional ausgedehnter Bereiche mit Gradient gleich Null. Durch eine Quadrierung des brownischen Rauschens (dargestellt in (b)) bilden sich Täler aus, wie in (d) anhand dunkelroter Pfade zu erkennen ist. Die Norm der Gradienten wird mit einer Farbskala angegeben. Achseneinheiten in »pxl«.

Zur Verdeutlichung der Transformation sind in den Abbildungen 5.2c–d die Norm der Gradienten der entsprechenden Rauschbilder aufgetragen. Die dunkelroten Pfade in Abbildung 5.2d zeigen die so entstandenen Täler mit verschwindendem Gradienten.

Im Allgemeinen sind abweichende Rauschfelder zur Generierung synthetisierter Pre-Penalty-Volumen möglich, wie beispielsweise die Verwendung anderer Exponenten α zur Parametrierung des Leistungsdichteabfalls im Frequenzraum über $1/\omega^\alpha$. Aufgrund der zur Hypothese über das Verkehrsgeschehen passenden Eigenschaften des brownischen Rauschens wird im Weiteren $\alpha = 2$ verwendet.

5.2.2 Analyse der synthetisierten Rauschfelder

Um Aussagen über Anforderungen an Trajektorienplanungsverfahren und im Speziellen die Eignung des ELM- und HMM-Algorithmus aus Kapitel 3 zu erhalten, werden synthetisierte Pre-Penalty-Volumen aus dem vorherigen Abschnitt 5.2.1 zur Analyse verwendet. Abbildung 5.3 zeigt das im Weiteren betrachtete 2D-Pre-Penalty-Volumen, dessen Einheiten mit $t \in [t_{\text{start}}, t_{\text{end}}]$ in »pxl_t« und $s \in [s_{\text{min}}, s_{\text{max}}]$ in »pxl_s« in Pixeleinheiten gegeben sind. Die hier beschriebene Evaluation orientiert sich an [E10]. In [S14] werden etwa 50 weitere unterschiedliche Durchläufe auf unterschiedlichen Rauschfeldern betrachtet.

Parametrierung der Trajektorienplanungsverfahren

Angelehnt an Gl. (3.16) ergibt sich der HMM-Zustand ζ aus der Fahrzeugposition $\xi_s \in [s_{\text{min}}, s_{\text{max}}]$ und der Geschwindigkeit $\dot{\xi}_s \in [-6, 6]$ in pxl_s/pxl_t als

$$\zeta_t = \begin{bmatrix} \zeta_t^s \\ \dot{\zeta}_t^s \end{bmatrix} = \begin{bmatrix} \xi_s(t) \\ \dot{\xi}_s(t) \end{bmatrix}. \quad (5.1)$$

Der Zustandsübergang nach Gl. (3.17) wird über die Beschleunigung $\ddot{\xi}_s \in [-1, 1]$ in pxl_s/(pxl_t)² beschrieben. Die Startposition $\xi(t_{\text{start}})$ wird als fix angenommen. Das Erreichen einer bestimmten Endposition $\xi(t_{\text{end}})$ wird nicht betrachtet.

Zur Bewertung des ELM-Algorithmus werden entsprechend Abschnitt 3.5.2 insgesamt 1.200 Starttrajektorien jeweils konstanter Geschwindigkeit generiert und optimiert. Eine Auswahl einiger Starttrajektorien $\xi_{\text{ELM}}^{(k)}$ ist in Abbildung 5.3a in Hellblau dargestellt mit den zugehörigen Ergebnistrajektorien ξ_{ELM}^k in Abbildung 5.3b in Grün. Die weiße Linie im zweiten Bild zeigt die global optimale Lösung ξ_{HMM} , die durch den HMM-Algorithmus gefunden wird.

Evaluationsergebnisse

Keine der 1.200 ELM-Trajektorien konvergiert zur global optimalen Lösung. Aufgrund feiner lokaler Details terminieren einige der ELM-Trajektorien in lokalen Minima, die sich in der Nähe hoher Penaltywerte befinden und somit erwartungsgemäß selbst hohe Penaltywerte an diesen Stellen aufweisen, wie in Abbildung 5.3b deutlich wird. Abbildung 5.3c zeigt die Verteilung der Penaltywerte als Histogramm, mit einer Normierung auf den HMM-Penaltywert $\mathcal{P}_{\text{HMM}} = 1$. Blau stellt dabei die ELM-Lösungen durch Starttrajektorien mit konstanter Geschwindigkeit nach Gl. (3.19) dar, Rot die ELM-Optimierung mit der HMM-Lösung als Starttrajektorie. Durch die Breite des Histogramms, aufgespannt zwischen den extremalen ELM-Penaltywerten $\mathcal{P}_{\text{ELM}}^{\min} = 1,27$ und $\mathcal{P}_{\text{ELM}}^{\max} = 7,43$ wird deutlich, dass die ELM-Trajektorien in einer Vielzahl an lokalen Minima des Pre-Penalty-Volumens terminieren, woraus sich im Mittel ein Penaltywert von $\mathcal{P}_{\text{ELM}}^{\text{mean}} = 4,66$ ergibt.

Tabelle 5.1 weist knapp 91% der ELM-Trajektorien mit mindestens doppeltem Penaltywert als die global optimale Lösung der HMM-Optimierung aus. Eine Analyse der Iterationen zeigt weiterhin, dass auch hier die ELM-Optimierung eine starke Heterogenität aufweist. So terminieren knapp 14% aller ELM-Starttrajektorien bereits nach einer Iteration, wobei der Mittelwert $I_{\text{ELM}}^{\text{mean}} = 18,69$ beträgt. Die maximale Anzahl an Iterationen ergibt sich zu $I_{\text{ELM}}^{\max} = 93$.

Die beste Trajektorie aller ELM-Optimierungen ξ_{ELM}^* mit einem knapp 30% höheren Penaltywert benötigt weit überdurchschnittlich viele Iterationen von $I_{\text{ELM}}^* = 31$. Unter Verwendung der HMM-Lösung ξ_{HMM} als Startlösung kann der iterative Optimierungsprozess die Trajektorie mit $I_{\text{ELM}}^{\text{HMM}} = 10$ Iterationen auf einen Penaltywert von $\mathcal{P}_{\text{ELM}}^{\text{HMM}} = 0,92$ verbessern. Diese Verbesserung liegt in der

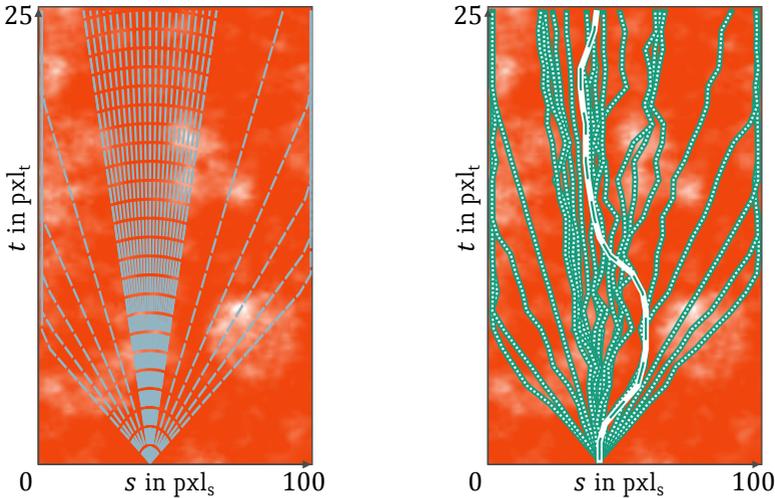
Diskretisierung des räumlichen Parameters s der HMM-Zustände begründet, der im Gegensatz dazu in der ELM-Optimierung – bis auf die Rechengenauigkeit – als kontinuierliche Variable vorliegt.

Penaltywerte-Verteilung		Prozentteil schlechterer ELM-Lösungen als global opt. HMM-Lösung		Anzahl benötigter Iterationen	
\mathcal{P}_{HMM}	1	$\rho_{0\%}^{\mathcal{P}}$	1,000	I_{ELM}^*	31
$\mathcal{P}_{\text{ELM}}^{\text{HMM}}$	0,92	$\rho_{10\%}^{\mathcal{P}}$	1,000	$I_{\text{ELM}}^{\text{HMM}}$	10
$\mathcal{P}_{\text{ELM}}^{\text{min}}$	1,27	$\rho_{30\%}^{\mathcal{P}}$	0,997	$I_{\text{ELM}}^{\text{min}}$	1
$\mathcal{P}_{\text{ELM}}^{\text{max}}$	7,43	$\rho_{50\%}^{\mathcal{P}}$	0,988	$I_{\text{ELM}}^{\text{max}}$	93
$\mathcal{P}_{\text{ELM}}^{\text{mean}}$	4,66	$\rho_{100\%}^{\mathcal{P}}$	0,909	$I_{\text{ELM}}^{\text{mean}}$	18,69
$\mathcal{P}_{\text{ELM}}^{\text{med}}$	5,37			$I_{\text{ELM}}^{\text{med}}$	16
$\mathcal{P}_{\text{ELM}}^{\sigma}$	1,98				

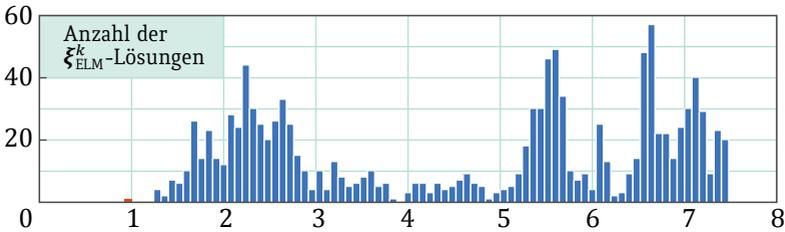
Tabelle 5.1: Analyse des synthetisierten Pre-Penalty-Volumens in Abbildung 5.3 anhand der Metriken aus Abschnitt 5.1.

Die iterative Optimierung des ELM-Prozesses hängt maßgeblich von den Starttrajektorien $\xi_{\text{ELM}}^{(k)}$ ab und kann dabei keine global optimale Lösung garantieren, wie das Beispiel aus Abbildung 5.3 bestätigt. Durch die kontinuierliche Beschreibung des räumlichen Parameters zusammen mit der linearen Interpolation der Pre-Penalty-Volumen-Werte kann die ELM-Optimierung jedoch die Lösung des HMM-Algorithmus iterativ verbessern und einen Qualitätsgewinn bewirken.

Im Gegensatz dazu hängt das Ergebnis des HMM-Algorithmus maßgeblich von der gewählten Diskretisierung ab, wie in Abbildung 5.4 deutlich wird. Das dargestellte Pre-Penalty-Volumen zeigt die jeweilige global optimale Lösung der HMM-Optimierung mit unterschiedlichen Diskretisierungen des Ortsparameters. Abbildung 5.4a zeigt die global optimale Lösung $\xi_{\text{HMM}}^{\text{low}}$ einer groben Auflösung mit $t \in \{0, 1, \dots, 200\}$ als $\zeta^s \in \{0, 1, \dots, 100\}$. Eine Erhöhung der HMM-Zustandsraum-Ortsauflösung auf $\zeta^s \in \{0, 1/8, 1/4, 3/8, \dots, 100\}$ mit gleichbleibender Zeitachse und einer linearen Interpolation des Pre-Penalty-Volumens resultiert in einer weitaus glatteren Trajektorie $\xi_{\text{HMM}}^{\text{high}}$ in Abbildung 5.4b.



(a) Auswahl der insgesamt 1.200 Startlösungen $\xi_{ELM}^{(k)}$. (b) Iterative ELM-Lösungen ξ_{ELM}^k in Grün und HMM-Lösung ξ_{HMM} in Weiß.



(c) Histogramm der Penaltywerte.

Abbildung 5.3: ELM- und HMM-Optimierung auf einem synthetisierten Pre-Penalty-Volumen.

(a) zeigt eine Auswahl der 1.200 ELM-Starttrajektorien. (b) zeigt die Optimierungsergebnisse mit einigen ELM-Trajektorien in lokalen Minima nahe hoher Penaltywerte aufgrund der Limitationen iterativer Algorithmen. Die HMM-Lösung ξ_{HMM} in Weiß als ELM-Startlösung resultiert in einer geringfügigen Verbesserung, wobei ξ_{ELM}^{HMM} in der obigen Darstellung unterhalb ξ_{HMM} liegt. (c) zeigt das Histogramm der ξ_{ELM}^k normiert auf $\mathcal{P}[\xi_{HMM}] = 1$. Keine der blauen ξ_{ELM}^k -Lösungen terminiert in einem ähnlich guten Penaltywert (Minimum $\mathcal{P}_{ELM}^{min} = 1,27$). Die iterative ELM-Optimierung der HMM-Lösung verbessert den Penaltywert geringfügig auf $\mathcal{P}[\xi_{ELM}^{HMM}] = 0,92$, dargestellt in Rot.

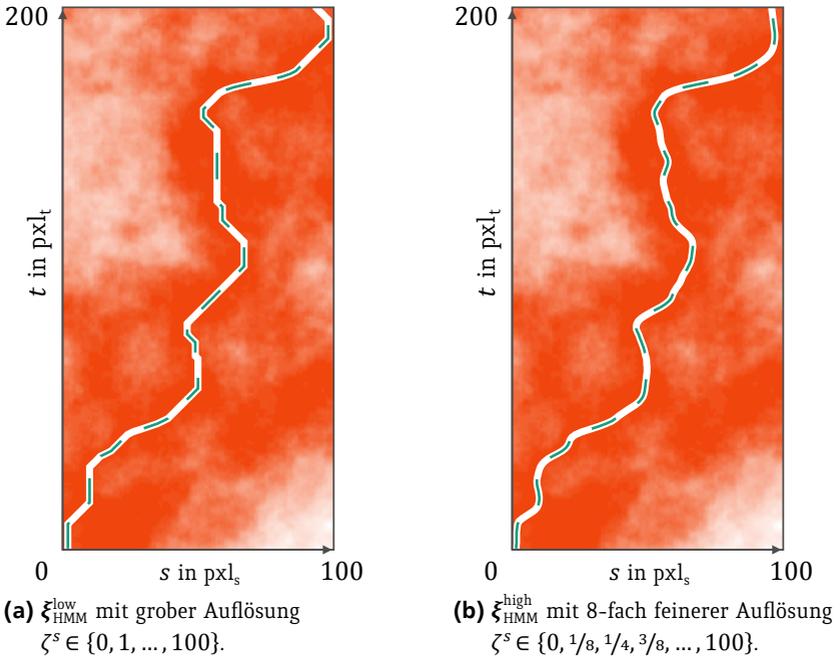


Abbildung 5.4: Einfluss der Zustandsraumdiskretisierung auf HMM-Lösung. Obwohl sich bei einer höheren Auflösung in (b) eine glattere und feinere Trajektorie $\xi_{\text{HMM}}^{\text{high}}$ im Vergleich zu $\xi_{\text{HMM}}^{\text{low}}$ in (a) ergibt, kommen beide Optimierungsprozesse zur selben Trajektorie, jedoch mit einem 360-fachen Rechenzeitunterschied.

Trotz der Unterschiede durch die feinere Auflösung von Ort und Geschwindigkeit beschreiben beide Trajektorien qualitativ dieselbe Kurve. Die Trajektorie $\xi_{\text{HMM}}^{\text{high}}$ benötigt dabei unter Verwendung rein seriellen Codes ein 360-faches an Rechenzeit (etwa 1 Minute gegenüber etwa 6 Stunden mit rein seriellem, unoptimiertem MATLAB-Code), sodass für dieses Beispiel die Erhöhung der Auflösung in keinem signifikanten Qualitätsanstieg resultiert.

Den guten Ergebnissen bei einer niedrigen Auflösung steht das Beispiel in Abbildung 5.5 entgegen, das eine sehr starke Vergrößerung der HMM-Zustandsraumauflösung darstellt. Die grobe Auflösung wird mit $\zeta^s \in \{0, 25, \dots, 300\}$

sowie zeitlich $t \in \{0, 15, \dots, 180\}$, die feine Auflösung mit $\zeta^s \in \{0, 1, \dots, 300\}$ und $t \in \{0, 1, \dots, 180\}$ optimiert und resultiert wiederum in den Trajektorien $\xi_{\text{HMM}}^{\text{low}}$ und $\xi_{\text{HMM}}^{\text{high}}$. Anhand dieses Beispiels werden die Probleme einer zu starken Vergrößerung deutlich, die zu einer signifikanten Verschlechterung des Ergebnisses führen und nicht mehr dieselbe Trajektorie beschreiben, ungeachtet dessen, dass beide Lösungen das jeweilige globale Optimum der entsprechenden Diskretisierung bedeuten.

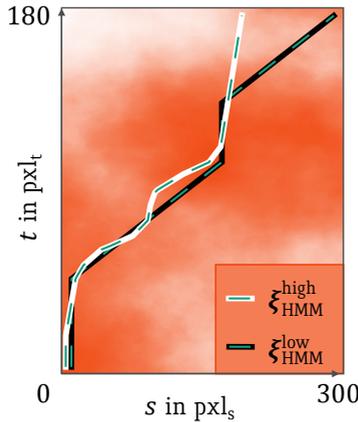


Abbildung 5.5: Beispiel einer zu groben Auflösung des HMM-Zustandsraums. Die Auflösung von $\xi_{\text{HMM}}^{\text{low}}$ ergibt sich zu $\zeta^s \in \{0, 25, \dots, 300\}$ mit $t \in \{0, 15, \dots, 180\}$, die Auflösung von $\xi_{\text{HMM}}^{\text{high}}$ zu $\zeta^s \in \{0, 1, \dots, 300\}$ mit $t \in \{0, 1, \dots, 180\}$. Aufgrund unterschiedlicher Endpunkte beschreiben $\xi_{\text{HMM}}^{\text{low}}$ und $\xi_{\text{HMM}}^{\text{high}}$ nicht mehr dieselbe Trajektorie.

Abbildung 5.6 stellt die möglichen auftretenden Probleme mit der HMM-Diskretisierung nochmals schematisch dar. Die Trennlinien in Blau und Lila beschreiben unterschiedliche Auflösungen des HMM-Zustandsraums. In Grün ist das globale Minimum dargestellt. Die hochaufgelöste Trajektorie $\xi_{\text{HMM}}^{\text{high}}$ in Lila befindet sich sowohl geometrisch als auch in Bezug auf den Penaltywert nah am globalen Minimum in Tal 2. In einem solchen Fall führt eine anschließende iterative Optimierung durch den ELM-Algorithmus zur global optimalen Lösung. In Blau ist das Ergebnis der Trajektorie $\xi_{\text{HMM}}^{\text{low}}$ mit einer größeren Auflösung dargestellt, die im Tal 1 zum Liegen kommt und dadurch geometrisch sehr weit

vom globalen Optimum entfernt ist, auch wenn sich ein ähnlicher Penaltywert für die grobe Trajektorie $\xi_{\text{HMM}}^{\text{low}}$ ergibt. Eine anschließende ELM-Optimierung mit $\xi_{\text{HMM}}^{\text{low}}$ als Starttrajektorie führt in diesem Fall zum lokalen Minimum in Tal 1 und erreicht das globale Optimum nicht.

Zusammenfassung der Ergebnisse

Durch die Evaluation anhand synthetisierter Pre-Penalty-Volumen werden die Anforderungen an Trajektorienplanungsalgorithmen deutlich: Einerseits ist eine robuste Konvergenz in das globale Optimum nötig unter Berücksichtigung der Echtzeitanforderungen an die Optimierung. Auf der anderen Seite ergibt sich die Notwendigkeit einer intuitiven Wahl der freien Parameter der Optimierungsmethoden.

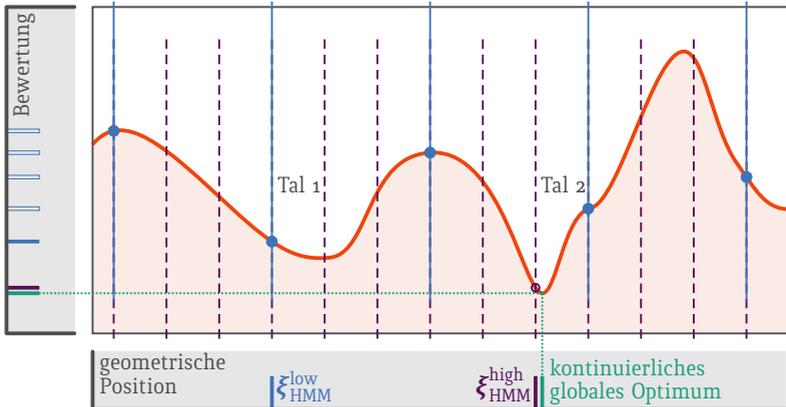


Abbildung 5.6: Schematische Betrachtung des Einflusses der Zustandsraumdiskretisierung des HMM. Die blauen und lilanen Trennlinien stellen unterschiedliche Auflösungen dar, Grün das globale Minimum. Die Penaltywerte beider Trajektorien liegen nah am globalen Optimum. Dennoch liegt die $\xi_{\text{HMM}}^{\text{low}}$ in Tal 1 und ist damit geometrisch sehr weit vom globalen Optimum in Tal 2 entfernt.

Wie bereits in Tabelle 3.1 gegenübergestellt, weisen die ELM- und HMM-Methode unterschiedliche Vor- und Nachteile im direkten Vergleich auf. Der ELM-Algo-

rithmus hängt massiv von den gegebenen Starttrajektorien ab, sodass auch bei der Verwendung einer sehr großen Anzahl an Starttrajektorien das Erreichen eines globalen Optimums nicht garantiert werden kann. Ein Vorteil des ELM-Algorithmus ist jedoch die kontinuierliche Zustandsbeschreibung, die das HMM nicht besitzt.

Der HMM-Algorithmus hängt maßgeblich von der gewählten Diskretisierung des Zustandsraums ab, sodass eine zu grob gewählte Auflösung in einer unzureichenden Trajektorie resultieren kann, wohingegen eine zu hohe Auflösung in einer qualitativ hochwertigen Trajektorie, jedoch bei einer seriellen Implementierung mit einer gravierenden Rechenzeiterhöhung einhergeht. Durch die Wahl der Auflösung als Zellengröße des Pre-Penalty-Volumens ist eine intuitive Interpretation der global optimalen Ergebnistrajektorie möglich.

Der hohen Rechenzeit steht jedoch ein hohes Parallelisierungspotenzial der speziellen Problemformulierung entgegen, das in [S8] in einer echtzeitfähigen Implementierung der HMM-Trajektorienplanungsmethode auf einer NVIDIA GE-FORCE GTX TITAN Grafikkarte (GPU) in einem *Speedup*¹ von 627 resultiert bei der Verwendung von einer GPU, beziehungsweise von 1.137 bei der Verwendung von zwei GPUs. Zusammen mit einer recheneffizienten GPU-Implementierung der Prädiktion über Faltungskerne innerhalb des Pre-Penalty-Volumens (prototypisch getestet), führt die Kombination zu einem echtzeitfähigen, global optimierenden SPARC-Ansatz zur Trajektorienplanung vollautomatischer Fahrzeuge.

5.3 Betrachtung anhand realer Beispielsituationen

Im Weiteren werden die Erkenntnisse des vorherigen Abschnitts 5.2 im Hinblick auf ihre Anwendbarkeit auf reales Verkehrsgeschehen entsprechend [E6] evaluiert. Hierfür werden vier alltägliche Beispielsituationen geometrisch nach Kapitel 4 in der Simulation nachgebildet und im *st*-Planungsraum eine Tra-

¹ X-fache Beschleunigung gegenüber seriellem Code.

jektorienplanung mit den Methoden aus Kapitel 3 durchgeführt und mit den Evaluationsmetriken aus Abschnitt 5.1 bewertet.

Abschnitt 5.3.1 gibt eine Beschreibung der ausgewählten Beispielsituationen mit anschließender topologischer Evaluation in Abschnitt 5.3.2 über die Trajektorienplanung mithilfe der ELM- und HMM-Methoden. Die Zusammenfassung der Erkenntnisse folgt in Abschnitt 5.4.

5.3.1 Auswahl und Beschreibung der Beispielsituationen

Die Beispielstraßengeometrien stammen aus über Karlsruhe und Umgebung im Juni 2014 aufgenommenen Luftbildern und umfassen einfache bis komplexe Verkehrssituationen, bei der jeweils ein Verkehrsteilnehmer als Ego-Fahrzeug angenommen und dessen Trajektorie für den anschließenden Prädiktionszeitraum geplant wird. Die Aufnahmeorte sind in Abbildung 5.7 zusammengefasst. Zur Veranschaulichung zeigen die Abbildungen 5.8 bis 5.11 neben den Luftbildern zusätzlich eine schematische Darstellung der Situationsgeometrie, ein Foto der nachgestellten (und retuschierten) Situation vom Boden aus, sowie den resultierenden Schnitt durch das Pre-Penalty-Volumen ρ .



Abbildung 5.7: Übersicht über die Orte der analysierten Beispielsituationen.

Quelle: OpenStreetMap Kartenmaterial.

Beschreibung Situation ① – Linksabbiegen durch Gegenverkehr

In Abbildung 5.8 ist eine alltägliche Linksabbiegesituation dargestellt. Das Ego-Fahrzeug plant von der Bannwaldallee in die Griesbachstraße über den Gegenfahrstreifen abzubiegen, auf dem sich zwei entgegenkommende Fahrzeuge (A,B) befinden. Die Möglichkeiten des Ego-Fahrzeugs sind die Überquerung des Gegenfahrstreifens vor oder nach den beiden Fahrzeugen sowie zwischen A und B. Neben der topologischen Analyse der Situation werden zwei unterschiedliche Geometrien für ein besseres Verständnis der Anforderungen an Trajektorienplanungsverfahren betrachtet und dafür zum einen eine schmale Lücke (Situation ①) und zum anderen eine weite Lücke (Situation ②) zwischen den entgegenkommenden Fahrzeugen angenommen.

Beschreibung Situation ② – Einfahrt in befahrenen Kreisel

Die zweite Beispielsituation in Abbildung 5.9 zeigt einen Kreisverkehr – im Weiteren als »Kreisel« bezeichnet – in einem Karlsruher Industriegebiet, der die Straßen DEA-Scholven-Straße, Raffineriestraße und Esso-Straße verbindet. Die Situation besteht aus vier weiteren Verkehrsteilnehmern, wovon sich drei Fahrzeuge bereits im Kreisel befinden (A,C,D) und ein Fahrzeug auf die Einfahrt in den Kreisel (B) wartet. Das Ego-Fahrzeug befindet sich noch außerhalb und plant den Kreisel an der nächsten Ausfahrt zu verlassen.

Durch die Vielzahl anderer Verkehrsteilnehmer mit mehreren Handlungsmöglichkeiten entsteht eine komplexe Verkehrssituation, deren Evolution nicht mit Sicherheit vorhersehbar ist. Das Fahrzeug D hat die Einfahrt des Ego-Fahrzeugs bereits passiert und beeinflusst daher die Situationsgeometrie lediglich indirekt über Rückwirkungen auf das dahinterfahrende Fahrzeug A. Die Bewegungen der Verkehrsteilnehmer B und C sind mit hohen Unsicherheiten verbunden.

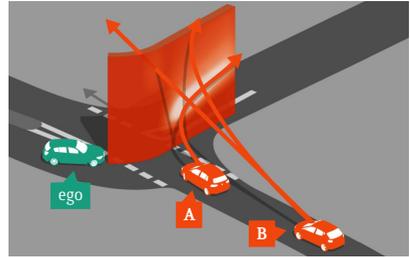
Die Handlungsmöglichkeiten des Ego-Fahrzeugs ergeben sich durch lokale Minima zwischen den einzelnen Fahrzeugen, da vorhergesagt wird, dass immer neue Verkehrsteilnehmer den Kreisel befahren.



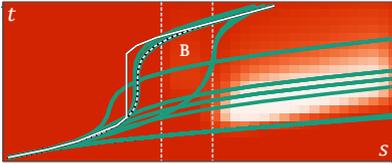
(a) Geometrie aus Bodenperspektive.



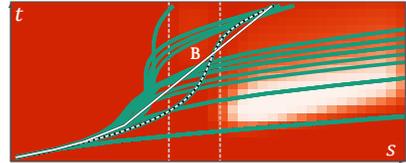
(b) Geometrie aus Vogelperspektive.



(c) Schematische Darstellung.



(d) Schmale Lücke: Schnitt durch Pre-Penalty-Volumen \mathcal{P} und Ergebnisse der Optimierung. ELM-Lösungen ξ_{ELM}^k in Grün dargestellt. HMM-Lösung ξ_{HMM} in Weiß. Über ELM verbesserte HMM-Lösung $\xi_{\text{HMM}}^{\text{ELM}}$ in Schwarz-Weiß. Ansteigende Penaltywerte von Dunkelrot nach Weiß.



(e) Weite Lücke: Schnitt durch Pre-Penalty-Volumen \mathcal{P} und Ergebnisse der Optimierung. ELM-Lösungen ξ_{ELM}^k in Grün dargestellt. HMM-Lösung ξ_{HMM} in Weiß. Über ELM verbesserte HMM-Lösung $\xi_{\text{HMM}}^{\text{ELM}}$ in Schwarz-Weiß. Ansteigende Penaltywerte von Dunkelrot nach Weiß.

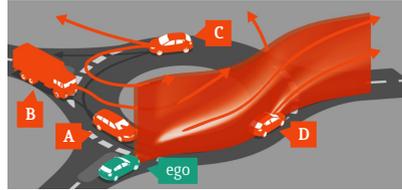
Abbildung 5.8: Beispielsituation ①: Einfaches Linksabbiegen durch Gegenverkehr. Zwei geometrische Ausprägungen als schmale Lücke ⊖ und weite Lücke ⊕.



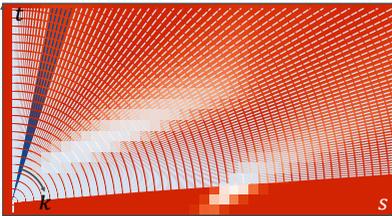
(a) Geometrie aus Bodenperspektive.



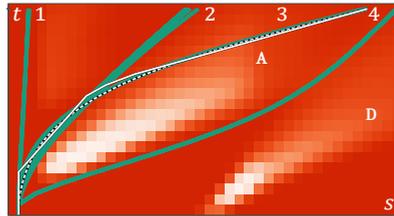
(b) Geometrie aus Vogelperspektive.



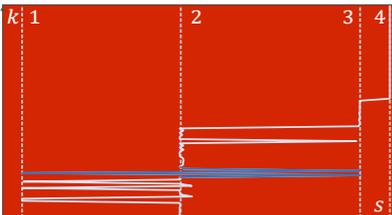
(c) Schematische Darstellung.



(d) »Fächer« an Startlösungen $\xi_{\text{ELM}}^{(k)}$. Die dunkelblauen Trajektorien terminieren mit steigendem k in den Optima 2,3,1,3,2.



(e) Schnitt durch Pre-Penalty-Volumen ρ und Ergebnisse der Optimierung. ELM-Lösungen ξ_{ELM}^k in Grün dargestellt. HMM-Lösung ξ_{HMM} in Weiß. Über ELM verbesserte HMM-Lösung $\xi_{\text{ELM}}^{\text{HMM}}$ in Schwarz-Weiß. Ansteigende Penaltypwerte von Dunkelrot nach Weiß.



(f) Lage der ELM-Lösungen ξ_{ELM}^k in lokalen Optima 1–4, aufgetragen über k mit dunkelblauen Ergebnissen gemäß (d).

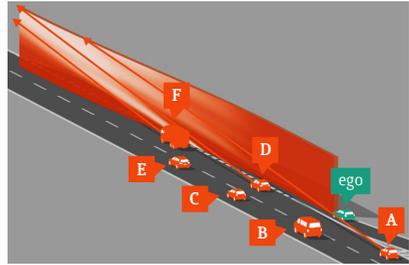
Abbildung 5.9: Beispielsituation ②: Einfahrt in befahrenen Kreisel.

Beschreibung Situation ③ – Einfädeln auf eine Schnellstraße

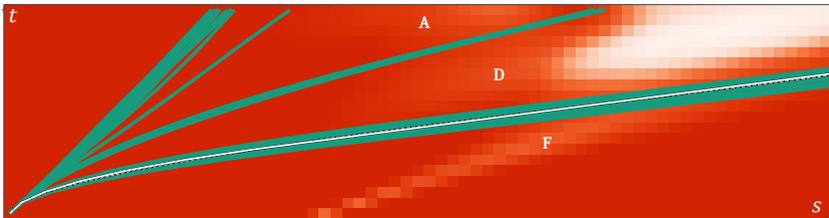
Abbildung 5.10 zeigt die Situation eines Einfädelvorgangs auf der Landstraße L605 in Richtung Ettlingen mit der Auffahrt auf Höhe der Pulverhausstraße. Es befindet sich eine Vielzahl an Fahrzeugen (A–F) auf zwei Fahrstreifen, deren Geschwindigkeitsbegrenzung bei 70 km/h liegt. Um Auffahren zu können, muss das Ego-Fahrzeug auf dem Beschleunigungsstreifen zunächst eine angemessene Geschwindigkeit erreichen, um sich dann in eine weite Lücke zwischen zwei Fahrzeugen ohne Behinderung des Verkehrs einzuordnen. Wie in Abschnitt 4.3 beschrieben wird dabei von einem Verkehrsgeschehen ohne Interaktion mit dem Ego-Fahrzeug ausgegangen – es wird also nicht erwartet, dass andere Fahrzeuge eine Lücke zum Einfädeln öffnen, die zum Planungszeitpunkt noch nicht existiert.



(a) Geometrie aus Bodenperspektive.



(b) Schematische Darstellung.

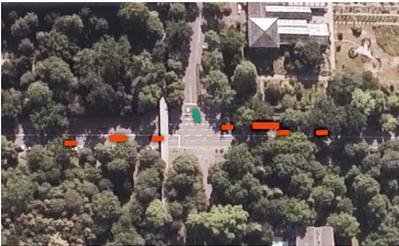


(c) Schnitt durch Pre-Penalty-Volumen ρ und Ergebnisse der Optimierung. ELM-Lösungen ξ_{ELM}^k in Grün dargestellt. HMM-Lösung ξ_{HMM} in Weiß. Über ELM verbesserte HMM-Lösung $\xi_{\text{ELM}}^{\text{HMM}}$ in Schwarz-Weiß. Ansteigende Penaltywerte von Dunkelrot nach Weiß.

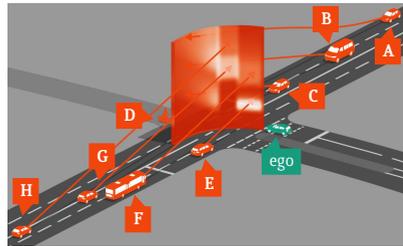
Abbildung 5.10: Beispielsituation ③: Einfädeln auf eine Schnellstraße.



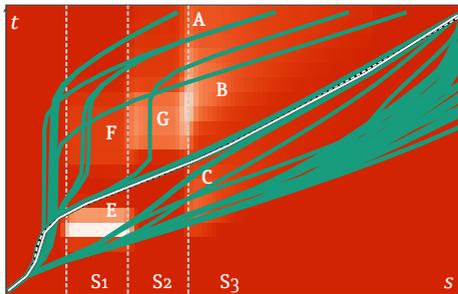
(a) Geometrie aus Bodenperspektive. Es ist lediglich ein Teil der Situation dargestellt.



(b) Geometrie aus Vogelperspektive.



(c) Schematische Darstellung.



(d) Schnitt durch Pre-Penalty-Volumen \wp und Ergebnisse der Optimierung. ELM-Lösungen ξ_{ELM}^k in Grün dargestellt. HMM-Lösung ξ_{HMM} in Weiß. Über ELM verbesserte HMM-Lösung ξ_{ELM}^{HMM} in Schwarz-Weiß. Ansteigende Penaltywerte von Dunkelrot nach Weiß. S_1 und S_2 beschreiben die zu kreuzenden Gegenfahrstreifen, S_3 den Ziel-Fahrstreifen.

Abbildung 5.11: Beispielsituation ④: Komplexe Kreuzungssituation.

Beschreibung Situation ④ – Komplexe Kreuzungssituation

Die letzte Beispielsituation, dargestellt in Abbildung 5.11, zeigt eine komplexe Kreuzungssituation ohne Ampelanlage der Straßen Am Fasanengarten und Adenauerring in der Karlsruher Innenstadt. Das Ego-Fahrzeug plant aus der Seitenstraße auf den Adenauerring abzubiegen und muss dafür zunächst zwei Gegenfahrstreifen (S_1 , S_2) überqueren und sich dann in den fließenden Verkehr einfädeln, der sich wiederum auf zwei Fahrstreifen befindet. Der geplante Ziel-Fahrstreifen des Ego-Fahrzeugs ist dabei der »innere« der beiden Fahrstreifen (S_3). Die Situation enthält insgesamt acht weitere Verkehrsteilnehmer (A–H) und stellt damit eine hochkomplexe – aber gleichwohl an diesem Ort übliche – Situation dar.

Durch das hohe Verkehrsaufkommen ist das Warten auf eine vollständig freie Kreuzung nicht sinnvoll, sodass die Trajektorienplanung eine sichere Trajektorie »durch den Verkehr« finden muss.

5.3.2 Analyse der Beispielsituationen

Parametrierung der Trajektorienplanungsverfahren

Zur Analyse der topologischen Eigenschaften der Beispielsituationen wird, wie bereits im vorherigen Abschnitt 5.2 für synthetisierte Pre-Penalty-Volumen geschehen, eine Abtastung des Trajektorienraums mit $K \approx 100$ Starttrajektorien konstanter Geschwindigkeit nach Gl. (3.19) für die ELM-Optimierungen durchgeführt mit einer maximalen Anzahl an zulässigen Iterationen von $I_{ELM}^{\max} \leq 800$. Die global optimale Lösung – gegeben der entsprechenden Zustandsraumauflösung – wird wiederum über den HMM-Algorithmus berechnet, dessen Zustandsraum sich nach Gl. (5.1) ergibt.

Evaluation Situation ① – Linksabbiegen bei Gegenverkehr

Die Abbildungen 5.8d und 5.8e zeigen die Optimierungsergebnisse des Linksabbiegemaneövers für eine schmale Lücke als Situation ①₋ und eine weite Lücke als Situation ①₊. Erwartungsgemäß ergeben sich bei beiden Ausprägungen drei

Optima, die entweder eine Fahrt vor beiden, hinter beiden oder zwischen beiden Fahrzeugen bedeuten. Die Penaltywerte $\mathcal{P}_{\text{ELM}}^{\max}$, $\mathcal{P}_{\text{ELM}}^{\text{mean}}$, $\mathcal{P}_{\text{ELM}}^{\text{med}}$, $\mathcal{P}_{\text{ELM}}^{\sigma}$ in Tabelle 5.2 weisen jedoch auf weitere lokale Optima in diesen Situationen hin.

Ausgenommen einiger Lösungen, die in kollisionsbehafteten Optima terminieren, konvergiert die Schar an ELM-Trajektorien ξ_{ELM}^k in beiden Situationsausprägungen in jedem der drei offensichtlichen Optima, wohingegen der HMM-Algorithmus die entsprechende intuitive Lösung liefert und bei einer weiten Lücke zwischen den Fahrzeugen sowie bei einer schmalen Lücke nach den Fahrzeugen terminiert. Durch eine verhältnismäßig grobe Diskretisierung in diesem Beispiel entsteht ein kantiges Aussehen der HMM-Lösung ξ_{HMM} , die durch eine iterative Verbesserung geglättet werden kann. Die daraus resultierenden Trajektorien $\xi_{\text{ELM}}^{\text{HMM}}$ verbessern den auf $\mathcal{P}_{\text{HMM}} = 1$ normierten Penaltywert auf $\mathcal{P}_{\text{ELM}}^{\text{HMM}} = 0,92$ im Fall der schmalen Lücke und $\mathcal{P}_{\text{ELM}}^{\text{HMM}} = 0,94$ im Fall der weiten Lücke. Die Trajektorien $\xi_{\text{ELM}}^{\text{HMM}}$ konvergieren in beiden Situationsgeometrien zur optimalen Lösung ξ_{ELM}^* innerhalb der Schar an ELM-Lösungen, sodass in beiden Situationen das globale Optimum durch die Abtastung des Trajektorienraums mit generischen Starttrajektorien von etwa 9% der Trajektorien gefunden wird.

Die Linksabbiegesituation weist von allen Beispielsituationen die schnellste Konvergenz mit einem Mittelwert von $I_{\text{ELM}}^{\text{mean}} = 58,01$ auf und kann somit in dieser Hinsicht als einfachstes Szenario betrachtet werden. Dabei zeigt sich besonders deutlich, dass bei iterativen Verfahren der Startwert eine wesentlich größere Bedeutung haben kann, als die konkrete Situation. Starttrajektorien, die ein Durchqueren der Lücke zwischen den Fahrzeugen vorsehen, konvergieren entsprechend – und nahezu unabhängig von der Breite der Lücke – stets zu Optima, die eine Durchquerung beschreiben. So terminieren selbst bei einer schmalen Lücke etwa 5% der ELM-Lösungen zwischen den beiden Fahrzeugen. Im Gegensatz dazu ist für den HMM-Algorithmus selbst bei einer groben Diskretisierung eine Unterscheidung zwischen den Situationen $\textcircled{1}$ und $\textcircled{4}$ möglich.

Evaluation Situation $\textcircled{2}$ – Einfahrt in befahrenen Kreis

Abbildung 5.9e zeigt die Optimierungsergebnisse der zweiten Beispielsituation. Die iterativen ELM-Lösungen ξ_{ELM}^k konvergieren in vier unterschiedliche lokale

Optima, die geometrisch das Abwarten aller Fahrzeuge (1), das Einfahren zwischen A und B (2, 3) und das Einfahren noch vor A (4) beschreiben. Die HMM-Lösung definiert das globale Optimum als Extremum 3.

In diesem Beispiel wird die Notwendigkeit einer geeigneten Wahl der HMM-Diskretisierung besonders deutlich, da die iterative Verbesserung der HMM-Lösung in dieser Konstellation die größten Erfolge auf einen Penaltywert von $\mathcal{P}_{\text{ELM}}^{\text{HMM}} = 0,77$ erzielt. Etwa 6% der ELM-Trajektorien $\xi_{\text{ELM}}^{(k)}$ konvergieren zum globalen Optimum. Die Standardabweichung erreicht im Vergleich aller Situationen den geringsten Wert von $\mathcal{P}_{\text{ELM}}^{\sigma} = 0,18$ mit einem maximalen Penaltywert von $\mathcal{P}_{\text{ELM}}^{\text{max}} = 1,29$. Die Situation besteht demnach aus leicht zu findenden lokalen Optima ähnlicher Penaltywerte. Auf der anderen Seite ergeben sich durch die Situationsgeometrie des Beispiels dennoch hohe Anforderungen an iterative Lösungsmethoden, die durch die Divergenz einiger Starttrajektorien und durch eine hohe Streuung der benötigten Iterationen mit einem Median von $J_{\text{ELM}}^{\text{med}} = 110$ und arithmetischen Mittel von $J_{\text{ELM}}^{\text{mean}} = 130,04$ deutlich wird.

Neben den rechentechnischen Herausforderungen der Beispielsituation wird anhand der Sprungmetrik in Tabelle 5.2 eine allgemeine Problematik der Starttrajektoriengenerierung iterativer Planungsverfahren aufgezeigt. Die Terminierung der Trajektorien in lokalen Optima – aufgetragen über den Index der Starttrajektorien k in Abbildung 5.9f – weist deutlich darauf hin, dass die Vorgabe einer Startlösung, die sich in der Nähe eines lokalen Optimums befindet, nicht zwingend auch in ebendiesem Optimum konvergiert. Dies erschwert die Entwicklung sowohl eines geeigneten Generators für Starttrajektorien als auch eines in dieser Hinsicht zuverlässigen iterativen Planungsalgorithmus, vor allem für sicherheitskritische Optimierungsanwendungen. Besonders deutlich wird dies bei den fünf hervorgehobenen benachbarten Starttrajektorien in Abbildung 5.9d, die mit steigendem Index k in den Optima 2, 3, 1, 3, 2 terminieren, wie in Abbildung 5.9f farblich dargestellt.

Weiterhin verdeutlicht die Analyse der Optima 2 und 3 eine interessante topologische Eigenschaft des Trajektorienplanungsraums von realem Verkehrsgeschehen und zeigt damit einen wesentlichen Vorteil des SPARC-Konzepts gegenüber rein kombinatorischen Ansätzen. Beide Optima beschreiben die geometrische

Einfädelscheidung zwischen A und B und stellen gleichzeitig zwei unterschiedliche Optima dar, in denen unterschiedliche Optimierungsterme dominieren, nämlich einmal sicherheits- und einmal zeitoptimal, wobei es sich bei Optimum 3 um das globale und bei 2 um das Minimum mit dem höchsten Penaltywert $\mathcal{P}_{\text{ELM}}^{\text{max}}$ handelt. Dabei terminieren 50% aller Startlösungen in diesem geometrischen Bereich, jedoch lediglich 15% der Starttrajektorien im globalen Optimum 3 aber 35% im schlechtesten lokalen Optimum 2. Ansätze, die auf rein geometrischen Betrachtungen basieren, können diese – im Straßenverkehr zweifelsfrei vorhandene – Unterscheidung der beiden Optima nicht leisten und laufen damit Gefahr, trotz der korrekten Identifikation des global optimalen geometrischen Bereichs dennoch mit einer hohen Wahrscheinlichkeit in einem weitaus schlechteren lokalen Optimum zu terminieren.

Analyse Situation ③ – Einfädeln auf eine Schnellstraße

Die Optimierungsergebnisse der Einfädelsituation in Abbildung 5.10c zeigen im Wesentlichen drei Bereiche von Optima, die sich als ein Spurwechsel zwischen F und D, einem Wechsel zwischen D und A und einem Auffahren nach A ergeben, mit mehreren unterschiedlichen Optima vor allem innerhalb des letztbeschriebenen Bereichs. Die iterative Verbesserung $\xi_{\text{ELM}}^{\text{HMM}}$ der diskretisierten Lösung des HMM-Algorithmus ξ_{HMM} kann in diesem Beispiel nur geringe Verbesserungen in der Größenordnung von 10^{-3} erzielen mit $I_{\text{ELM}}^{\text{HMM}} = 15$ Iterationen.

Die Beispielsituation bietet durch die gleichförmige Bewegung und Geschwindigkeit der anderen Verkehrsteilnehmer eine sehr strukturierte Situationsgeometrie, sodass sich im Vergleich der Situationen untereinander in der Einfädelsituation die geringsten Vorhersagbarkeitsmetriken mit $J_{\text{ELM}}^{\text{P}} = 5,05$ und $J_{\text{ELM}}^{\text{end}} = 1,44$ ergeben, also demnach die geringsten unvorhersagbaren Sprünge in entfernte Optima auftreten. Durch die Strukturiertheit der Situation werden die lokalen Optima im arithmetischen Mittel von $I_{\text{ELM}}^{\text{mean}} = 63,66$ Iterationen gefunden, wobei 49% der ELM-Lösungen zum globalen Optimum konvergieren.

Trotz der guten iterativen Optimierungsergebnisse stellt die Einfädelsituation eine kritische Beispielsituation dar, da das zum globalen Optimum nächstgelegene lokale Optimum bereits einen 2,5-fach höheren Penaltywert besitzt und

somit eine weitaus schlechtere Lösung der Trajektorienplanung darstellt. Bei einer geringeren Anzahl an Starttrajektorien zur Einhaltung der Echtzeitanforderungen ist daher nicht sichergestellt, das globale Optimum – oder ein qualitativ vergleichbares lokales Optimum – zu finden, was in einem sicherheitskritischen Manöver resultieren könnte.

Analyse Situation ④ – Komplexe Kreuzungssituation

Die letzte Situation in Abbildung 5.11d stellt die komplexeste Situationstopologie mit einer Vielzahl an lokalen Optima dar. Die global optimale HMM-Lösung ξ_{HMM} ergibt sich als Abwarten des Verkehrsteilnehmers E, dem Überqueren der beiden Gegenfahrstreifen S1 und S2 vor F und G, sowie dem Einfädeln in den Ziel-Fahrstreifen S3 nach Fahrzeug C und vor Fahrzeug B.

Die Lösungen von 90% der ELM-Trajektorien übersteigen den Penaltywert des globalen HMM-Algorithmus um 100%, einige sogar über 400%. Der maximale Penaltywert ergibt sich im Vergleich aller Beispiele mit $\mathcal{P}_{\text{ELM}}^{\max} = 5,13$ als höchster Wert sowie auch das arithmetische Mittel mit $\mathcal{P}_{\text{ELM}}^{\text{mean}} = 3,34$, der Median mit $\mathcal{P}_{\text{ELM}}^{\text{med}} = 2,73$ sowie die mittlere Anzahl an Iterationen mit $I_{\text{ELM}}^{\text{mean}} = 252,58$ und dessen Median mit $I_{\text{ELM}}^{\text{med}} = 206$ Iterationen. Neben der Divergenz einiger Trajektorien ergibt sich in diesem Beispiel die größte Streuung an Iterationen von $I_{\text{ELM}}^{\min} = 79$ bis $I_{\text{ELM}}^{\max} > 800$. Die beste iterative Lösung ξ_{ELM}^* benötigt $I_{\text{ELM}}^* = 215$ Iterationen für einen Penaltywert von $\mathcal{P}_{\text{ELM}}^{\min} = 1,26$. Eine iterative Verbesserung der diskretisierten HMM-Lösung $\xi_{\text{ELM}}^{\text{HMM}}$ ergibt eine Verbesserung von lediglich 2% unter Verwendung von $I_{\text{ELM}}^{\text{HMM}} = 185$ Iterationen.

Die Analyse der Metriken zur Vorhersagbarkeit weist die komplexe Kreuzungssituation als eine von den anderen Beispielen stark abweichende Situation aus, bei der Trajektorien gleicher Endpunkte signifikant voneinander abweichende Penaltywerte aufweisen. Die Endpunktmatrix mit einem relativ niedrigen Wert von $J_{\text{ELM}}^{\text{nd}} = 2,15$ beschreibt einen starken Zusammenhang zwischen der Lage der Starttrajektorien $\xi_{\text{ELM}}^{(k)}$ und entsprechenden Ergebnistrajektorien ξ_{ELM}^k . Dem entgegen steht die für alle Situationen mit Abstand höchste Sprungmetrik der Penaltywerte von $J_{\text{ELM}}^{\text{P}} = 27,67$, die somit auf eine Vielzahl an eng aufeinanderfolgender lokaler Optima sehr unterschiedlicher Penaltywerte hindeutet.

	Sit. ①-	Sit. ①+	Sit. ②	Sit. ③	Sit. ④
	Abbiegen schmal & weit		Kreisel	Einfädeln	Komplex
Penaltywerte-Verteilung					
Einfärbung entsprechend minimaler (hell) und maximaler (dunkel) Werte — <i>spaltenweise</i>					
\mathcal{P}_{HMM}	1	1	1	1	1
$\mathcal{P}_{\text{ELM}}^{\text{HMM}}$	0,92	0,94	0,77	1,00	0,98
$\mathcal{P}_{\text{ELM}}^{\text{min}}$	0,92	0,94	0,77	1,00	1,26
$\mathcal{P}_{\text{ELM}}^{\text{max}}$	3,91	3,81	1,29	2,52	5,13
$\mathcal{P}_{\text{ELM}}^{\text{mean}}$	1,13	1,15	1,18	1,77	3,34
$\mathcal{P}_{\text{ELM}}^{\text{med}}$	1,01	1,04	1,23	2,52	2,73
$\mathcal{P}_{\text{ELM}}^{\sigma}$	0,54	0,48	0,18	0,76	1,09
Prozentteil schlechterer ELM-Lösungen als global optimale HMM-Lösung					
Einfärbung entsprechend minimaler (hell) und maximaler (dunkel) Werte — <i>zeilenweise</i>					
$\mathcal{P}_{0\%}^{\mathcal{P}}$	0,81	0,85	0,84	0,51	1,00
$\mathcal{P}_{10\%}^{\mathcal{P}}$	0,08	0,11	0,84	0,51	1,00
$\mathcal{P}_{30\%}^{\mathcal{P}}$	0,08	0,11	0,00	0,51	0,90
$\mathcal{P}_{50\%}^{\mathcal{P}}$	0,07	0,09	0,00	0,51	0,90
$\mathcal{P}_{100\%}^{\mathcal{P}}$	0,05	0,04	0,00	0,51	0,90
Anzahl benötigter Iterationen					
Einfärbung entsprechend minimaler (hell) und maximaler (dunkel) Werte — <i>zeilenweise</i>					
J_{ELM}^*	67,00	96,00	100,00	71,00	215,00
$J_{\text{ELM}}^{\text{HMM}}$	66,00	91,00	105,00	15,00	185,00
$J_{\text{ELM}}^{\text{min}}$	33,00	33,00	52,00	25,00	79,00
$J_{\text{ELM}}^{\text{max}}$	137,00	104,00	> 800,00	169,00	> 800,00
$J_{\text{ELM}}^{\text{mean}}$	58,01	55,16	130,04	63,66	252,58
$J_{\text{ELM}}^{\text{med}}$	49,00	49,00	110,00	62,00	206,00
Vorhersagbarkeit des Optimierungsprozesses					
Einfärbung entsprechend minimaler (hell) und maximaler (dunkel) Werte — <i>zeilenweise</i>					
$J_{\text{ELM}}^{\mathcal{P}}$	9,54	10,06	6,71	5,05	27,67
$J_{\text{ELM}}^{\text{end}}$	2,57	2,46	7,17	1,44	2,15

Tabelle 5.2: Analyse der Beispielsituationen anhand der Metriken aus Abschnitt 5.1.

5.4 Schlussfolgerungen aus den topologischen Betrachtungen

Die topologischen Betrachtungen anhand synthetisierter Pre-Penalty-Volumen in Abschnitt 5.2 zeigen offenkundige Schwächen der iterativen Optimierung, die die Qualität und Eignung des ELM als Trajektorienplanungsverfahren maßgeblich bestimmen. Im diskutierten synthetisierten Beispiel konvergiert keine der 1.200 Startlösungen zur global optimalen Trajektorie, die über das HMM gefunden wird. Die beste iterative ELM-Trajektorie ergibt sich dabei mit einem um 30% höheren Penaltywert im Vergleich zur global optimalen Trajektorie mit einer überdurchschnittlich hohen Iterationsanzahl im Gesamtvergleich der ELM-Lösungen.

Vorteile der ELM-Optimierung ergeben sich lediglich durch die kontinuierliche Beschreibung der Ortskomponente, die eine iterative Verbesserung der diskretisierten HMM-Lösung um nochmals 8% ermöglicht. Experimente auf synthetisierten Pre-Penalty-Volumen hinsichtlich der Auflösung der HMM-Trajektorienplanung zeigen deutliche Limitationen der Echtzeitfähigkeit des Algorithmus bei serieller Ausführung des Verfahrens. Durch die vorliegende Problemstruktur ist jedoch eine hohe Parallelisierbarkeit gegeben, die eine Anwendung im Bereich der Trajektorienplanung ermöglicht. Hinzu kommen die Erkenntnisse des Vergleichs von HMM-Ergebnissen mit hoher und niedriger Auflösung, die bei bedachter Wahl der niedrigen Auflösung qualitativ gleichwertige Ergebnisse bei einem Bruchteil an Rechenzeit liefern.

Die Analyse von realen Beispielsituationen in Abschnitt 5.3 bestätigt die für synthetisierte Pre-Penalty-Volumen gewonnenen Erkenntnisse. Die dafür ausgesuchten Situationen eines Linksabbiegemanövers (Situation ①), einer Kreiselfahrt (Situation ②), eines Einfädelvorgangs (Situation ③) und einer komplexen Kreuzungssituation (Situation ④) weisen gleichbedeutende topologische Eigenschaften zu den synthetisierten Pre-Penalty-Volumen auf.

Die Analyse der exemplarischen Verkehrssituationen resultiert in interessanten Erkenntnissen über die topologische Beschaffenheit von realen Verkehrssituationen. Ungeachtet der Situationskomplexität zeigen sich in allen Situationen

lokale Optima, die sowohl rein geometrischer Natur durch die Existenz mehrerer Verkehrsteilnehmer, aber auch parametrischer Natur sein können, wie in der Kreiselsituation ② deutlich wird. Aus dieser Erkenntnis lassen sich Limitationen kombinatorischer Ansätze ableiten, die lediglich aus der Situationsgeometrie herrührende Optima identifizieren können. Zudem gibt die Analyse des komplexen Kreuzungsszenarios ④ durch die dort auftretende Vielzahl an lokalen Optima einen Einblick in die Komplexität von alltäglichen Verkehrssituationen, auf die zukünftige Trajektorienplanungsverfahren abgestimmt sein müssen. In einigen Fällen ergeben sich große Penaltywert-Schwankungen vom globalen Optimum hin zum nächstbesten lokalen Extremum, die wiederum auf eine hohe Komplexität des Straßenverkehrs schließen lassen.

Neben den Erkenntnissen über die topologische Beschaffenheit des Verkehrsgeschehens bestätigen sich die Limitationen des iterativen ELM-Algorithmus aus den synthetisierten Betrachtungen, dessen Konvergenz in lokale Optima in allen Beispielen deutlich wird und die Gefahr einer Divergenz in den Situationen ② und ④ illustriert. Zudem ist das Auffinden des globalen Optimums mit dem ELM auch bei einer großen Zahl an Startlösungen nicht sichergestellt, wie das Beispiel der komplexen Kreuzungssituation ④ zeigt. Weiterhin wird in der Kreiselsituation ② die algorithmisch bedingte Unvorhersagbarkeit des ELM-Algorithmus deutlich, da dort viele Sprünge in unterschiedliche Optima für aufeinanderfolgende Starttrajektorien zu verzeichnen sind.

Abschließend bestätigen sich die Erkenntnisse der synthetisierten Beispiele hinsichtlich HMM-Zustandsraumauflösung mit der Betrachtung der Kreiselsituation ②, in der sich eine signifikante Verbesserung der HMM-Lösung über eine iterative ELM-Optimierung ergibt und damit auf eine potentiell zu grob gewählte Auflösung für diese Situation hinweist.

Die Zusammenfassung der topologischen Eigenschaften von Verkehrsgeschehen resultiert in Anforderungen an zukünftige Trajektorienplanungsverfahren. So bestätigt sich eine hohe Komplexität des Trajektorienraums realer Verkehrssituationen mit einer Vielzahl an lokalen Optima, die nicht ausschließlich aus der Situationsgeometrie herrühren. Durch die dadurch bedingte Unzuverlässigkeit sowohl in Bezug auf die nicht gewährleistbare Erreichung irgendeiner kon-

vergierenden Lösung, als auch – sofern sie existiert – deren Qualität, werden iterative Trajektorienplanungsverfahren oder kombinatorische Ansätze als nur bedingt geeignet für die Bewegungsplanungsaufgabe betrachtet, in der für den Serieneinsatz ein Nachweis der Zuverlässigkeit für sicherheitskritische Funktionalitäten noch zu erbringen ist.

6

Beispielanwendungen der Trajektorienpla- nungsverfahren

Die geometrischen und topologischen Betrachtungen in den vorangegangenen Kapiteln 4 und 5 geben Aufschluss über die Beschaffenheit der Trajektorienplanungsaufgabe vollautomatischen Fahrens. Daraus abgeleitete Anforderungen an Planungsalgorithmen führen zu den Trajektorienplanungsmethoden in Kapitel 3 und resultieren als Gesamtprozess im SPARC-Konzept. Obwohl der Fokus der Arbeit vornehmlich auf der theoretischen Analyse der Problembeschreibung liegt, werden in den folgenden Abschnitten Beispielausprägungen der vorgestellten Verfahren zur Trajektorienplanung zum besseren Verständnis gegeben, beginnend mit der Evaluation der zyklischen Implementierung des Gesamtprozesses SPARC in Abschnitt 6.1 am Beispiel des ELM-Algorithmus und weiterführend mit HMM-Anwendungen auf mehrspurige Straßen in Abschnitt 6.2 und zur Generierung von Notfalltrajektorien in Abschnitt 6.3 bis hin zur Erweiterung des SPARC-Konzepts auf die Berücksichtigung von Interaktionen mit dem Ego-Fahrzeug innerhalb der Trajektorienplanung in Abschnitt 6.4.

6.1 Zyklischer Gesamtprozess SPARC

Der in Abschnitt 4.3 beschriebene zyklische Gesamtprozess des SPARC-Konzepts wird in [E5] anhand einer über 11 Sekunden in Videoaufnahmen beobachteten

Beispielsituation betrachtet und mit dem ELM-Verfahren optimiert. Die Abbildungen 6.1 bis 6.3 zeigen die reale Entwicklung der initialen Situation $\mathcal{S}_{\text{start}}$ mit den jeweiligen in die Zukunft prädizierten Situationen \mathcal{S}_t in Form einzelner Pre-Penalty-Volumen $\mathcal{P}_{t_{\text{real}}}$ zu den Zeitpunkten $t_{\text{real}} \in \{0 \text{ s}, 1 \text{ s}, \dots, 10 \text{ s}\}$ und Prädiktionszeiträumen mit $t \in T_p = [1 \text{ s}, 10 \text{ s}]$ nach Gl. (4.26). Die Pre-Penalty-Volumen

$$\mathcal{P}_{t_{\text{real}}}(\mathbf{x}^W, t) = \sum_{i \in \{A, B, C\}} K_i \cdot p_i(\mathcal{E}_{\mathbf{x}^W}^{\text{Bel}} | t, \mathcal{S}_{\text{start}}) \quad (6.1)$$

der einzelnen Zeitpunkte t_{real} bestehen jeweils aus der Summe der Aufenthaltswahrscheinlichkeiten $p_i(\mathcal{E}_{\mathbf{x}^W}^{\text{Bel}} | t, \mathcal{S}_{\text{start}})$ und Schadenskosten K_i nach Gl. (4.23) von drei weiteren Verkehrsteilnehmern mit $i = \{A, B, C\}$, die einen Kreisel mit fünf Ein- und Ausfahrten (I, II, III, IV, V) passieren wollen. Zum Zeitpunkt $t_{\text{real}} = 0 \text{ s}$ befindet sich das Ego-Fahrzeug mit langsamer Geschwindigkeit an der Einfahrt V und plant den Kreisel an der nächstgelegenen Ausfahrt I entlang des grünen Pfads $\bar{\xi}_{\text{Ego}}$ in Abbildung 6.1a zu verlassen.

Pre-Penalty-Volumen

Bei der Berechnung der Aufenthaltswahrscheinlichkeiten anderer Verkehrsteilnehmer über die Kumaraswamyverteilung aus Gl. (4.2.2) wird eine Pfad-Verteilungsfunktion der einzelnen Ausfahrten gemäß

$$p(\bar{\xi}_i) = \begin{cases} 0,3 & \text{wenn } \bar{\xi}_i = \text{I} \\ 0,0 & \text{wenn } \bar{\xi}_i = \text{II} \\ 0,3 & \text{wenn } \bar{\xi}_i = \text{III} \\ 0,1 & \text{wenn } \bar{\xi}_i = \text{IV} \\ 0,3 & \text{wenn } \bar{\xi}_i = \text{V} \end{cases} \quad (6.2)$$

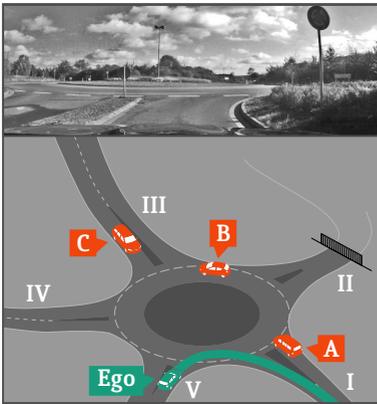
angenommen. Dabei ist Ausfahrt II aufgrund einer permanenten Sperrung Null und Pfad IV eine Zufahrt zu einer Wohngegend und damit gering gewichtet. Die Ausfahrten I, III, V stellen im Gegensatz dazu wichtige Knotenpunkte zu Bundesstraßen und Einkaufszentren dar. Zum Zweck einer besseren Darstellung

werden vollständige Umrundungen des Kreisels in diesem Beispiel nicht modelliert, sodass die zur jeweiligen Einfahrt der einzelnen Verkehrsteilnehmer gehörende Ausfahrtswahrscheinlichkeit an derselben Stelle aus Gl. (6.2) auf die verbleibenden Ausfahrten gleichermaßen aufgeteilt wird. Dies stellt jedoch keine notwendige Vereinfachung der Anwendbarkeit der Algorithmen dar.

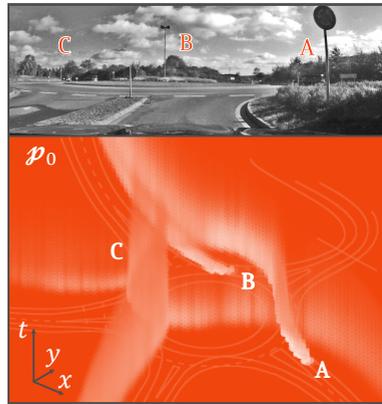
Zu Beginn der Situation zum Zeitpunkt $t_{\text{real}} = 0$ s befindet sich Fahrzeug B bereits im Kreisel, wobei anhand von vorhergehenden Beobachtungen das sichere Verlassen an der nächsten Ausfahrt III bekannt ist. Für die Fahrzeuge A und C werden zu diesem Zeitpunkt mehrere mögliche mit der Verteilung aus Gl. (6.2) gewichtete Pfade modelliert, die innerhalb des Pre-Penalty-Volumens in Verzweigungen resultieren. Zum Zeitpunkt $t_{\text{real}} = 4$ s wird die Intention des Fahrzeugs A deutlich, den Kreisel an Ausfahrt III zu verlassen. Dadurch werden die im vorherigen Zyklus vorhandenen Wahrscheinlichkeiten der Ausfahrtspfade IV und V zu Null aktualisiert, die Aufenthaltswahrscheinlichkeiten für Ausfahrt III maximal und damit in Abbildung 6.2b zu einem Bereich mit deutlich erhöhten Belegungswahrscheinlichkeiten. Für den Verkehrsteilnehmer C ergibt sich eine solche Reduktion der möglichen Pfade zu den Zeitpunkten $t_{\text{real}} = 5$ s und $t_{\text{real}} = 7$ s bis zum sicheren Verlassen des Kreisels über Ausfahrt I. Die Auswirkungen der Pfadreduktionen zu entsprechenden Zeitpunkten sind weiterhin deutlich in Abbildung 6.4 erkennbar.

Trajektorienplanung

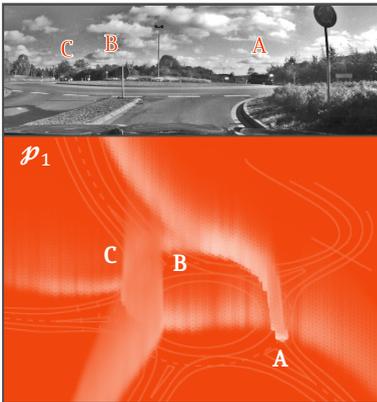
Die zyklische *st*-Planung des ELM-Algorithmus ergibt sich nach Abschnitt 3.5.1 als Schnitt durch das Pre-Penalty-Volumen $\mathcal{P}_{t_{\text{real}}}$ entlang des in Grün markierten Ego-Fahrzeug-Pfads ξ_{Ego} in Abbildung 6.1a und der Penalty-Lagrangefunktion \mathcal{P}_L aus Gleichungen (3.1) und (3.2) mit einer geeigneten Endposition $\mathbf{x}_{\text{end}}^W$ und den jeweiligen Start-Positionen $\mathbf{x}_{\text{start}}^W$ und -Geschwindigkeiten $\dot{\mathbf{x}}_{\text{start}}^W$ des aktuellen Ego-Fahrzeug-Zustands und unter Vernachlässigung der Secondary-Outer-Penaltys $\mathcal{P}_{\text{out}}''$. Die optimale Trajektorie eines Zeitschritts wird als Starttrajektorie des darauffolgenden Zyklus verwendet. In Abbildung 6.4 werden die Planungsergebnisse $\xi(t) \forall t \in [1 \text{ s}, 10 \text{ s}]$ bei $t_{\text{real}} \in \{0 \text{ s}, 2 \text{ s}, \dots, 10 \text{ s}\}$ dargestellt, die sich aufgrund von aktualisierten Situationsinformationen über den Beobachtungszeitraum von 11 Sekunden kontinuierlich anpassen.



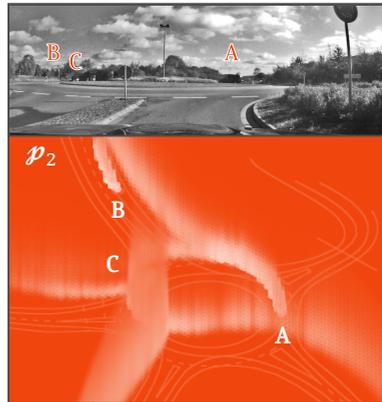
(a) Schematische Darstellung zum Zeitpunkt $t_{\text{real}} = 0$ s. Pfad des Ego-Fahrzeugs ξ_{Ego} zur st -Planung in Grün.



(b) Situation bei $t_{\text{real}} = 0$ s.



(c) Situation bei $t_{\text{real}} = 1$ s.



(d) Situation bei $t_{\text{real}} = 2$ s.

Abbildung 6.1: Evolution des Pre-Penalty-Volumens einer über 11 Sekunden beobachteten Kreiselsituation – 1. Pre-Penalty-Volumen $p_{t_{\text{real}}}$ gegeben drei Verkehrsteilnehmer A, B, C zu unterschiedlichen Zeitpunkten t_{real} nach Gl. (6.1). Darstellung in der \mathbf{x}^W -Ebene mit $\mathbf{x}^W \in X^W \times Y^W$ mit Prädiktionen für $t \in T_p$ als weiße »Wolken« gemäß Koordinatensystem in Abbildung 6.1b. Die Bilddaten zeigen die initiale Situation $\mathcal{S}_{\text{start}}$. Fortsetzung in Abbildungen 6.2 und 6.3.

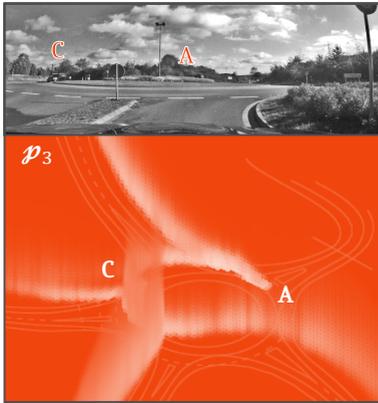
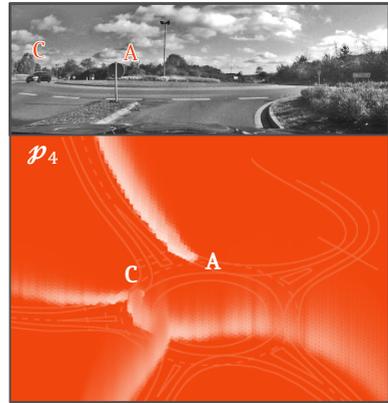
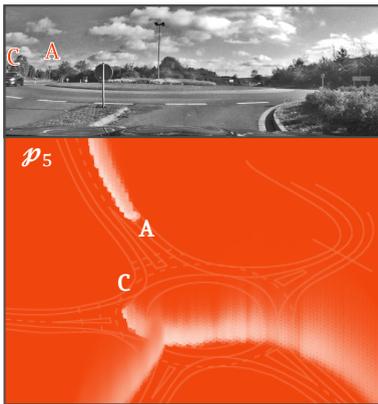
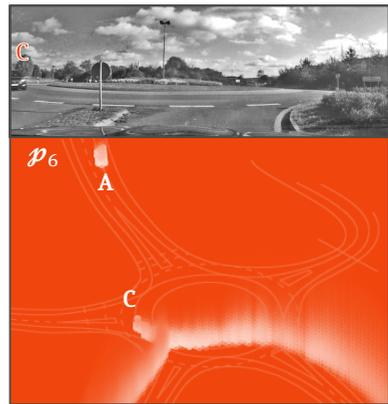
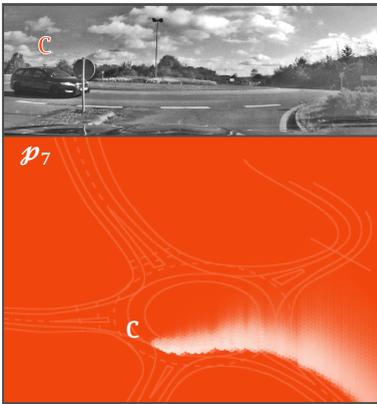
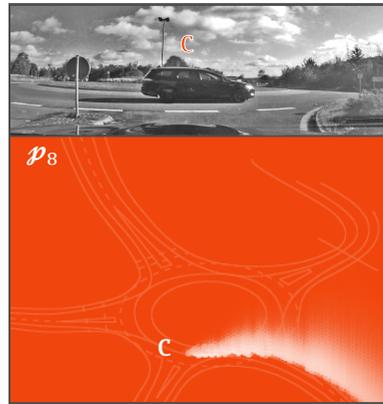
(a) Situation bei $t_{\text{real}} = 3$ s.(b) Situation bei $t_{\text{real}} = 4$ s.(c) Situation bei $t_{\text{real}} = 5$ s.(d) Situation bei $t_{\text{real}} = 6$ s.

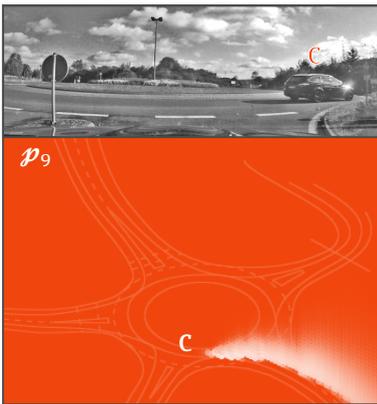
Abbildung 6.2: Evolution des Pre-Penalty-Volumens einer über 11 Sekunden beobachteten Kreiselsituation – 2. Pre-Penalty-Volumen $\mathcal{P}_{t_{\text{real}}}$ gegeben drei Verkehrsteilnehmer A, B, C zu unterschiedlichen Zeitpunkten t_{real} nach Gl. (6.1). Darstellung in der \mathbf{x}^W -Ebene mit $\mathbf{x}^W \in X^W \times Y^W$ mit Prädiktionen für $t \in T_p$ als weiße »Wolken« gemäß Koordinatensystem in Abbildung 6.1b. Die Bilddaten zeigen die initiale Situation $\mathcal{S}_{\text{start}}$. Fortsetzung aus Abbildung 6.1 sowie in Abbildung 6.3.



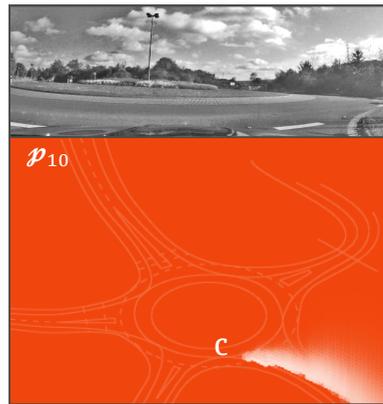
(a) Situation bei $t_{\text{real}} = 7$ s.



(b) Situation bei $t_{\text{real}} = 8$ s.



(c) Situation bei $t_{\text{real}} = 9$ s.



(d) Situation bei $t_{\text{real}} = 10$ s.

Abbildung 6.3: Evolution des Pre-Penalty-Volumens einer über 11 Sekunden beobachteten Kreiselsituation – 3. Pre-Penalty-Volumen $\mathcal{P}_{t_{\text{real}}}$ gegeben drei Verkehrsteilnehmer A, B, C zu unterschiedlichen Zeitpunkten t_{real} nach Gl. (6.1). Darstellung in der \mathbf{x}^W -Ebene mit $\mathbf{x}^W \in X^W \times Y^W$ mit Prädiktionen für $t \in T_p$ als weiße »Wolken« gemäß Koordinatensystem in Abbildung 6.1b. Die Bilddaten zeigen die initiale Situation $\mathcal{S}_{\text{start}}$. Fortsetzung aus Abbildungen 6.1 und 6.2.

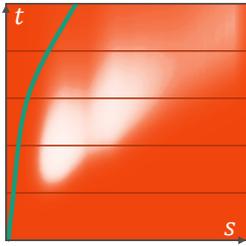
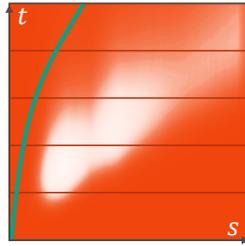
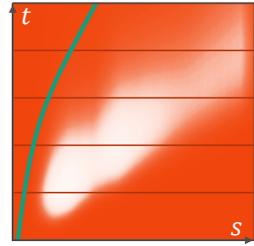
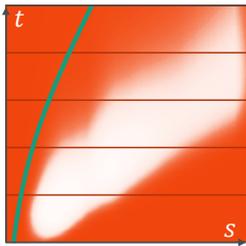
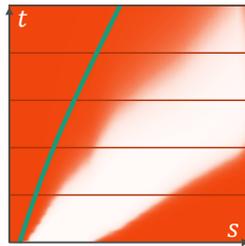
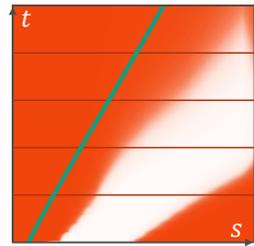
(a) Planung bei $t_{\text{real}} = 0$ s.(b) Planung bei $t_{\text{real}} = 2$ s.(c) Planung bei $t_{\text{real}} = 4$ s.(d) Planung bei $t_{\text{real}} = 6$ s.(e) Planung bei $t_{\text{real}} = 8$ s.(f) Planung bei $t_{\text{real}} = 10$ s.

Abbildung 6.4: Zyklische Trajektorienplanung einer über 11 Sekunden beobachteten Kreiselsituation. ELM-Ergebnisstrajektorien ξ_{ELM}^* für die in Abbildungen 6.1 bis 6.3 dargestellten Pre-Penalty-Volumen $\mathcal{P}_{t_{\text{real}}}$.

Trotz eines leeren Kreisels an der Einfahrt **V** während der nächsten 2,5 Sekunden – erkennbar an den durchgehend roten ersten Ebenen – ergibt sich die optimale Trajektorie zum Zeitpunkt $t_{\text{real}} = 0$ s aufgrund der geringen Startgeschwindigkeit des Ego-Fahrzeugs und der Berücksichtigung des Komforts als eine langsame Annäherung an die Kreiselleinfahrt **V** – erkennbar als leichte Startkrümmung – und einem verzögerten Kreiseleintritt hinter den Fahrzeugen **A** und **C** zum Prädiktionszeitpunkt $t = 7$ s. Eine höhere Startgeschwindigkeit würde in einem direkten Passieren des Kreisels noch vor den anderen Verkehrsteilnehmern resultieren.

Während der darauffolgenden Zeitpunkte t_{real} berechnet sich die optimale Trajektorie entsprechend ähnlich mit kontinuierlich »herannahendem« prädierten Eintrittszeitpunkt t des Ego-Fahrzeugs in den Kreisel – erkennbar als Steigungsänderung der Trajektorie – bis zum Zeitpunkt $t_{\text{real}} = 8$ s das Fahrzeug **C**

die Einfahrt V passiert und die Trajektorienplanung nun eine Beschleunigung auf eine konstante Geschwindigkeit vorsieht – erkennbar als konstante Steigung in $t_{\text{real}} = 10$ s.

Durch den Anstieg an Unsicherheiten in der Zukunft ergibt sich eine verringere Geschwindigkeit der geplanten Trajektorie im Vergleich zur erwarteten Geschwindigkeit von C – erkennbar an der abweichenden Steigung der Trajektorie in Hinblick auf die mittlere Steigung der Prädiktionswolke. Unter Berücksichtigung zukünftiger Sensorinformationen kann die Geschwindigkeit des Ego-Fahrzeugs an das reale Fahrverhalten des Fahrzeugs C angepasst werden.

6.2 Globale Trajektorienplanung für mehrspurige Straßen

Neben der Berechnung der global optimalen Lösung der vollständigen Problemformulierung über das korrespondierende HMM-Verfahren können bei einer Implementierung des SPARC-Konzepts unter Verwendung des HMM-Ansatzes zusätzliche Anforderungen an die Ego-Fahrzeug-Trajektorie durch eine geeignete Modellierung des HMM-Zustandsraums integriert werden, deren Umsetzung innerhalb der ELM-Algorithmik mit hohem Aufwand verbunden wäre.

Als Beispiel hierfür wird das HMM-Verfahren in [E7] auf mehrspurige Straßen angewendet und eine gezielte Reduktion des Lösungsraums auf »erwünschtes Fahrverhalten« hergeleitet. Die Berechnung der Trajektorie $\xi = \xi_{\text{HMM}}$ ergibt sich mit der Penalty-Lagrangefunktion gemäß Gl. (3.1) mit Gl. (3.2) und den Nebenbedingungen nach Gl. (3.4) unter Verwendung des Penalty-Viterbi-Algorithmus aus Abschnitt 3.5.3.

Modellierung

Für die Trajektorienplanung auf mehrspurigen Straßen werden zwei Arten von HMM-Zuständen eingeführt, die in Abbildung 6.5 als Zustandsübergangsgraph unter Vernachlässigung der Prädiktionskomponente t dargestellt werden.

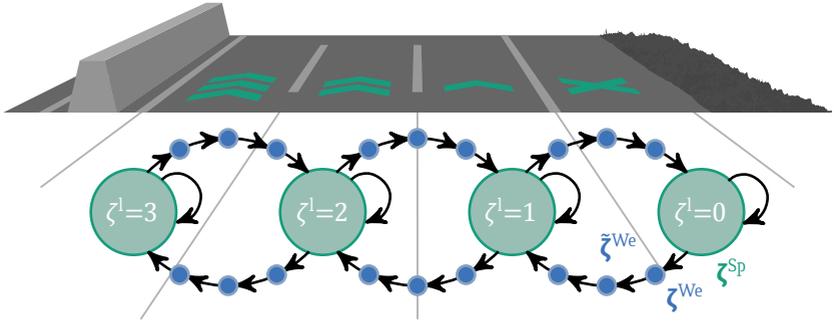


Abbildung 6.5: HMM-Zustandsraum für mehrspurige Straßen. Das HMM besteht aus zwei Arten von Zuständen. Grüne Kreise beschreiben Spurzustände ζ^{Sp} und blaue Kreise beschreiben Wechselzustände ζ^{We} . Ein Fahrspurwechsel wird über die deterministische Kette ζ^{We} beschrieben.

Die erste Zustandsart – der Spurzustand¹ ζ^{Sp} – ergibt sich aus der in Gl. (5.1) eingeführten Zustandsbeschreibung der *st*-Planung mit $s \in S^{\text{W}}$ gemäß Gl. (2.7) als Bogenlänge entlang des Fahrstreifens in Kombination mit einer dazu orthogonalen Zustandskomponente zur Beschreibung des Fahrstreifens. Die Erweiterung des *st*-Planungs-Zustandsraums mit einer lateralen Fahrstreifenkomponente resultiert in einer reduzierten *xyt*-Planung mit einem Spurzustand gemäß

$$\zeta_t^{\text{Sp}} = \begin{bmatrix} \zeta_t^s \\ \zeta_t^l \\ \zeta_t^1 \end{bmatrix} = \begin{bmatrix} \xi_s(t) \\ \dot{\xi}_s(t) \\ \zeta_t^1 \end{bmatrix} \quad (6.3)$$

Die Fahrstreifenkomponente ergibt sich dabei zu

$$\zeta^1 \in \{0, 1, \dots, L\} \quad (6.4)$$

mit »0« für den nicht zur Fahrbahn zählenden ↯Seitenstreifen (siehe [47]), dem benachbarten Fahrstreifen »1« für Fahrzeuge langsamer Geschwindigkeit bis hin zum für Überholmanöver verwendeten Fahrstreifen »L« (bei Rechts-

¹ Hier wird abweichend zur Begrifflichkeit ↯Fahrstreifen das Wort »Spur« aufgrund der Bezeichnung als »mehrspurige« Straße beibehalten.

verkehr der linke Fahrstreifen, entsprechend die »äußerste Überholspur«²). Die Geschwindigkeitskomponente ζ^s ergibt sich entlang des Fahrstreifens zur Integration der Nebenbedingungen zu

$$\zeta^s \in [v_{\min}, v_{\max}]. \quad (6.5)$$

Die Modellierung eines *Fahrspurwechsels*³ wird durch die zweite Zustandsart – die *Wechselzustände* ζ^{We} – beschrieben, die »unerwünschtes Fahrverhalten« ausschließen. In Abbildung 6.6 sind zulässige (A bis C) und unzulässige Manöver (D) dargestellt. Die Beschränkung des Fahrverhaltens führt dazu, dass das Ego-Fahrzeug

- einen Spurwechsel nur in bestimmten, klar definierten Situationen durchführt (Überholvorgang, Spurwechsel zur Abbiegerspur, etc.),
- einen »standardisierten« Spurwechsel durchführt,
- nicht auf der *Fahrsreifenmarkierung* verweilt und
- die Fahrsreifenmarkierung nicht lediglich anschneidet.

Je nach Rechenleistung sind unterschiedlich komplexe Definitionen der Wechselzustände möglich. Zur weiteren Reduktion des Zustandsraums wird eine Modellierung des Wechselzustands ζ^{We} vorgeschlagen mit einer Komponente, die den HMM-Startzustand zum Wechselbeginn $t_{\text{We,Start}}$ beschreibt $\zeta^{\text{Start}} = \zeta_{t_{\text{We,Start}}}^{\text{Sp}}$, einer Komponente $\zeta^{\text{Richt}} \in \{\text{Rechts, Links}\}$, die die Wechselrichtung modelliert und einem Zustandswechselzählparameter $\zeta^{\text{Num}} \in \mathbb{N}$

$$\zeta_t^{\text{We}} = \begin{bmatrix} \zeta_t^{\text{Start}} \\ \zeta_t^{\text{Richt}} \\ \zeta_t^{\text{Num}} \end{bmatrix}. \quad (6.6)$$

Ein vollständiger Fahrspurwechsel innerhalb des Wechselintervalls

$$T_{\text{We}} = [t_{\text{We,Start}}, t_{\text{We,End}}] \subset T \quad (6.7)$$

² Die umständliche Umschreibung der Fahrsreifen ist der universellen Anwendbarkeit auf Rechts- und Linksverkehr geschuldet.

³ Entsprechend der Umgangssprache wird ein korrekterweise bezeichneter Fahrsreifenwechsel im Weiteren als Fahrspurwechsel bezeichnet.

muss in einem Spurzustand ζ^{Sp} eines benachbarten Fahrstreifens terminieren. Da dieser Endzustand ζ^{End} nicht als Bestandteil des Wechselzustands ζ^{We} in Gl. (6.6) modelliert wird, muss der Endzustand eindeutig über den Wechselzustand beschrieben sein. Dies geschieht durch die Definition einer deterministischen Kette $\tilde{\zeta}^{\text{We}}$ an aufeinanderfolgenden Wechselzuständen $\zeta_t^{\text{We}} \forall t \in T_{\text{We}}$ mit aufsteigendem ζ^{Num} , die in einem festen Endzustand $\zeta^{\text{End}} = \zeta_{t_{\text{We,End}}}^{\text{Sp}}$ terminiert⁴. Die Anzahl an Wechselzuständen und entsprechend die Größe des Wechselintervalls aus Gl. (6.7) orientieren sich dabei an der realen Zeit, die ein Fahrspurwechsel benötigt. Auf diese Weise kann das vollständige Spurwechselmanöver mit festen – und geeignet hohen – Penaltys und einer festen Intervallgröße zur Durchführung belegt werden.

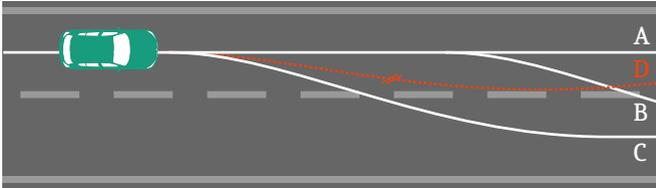


Abbildung 6.6: *Erwünschtes und unerwünschtes Fahrverhalten auf mehrspurigen Straßen.* Die Manöver A bis C stellen ein erwünschtes Fahrverhalten dar, wohingegen D ein unzulässiges Manöver beschreibt.

Durch die deterministische Zustandskette $\tilde{\zeta}^{\text{We}}$ werden zudem Trajektorien ausgeschlossen, die ein Wechselmanöver mit einem planmäßigen Abbruch innerhalb des betrachteten Prädiktionszeitraums T_p nach Gl. (4.26) vorsehen. Diese Einschränkung stellt die Notwendigkeit der Fertigstellung eines geplanten Wechselmanövers dar, im Gegensatz zu einem bereits begonnenen. Um jedoch auf unerwartete Situationen während eines begonnenen Wechselmanövers reagieren zu können, ist ein Abbruch aus der deterministischen Zustandskette heraus jederzeit möglich.

Die unterschiedlichen Arten der HMM-Zustände zeichnen sich demnach über unterschiedliche Transitionsmöglichkeiten aus, wie in Abbildung 6.7 dargestellt

⁴ Die Position des Ego-Fahrzeug während des Fahrstreifenwechsels ist durch den deterministischen Charakter eindeutig definiert, sodass dieser auch nicht innerhalb ζ^{We} modelliert werden muss.

wird. Spurzustände ζ^{SP} können entweder in einen neuen Spurzustand wechseln oder in eine vollständige Wechselkette ζ^{We} , die bis zum endenden Spurzustand $\zeta_{t_{\text{We,End}}}^{\text{SP}}$ durchlaufen werden muss. Im Gegensatz dazu können Wechselzustände ζ^{We} entweder in der deterministischen Kette verbleiben und im Endzustand terminieren, oder können im Hindernisfall in den ursprünglichen Spurzustand zurückkehren. Der Abbruch kann dabei wiederum durch eine deterministische Kette beschrieben werden und sollte mit einer geeignet hohen Penalty behaftet sein, um unnötigen Abbrüchen entgegenzuwirken.

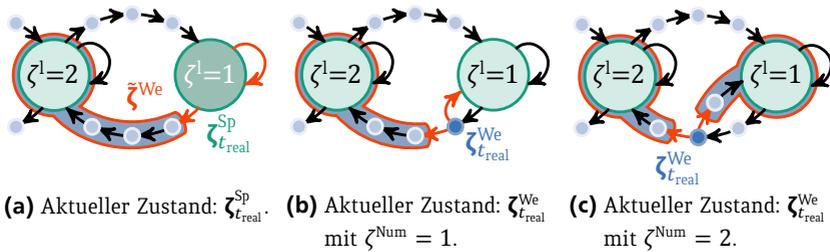


Abbildung 6.7: Transitionsmöglichkeiten der HMM-Zustandsarten mehrspuriger Straßen. Grüne Kreise beschreiben Spurzustände ζ^{SP} , blaue Kreise Wechselzustände ζ^{We} . Deterministische Wechselketten ζ^{We} werden mit rot umrandetem Schlauch dargestellt. Der dunkle Zustand stellt den aktuellen Zustand zum Zeitpunkt t_{real} dar. Die Pfeile beschreiben die Transitionsmöglichkeiten zu t_{real} .

Evaluation

Das für mehrspurige Straßen vorgeschlagene HMM wird anhand einer in Luftbildern beobachteten Beispielsituation eines Überholmanövers evaluiert. Ein weiteres Überholmanöver ist in [E7] zu finden. Abbildung 6.8 zeigt Luftbilder mit einer Bodenauflösung von etwa 0,5 Metern pro Bildpixel (m/pxl) und einer Aufzeichnungsrate von 25 Bildern pro Sekunde (FPS). Dargestellt ist jedes 15-te Bild, entsprechend im Zeitabstand von etwa 0,6 Sekunden. In der Situation befinden sich insgesamt vier relevante Fahrzeuge A,B,C und e, wobei e im Laufe der beobachteten Situation (in den Bildern 7 bis 13) ein Überholmanöver durchführt. Daher wird das Fahrzeug e im Weiteren als Ego-Fahrzeug ange-

nommen, eine *einmalige fiktive Trajektorienplanung* zum dargestellten Zeitpunkt von Bild 1 durchgeführt und die sich ergebene Trajektorie ξ mit der realen Evolution der Situation zu den anschließenden Zeitpunkten verglichen. Aufgrund der fehlenden Möglichkeit zur Steuerung des realen Fahrzeugs e wird auf eine zyklische Neuplanung innerhalb des betrachteten Zeitraums verzichtet. Erste Anhaltspunkte einer solchen Evaluation des zyklischen Gesamtprozesses sind im vorherigen Abschnitt 6.1 gegeben, stellen jedoch durch die nun geschaffene Möglichkeit zur Integration des SPARC-Algorithmus in die VERTEX-Fahrzeuge relevante, an diese Arbeit anschließende Aufgabestellungen dar.

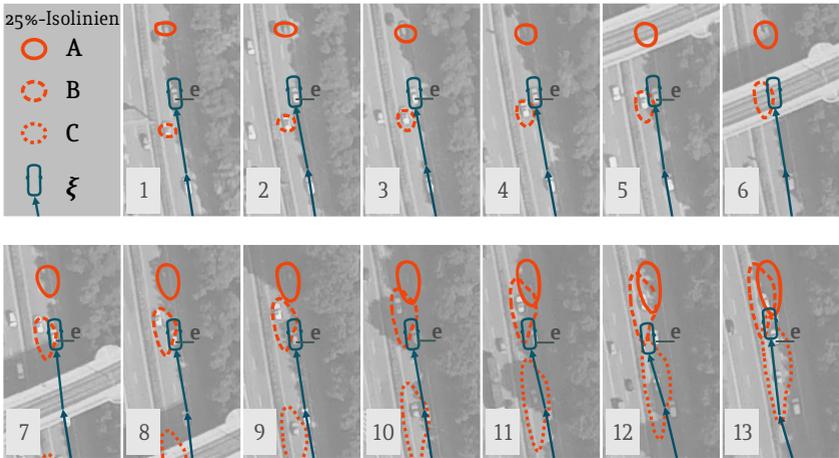


Abbildung 6.8: Trajektorienplanung eines Überholvorgangs. In Rot sind die 25%-Isolinien der prädizierten Aufenthaltswahrscheinlichkeiten der beteiligten Verkehrsteilnehmer A–C dargestellt. Blau zeigt die einmalig zum Zeitpunkt von Bild 1 geplante Trajektorie ξ zu einzelnen Prädiktszeitpunkten $t \in T_p$.

Die Aufenthaltswahrscheinlichkeiten $p_i(\mathcal{E}_{x_w}^{\text{Bel}}|t)$ der Fahrzeuge $i \in \{A, B, C\}$ werden entsprechend Abschnitt 4.2 mit der Kumaraswamyverteilung berechnet – die anhand früherer Informationen über die Verkehrsteilnehmer in den Luftbildern parametrisiert wird – und werden in Form einer »25%-Isolinie« bei einem Abfall auf 25% des maximalen Wahrscheinlichkeitswerts der jeweiligen Verteilung dargestellt. Die laterale Asymmetrie der Verteilungsfunktion

beschreibt dabei die modellierte Spurwechselwahrscheinlichkeit eines anderen Verkehrsteilnehmers.

Das Fahrzeug e plant einen Überholvorgang des Fahrzeugs A unter Berücksichtigung der Fahrzeuge B und C , die sich mit einer höheren Geschwindigkeit auf der Überholspur befinden. Sowohl die zu Beginn geplante Trajektorie ξ – dargestellt in Blau – als auch der reale Fahrer des Fahrzeugs e – in den Luftbildern – entscheiden sich für einen Spurwechsel auf die Überholspur hinter B und vor C . Der Vergleich zwischen der realen Evolution der beobachteten Situation und der einmalig geplanten Trajektorie weist dennoch einige Unterschiede auf. Zur Vorbereitung des Spurwechsels verlangsamt der HMM-Algorithmus die Geschwindigkeit kontinuierlich, um maximalen Komfort für die Insassen zu gewährleisten, wohingegen der menschliche Fahrer in den Luftbildern die Geschwindigkeit erst kurz vor Beginn des Überholmanövers verringert. Zudem startet der menschliche Fahrer das Überholmanöver im Vergleich zur geplanten Trajektorie unnötig verspätet, sodass sich ein erhöhtes Unfallrisiko mit dem herannahenden Fahrzeug C ergibt.

Die Evaluation legt vergleichbare Manöverentscheidungen nahe, wobei sich andeutet, dass die HMM-Trajektorienplanung eine für Insassen komfortablere Lösung unter Einhaltung höherer Sicherheitsabstände innerhalb der betrachteten Situation bietet.

6.3 Notfalltrajektorienplanung

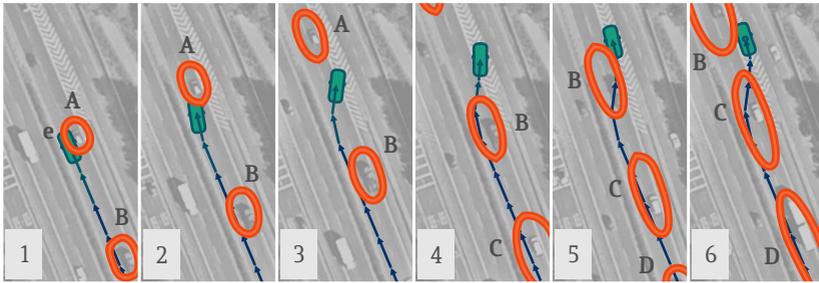
Mithilfe des HMM-Verfahrens aus Abschnitt 3.4 kann neben der Bewegungsplanung des *Normalbetriebs* ξ in jedem Zeitschritt ohne nennenswerte Rechenzeiterhöhung eine zusätzliche *Notfalltrajektorie* ξ_{Emerg} berechnet werden, die im Fall eines Sensor- oder Rechnerausfalls zur reinen Steuerung des Ego-Fahrzeugs herangezogen wird. Bei einem solchen Systemausfall – ungeachtet, ob es sich um einen Fehler bei der Bereitstellung der neuen Datenbasis oder um einen Defekt in der Planungshardware handelt – ist keine Neuplanung der Trajektorie mehr möglich. Durch den vergleichsweise langen Planungshorizont des SPARC-Konzepts kann jedoch auch in einem solchen Fall ein Manöver basierend

auf dem letzten »gültigen« Planungsstand durch das Ego-Fahrzeug ausgeführt werden. Hierfür muss im Vorhinein in jedem funktionsfähigen Zyklus eine zusätzliche Notfalltrajektorie mitberechnet werden, die – von einem ausfallsicheren Register aus – bei einem Komponentenausfall »blind« als Steuerung auf die Aktuatorik gegeben werden kann.

Zur Verdeutlichung der Anwendung wird in [E7] die HMM-Zustandsraummodellierung für mehrspurige Straßen des vorherigen Abschnitts 6.2 um die Planung von Notfalltrajektorien erweitert, die das Ego-Fahrzeug unter Verwendung der letzten validen Sensor- und Prädiktionsinformationen in einen *sicheren Fahrzeugzustand* überführt. Durch die Berechnung aller Penaltys des vollständigen HMM-Zustandsraums für den Normalbetrieb ist lediglich ein weiterer, rechenaufwandsarmer Backtrackingprozess gemäß Algorithmus 3.1 zur Berechnung der Notfalltrajektorie nötig, beginnend von einem sicheren HMM-Endzustand ξ_N^{Emerg} , der sich aus einer vom Normalbetrieb abweichenden Bewertung mit einer Notfall-Penalty-Funktion $\mathcal{P}_{\text{emerg}}$ ergibt und beispielsweise einen Stillstand auf dem Seitenstreifen oder anderweitigem befahrbaren Straßennebenbereich aus Abschnitt 4.2.1 beschreibt.

Evaluation

Das in Abbildung 6.9a in Luftbildern beobachtete bereits begonnene Überholmanöver auf der mehrspurigen Karlsruher Südtangente B10 in der Nähe der Ausfahrt »Rastatt Mühlburg« zeigt eine Situation mit vier relevanten Verkehrsteilnehmern A, B, C und e. Wie bereits im vorherigen Abschnitt 6.2 wird zum Zeitpunkt von Bild 1 eine fiktive Trajektorienplanung für das Fahrzeug e durchgeführt. Zusätzlich wird zum Startzeitpunkt ein vollständiger Systemausfall angenommen und somit die entsprechende Notfalltrajektorie ξ_{Emerg} – geplant zum Zeitpunkt von Bild 1 – analysiert und mit der beobachteten Evolution der Situation verglichen. Die Aufenthaltswahrscheinlichkeiten der anderen Fahrzeuge sind wiederum als 25%-Isolinien dargestellt. Das reale Ego-Fahrzeug e wird nicht weiter betrachtet. Abbildung 6.9b zeigt die nachgestellte Situation nach erfolgreicher Durchführung des Notfallmanövers.



(a) Luftbilder des Überholmanövers mit geplanter HMM-Notfalltrajektorie ξ_{Emerg} . Das beobachtete Fahrzeug e ist zum besseren Verständnis wegetuschiert.



(b) Nachgestellte Situation nach Beendigung des Notfallmanövers.

Abbildung 6.9: HMM-Trajektorienplanung einer Notfalltrajektorie. Ein Systemausfall führt zur blauen Notfalltrajektorie ξ_{Emerg} , die auf einer Verkehrsinsel zu stehen kommt. In Rot sind die 25%-Isolinien der Aufenthaltswahrscheinlichkeiten der Fahrzeuge A–D dargestellt.

Als sicherer Endzustand ξ_N^{Emerg} ergibt sich ein Stillstand auf der nahegelegenen Verkehrsinsel, sodass die HMM-Notfalltrajektorie ξ_{Emerg} mit einer leichten Bremsung zunächst zu einem Abbruch des bereits begonnenen Überholmanövers führt, um zwischen den Fahrzeugen A und B hindurch auf den Seitenstreifen und die Verkehrsinsel zu gelangen ohne Behinderung von C. Dadurch ergibt sich eine Notfalltrajektorie mit kontinuierlich sinkender Geschwindigkeit und ohne Befahrung von Positionen mit hohen Aufenthaltswahrscheinlichkeiten anderer Fahrzeuge. Die Trajektorie beschreibt damit die intuitive Auflösung dieser Notfallsituation.

6.4 Interaktion mit Verkehrsteilnehmern – Progressively Interacting Trajectories

Menschliche Fahrer treffen im heutigen Straßenverkehr oftmals Manöverentscheidungen, die die Reaktion anderer Verkehrsteilnehmer auf das eigens ausgeführte Manöver in die Planung miteinbeziehen. Oftmals sind Manöver notwendig, die eine *Interaktion* anderer Verkehrsteilnehmer zwingend voraussetzen, um am Verkehrsgeschehen teilnehmen zu können. Ein klassisches Beispiel sind Einschermanöver in den fließenden Verkehr in kleine Lücken, wie in Abbildung 6.11 dargestellt, die die Kooperation des hinteren Fahrzeugs in Form eines Bremsmanövers zur erneuten Herstellung des Sicherheitsabstands voraussetzen. Daneben zeigt Abbildung 6.10 zur Verdeutlichung der Problematik ein typisches Ausparkmanöver in den fließenden Verkehr, wobei Abbildung 6.10a die Situation ohne aktive Beeinflussung und Abbildung 6.10b die Situation unter gezielter Beeinflussung des Fahrverhaltens der anderen Verkehrsteilnehmer darstellt. Ohne erzwungene Interaktion ist das Verlassen der Parklücke für das grüne Fahrzeug innerhalb des betrachteten Zeitraums nicht realisierbar.

Reaktive SPARC-Trajektorienplanung

Zur Berücksichtigung von Interaktionen bedarf es geeigneter Modelle, die die Reaktion anderer Verkehrsteilnehmer auf das eigene Verhalten beschreiben. Daneben resultiert die Einbeziehung von Interaktion in einer drastischen Vergrößerung des Lösungsraums der Trajektorienplanung, da zusätzlich entsprechende Reaktionsmöglichkeiten betrachtet und etwa über die Penalty-Lagrangefunktion in Gl. (3.1) bewertet werden müssen. Aktuelle Ansätze aus Abschnitt 1.2 – sowie auch das klassische SPARC-Konzept – vernachlässigen daher die explizite Modellierung von Interaktionen vollständig. Wie für SPARC in Abschnitt 4.3 beschrieben, ergibt sich durch die zyklische Neuplanung mit geeignet hoher Aktualisierungsrate mancher Ansätze dennoch eine implizite Einbeziehung von Interaktionen, die jedoch einen rein reaktiven Charakter aufweist. Reaktionen anderer Verkehrsteilnehmer auf eigene Manöver fließen implizit in die Planung

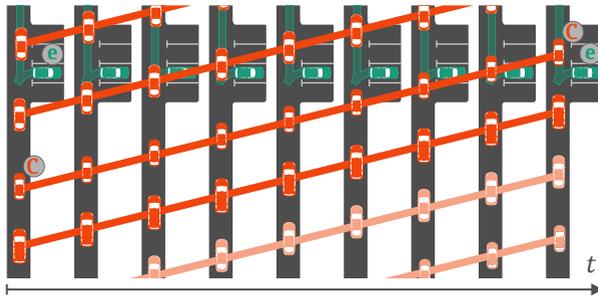
ein, indem der folgende Zyklus mit den bereits erkennbaren Reaktionen eine darauf angepasste Trajektorie plant.

Abbildung 6.11 zeigt einen Einfädelvorgang über ein *Reißverschlussverfahren*. Aufgrund fehlender geeigneter Lücken für eine Einfahrt in den fließenden Verkehr ohne Beeinträchtigung anderer Verkehrsteilnehmer plant das Ego-Fahrzeug mit reaktivem SPARC zunächst in Abbildung 6.11a eine Verringerung der Geschwindigkeit. Ein (kooperativer) menschlicher Fahrer in C lässt eine Lücke entstehen, die innerhalb anschließender Planungszyklen in Abbildung 6.11b für eine reaktive SPARC-Trajektorienplanung verwendet werden kann.

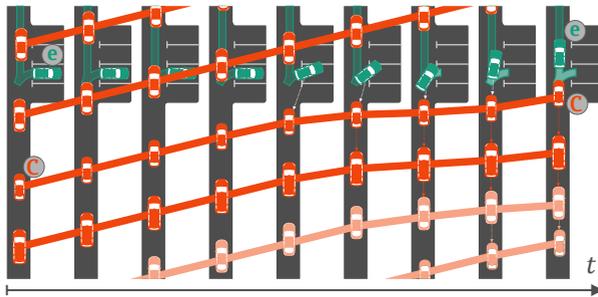
Vollständige Problemformulierung der Interaktionsplanung

Im Folgenden wird eine kurze und intuitive Einführung in die Modellierung der *Interaktionsplanung* gegeben und zum besseren Verständnis direkt auf die HMM-Planung angewendet. Eine vollständige mathematische Herleitung der allgemeinen ELM-Problemformulierung zur Berücksichtigung von Reaktionen auf geplante Handlungen wird in [E11] gegeben.

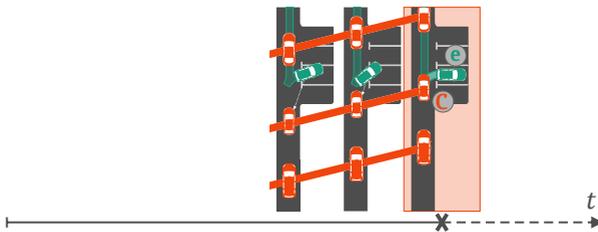
Zur Interaktionsplanung wird der Lösungsraum der Trajektorienplanung erweitert, indem für jeden Zustand ζ_t gemäß Gl. (3.16) und für jeden Planungszeitpunkt $t \in T_p$ gemäß Gl. (4.26) eine neue Situationsprädiktion $\mathcal{S}^{\zeta_t}(t)$ – mit einem neuen Pre-Penalty-Volumen \mathcal{P}^{ζ_t} – berechnet wird. Während bei der ursprünglichen SPARC-Modellierung ein einziges Pre-Penalty-Volumen \mathcal{P} ausreichend ist, ergeben sich in einem vollständigen Modell zur Interaktionsplanung $|Z|^{|\mathcal{T}_p|}$ Pre-Penalty-Volumen mit der Größe des HMM-Zustandsraums $|Z|$ und des Prädiktionsintervalls $|\mathcal{T}_p|$, da durch die eindeutige Bestimmung der Startposition des Ego-Fahrzeugs lediglich ein Pre-Penalty-Volumen $\mathcal{P}^{\zeta_{t_{\text{real}}}}$ für $t = t_{\text{real}}$ existiert. Dies führt zu einer Rechenzeit von $\text{TIME}\left(\left(\prod_{i \in S} |R_i|\right)^{|\mathcal{T}_p|}\right)$ als untere Schranke der Rechenzeit aller Pre-Penalty-Volumen bei einer vollständigen Berechnung aller Reaktionen R_i von $i \in S$ Verkehrsteilnehmern. Zusammen mit der entsprechend erweiterten Trajektorienplanung mit $\text{TIME}\left(|Z|^{|\mathcal{T}_p|}\right)$ ist das vollständige Modell der Interaktionsplanung als Echtzeitanwendung somit praktisch nicht realisierbar.



(a) PITRA-Variante 1: Ausparkmanöver ohne aktive Beeinflussung.

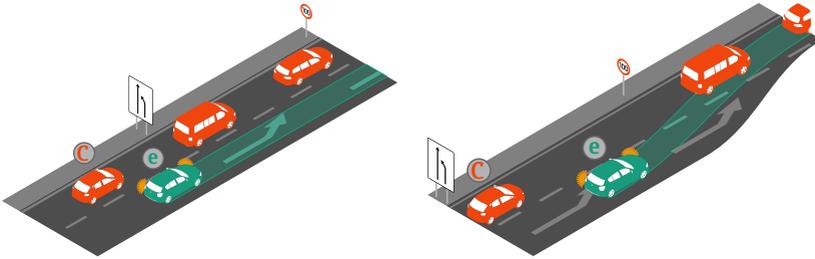


(b) PITRA-Variante 2: Ausparkmanöver mit aktiver Beeinflussung.



(c) PITRA-Variante 3: Wird wegen (a) von PITRA-Heuristik verworfen.

Abbildung 6.10: *PITRA-Planungsvarianten eines Ausparkmanövers.* (a) zeigt die Prädiktion ohne aktive Beeinflussung, wie sie auch im klassischen SPARC vorkommt. (b) zeigt das Manöver unter aktiver Beeinflussung des Verkehrs, sodass C ein Bremsmanöver ausführt. Diese Variante wird in der Prädiktion des klassischen SPARC nicht berücksichtigt. (c) zeigt die Variante, die durch die PITRA-Heuristik aufgrund identischen Zustands zu (a) verworfen wird.



- (a) Aufgrund fehlender Lücken plant das Ego-Fahrzeug e kein Einfädelmanöver.
 (b) Durch die Reaktion von C auf den Einfädelwunsch entsteht eine Lücke, die nun von dem Ego-Fahrzeug e in die Planung miteinbezogen wird.

Abbildung 6.11: *Reaktive Interaktion des SPARC-Konzepts.* Durch stetiges Neuplanen ergibt sich mit SPARC (grünes Ego-Fahrzeug) eine Interaktion, die durch die Aktualisierung der Situationsprädiktion eine Rückmeldung der Reaktionen anderer Verkehrsteilnehmer auf die vorangegangene eigene Manöverentscheidung bedeutet.

PITRA-Modell als interaktive SPARC-Erweiterung

Das PITRA-Modell (Progressively Interacting Trajectories) als eine Erweiterung des SPARC-Konzepts auf Interaktionsplanung stellt eine Vereinfachung der vollständigen Problembeschreibung dar und resultiert aus einer an dynamische Programmierung angelehnten *Heuristik* zur Reduktion des Lösungsraums. Hierfür wird jedem Zustand ζ_t jenes Pre-Penalty-Volumen zuordnet, das zur optimalen Zustandsfolge $\bar{\zeta}_t^*$ gemäß Gl. (2.70) für das vorangegangene Prädiktionsintervall $[t_{\text{start}}, t]$ mit ζ_t als Endzustand führt.

Mit der bereits in Algorithmus 3.1 verwendeten Substitution $t = t_{\text{start}} + \tau \cdot \Delta t$ mit $\tau \in \mathbb{N}$ wird – unter Erweiterung des Penalty-Viterbi-Algorithmus – zunächst für einen Zustand ζ_τ der beste Vorgängerzustand $\zeta_{\tau-1}^*$ über die Minimierung von Vorgänger- und Übergangspenaltys gesucht. Die unterschiedlichen Pre-Penalty-Volumen $\mathcal{P}_k^{\zeta_{\tau-1}}$ der betrachteten Vorgängerzustände $\zeta_{\tau-1}^k$ mit $k \in \mathbb{N}$ fließen lediglich indirekt über die Bewertung mit der Penalty-Lagrangefunktion \mathcal{P}_L aus Gl. (3.1) ein, die das jeweilige Pre-Penalty-Volumen $\mathcal{P}_k^{\zeta_{\tau-1}}$ verwendet.

Das Pre-Penalty-Volumen des besten Vorgängers $\zeta_{\tau-1}^*$ wird dem betrachteten Zustand ζ_τ zugeordnet und gegeben der Prädiktions- und Interaktionsmodelle für den daran anschließenden Prädiktionszeitschritt $\tau + 1$ weiterentwickelt.

Die beschriebene Heuristik zur Zustandsraumreduktion führt zur Verwerfung aller Pre-Penalty-Volumen, deren Zustände ζ_τ zum Zeitpunkt τ nicht in einem minimalen Penaltywert resultieren, sodass vereinfachend angenommen wird, dass nichtoptimale Situationen zum Zeitpunkt τ auch zu keinem späteren Zeitpunkt entsprechend eine Optimalität erlangen. Strategische Langzeitpläne, deren Optimalität erst zu späteren Zeitpunkten deutlich wird, sind demnach über das PITRA-Modell nicht modellierbar.

Die Rechenzeit der Trajektorienplanung – ohne Betrachtung der Prädiktionsberechnung – mit dem PITRA-Modell ergibt sich wiederum entsprechend des Penalty-Viterbi-Algorithmus gemäß Tabelle 3.1 als $\text{TIME}(|T_d| \cdot |Z| \cdot |\dot{Z}|)$ mit \dot{Z} als Zustandsübergangsraum und der Anzahl an Zeitschritten $T_d = T_p + 1$.

Zur Verdeutlichung des Ansatzes wird in Abbildung 6.12 das PITRA-Modell an einer Beispielsituation dargestellt, in der das Ego-Fahrzeug in Grün einem Lastwagen A auf einer mehrspurigen Straße folgt und ein weiterer Verkehrsteilnehmer B die Auffahrt auf die beiden zur Verfügung stehenden Fahrstreifen der Ego-Fahrzeug-Fahrtrichtung plant. Die dargestellten Fahrzeuge beschreiben dabei die mit der Kumaraswamyverteilung nach Abschnitt 4.2 berechneten Positionserwartungswerte. Innerhalb des PITRA-Modells ergeben sich nun mehrere Varianten der Situationsevolution zum Zeitpunkt $t \in T_p$ und entsprechende geplante Trajektorien, dargestellt als horizontale grüne Schläuche auf der Asphalteebene:

- Variante I: Das Ego-Fahrzeug bleibt hinter dem Lastwagen A, sodass B auffahren kann.
- Variante II: Das Ego-Fahrzeug überholt A, blockiert den Fahrstreifen für B und beeinflusst damit sein Fahrverhalten.
- Variante III: Das Ego-Fahrzeug bleibt auf dem rechten Fahrstreifen, da der Lastwagen A auf den Seitenstreifen gefahren ist, um Platz zu machen. B kann somit den linken Fahrstreifen benutzen.
- Variante IV: Das Ego-Fahrzeug überholt A links über den Seitenstreifen, sodass B den linken Fahrstreifen verwenden kann.

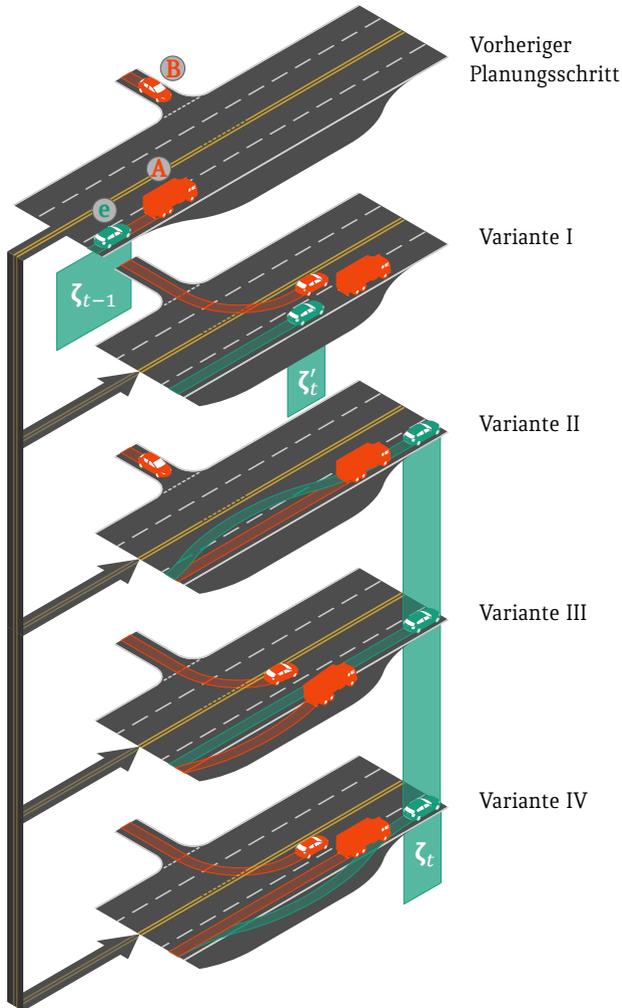


Abbildung 6.12: Heuristik des PITRA-Modells. Zum Planungszeitpunkt t gibt es mehrere Interaktionsmöglichkeiten mit anderen Verkehrsteilnehmern. Variante I befindet sich in Zustand ζ'_t ; Varianten II–IV resultieren in identischem Zustand ζ_t . Durch die PITRA-Heuristik wird (neben I) Variante II für die Planung des nächsten Zeitschritts verwendet, III und IV werden verworfen.

Die Varianten II bis IV führen zu identischer Position und Geschwindigkeit des Ego-Fahrzeugs und terminieren damit alle im selben Zustand ζ_t . Entsprechend der Heuristik wird lediglich jene Situation beibehalten und ζ_t zugeordnet, dessen Penaltywert sich als Minimum ergibt. Das für Lastwagen kaum erwartete Verhalten in Variante III resultiert in einer geringen Wahrscheinlichkeit dieses Überholvorgangs, wohingegen Variante IV eine Befahrung des Seitenstreifen darstellt und damit ein Verstoß gegen die Straßenverkehrsordnung mit hohen Penaltywerten. Die optimale Teillösung ergibt sich als Variante II, die zur weiteren Planung (neben Variante I) alleinig beibehalten wird. Dass B in dieser Variante voraussichtlich vorerst seine Ausfahrt nicht verlässt, wird zwar präzisiert, jedoch nicht aktiv und bewusst über die PITRA-Heuristik optimiert.

Im Fall des Ausparkmanövers zeigt Abbildung 6.10c jene Variante, die für den nächsten Planungsschritt durch die PITRA-Heuristik verworfen wird. Der Abbruch des Ausparkmanövers führt in einen zu Abbildung 6.10a identischen Zustand, der jedoch durch das bewegungsfreie Abwarten in der Lücke wesentlich geringere Sicherheitsrisiken aufweist und damit eine bessere Zustandsfolge beschreibt, die deshalb alleinig für die weitere Planung gemäß der PITRA-Heuristik beibehalten wird.

Zusammenfassung

Durch die Reduktion des Lösungsraums ist die Ergebnistrajektorie des PITRA-Modells nicht mehr global optimal. Durch die Minimierung der Penaltys zu allen Zeitschritten $t \in T_p$ ist jedoch zu erwarten, dass diejenigen Trajektorien, die bis zum Prädiktionsende $t = t_{\text{end}}$ durch die Heuristik propagiert werden, geringe Penaltywerte aufweisen und somit zumindest gute Approximationen der global optimalen Lösung beschreiben. Dazu kommt, dass zwar innerhalb des PITRA-Ansatzes nicht alle Varianten berücksichtigt werden – für diejenigen, die berücksichtigt werden, werden allerdings die Penaltywerte korrekt gemäß der zugrundeliegenden Modelle für Interaktionsprädiktion berechnet.

Für reales Verkehrsgeschehen ist anzunehmen, dass die lokalen optimalen Lösungen des PITRA-Modells im Mittel durch die hohe Anzahl an betrachteten

Alternativen mit einer zyklischen Neuberechnung eine gute mittlere Trajektoriengüte produzieren. Für einen Nachweis dieser Hypothese sind jedoch umfangreiche Verkehrsstatistiken zur Evaluation sowie valide Interaktionsmodelle notwendig. In weitergehende Arbeiten ist zudem eine Abwägung des weiterhin rechenintensiven PITRA-Modells hinsichtlich der sich ergebenden Vorteile durchzuführen und die Notwendigkeit einer Interaktionsmodellierung im Straßenverkehr zu prüfen. Dabei stellt die Weiterentwicklung und Evaluation des PITRA-Modells einen interessanten Bestandteil nachfolgender Arbeiten dar.

7

Zusammenfassung und Ausblick

Die vorliegende Arbeit hatte zum Ziel, allgemeine Aussagen über das Verkehrsgeschehen anhand geometrischer und topologischer Betrachtungen zu erlangen und basierend auf den daraus gewonnenen Erkenntnissen ein universelles und generisches Konzept für das gesamte Anwendungsspektrum des vollautomatischen Fahrens zu entwickeln. Eine konkrete Realisierung des generischen Konzepts ist dabei abhängig von einer Vielzahl an größtenteils systemspezifischen Parametern, wie beispielsweise den Sensorgenauigkeiten und -einbaupositionen, der Wunschgeschwindigkeit des Ego-Fahrzeugs und dessen physikalischen Eigenschaften, der Qualität des zugrundeliegenden Prädiktionsmodells, den Updateraten von Sensoren und Trajektorienplanung, sowie deren Prädiktionshorizont, aber auch von der Bewertungsfunktion mit konkreten Sicherheitszielen, dem geplanten Manöver des Ego-Fahrzeugs und nicht zuletzt von den betrachteten Anwendungsfällen – und war daher außerhalb des Fokus dieser Arbeit. Vielmehr lag der Schwerpunkt in der Entwicklung und systematischen Analyse eines Konzepts, das an nahezu alle denkbaren Ausprägungen der zuvor genannten Parameter angepasst werden kann.

Zur Entwicklung dieses Konzepts wurde zunächst eine intuitive Problemformulierung aus der Domäne der Variationsrechnung abgeleitet, die eine Minimierung von Funktionen anhand eines Bewertungsfunktional beschreibt. Durch die Transformation des so modellierten diskreten Variationsproblems in ein Optimierungsproblem von Funktionen mehrerer Variablen konnte die optimale Bewegungstrajektorie des Ego-Fahrzeugs mit gängigen iterativen Opti-

mierungsalgorithmen berechnet werden, woraus sich das *Euler-Lagrange-Modell zur Trajektorienplanung* (ELM) ergibt. Aufgrund der bekannten Nachteile iterativer Optimierung vor allem in Hinblick auf die sicherheitskritische Echtzeitanwendung der Bewegungsplanungsaufgabe wurde eine Korrespondenz des ELM mit speziellen probabilistischen Graphenmodellen zur Modellierung des *Hidden-Markov-Modells zur Trajektorienplanung* (HMM) beschrieben, das wesentliche Einschränkungen der iterativen Optimierung überwindet.

Für die *geometrischen Betrachtungen des Trajektorienraums* wurde eine umfassende Modellierung der Umgebung des Ego-Fahrzeugs, der aktuellen Situation und ihrer Prädiktion in die Zukunft hergeleitet, die sich über eine probabilistische Modellierung über das *Risiko* eines Manövers in Form des *Erwartungswerts des Schadens* definieren und etwa über die Kumaraswamyverteilung oder Diffusionsprozesse beschreiben lässt. Dadurch konnten Unsicherheiten über Sensorik oder Verhaltensweisen anderer Verkehrsteilnehmer in einer gemeinsamen Bewertungsfunktion vereint werden mit intrinsischen Trajektorieneigenschaften, die beispielsweise Insassenkomfort über Beschleunigungen, aber auch die Einhaltung von Geschwindigkeitsbegrenzungen beschreiben. Durch das hergeleitete analytische inverse Fahrzeugmodell ließ sich die Bewertung des Ego-Fahrzeug-Zustands vollständig auf eine Trajektorie sowie Konstruktionsparameter aus dem Datenblatt des Ego-Fahrzeugs zurückführen, sodass sich dadurch ein schlankes, einfach zu berechnendes Fahrzeugmodell ergab, das simulativ und im realen Versuchsfahrzeug evaluiert und für den Anwendungsfall als angemessen befunden wurde.

Zur *topologischen Analyse* wurde die global optimale Lösung der korrespondierenden HMM-Optimierung zusammen mit der Abtastung des Trajektorienraums über eine erschöpfende Generierung von Starttrajektorien für die iterative ELM-Optimierung eingesetzt und sowohl anhand synthetisierter Räume als auch realer Beispielsituationen evaluiert. Dabei zeigte sich eine hohe Komplexität des Trajektorienraums realen Verkehrsgeschehens, der durch eine hohe Zahl an lokalen Optima unterschiedlicher Qualität geprägt ist. Die Erkenntnisse gaben Aufschluss hinsichtlich Anforderungen an Trajektorienplanungsverfahren, die iterative Optimierungsverfahren und kombinatorische Ansätze als nur bedingt

geeignet zur Bewegungsplanung identifizierten. Die Trajektorienplanung mittels HMM-Algorithmus erwies sich als eine geeignete Methode, wobei gerade die Analyse der synthetisierten Räume zeigte, dass bei der zukünftigen Modellauslegung ein erhebliches Augenmerk auf die Wahl einer geeigneten HMM-Zustandsraumdiskretisierung zu legen ist.

Das aus den geometrischen und topologischen Betrachtungen resultierende Gesamtkonzept aus probabilistischer Situationsbeschreibung und intuitiver Trajektorienplanungsmodellierung namens *Situation Prediction and Reaction Control* (SPARC) wurde beispielhaft als zyklischer Gesamtprozess, auf mehrspurigen Straßen und zur Generierung von Notfalltrajektorien angewendet. Abschließend wurde eine Erweiterung der Methodik auf interaktive Verhaltensmodelle zur Beeinflussung der Reaktion anderer Verkehrsteilnehmer vorgestellt. Die Ergebnisse der Beispielanwendungen demonstrierten eine prinzipielle Machbarkeit und zeigten die beispielhafte Funktionalität des vorgestellten Ansatzes.

Ausblick auf weiterführende Themen

Die beispielhafte Anwendung auf einzelne ausgesuchte Teilaufgabenfelder in Kapitel 6 zeigt das Potenzial und die prinzipielle Funktionalität des SPARC-Konzepts. Die natürliche Weiterentwicklung ergibt sich über die Integration und Evaluation im realen Fahrversuch in den beiden VERTEX-Versuchsfahrzeugen des Iosb. Durch den theoretischen Fokus dieser Arbeit ergeben sich dabei neue praktische Fragestellungen hinsichtlich Systemauslegung sowie Repräsentation und Qualität von Eingangs- und Ausgangsdaten.

Hierfür wird – neben dem gesamten Spektrum valider Modellierung von Fahrverhalten – zunächst eine Anpassung der Situationsinterpretation (S_p) auf die konkrete VERTEX-Sensorik notwendig werden, die dem SPARC-Ansatz über eine dynamische Karte als Eingangsdaten dient. Die Prädiktionsmodellierung stellt dabei einen wichtigen Themenbereich dar, der für einen erfolgreichen Praxistest des SPARC-Konzepts erschlossen werden muss. Die Vorteile der Berechnung über Faltungskernndiffusion sind in diesem Zuge zu analysieren und weiterzuentwickeln. Dabei ist eine Evaluation der in Abschnitt 4.2 beschriebenen Ver-

fahren hinsichtlich der Qualität und Beschaffenheit der zur Verfügung stehenden VERTEX-Sensordaten notwendig sowie ein Vergleich mit gegebenen der Sensorausstattung möglicherweise besser geeigneten Verfahren, wie beispielsweise der Verwendung von Kalman- oder Partikelfiltern. Auch die in Abschnitt 4.2 vorgestellte Einbeziehung von Navigationsanweisungen und Verkehrsregeln ist im nächsten Entwicklungsschritt auf ihr Potenzial hin zu prüfen und mit anderen Ansätzen zu vergleichen, wie beispielsweise nach [142] als Beschreibung über logische Nebenbedingungen.

Gleichzeitig ergeben sich mögliche Weiterentwicklungen in der Manöverplanung (Rc) durch Erkenntnisse, die bei der Präzisierung des SP-Teils gewonnen werden. Hierzu zählt eine auf Realdaten basierende Evaluation der Penalty-Lagrangefunktion aus Abschnitt 3.1, um relevante Einflussfaktoren, die sich als die einzelnen Bewertungsterme widerspiegeln, zu analysieren und konkrete Gewichtungsfaktoren und Parameter zu identifizieren. Für die Untersuchungen des Komfort- und Wohlbefindens zukünftiger Fahrzeuginsassen bieten sich beispielhaft Probandenstudien unter Verwendung des Fahrsimulators »Integrative Simulationsplattform für den Automotive-Bereich« (ISAB) am Fraunhofer Iosb oder der VERTEX-Fahrzeuge des Iosb an.

Hinsichtlich der Echtzeitfähigkeit des HMM zur Trajektorienplanung können die ersten erfolgsversprechenden Ergebnisse der Hardwareimplementierung auf einer NVIDIA GeForce GTX TITAN Grafikkarte in [S8] als Grundlage zur Portierung auf eine auf Automotive-Anwendungen spezialisierte NVIDIA DRIVE Px [133] dienen. Weiterentwicklungen ergeben sich dabei durch die Erweiterung des Zustandsraums auf eine vollständige xyt -Planung. Basierend auf Realdaten kann dabei eine adäquate Diskretisierung des HMM-Zustandsraums analysiert werden, die einerseits ausreichende Auflösung für die Planungsaufgabe und andererseits innerhalb der Echtzeitanforderungen bleibt. Anhand von Simulationen und realen Testfahrten können adaptive Zustandsraumdiskretisierungen entwickelt werden, die beispielsweise in einer abstandsgebundenen Verringerung der Auflösung zur Reduktion des Lösungsraums bestehen.

Trotz der Erkenntnisse diese Arbeit hinsichtlich der bedingten Anwendbarkeit des ELM zur Trajektorienplanung kann eine Kombination mit dem HMM möglicherweise gewinnbringend eingesetzt werden. Dabei ergeben sich neue

Aufgaben hinsichtlich geeigneter Generierungsverfahren von Starttrajektorien, die die HMM-Optimierung verwenden.

Weiterhin ergibt sich mit geeigneten Interaktionsstatistiken ein interessantes Forschungsfeld in der Weiterentwicklung und Erprobung des PITRA-Modells. Durch Simulationen vieler Testfälle ergeben sich Aussagen über den Gewinn eines Interaktions-bewussten Trajektorienplaners, der innerhalb der Planung die aktive Beeinflussung des Verkehrs berücksichtigt. Gegeben der Vorteilsanalyse kann daran anschließend eine Kosten-Nutzen-Kalkulation bezüglich der zusätzlichen Rechenkapazitäten durchgeführt werden.

Nach erfolgreicher Modellierung und Parameteridentifikation des SPARC-Konzepts können reale Testfahrten Aufschluss über die Regelgenauigkeit des Gesamtsystems geben. Entsprechend erfolgt gegebenenfalls eine Verringerung der Planungs-Zykluszeit oder die Entwicklung eines Low-Level-Regelungskonzepts. Zudem kann die redundante Auslegung der VERTEX-Sensorausstattung zur Evaluation eines optimalen – und auf die Belange der Trajektorienplanung abgestimmten – Sensorkonzepts dienen und wertvolle Hinweise hinsichtlich einer minimalen Sensorausstattung von zukünftigen Serienfahrzeugen geben.

Neben der Integration in die VERTEX-Fahrzeuge und der damit einhergehenden Weiterentwicklung des SPARC-Konzepts stellt der umfängliche Vergleich mit anderen Gesamtsystemen eine weitere interessante Forschungsrichtung dar. Da derzeitige Algorithmen auf unterschiedlichen Annahmen beruhen – etwa über die Struktur des Verkehrs, die Häufigkeit von Situationen sowie die Verhaltensweisen anderer Verkehrsteilnehmer – ist zunächst ein übergeordnetes Verständnis der Problemstellung des vollautomatischen Fahrens zu entwickeln, um damit eine situations- und modellunabhängige Bewertung der Verfahren zu ermöglichen. Hierfür ist eine gemeinsame Evaluationsmetrik zu definieren, um eine Vergleichbarkeit zu ermöglichen. Die vorliegende Arbeit hatte in diesem Zusammenhang zum Ziel, erste allgemeine Erkenntnisse über das Verkehrsgeschehen zu erlangen.

Abschließend kann der Bereich der Luftbilddauswertung wertvolle Beiträge zur Erforschung von Verkehrssituationen und zur Erstellung von Verhaltensstatistiken leisten. In diesem Themenfeld ergeben sich weitere Forschungspotenziale, die sich mit der Auswertung der Luftbilder im Hinblick auf die neuartige Anwendung des vollautomatischen Fahrens befassen. Erste Ansätze in [S16] mit klassischen Bildauswertemethoden – wie beispielsweise der Hintergrundsubtraktion – zeigen gute Ergebnisse, die weiterführend eine Prozessierungskette zur Massendatenauswertung von Luftbilddaufnahmen – unter Beachtung der Persönlichkeitsrechte – ergeben. Dies führt zu validen Verkehrsstatistiken für spezifische Straßen und Kreuzungen, aber auch zu allgemeinen Aussagen über Fahrverhalten auf bestimmten Straßentypen, die im Rahmen vollautomatischen Fahrens sowohl zur Parametrierung der Systeme als auch zur simulativen Evaluation dienen können.

G

Glossar

B

Bayessches Netz

Schlagworte:	—
Literatur:	Abschnitt 2.3, [155]

Ein bayessches Netz ist ein bekannter Vertreter \leftrightarrow probabilistischer graphischer Modelle und stellt einen statischen gerichteten azyklischen Graphen dar, der über Zufallsvariablen als Knoten und Relationen als Kanten zwischen Knoten multivariate Wahrscheinlichkeitsverteilungen modelliert. Jeder Knoten beschreibt dabei eine – von den Eltern-Knoten abhängige – bedingte Wahrscheinlichkeitsverteilung.

C

C^2 -Modell

Schlagworte:	inverses (Fahrzeug-)Modell
Literatur:	Abschnitt 4.1, [E3]

Das C^2 -Modell ist ein einfach parametrierbares und rechenaufwandsarmes inverses Fahrzeugmodell, das aus der Fahrzeugbewegung (der \leftrightarrow Trajektorie) unterschiedliche Zustandsparameter des Fahrzeugs schätzt. Das Modell findet Verwendung in der Extraktion des Fahrzeugzustands aus Luftbildaufnahmen und in der \leftrightarrow Trajektorienplanung (beispielsweise innerhalb des \leftrightarrow SPARC-Ansatzes). Es ist damit Bestandteil der \leftrightarrow Geometrie des \leftrightarrow Trajektorienraums, beschrieben als Fahrzeuggeometrie.

D

Dynamische Programmierung

Schlagnote:	—
Literatur:	Abschnitt 4.1, [125]

Die dynamische Programmierung beschreibt eine Klasse an Algorithmen, die das Optimalitätsprinzip von Bellman verwenden, das besagt, dass die optimale Lösung eines in Teilprobleme zerlegbaren Gesamtproblems sich wiederum aus der Zusammensetzung der optimalen Lösungen jener Teilprobleme ergibt. Ein Beispiel stellt der \hookrightarrow Viterbi-Algorithmus dar.

E

Ego-Fahstreifen

Schlagnote:	Ego-Fahrzeug-Fahspur
Literatur:	Abschnitt 4.2.1

Der Ego-Fahstreifen beschreibt in dieser Arbeit einen oder mehrere \hookrightarrow Fahstreifen, die in Fahrtrichtung des \hookrightarrow Ego-Fahrzeugs befahren werden dürfen.

Ego-Fahrzeug

Schlagnote:	—
Literatur:	Abschnitt 2.1, [E1, E4–E7, E10, E11]

Das Ego-Fahrzeug bezeichnet jenes Fahrzeug, für dessen Bewegung die beschriebene \hookrightarrow Trajektorienplanung durchgeführt wird. Das Ego-Fahrzeug wird in dieser Arbeit in Grün dargestellt, im Gegensatz zu anderen Verkehrsteilnehmern in Rot.

Ego-Fahrzeug-Ausdehnung

Schlagworte:	—
Literatur:	Abschnitt 4.2.1

Die Ego-Fahrzeug-Ausdehnung beschreibt die \hookrightarrow Fahrzeugausdehnung des entsprechenden \hookrightarrow Ego-Fahrzeugs.

Ego-Umgebung

Schlagworte:	Ego-Umfeld, Ego-Fahrzeug-Umgebung
Literatur:	Abschnitt 4.2.1

Die Ego-Umgebung stellt die vollständige Modellierung der Umgebung des entsprechenden \hookrightarrow Ego-Fahrzeugs zum aktuellen Zeitpunkt dar und setzt sich aus der \hookrightarrow Straßengeometrie, dem \hookrightarrow Straßennebenbereich und anderen Verkehrsteilnehmern zusammen.

Erwartungswert des Schadens

Schlagworte:	Schadenserwartungswert
Literatur:	Abschnitt 4.2.1, [E1]

Siehe \hookrightarrow Schadenserwartungswert.

Euler-Lagrange-Gleichung

Schlagworte:	—
Literatur:	Abschnitt 2.2, [50, 120, 174, 178]

Die Euler-Lagrange-Gleichung beschreibt eine notwendige Bedingung eines lokalen Extremums (oder Sattelpunkts) eines Funktionals zur Bewertung einer Funktion und ist zentraler Bestandteil der Variationsrechnung. Innerhalb iterativer Optimierungsmethoden kann die Euler-Lagrange-Gleichung zur Gradientenberechnung herangezogen werden.

Euler-Lagrange-Modell zur Trajektorienplanung (ELM)

Schlagnote:	—
Literatur:	Abschnitt 3.2, [E4]

Das über iterative Vektoroptimierungsmethoden umgesetzte Euler-Lagrange-Modell zur Trajektorienplanung basiert auf der intuitiven Problembeschreibung der \hookrightarrow Trajektorienplanungsaufgabe als Variationsproblem und wird in dieser Arbeit in Anlehnung an die \hookrightarrow Euler-Lagrange-Gleichung als ELM bezeichnet.

F

Fahrbahn

Schlagnote:	—
Literatur:	Abschnitt 4.2.1, [47]

Die Fahrbahn beschreibt den (meist asphaltierten) Bereich einer Straße, der zur Befahrung mit Fahrzeugen zugelassen ist. Er besteht aus einem oder mehreren \hookrightarrow Fahrstreifen in Fahrtrichtung und Gegenrichtung.

Weitere Bestandteile der Straße – jedoch kein Bestandteil der Fahrbahn – sind Rad- und Fußwege, sowie der \hookrightarrow Seitenstreifen.

Fahrstreifen

Schlagnote:	Fahrspur
Literatur:	Abschnitt 4.2.1, [47]

Der Fahrstreifen bezeichnet einen Teil der \hookrightarrow Fahrbahn und ist durch Fahrstreifenmarkierungen zu anderen Fahrstreifen getrennt. Dabei kann es sich um Fahrstreifen in dieselbe Fahrtrichtung oder um Fahrstreifen in die Gegenrichtung handeln, die in dieser Arbeit als \hookrightarrow Ego-Fahrstreifen und \hookrightarrow Gegenfahrstreifen bezeichnet werden.

Die Begrifflichkeit Fahrspur wird oftmals synonym zu Fahrstreifen verwendet, führt jedoch aufgrund Begriffsähnlichkeiten zur Spur(-breite) eines Fahrzeugs zu Verwirrung und wird daher nicht verwendet.

Fahrzeugausdehnung

Schlagworte:	—
Literatur:	Abschnitt 4.2.1

Die Fahrzeugausdehnung beschreibt die räumliche Ausdehnung eines Fahrzeugs projiziert auf die Bodenebene. Sie wird innerhalb der zellenbasierten Darstellung des \hookrightarrow Pre-Penalty-Volumens verwendet.

Fahrzeuggeometrie

Schlagworte:	—
Literatur:	Abschnitt 4.1

Siehe \hookrightarrow C²-Modell.

Fahrzeug-zu-X-Kommunikation

Schlagworte:	Fahrzeug-zu-Fahrzeug-, Fahrzeug-zu-Infrastruktur-Kommunikation
Literatur:	Abschnitt 4.2.1, [196]

Mit Fahrzeug-zu-X-Kommunikation wird der kabellose Austausch von Informationen und Daten eines Fahrzeugs mit einem Kommunikationspartner X bezeichnet, wobei »X« für andere Fahrzeuge oder entsprechend geeignete Infrastruktur steht. Die Kommunikation dient der Bereitstellung relevanter Informationen zur Erhöhung des Informationsgrades, z.B. zur verbesserten Routenplanung, Unfallwarnung oder einer angereicherten Umfeldwahrnehmung des Fahrzeugs.

G

Geometrie des Trajektorienraums

Schlagworte:	—
Literatur:	Kapitel 4, [16]

Ursprünglich zum Flächen- und Längenvergleich entwickelt, befasst sich die Geometrie mit der Vermessung von Räumen.

In dieser Arbeit wird der Begriff Geometrie auf die \hookrightarrow Trajektorienplanungsaufgabe übertragen und beschreibt dort die geometrischen Eigenschaften des \hookrightarrow Trajektorienraums, der sich aus der geometrischen Modellierung aller für die Lösung relevanten Einflussfaktoren ergibt. Die Geometrie des Trajektorienraums setzt sich dabei aus der \hookrightarrow Situationsgeometrie und der \hookrightarrow Fahrzeuggeometrie zusammen.

Gegenfahrstreifen

Schlagworte:	Gegenfahrspur
Literatur:	Abschnitt 4.2.1

Der Gegenfahrstreifen beschreibt in dieser Arbeit einen oder mehrere \hookrightarrow Fahrstreifen, die entgegen der Fahrtrichtung des \hookrightarrow Ego-Fahrzeugs befahren werden dürfen.

Ground Truth

Schlagworte:	Referenzdaten, Grundwahrheit
Literatur:	Abschnitt 4.1.2

Siehe \hookrightarrow Referenzdaten.

H

Hidden-Markov-Modell

Schlagworte:	—
Literatur:	Abschnitt 2.3, [162, 166]

Ein Hidden-Markov-Modell stellt einen \hookrightarrow stochastischen Prozess dar und besteht aus einer \hookrightarrow Markov-Kette von (meist) unbeobachtbaren Zuständen, die wiederum beobachtbare Symbole emittieren. Dabei beschreibt eine Markov-Kette (erster Ordnung) einen dynamischen gerichteten Graphen von Zufallsvariablen zu einzelnen Zeitpunkten, dessen einzelne Knoten lediglich vom Vorgängerknoten abhängig sind. Diese Eigenschaft wird als \hookrightarrow Markov-Eigenschaft bezeichnet.

Hidden-Markov-Modell zur Trajektorienplanung (HMM)

Schlagworte:	—
Literatur:	Abschnitt 3.4, [E6, E7, E10]

In der Arbeit wird die Korrespondenz von Variationsrechnung und \hookrightarrow Hidden-Markov-Modellen eingesetzt, um ein zum \hookrightarrow ELM korrespondierendes Hidden-Markov-Modell zur Trajektorienplanung (HMM) herzuleiten. Das HMM beschreibt hierdurch einerseits die intuitive Problemformulierung aus der Variationsrechnung und ermöglicht andererseits die Optimierung mittels \hookrightarrow dynamischer Programmierung über den \hookrightarrow Viterbi-Algorithmus.

K

Konstruktionsparameter des Fahrzeugs

Schlagworte:	Fahrzeugkonstruktionsparameter
Literatur:	Abschnitt 4.1.1

Konstruktionsparameter eines Fahrzeugs bezeichnen konstruktionsbedingte Parameter, die sich auf das Fahrverhalten auswirken und im Allgemeinen in einem Datenblatt zu finden sind. Beispiele hierfür sind der Achsabstand l , die halbe Spurbreite h und die Radien r der montierten Räder.

M

Markov-Eigenschaft

Schlagworte:	—
Literatur:	Abschnitt 2.3, [162, 175]

Die Markov-Eigenschaft beschreibt die Gedächtnislosigkeit eines \hookrightarrow stochastischen Prozesses. Siehe hierzu \hookrightarrow Markov-Kette.

Markov-Kette (*n*-ter Ordnung)

Schlagworte:	—
Literatur:	Abschnitt 2.3, [162, 175]

Eine Markov-Kette beschreibt einen zeitdiskreten \hookrightarrow stochastischen Prozess mit Zufallsvariablen, die lediglich von ihrem n -ten Vorgänger abhängen. Für $n = 1$ wird diese Eigenschaft als Gedächtnislosigkeit oder als \hookrightarrow Markov-Eigenschaft bezeichnet.

Oftmals wird der Begriff »Markov-Kette« synonym für eine »Markov-Kette erster Ordnung« verwendet. Markov-Ketten höherer Ordnung können über eine Zustandserweiterung in Markov-Ketten erster Ordnung transformiert werden.

N

Nebenbedingungen

Schlagworte:	harte Nebenbedingungen, Randbedingungen
Literatur:	Abschnitt 2.2, [98]

Harte Nebenbedingungen beschreiben Bedingungen innerhalb der Problemformulierung, die bei der Optimierung nicht verletzt werden dürfen. Ein Beispiel hierfür sind physikalische Grenzen eines Fahrzeugs, wie maximale Geschwindigkeit oder Beschleunigung.

P

Penalty

Schlagworte:	Strafe
Literatur:	Abschnitt 3.1, [E4, E5]

In dieser Arbeit bezeichnet eine Penalty einen Bestrafungsterm – oder skalaren Bestrafungswert – auf eine unerwünschte Eigenschaft einer \hookrightarrow Trajektorie, die sich aus der Problemformulierung der \hookrightarrow Trajektorienplanungsaufgabe als Variationsproblem ergibt.

Dabei wird bewusst die englische Bezeichnung »Penalty« für konkret modellierten Strafen gewählt, um eine Abgrenzung der konkreten Problemformulierung hin zu den allgemeinen Erläuterungen zur Variationsrechnung im Grundlagenkapitel 2 zu verdeutlichen. Aus demselben Grund erhalten Variablen, Funktionen und Konstrukte, die sich auf die Penalties beziehen zur Verdeutlichung entsprechend daran angelehnte Bezeichner (siehe hierfür beispielsweise \hookrightarrow Penalty-Lagrangefunktion).

Penalty-Funktional, Penalty-Lagrangefunktion, Penalty-Funktion, Penalty-Bewertungseinheit, Penalty-Euler–Lagrange-Gleichung

Schlagworte:	—
Literatur:	Abschnitt 3.1, Abschnitt 4.2.1

Die hier zusammengefassten Penalty-Begrifflichkeiten stammen (größtenteils) aus der mathematischen Disziplin der Variationsrechnung und werden zur Verdeutlichung der konkreten Ausprägung in dieser Arbeit mit der Bezeichnung »Penalty« gekennzeichnet.

Das Penalty-Funktional bewertet dabei eine \hookrightarrow Trajektorie über die Zuordnung eines entsprechenden Penaltywerts. Über die Minimierung des Penalty-Functionals wird die optimale Trajektorie gefunden.

Die Penalty-Lagrangefunktion stellt die vollständige Bewertungsvorschrift der einzelnen Zeitpunkte der Trajektorie dar, die innerhalb des Penalty-Functionals aufintegriert werden.

Die Penalty-Lagrangefunktion besteht aus einzelnen Penalty-Funktionen, die unterschiedliche Eigenschaften der Trajektorie bewerten.

Die in dieser Arbeit vorgeschlagene probabilistische Modellierung über einen \hookrightarrow Erwartungswert des Schadens ermöglicht die Bewertung unterschiedlicher Eigenschaften der Trajektorie mit einer einheitlichen Penalty-Bewertungseinheit, wie beispielsweise mit der Währung €.

Für die Penalty-Euler-Lagrange-Gleichung siehe \hookrightarrow Euler-Lagrange-Gleichung.

Penalty-Viterbi-Algorithmus

Schlagworte:	—
Literatur:	Abschnitt 3.5.3, [E10]

Der in dieser Arbeit entwickelte Penalty-Viterbi-Algorithmus beschreibt den klassischen \hookrightarrow Viterbi-Algorithmus angepasst auf die Problemformulierung der \hookrightarrow Trajektorienplanungsaufgabe. Die wesentlichen Anpassungen ergeben sich als Summation an Stelle einer Multiplikation und Minimierung an Stelle einer Maximierung.

Pfad

Schlagworte:	—
Literatur:	Abschnitt 2.1

Ein Pfad beschreibt die räumliche Bewegung eines \hookrightarrow Ego-Fahrzeugs entlang eines longitudinalen Raumparameters. Im Gegensatz zur \hookrightarrow Trajektorie wird dabei keine Zeitabhängigkeit betrachtet.

Pfadplanung

Schlagworte:	—
Literatur:	[34]

Die Pfadplanung hat zur Aufgabe, die räumliche Bewegung eines \hookrightarrow Ego-Fahrzeugs zu planen. Das Ergebnis ist ein \hookrightarrow Pfad. Die simultane Planung von Raum und Zeit stellt hingegen eine \hookrightarrow Trajektorienplanung dar.

PITRA-Konzept

Schlagworte:	—
Literatur:	Abschnitt 6.4, [E11]

Das »Progressively Interacting Trajectories«-Konzept (PITRA) stellt eine Erweiterung des $\hookrightarrow_{\text{SPARC-KONZEPT}}$ auf die Einbeziehung der Reaktionen anderer Verkehrsteilnehmer auf Handlungen des $\hookrightarrow_{\text{Ego-Fahrzeugs}}$ dar.

Planungsraum

Schlagworte:	Lösungsraum, <i>xyt</i> -Planungsraum, <i>st</i> -Planung
Literatur:	Abschnitt 3.5.1

In dieser Arbeit wird der Lösungsraum der Optimierung des $\hookrightarrow_{\text{Trajektorienplanungsproblems}}$ als Planungsraum bezeichnet. Dabei wird in dieser Arbeit unterschieden zwischen einer *xyt*-Planung und einer *st*-Planung entsprechend der in der Problemformulierung und Optimierung auftretenden Parameter.

Prädiktion

Schlagworte:	Situationsprädiktion
Literatur:	Abschnitt 4.2.2, [E5]

In dieser Arbeit bezeichnet die Prädiktion die mit Unsicherheiten behaftete Vorhersage, wie sich die initiale Situation in der Zukunft weiterentwickelt. Sie ist wesentlicher Bestandteil des $\hookrightarrow_{\text{Pre-Penalty-Volumens}}$ als Darstellung der $\hookrightarrow_{\text{Situationsgeometrie}}$.

Pre-Penalty-Volumen

Schlagworte:	Pre-Penalty-Feld, Raum-Zeit-Volumen
Literatur:	Abschnitt 4.3, [E4, E5]

Das Pre-Penalty-Volumen stellt die ganzheitliche Beschreibung der \hookrightarrow Umgebung des Ego-Fahrzeugs und dessen \hookrightarrow Prädiktion in die Zukunft dar. Es umfasst dabei alle für die Problembeschreibung relevanten Informationen der \hookrightarrow Situationsgeometrie und dient der \hookrightarrow Penalty-Lagrangefunktion als nichtoptimierbare Vorbedingung.

Dabei deutet die Begrifflichkeit »Pre-« darauf hin, dass innerhalb des Pre-Penalty-Volumens die Bewertungskomponenten in einer abstrakten Form abgelegt sind. Erst unter Verwendung der \hookrightarrow Penalty-Funktionen werden die sich für die Trajektorie ergebenden \hookrightarrow Penaltys aus dem Pre-Penalty-Volumen berechnet.

Probabilistische graphische Modelle

Schlagworte:	—
Literatur:	Abschnitt 2.3, [166]

Probabilistische graphische Modelle dienen der Darstellung multivariater Wahrscheinlichkeitsverteilungen mit den Knoten als einzelne Zufallsvariablen und den Kanten als probabilistische Relationen zwischen den Knoten. Beispiele für probabilistische graphische Modelle sind \hookrightarrow Bayessche Netze, \hookrightarrow Markov-Ketten und \hookrightarrow Hidden-Markov-Modelle.

R

Referenzdaten

Schlagworte:	Grundwahrheit
Literatur:	Abschnitt 4.1.2

Als Referenzdaten – englisch: Ground Truth – werden in dieser Arbeit solche Daten bezeichnet, die die »wahren Werte« darstellen. In der Regel ist die Messung der echten »Wahrheit« nicht möglich, sodass die als »wahr« angenommenen Daten zunächst als solche spezifiziert werden müssen.

S

Schadenserwartungswert

Schlagworte:	Erwartungswert des Schadens
Literatur:	Abschnitt 4.2.1, [E1]

Die \hookrightarrow Situationsgeometrie wird in dieser Arbeit über das Risiko eines Manövers beispielhaft in Form des Erwartungswerts eines Schadens modelliert, bestehend aus den anfallenden Sachkosten und der Wahrscheinlichkeit einer Kollision.

Situationsgeometrie

Schlagworte:	—
Literatur:	Abschnitt 4.2

Die Situationsgeometrie und \hookrightarrow Fahrzeuggeometrie beschreiben die \hookrightarrow Geometrie des Trajektorienraums. Dabei setzt sich die Situationsgeometrie wiederum zusammen aus der \hookrightarrow Ego-Umgebung – die die Situation zum aktuellen Zeitpunkt beschreibt – und der \hookrightarrow Situationsprädiktion in die Zukunft.

SPARC-Konzept

Schlagworte:	—
Literatur:	Abschnitt 4.3, [E4, E5]

Das »Situation Prediction and Reaction Control«-Konzept (SPARC) stellt einen Ansatz zur Situationsinterpretation und Manöverplanung für vollautomatische Fahrzeuge dar und basiert auf einer intuitiven Problemformulierung der \hookrightarrow Trajektorienplanungsaufgabe mittels Variationsrechnung und einer probabilistischen Beschreibung der \hookrightarrow Situationsgeometrie über den \hookrightarrow Erwartungswert des Schadens.

Seitenstreifen

Schlagworte:	Standstreifen
Literatur:	Abschnitt 4.2.1, [47]

Der Seitenstreifen ist kein Bestandteil der \hookrightarrow Fahrbahn und darf im Allgemeinen – sofern befestigt – zum Halten und Parken verwendet werden mit Ausnahme auf Autobahnen. Der Seitenstreifen wird in dieser Arbeit als ein geeigneter sicherer Bereich für Notfallmanöver herangezogen und wird daher als ein Teil des \hookrightarrow Straßennebenbereichs modelliert, dessen Befahrung in Notfallsituationen zulässig ist.

Stochastischer Prozess

Schlagworte:	—
Literatur:	Abschnitt 2.3, [166, 175]

Ein stochastischer Prozess beschreibt im Allgemeinen einen zeitabhängigen, zufälligen Vorgang und wird in dieser Arbeit zur Beschreibung der zeitlichen Evolution zeitabhängiger \hookrightarrow probabilistischer Graphen über die Modellierung zeitabhängiger Zufallsvariablen eingeführt. Beispiele hierfür sind \hookrightarrow Markov-Ketten und \hookrightarrow Hidden-Markov-Modelle.

Straßengeometrie

Schlagworte:	—
Literatur:	Abschnitt 4.2.1

In dieser Arbeit enthält die Straßengeometrie den für das \hookrightarrow Ego-Fahrzeug relevanten Teil des umgebenden Straßenverlaufs sowie die geometrischen Eigenschaften der \hookrightarrow Fahrbahn.

Straßennebenbereich

Schlagworte:	—
Literatur:	Abschnitt 4.2.1

In dieser Arbeit enthält der Straßennebenbereich an die \hookrightarrow Fahrbahn angrenzende Teile der \hookrightarrow Ego-Umgebung, die in Notfällen gegebenenfalls als Ausweichflächen genutzt werden können. So kann der \hookrightarrow Seitenstreifen beispielsweise als sicherer Bereich im Fall eines Systemausfalls dienen.

T

Topologie des Trajektorienraums

Schlagworte:	Topologie
Literatur:	Kapitel 5, [122]

Die Topologie beschäftigt sich im Allgemeinen mit Nachbarschaftsbeziehungen, die durch Deformationen des Raums erhalten bleiben.

In dieser Arbeit wird der Begriff Topologie auf die \hookrightarrow Trajektorienplanungsaufgabe übertragen. Dabei erweisen sich die (lokalen und globalen) Optima als invariant gegenüber \hookrightarrow geometrischen Raumänderungen.

Trajektorie

Schlagworte:	Trajektorie
Literatur:	Abschnitt 2.1

Eine Trajektorie beschreibt die raum-zeitliche Bewegung des \hookrightarrow Ego-Fahrzeugs. Die Vernachlässigung der zeitlichen Komponente resultiert dabei in einem entsprechenden \hookrightarrow Pfad.

Trajektorienplanung

Schlagworte:	Bewegungsplanung, Manöverplanung
Literatur:	Abschnitt 3, [E1, E4, E7]

Die Trajektorienplanung hat zur Aufgabe, eine Bewegung für ein \hookrightarrow Ego-Fahrzeug simultan durch Raum und Zeit zu planen. Das Ergebnis der Planung ist eine \hookrightarrow Trajektorie. Eine rein räumliche Planung wird als \hookrightarrow Pfadplanung bezeichnet. In dieser Arbeit werden die Begriffe »Manöverplanung« und »Bewegungsplanung« synonym zur Trajektorienplanung verwendet.

Trajektorienraum

Schlagworte:	Trajektorienplanungsraum, Lösungsraum, Lösungsmenge
Literatur:	Kapitel 4, Kapitel 5

In dieser Arbeit beschreibt der Trajektorienraum die Menge aller Lösungen des \hookrightarrow Trajektorienplanungsproblems. Entsprechender Lösungsraum ergibt sich aus der Kombination von intuitiver Problembeschreibung als Variationsproblem und der probabilistischen \hookrightarrow Situationsgeometrie sowie \hookrightarrow Fahrzeuggeometrie. Konkrete Ausprägungen in dieser Arbeit sind \hookrightarrow xyt-Planung und \hookrightarrow st-Planung.

V

Viterbi-Algorithmus

Schlagworte:	—
Literatur:	Abschnitt 2.3, [166]

Der Viterbi-Algorithmus wird zur Dekodierung eines \hookrightarrow Hidden-Markov-Modells verwendet, um aus einer Folge an emittierten Symbolen auf die wahrscheinlichste Zustandsfolge des Hidden-Markov-Modells zu schließen. Der Viterbi-Algorithmus ist ein Beispiel für \hookrightarrow dynamische Programmierung und resultiert in einem globalen Optimum.

In dieser Arbeit wird der Viterbi-Algorithmus auf die Problemformulierung der \hookrightarrow Trajektorienplanungsaufgabe angepasst und dann entsprechend als \hookrightarrow Penalty-Viterbi-Algorithmus bezeichnet.

Z

zeitlicher Positionsverlauf

Schlagworte:	—
Literatur:	Abschnitt 2.1

Der zeitliche Positionsverlauf einer \hookrightarrow Trajektorie beschreibt diejenige Funktion, die den Raumparameter des zugehörigen \hookrightarrow Pfads auf den zeitlichen Verlauf der Trajektorie abbildet.



Abbildungsverzeichnis

1.1	Automatisierungsstufen nach SAE International Standard J3016.	3
1.2	Technischer Projektüberblick des Dissertationsprojekts »V50«.	20
1.3	Versuchsfahrzeug für Technologie-Experimente (VERTEX) des Fraunhofer Iosb.	21
1.4	Gliederung der Arbeit.	27
2.1	Markov-Kette und Hidden-Markov-Modell.	50
3.1	Anpassungen des Hidden-Markov-Modells zur Trajektorienplanung.	70
3.2	Schnitt durch 3D-Pre-Penalty-Volumen.	72
4.1	Geometrische Parameter des C^2 -Modells.	84
4.2	Überblick über Evaluationen des C^2 -Modells in der Simulation.	90
4.3	Fehlerkurven der Sinuslenkung des mittleren Einschlagwinkels und der Geschwindigkeit.	93
4.4	Fehlermetriken der Sinuslenkung über Amplitude und Frequenz.	94
4.5	Hockenheimering mit IPGDRIVER und C^2 -Modell-Steuerung.	96
4.6	Korrelationsplots von C^2 -Modell und Referenzdaten – Geschwin- digkeit, Beschleunigung, Einschlagwinkel.	98

4.7	Korrelationsplots von C^2 -Modell und Referenzdaten – Raddrehgeschwindigkeiten.	99
4.8	Vergleich C^2 -Modell-geschätzte Parameter mit Referenzdaten über dem Streckenverlauf – Geschwindigkeit und Beschleunigung.	100
4.9	Vergleich C^2 -Modell-geschätzte Parameter mit Referenzdaten über dem Streckenverlauf – mittlerer Einschlagwinkel.	101
4.10	Vergleich C^2 -Modell-geschätzte Parameter mit Referenzdaten über dem Streckenverlauf – mittlerer Einschlagwinkel und laterale Geschwindigkeit eines Streckenabschnitts.	102
4.11	Vergleich geschätzte C^2 -Modell-Parameter mit Simulationsergebnissen selbiger Parameter als Stellbefehle – Lenkradwinkel.	104
4.12	Vergleich geschätzte C^2 -Modell-Parameter mit Simulationsergebnissen selbiger Parameter als Stellbefehle – Geschwindigkeit.	105
4.13	Testfahrt mit dem VERTEX-Fahrzeug auf dem Exerzierplatz am KIT-Campus Ost.	106
4.14	Daten und approximierte Lenkübertragungsfunktion des Vw eGOLF VII.	109
4.15	Korrelationsplots von C^2 -Modell und VERTEX-Daten – Geschwindigkeit und Lenkradwinkel.	110
4.16	Korrelationsplots von C^2 -Modell und VERTEX-Daten – Radmittelpunktgeschwindigkeit.	111
4.17	Vergleich der C^2 -Modell-geschätzten Parameter mit den VERTEX-Daten – Geschwindigkeit und Lenkradwinkel.	113
4.18	C^2 -Modell-geschätzte laterale Beschleunigung der realen Testfahrten.	114
4.19	Bestandteile der Ego-Fahrzeug-Umgebung.	117
4.20	Aus Aufenthaltswahrscheinlichkeiten eines Fahrzeugs resultierende Belegungswahrscheinlichkeiten.	121
4.21	Geschwindigkeits- und -zonenabhängige Outer-Penaltys.	123

4.22	Einzelne Schritte zur Prädiktion von Aufenthalts- und zugehörigen Belegungswahrscheinlichkeiten.	126
4.23	Bayessches Netz zur Interaktionsmodellierung in der Verhaltensprädiktion anderer Fahrzeuge.	127
4.24	Darstellung der per Kumaraswamyverteilung approximierten longitudinalen Aufenthaltswahrscheinlichkeitsverteilung zur Berechnung der zugehörigen Belegungswahrscheinlichkeiten.	130
4.25	Mit Kumaraswamyverteilung approximierte Geschwindigkeitsmassenverteilung.	131
4.26	Beispiel paarweise verschiedene Pfade $\bar{\xi}_1$ bis $\bar{\xi}_4$	133
4.27	Relevanzgrenze der Umgebungsmodellierung anhand einer beispielhaften Situationsgeometrie.	135
4.28	Das SPARC-Konzept.	137
4.29	Modellvereinfachungen des SPARC-Konzepts.	141
5.1	Beispiel einer einfachen Verkehrssituation mit einer Verengung. . .	144
5.2	Generierung synthetisierter Pre-Penalty-Volumen als brownisches Rauschen.	150
5.3	ELM- und HMM-Optimierung auf einem synthetisierten Pre-Penalty-Volumen.	154
5.4	Einfluss der Zustandsraumdiskretisierung auf HMM-Lösung.	155
5.5	Beispiel einer zu groben Auflösung des HMM-Zustandsraums.	156
5.6	Schematische Betrachtung des Einflusses der Zustandsraumdiskretisierung des HMM.	157
5.7	Übersicht über die Orte der analysierten Beispielsituationen.	159
5.8	Beispielsituation ①: Einfaches Linksabbiegen durch Gegenverkehr. .	161
5.9	Beispielsituation ②: Einfahrt in befahrenen Kreisel.	162
5.10	Beispielsituation ③: Einfädeln auf eine Schnellstraße.	163
5.11	Beispielsituation ④: Komplexe Kreuzungssituation.	164

6.1	Evolution des Pre-Penalty-Volumens einer über 11 Sekunden beobachteten Kreiselsituation – 1.	178
6.2	Evolution des Pre-Penalty-Volumens einer über 11 Sekunden beobachteten Kreiselsituation – 2.	179
6.3	Evolution des Pre-Penalty-Volumens einer über 11 Sekunden beobachteten Kreiselsituation – 3.	180
6.4	Zyklische Trajektorienplanung einer über 11 Sekunden beobachteten Kreiselsituation.	181
6.5	HMM-Zustandsraum für mehrspurige Straßen.	183
6.6	Erwünschtes und unerwünschtes Fahrverhalten auf mehrspurigen Straßen.	185
6.7	Transitionsmöglichkeiten der HMM-Zustandsarten mehrspuriger Straßen.	186
6.8	Trajektorienplanung eines Überholvorgangs.	187
6.9	HMM-Trajektorienplanung einer Notfalltrajektorie.	190
6.10	PITRA-Planungsvarianten eines Ausparkmanövers.	193
6.11	Reaktive Interaktion des SPARC-Konzepts.	194
6.12	Heuristik des PITRA-Modells.	196



Tabellenverzeichnis

3.1	Gegenüberstellung Euler-Lagrange- und Hidden-Markov-Modell. . .	65
5.1	Topologische Analyse des synthetisierten Pre-Penalty-Volumens. . .	153
5.2	Topologische Analyse der Beispielsituationen.	170



Eigene Publikationen

- [E1] RUF, M.: *Considerations on Trajectory Planning Models in Automated Driving*. In: BEYERER, J. und A. PAK (Hrsg.): *Proceedings of the 2015 Joint Workshop of Fraunhofer IOSB and Institute for Anthropomatics, Vision and Fusion Laboratory*, Karlsruher Schriften zur Anthropomatik. KIT Scientific Publishing, Karlsruhe, 2015.
- [E2] RUF, M., J. R. ZIEHN, L. GERMAN, B. ROSENHAHN, D. WILLERSINN, J. BEYERER und H. GOTZIG: *Lightweight, Non-invasive Collection of Steering Wheel Angles and Pedal Positions*. In: *Proceedings of the International Conference on Instrumentation, Control and Automation (ICA 2016)*, S. 189–196, 2016.
- [E3] RUF, M., J. R. ZIEHN, B. ROSENHAHN, J. BEYERER, D. WILLERSINN und H. GOTZIG: *Evaluation of an Analytic Model for Car Dynamics*. In: *Proceedings of the International Conference on Mechatronics and Control (ICMC 2014)*, S. 2446–2451, 2014.
- [E4] RUF, M., J. R. ZIEHN, B. ROSENHAHN, J. BEYERER, D. WILLERSINN und H. GOTZIG: *Situation Prediction and Reaction Control (SPARC)*. In: FÄRBER, B., K. DIETMAYER, K. BENGLER, M. MAURER, C. STILLER und H. WINNER (Hrsg.): *9. Workshop Fahrerassistenzsysteme (FAS 2014)*, S. 55–66, 2014.
- [E5] RUF, M., J. R. ZIEHN, D. WILLERSINN, B. ROSENHAHN, J. BEYERER und H. GOTZIG: *A Continuous Approach to Autonomous Driving*. In: *Proceedings of the Conference on Vehicle and Infrastructure Safety Improvement in Adverse Conditions and Night Driving (VISION 2014)*, Versailles, Frankreich, 2014.

- [E6] RUF, M., J. R. ZIEHN, D. WILLERSINN, B. ROSENHAHN, J. BEYERER und H. GOTZIG: *Comparison of Local vs. Global Optimization for Trajectory Planning in Automated Driving*. In: STILLER, C., K. BENGLER, K. DIETMAYER, L. ECKSTEIN, B. FÄRBER, M. MAURER und H. WINNER (Hrsg.): *10. Workshop Fahrerassistenzsysteme (FAS2015)*, S. 71–83, 2015.
- [E7] RUF, M., J. R. ZIEHN, D. WILLERSINN, B. ROSENHAHN, J. BEYERER und H. GOTZIG: *Global Trajectory Optimization on Multilane Roads*. In: *Proceedings of the IEEE 18th International Conference on Intelligent Transportation Systems (ITSC 2015)*, S. 1908–1914, 2015.
- [E8] ZIEHN, J. R., B. ROSENHAHN, M. RUF, D. WILLERSINN, B. SCHEUERMANN und VAIS, ALEXANDER (ERFINDER). FRAUNHOFER-GESELLSCHAFT ZUR FÖRDERUNG DER ANGEWANDTEN FORSCHUNG E.V., 80686 MÜNCHEN, DE (PATENTINHABER): *Verfahren zum Steuern eines Fahrzeugs, Vorrichtung zum Erzeugen von Steuersignalen für ein Fahrzeug und Fahrzeug (angemeldet)*, Deutsches Patent. DE 10 2013 225 057 A1. 2013.
- [E9] ZIEHN, J. R., B. ROSENHAHN, M. RUF, D. WILLERSINN, B. SCHEUERMANN und VAIS, ALEXANDER (ERFINDER). FRAUNHOFER-GESELLSCHAFT ZUR FÖRDERUNG DER ANGEWANDTEN FORSCHUNG E.V., 80686 MÜNCHEN, DE (PATENTINHABER): *Verfahren zum Steuern eines Fahrzeugs, Vorrichtung zum Erzeugen von Steuersignalen für ein Fahrzeug und Fahrzeug*, Europäisches Patent. EP 2 881 829 A2. 2014.
- [E10] ZIEHN, J. R., M. RUF, B. ROSENHAHN, D. WILLERSINN, J. BEYERER und H. GOTZIG: *Correspondence between Variational Methods and Hidden Markov Models*. In: *Proceedings of the IEEE Intelligent Vehicles Symposium (IV 2015)*, S. 380–385, 2015.
- [E11] ZIEHN, J. R., M. RUF, D. WILLERSINN, B. ROSENHAHN, J. BEYERER und H. GOTZIG: *A Tractable Interaction Model for Trajectory Planning in Automated Driving*. In: *Proceedings of the IEEE 19th International Conference on Intelligent Transportation Systems (ITSC 2016)*, S. 1410–1417, 2016.

B

Betreute Arbeiten

- [S1] DÜRR, F.: *Manöverplanung auf riemannschen Oberflächen*. Proseminararbeit, Karlsruher Institut für Technologie (KIT), 2014.
- [S2] DÜRR, F.: *Entwicklung und Evaluation einer Simulationsumgebung für automatisiertes Fahren*. Bachelorarbeit, Karlsruher Institut für Technologie (KIT), 2015.
- [S3] DÜRR, F.: *Neuronale Netze für automatisches Fahren*. Seminararbeit, Karlsruher Institut für Technologie (KIT), 2016.
- [S4] DÜRR, F.: *Notbremssystem für Systemausfälle im vollautomatischen Fahren*. Masterarbeit, Karlsruher Institut für Technologie (KIT), 2018.
- [S5] FILSINGER, M.: *Tiefenschätzungsverfahren für Gated Viewing im Bereich des automatischen Fahrens*. Masterarbeit, Karlsruher Institut für Technologie (KIT), 2016.
- [S6] GALL, I.: *Automatische Kamerakalibrierung für Stere oanwendungen*. Masterarbeit, Karlsruher Institut für Technologie (KIT), 2014.
- [S7] GIFFHORN, C.: *Realisierung und Evaluation einer stochastischen Situationsprädiktion*. Diplomarbeit, Karlsruher Institut für Technologie (KIT), 2013.
- [S8] GRESSENBUCH, L.: *Implementierung und Evaluation eines Trajektorienplanungsalgorithmus in paralleler Hardware*. Bachelorarbeit, Karlsruher Institut für Technologie (KIT), 2017.
- [S9] KÖNIG, J.: *Szenariensimulation und Kollisionsdetektion innerhalb des Entwicklungstools CarMaker*. Bachelorarbeit, Karlsruher Institut für Technologie (KIT), 2013.

- [S10] MOHRA, A.: *Stereo-Rekonstruktion*. Proseminararbeit, Karlsruher Institut für Technologie (KIT), 2014.
- [S11] OEMIGK, J.-P.: *Entwurf und Evaluation einer Folgeregelung für ein autonomes Fahrzeug*. Bachelorarbeit, Fachhochschule Aachen, 2014.
- [S12] ORTELT, B.: *Instanzbasiertes semantisches Labeling von Straßenbilddaten aus Fahrzeugperspektive basierend auf tiefen neuronalen Netzen*. Masterarbeit, Karlsruher Institut für Technologie (KIT), 2017.
- [S13] PETERS, C.: *Connection of a FEM-Simulation to the Open-Source Simulation OCTANE*. Bachelorarbeit, Karlsruher Institut für Technologie (KIT), 2018.
- [S14] RAUSCH, D.: *Hidden-Markov-Modelle zur Trajektorienplanung*. Masterarbeit, Karlsruher Institut für Technologie (KIT), 2015.
- [S15] REITH, Z.: *Trajektorienoptimierung unter harten Nebenbedingungen*. Masterarbeit, Karlsruher Institut für Technologie (KIT), 2014.
- [S16] STEIN, F.: *Extraction of Traffic Situations from Aerial Footage*. Masterarbeit, Karlsruher Institut für Technologie (KIT), 2017.
- [S17] WOLF, D.: *Evaluation eines modellprädiktiven Ansatzes im Kontext des SPARC-Konzepts*. Masterarbeit, Karlsruher Institut für Technologie (KIT), 2014.
- [S18] ZÄBISCH, T.: *Extraktion der Radstellung aus Videodaten*. Bachelorarbeit, Hochschule Karlsruhe, 2016.



Literaturverzeichnis

- [1] ACV AUTOMOBIL-CLUB VERKEHR E.V.: *ACV Akzeptanzstudie: Autonomes Fahren*. Online verfügbar unter <https://www.acv.de/uploads/2015/02/acv-akzeptanzstudie-autonomes-fahren.pdf>, zuletzt geprüft am 13. November 2017.
- [2] AGRESTI, A.: *An introduction to categorical data analysis*. Wiley-Interscience, Hoboken, NJ, 2. Aufl., 2007.
- [3] ALESIANI, F. und C. WUTHISHUWONG: *Locally Growing Rapid Tree (LGRT) Motion Planning for Autonomous Driving*. In: *Proceedings of the IEEE 19th International Conference on Intelligent Transportation Systems (ITSC 2016)*, S. 1120–1125, 2016.
- [4] ALTICHE, F., P. POLACK und A. DE LA FORTELLE: *A simple dynamic model for aggressive, near-limits trajectory planning*. In: *Proceedings of the IEEE Intelligent Vehicles Symposium (IV 2017)*, S. 141–147, 2017.
- [5] ANVARI, B., M. G. BELL, A. SIVAKUMAR und W. Y. OCHIENG: *Modelling shared space users via rule-based social force model*. *Transportation Research Part C: Emerging Technologies*, 51:83–103, 2015.
- [6] AOUDE, G. S., B. D. LUDERS, D. S. LEVINE und J. P. HOW: *Threat-aware Path Planning in Uncertain Urban Environments*. In: *Proceedings of the IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS 2010)*, S. 6058–6063, 2010.
- [7] ARORA, S. und B. BARAK: *Computational Complexity: A Modern Approach*. Cambridge University Press, New York, 1. Aufl., 2016.

- [8] ARSLAN, O. und P. TSIOTRAS: *Use of relaxation methods in sampling-based algorithms for optimal motion planning*. In: *Proceedings of the 2013 IEEE International Conference on Robotics and Automation (ICRA)*, S. 2421–2428, 2013.
- [9] BACHA, A., C. BAUMAN, R. FARUQUE, M. FLEMING, C. TERWELP, C. REINHOLTZ, D. HONG, A. WICKS, T. ALBERI, D. ANDERSON, S. CACCIOLA, P. CURRIER, A. DALTON, J. FARMER, J. HURDUS, S. KIMMEL, P. KING, A. TAYLOR, D. VAN COVERN und M. WEBSTER: *Odin: Team VictorTango's entry in the DARPA Urban Challenge*. *Journal of Field Robotics*, 25(8):467–492, 2008.
- [10] BAMBERG, G.: *Statistische Entscheidungstheorie*. Springer-Verlag Berlin Heidelberg, 1. Aufl., 1972.
- [11] BATZ, T., K. WATSON und J. BEYERER: *Recognition of dangerous situations within a cooperative group of vehicles*. In: *2009 IEEE Intelligent Vehicles Symposium*, S. 907–912, 2009.
- [12] BAUER, E., F. LOTZ, M. PFROMM, M. SCHREIER, B. ABENDROTH, S. CIELER, A. ECKERT, A. HOHM, S. LÜKE, P. RIETH, V. WILLERT und J. ADAMY: *PRORETA 3: An Integrated Approach to Collision Avoidance and Vehicle Automation*. at - Automatisierungstechnik, 60(12):755–765, 2012.
- [13] BEAL, C. E. und J. C. GERDES: *Model Predictive Control for Vehicle Stabilization at the Limits of Handling*. *IEEE Transactions on Control Systems Technology*, 21(4):1258–1269, 2013.
- [14] BENDER, P. und C. STILLER: *Trajektorienplanung: Manöveridentifikation anhand der Topologie des Freiraums*. In: STILLER, C., K. BENGLER, K. DIETMAYER, L. ECKSTEIN, B. FÄRBER, M. MAURER und H. WINNER (Hrsg.): *10. Workshop Fahrerassistenzsysteme (FAS2015)*, 2015.
- [15] BENDER, P., O. S. TAS, J. ZIEGLER und C. STILLER: *The Combinatorial Aspect of Motion Planning: Maneuver Variants in Structured Environments*. In: *Proceedings of the IEEE Intelligent Vehicles Symposium (IV 2015)*, S. 1386–1392, 2015.
- [16] BERCHTOLD, F.: *Geometrie*. Springer Berlin Heidelberg, Berlin, Heidelberg, 2017.

- [17] BERGLUND, T., A. BRODNIK, H. JONSSON, M. STAFFANSON und I. SODERKVIST: *Planning Smooth and Obstacle-Avoiding B-Spline Paths for Autonomous Mining Vehicles*. IEEE Transactions on Automation Science and Engineering, 7(1):167–172, 2010.
- [18] BERKEMEIER, M. D., S. PEREZ und D. BEVLY: *On the suitability of Nonlinear Model Predictive Control for Unmanned Ground Vehicles*. In: *Proceedings of the American Control Conference (ACC 2014)*, S. 4605–4610, 2014.
- [19] BERNTORP, K., B. OLOFSSON, K. LUNDAHL und L. NIELSEN: *Models and methodology for optimal trajectory generation in safety-critical road-vehicle manoeuvres*. Vehicle System Dynamics, 52(10):1304–1332, 2014.
- [20] BERTONCELLO, M. und D. WEE: *Ten ways autonomous driving could redefine the automotive world*, 2015. Online verfügbar unter <https://www.mckinsey.com/industries/automotive-and-assembly/our-insights/ten-ways-autonomous-driving-could-redefine-the-automotive-world>, zuletzt geprüft am 13. November 2017.
- [21] BESSELMANN, T. und M. MORARI: *Autonomous Vehicle Steering Using Explicit LPV-MPC*. In: *Proceedings of the IEEE European Control Conference (ECC 2009)*, S. 2628–2633, 2009.
- [22] BEYERER, J., F. PUENTE LEÓN und C. FRESE: *Automatische Sichtprüfung: Grundlagen, Methoden und Praxis der Bildgewinnung und Bildauswertung*. Springer Berlin und Springer Vieweg, Berlin, 2. erw. u. verb. Aufl., 2016.
- [23] BOHREN, J., T. FOOTE, J. KELLER, A. KUSHLEYEV, D. LEE, A. STEWART, P. VERNAZA, J. DERENICK, J. SPLETZER und B. SATTERFIELD: *Little Ben: The Ben Franklin Racing Team's entry in the 2007 DARPA Urban Challenge*. Journal of Field Robotics, 25(9):598–614, 2008.
- [24] BOROUJENI, Z., D. GOEHRING, F. ULBRICH, D. NEUMANN und R. ROJAS: *Flexible unit A-star trajectory planning for autonomous vehicles on structured road maps*. In: *Proceedings of the IEEE International Conference on Vehicular Electronics and Safety (ICVES 2017)*, S. 7–12, 2017.
- [25] BORRELLI, F., A. BEMPORAD und M. MORARI: *Predictive control for linear and hybrid systems*. Cambridge University Press, Cambridge, 2017.

- [26] BOYER, F. und F. LAMIRAUX: *Trajectory deformation applied to kinodynamic motion planning for a realistic car model*. In: *Proceedings of the IEEE International Conference on Robotics and Automation (ICRA 2006)*, S. 487–492, 2006.
- [27] BRAID, D., A. BROGGI und G. SCHMIEDEL: *The TerraMax autonomous vehicle*. *Journal of Field Robotics*, 23(9):693–708, 2006.
- [28] BRECHTEL, S., T. GINDELE und R. DILLMANN: *Probabilistic MDP-behavior planning for cars*. In: *Proceedings of the 14th International IEEE Conference on Intelligent Transportation Systems (ITSC 2011)*, S. 1537–1542, 2011.
- [29] BRECHTEL, S., T. GINDELE und R. DILLMANN: *Solving Continuous POMDPs: Value Iteration with Incremental Learning of an Efficient Space Representation*. In: *Proceedings of the 30th International Conference on Machine Learning (PMLR 2013)*, Bd. 28 d. Reihe *Proceedings of Machine Learning Research*, S. 370–378, 2013.
- [30] BRECHTEL, S., T. GINDELE und R. DILLMANN: *Probabilistic decision-making under uncertainty for autonomous driving using continuous POMDPs*. In: *Proceedings of the 17th International IEEE Conference on Intelligent Transportation Systems (ITSC 2014)*, S. 392–399, 2014.
- [31] BREITINGER, MATTHIAS: *Gutachter sehen im Tesla-Autopiloten "erhebliche Verkehrsgefährdung"*, 7.10.2016. Online verfügbar unter <http://www.zeit.de/mobilitaet/2016-10/autopilot-tesla-model-s-gutachten-verkehrsministerium-zulassung>, zuletzt geprüft am 08. November 2017.
- [32] BROCK, O.: *Generating Robot Motion: The Integration of Planning and Execution*. Dissertation, Stanford University, 1999.
- [33] BROGGI, A., P. MEDICI, P. ZANI, A. COATI und M. PANCIOLOI: *Autonomous vehicles control in the VisLab Intercontinental Autonomous Challenge*. *Annual Reviews in Control*, 36(1):161–171, 2012.
- [34] BUEHLER, M., K. IAGNEMMA und S. SINGH (Hrsg.): *The DARPA Urban Challenge*, Bd. 56. Springer Berlin Heidelberg, Berlin, Heidelberg, 2009.

- [35] CARVALHO, A., Y. GAO, A. GRAY, H. E. TSENG und F. BORRELLI: *Predictive control of an autonomous ground vehicle using an iterative linearization approach*. In: *Proceedings of the 16th International IEEE Conference on Intelligent Transportation Systems (ITSC 2013)*, S. 2335–2340, 2013.
- [36] COSTESEQUE, G. und J.-P. LEBACQUE: *Multi-anticipative Car-Following Behaviour: Macroscopic Modeling*. In: CHRAIBI, M. (Hrsg.): *Traffic and Granular Flow'13*, S. 395–405. Springer, Cham, 2015.
- [37] CREMEAN, L. B., T. B. FOOTE, J. H. GILLULA, G. H. HINES, D. KOGAN, K. L. KRIECHBAUM, J. C. LAMB, J. LEIBS, L. LINDZEY, C. E. RASMUSSEN, A. D. STEWART, J. W. BURDICK und R. M. MURRAY: *Alice: An Information-Rich Autonomous Vehicle for High-Speed Desert Navigation*. *Journal of Field Robotics*, 23(9):777–810, 2006.
- [38] DAGLI, I., M. BROST und G. BREUEL: *Action Recognition and Prediction for Driver Assistance Systems Using Dynamic Belief Networks*. In: KOWALCZYK, R. (Hrsg.): *Proceedings of the Agent Technology Workshops 2002*, Bd. 2592 d. Reihe *Lecture Notes in Computer Science*, S. 179–194. Springer, Berlin, 2003.
- [39] DARIANI, R., S. SCHMIDT und R. KASPER: *Optimal control based approach for autonomous driving*. In: *Proceedings of the IEEE 21st International Conference on Emerging Technologies and Factory Automation (ETFA 2016)*, S. 1–8, 2016.
- [40] DI FABIO, U., M. BROY, R. JUNGO BRÜNGGER, U. EICHHORN, A. GRUNWALD, D. HECKMANN, E. HILGENDORF, H. KAGERMANN, A. LOSINGER, M. LUTZBACHMANN, C. LÜTGE, A. MARKL, K. MÜLLER und K. NEHM: *Bericht der Ethik-Kommission: Automatisiertes und vernetztes Fahren*. Online verfügbar unter <http://www.bmvi.de/SharedDocs/DE/Publikationen/G/bericht-der-ethik-kommission.html>, zuletzt geprüft am 22. November 2017.
- [41] DOLGOV, D., S. THRUN, M. MONTEMERLO und J. DIEBEL: *Path Planning for Autonomous Vehicles in Unknown Semi-structured Environments*. *The International Journal of Robotics Research*, 29(5):485–501, 2010.
- [42] ESCHENBURG, J.-H. und J. JOST: *Differentialgeometrie und Minimalflächen*. Springer, Berlin, Heidelberg und New York, 2., vollst. überarb. und erw. Aufl., 2007.

- [43] EVESTEDT, N., E. WARD, J. FOLKESSON und D. AXEHILL: *Interaction aware trajectory planning for merge scenarios in congested traffic situations*. In: *Proceedings of the IEEE 19th International Conference on Intelligent Transportation Systems (ITSC 2016)*, S. 465–472, 2016.
- [44] FALCONE, P., F. BORRELLI, J. ASGARI, H. E. TSENG und D. HROVAT: *Predictive Active Steering Control for Autonomous Vehicle Systems*. *IEEE Transactions on Control Systems Technology*, 15(3):566–580, 2007.
- [45] FALCONE, P., F. BORRELLI, H. E. TSENG, J. ASGARI und D. HROVAT: *Linear time-varying model predictive control and its application to active steering systems: Stability analysis and experimental validation*. *International Journal of Robust and Nonlinear Control*, 18(8):862–875, 2008.
- [46] FAULWASSER, T. und R. FINDEISEN: *Ein prädiktiver Ansatz zur Lösung nichtlinearer Pfadverfolgungsprobleme unter Beschränkungen*. *at - Automatisierungstechnik*, 57(8):386–394, 2009.
- [47] FENGLER, B. und M. STREHL: *autofahren: Lehrbuch für die Fahrerlaubnisklasse B*. Verkehrs-Verlag GmbH, Remagen, 2013.
- [48] FERGUSON, D., T. M. HOWARD und M. LIKHACHEV: *Motion planning in urban environments*. *Journal of Field Robotics*, 25(11-12):939–960, 2008.
- [49] FERGUSON, D., T. M. HOWARD und M. LIKHACHEV: *Motion planning in urban environments - Part I*. In: *Proceedings of the IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS 2008)*, S. 1063–1069, 2008.
- [50] FISCHER, H. und H. KAUL: *Mathematik für Physiker - Band 3: Variationsrechnung - Differentialgeometrie - Mathematische Grundlagen der Allgemeinen Relativitätstheorie*. Springer, 2017.
- [51] FLEURY, S., P. SOUERES, J.-P. LAUMOND und R. CHATILA: *Primitives for smoothing mobile robot trajectories*. *IEEE Transactions on Robotics and Automation*, 11(3):441–448, 1995.
- [52] FRESE, C.: *Planung kooperativer Fahrmanöver für kognitive Automobile*, Bd. 10 d. Reihe *Karlsruher Schriften zur Anthropomatik*. KIT Scientific Publishing, Karlsruhe, 2012.

- [53] FRESE, C., T. BATZ und J. BEYERER: *Kooperative Verhaltensentscheidung für Gruppen kognitiver Automobile auf Grundlage des gemeinsamen Lagebilds Cooperative Behavior of Groups of Cognitive Automobiles based on a Common Relevant Picture*. at - Automatisierungstechnik, 56(12):644–652, 2008.
- [54] FRESE, C., T. BATZ und J. BEYERER: *Kooperative Bewegungsplanung zur Unfallvermeidung im Straßenverkehr mit der Methode der elastischen Bänder*. In: BRAUER, W., R. DILLMANN, J. BEYERER, C. STILLER, J. M. ZÖLLNER und T. GINDELLE (Hrsg.): *Autonome Mobile Systeme 2009*, Informatik aktuell, S. 193–200. Springer Berlin Heidelberg, Berlin, Heidelberg, 2009.
- [55] FRESE, C. und J. BEYERER: *Planning Cooperative Motions of Cognitive Automobiles Using Tree Search Algorithms*. In: DILLMANN, R., J. BEYERER, U. D. HANEBECK und T. SCHULZ (Hrsg.): *KI 2010*, Lecture Notes in Computer Science. Springer, Berlin, 2010.
- [56] FRESE, C. und J. BEYERER: *A comparison of motion planning algorithms for cooperative collision avoidance of multiple cognitive automobiles*. In: *Proceedings of the IEEE Intelligent Vehicles Symposium (IV 2011)*, S. 1156–1162, 2011.
- [57] FRESE, C., J. BEYERER und P. ZIMMER: *Cooperation of Cars and Formation of Cooperative Groups*. In: *Proceedings of the IEEE Intelligent Vehicles Symposium (IV 2007)*, S. 227–232, 2007.
- [58] FUNKE, J., P. THEODOSIS, R. HINDIYEH, G. STANEK, K. KRITATAKIRANA, C. GERDES, D. LANGER, M. HERNANDEZ, B. MÜLLER-BESSLER und B. HUHNKE: *Up to the Limits: Autonomous Audi TTS*. In: *Proceedings of the IEEE Intelligent Vehicles Symposium (IV 2012)*, S. 541–547, 2012.
- [59] GAO, W., Z.-P. JIANG und K. OZBAY: *Adaptive optimal control of connected vehicles*. In: *Proceedings of the 10th International Workshop on Robot Motion and Control (RoMoCo)*, S. 288–293, 2015.
- [60] GEHRIG, S. K. und F. J. STEIN: *Collision Avoidance for Vehicle-Following Systems*. IEEE Transactions on Intelligent Transportation Systems, 8(2):233–244, 2007.
- [61] GEIGER, C. und C. KANZOW: *Theorie und Numerik restringierter Optimierungs-aufgaben*. Springer, Berlin, 2002.

- [62] GINDELE, T., S. BRECHTEL und R. DILLMANN: *A probabilistic model for estimating driver behaviors and vehicle trajectories in traffic environments*. In: *Proceedings of the 13th International IEEE Conference on Intelligent Transportation Systems (ITSC 2010)*, S. 1625–1631, 2010.
- [63] GINDELE, T., S. BRECHTEL und R. DILLMANN: *Learning context sensitive behavior models from observations for predicting traffic situations*. In: *Proceedings of the 16th International IEEE Conference on Intelligent Transportation Systems (ITSC 2013)*, S. 1764–1771, 2013.
- [64] GIPPS, P. G.: *A behavioural car-following model for computer simulation*. *Transportation Research Part B: Methodological*, 15(2):105–111, 1981.
- [65] GLATTFELDER, A. H. und W. SCHAUFELBERGER: *A Path from Antiwindup to Override Control*. *IFAC Nonlinear Control Systems*, 37(13):1099–1104, 2004.
- [66] GONZALEZ, D., J. PEREZ, R. LATTARULO, V. MILANES und F. NASHASHIBI: *Continuous curvature planning with obstacle avoidance capabilities in urban scenarios*. In: *Proceedings of the 17th International IEEE Conference on Intelligent Transportation Systems (ITSC 2014)*, S. 1430–1435, 2014.
- [67] GONZALEZ, D., J. PEREZ, V. MILANES und F. NASHASHIBI: *A Review of Motion Planning Techniques for Automated Vehicles*. *IEEE Transactions on Intelligent Transportation Systems*, 17(4):1135–1145, 2016.
- [68] GUAN, T. und C. W. FREY: *Predictive fuel efficiency optimization using traffic light timings and fuel consumption model*. In: *Proceedings of the 16th International IEEE Conference on Intelligent Transportation Systems (ITSC 2013)*, S. 1553–1558, 2013.
- [69] GUAN, T. und C. W. FREY: *Improvement of Predictive Energy Efficiency Optimization using Long Distance Horizon Estimation*. In: *Proceedings of the IEEE Intelligent Vehicles Symposium (IV 2017)*, S. 1249–1255, 2017.
- [70] GUTJAHN, B., L. GROLL und M. WERLING: *Lateral Vehicle Trajectory Optimization Using Constrained Linear Time-Varying MPC*. *IEEE Transactions on Intelligent Transportation Systems*, 18(6):1586–1595, 2017.

- [71] GUTJAHR, B., C. PEK, L. GRÖLL und M. WERLING: *Recheneffiziente Trajektorienoptimierung für Fahrzeuge mittels quadratischem Programm*. at - Automatisierungstechnik, 64(10), 2016.
- [72] GUTJAHR, B. und M. WERLING: *Optimale Fahrzeugquerführung mittels linearer, zeitvarianter MPC*. In: STILLER, C., K. BENGLER, K. DIETMAYER, L. ECKSTEIN, B. FÄRBER, M. MAURER und H. WINNER (Hrsg.): *10. Workshop Fahrerassistenzsysteme (FAS2015)*, S. 61–70, 2015.
- [73] HALES, T. C.: *Dense Sphere Packings: A Blueprint for Formal Proofs*, Bd. 400 d. Reihe *London Mathematical Society lecture note series*. Cambridge University Press, Cambridge und New York, 2012.
- [74] HAN, L., H. YASHIRO, H. TEHRANI NIK NEJAD, Q. H. DO und S. MITA: *Bézier curve based path planning for autonomous vehicle in urban environment*. In: *Proceedings of the IEEE Intelligent Vehicles Symposium (IV 2010)*, S. 1036–1042, 2010.
- [75] HEINRICH, S., J. STUBBEMANN und R. ROJAS: *Optimizing a driving strategy by its sensor coverage of relevant environment information*. In: *2016 IEEE Intelligent Vehicles Symposium (IV 2016)*, S. 441–446, 2016.
- [76] HEINRICHS, D.: *Autonomes Fahren und Stadtstruktur*. In: MAURER, M., J. C. GERDES, B. LENZ und H. WINNER (Hrsg.): *Autonomes Fahren: Technische, rechtliche und gesellschaftliche Aspekte*, S. 219–239. Springer Vieweg, Berlin, 2015.
- [77] HESSE, T. und T. SATTEL: *An Approach to Integrate Vehicle Dynamics in Motion Planning for Advanced Driver Assistance Systems*. In: *Proceedings of the IEEE Intelligent Vehicles Symposium (IV 2007)*, S. 1240–1245, 2007.
- [78] HESTENES, M. R. und E. STIEFEL: *Methods of Conjugate Gradients for Solving Linear Systems*. Journal of Research of the National Bureau of Standards, 49(6):409, 1952.
- [79] HIDAS, P.: *Modelling vehicle interactions in microscopic simulation of merging and weaving*. Transportation Research Part C: Emerging Technologies, 13(1):37–62, 2005.

- [80] HILGERT, J., K. HIRSCH, T. BERTRAM UND M. HILLER: *Emergency path planning for autonomous vehicles using elastic band theory*. In: *Proceedings of the IEEE/ASME International Conference on Advanced Intelligent Mechatronics (AIM 2003)*, S. 1390–1395, 2003.
- [81] HORST, J. UND A. BARBERA: *Trajectory generation for an on-road autonomous vehicle*. In: *SPIE*, S. 62302J, 2006.
- [82] HORVÁTH & PARTNERS UND FRAUNHOFER IAO: *The Value of Time: Nutzerbezogene Service-Potenziale durch autonomes Fahren*.
- [83] HUANG, Q. UND H. WANG: *Fundamental Study of Jerk: Evaluation of Shift Quality and Ride Comfort*. In: *Proceedings of the Automotive Dynamics, Stability & Controls Conference and Exhibition*, SAE Technical Paper Series, 2004.
- [84] HUANG, W., M. FELLENDORF UND R. SCHÖNAUER: *Social Force based Vehicle Model for 2-dimensional Spaces*. In: THE TRANSPORTATION RESEARCH BOARD (Hrsg.): *91st TRB Annual Meeting*, 2012.
- [85] HUBMANN, C., M. AEBERHARD UND C. STILLER: *A Generic Driving Strategy for Urban Environments*. In: *Proceedings of the IEEE 19th International Conference on Intelligent Transportation Systems (ITSC 2016)*, S. 1010–1016, 2016.
- [86] HUBMANN, C., M. BECKER, D. ALTHOFF, D. LENZ UND C. STILLER: *Decision making for autonomous driving considering interaction and uncertain prediction of surrounding vehicles*. In: *Proceedings of the IEEE Intelligent Vehicles Symposium (IV 2017)*, S. 1671–1678, 2017.
- [87] ISERMANN, R.: *Fahrdynamik-Regelung: Modellbildung, Fahrerassistenzsysteme, Mechatronik*. Friedr. Vieweg & Sohn Verlag, Wiesbaden, 2006.
- [88] JANSON, L., E. SCHMERLING, A. CLARK UND M. PAVONE: *Fast Marching Tree: A Fast Marching Sampling-Based Method for Optimal Motion Planning in Many Dimensions*. *The International Journal of Robotics Research*, 34(7):883–921, 2015.
- [89] JEON, J. H., R. V. COWLAGI, S. C. PETERS, S. KARAMAN, E. FRAZZOLI, P. TSIOTRAS UND K. IAGNEMMA: *Optimal motion planning with the half-car dynamical model for autonomous high-speed driving*. In: *Proceedings of the American Control Conference (ACC 2013)*, S. 188–193, 2013.

- [90] JOHNSON, J. und K. HAUSER: *Optimal longitudinal control planning with moving obstacles*. In: *Proceedings of the IEEE Intelligent Vehicles Symposium (IV 2013)*, S. 605–611, 2013.
- [91] KALA, R. und K. WARWICK: *Planning of multiple autonomous vehicles using RRT*. In: *Proceedings of the IEEE 10th International Conference on Cybernetic Intelligent Systems (CIS 2011)*, S. 20–25, 2011.
- [92] KALA, R. und K. WARWICK: *Multi-Level Planning for Semi-autonomous Vehicles in Traffic Scenarios Based on Separation Maximization*. *Journal of Intelligent & Robotic Systems*, 72(3-4):559–590, 2013.
- [93] KAMMEL, S., J. ZIEGLER, B. PITZER, M. WERLING, T. GINDELE, D. JAGZENT, J. SCHRÖDER, M. THUY, M. GOEBL, F. VON HUNDELSHAUSEN, O. PINK, C. FRESE und C. STILLER: *Team AnnieWAY's Autonomous System for the 2007 DARPA Urban Challenge*. *Journal of Field Robotics*, 25(9):615–639, 2008.
- [94] KARAMAN, S., M. R. WALTER, A. PEREZ, E. FRAZZOLI und S. TELLER: *Anytime Motion Planning using the RRT**. In: *Proceedings of the IEEE International Conference on Robotics and Automation (ICRA 2011)*, S. 1478–1483, 2011.
- [95] KELLERMANN, G.: *Geschwindigkeitsverhalten im Autobahnnetz 1992*. *Straße und Autobahn*, (5):283–287, 1995.
- [96] KESSLER, T., P. MINNERUP, D. LENZ und A. KNOLL: *Systematically comparing control approaches in the presence of actuator errors*. In: *Proceedings of the IEEE Intelligent Vehicles Symposium (IV 2017)*, S. 353–358, 2017.
- [97] KHATIB, M., H. JAOUNI, R. CHATILA und J. P. LAUMOND: *Dynamic path modification for car-like nonholonomic mobile robots*. In: *Proceedings of the International Conference on Robotics and Automation (ICRA 1997)*, S. 2920–2925, 1997.
- [98] KIELHÖFER, H.: *Variationsrechnung: Eine Einführung in die Theorie einer unabhängigen Variablen mit Beispielen und Aufgaben*. Aus dem Programm Mathematik. Vieweg + Teubner, Wiesbaden, 1. Aufl., 2010.
- [99] KIM, E., J. KIM und M. SUNWOO: *Model predictive control strategy for smooth path tracking of autonomous vehicles with steering actuator dynamics*. *International Journal of Automotive Technology*, 15(7):1155–1164, 2014.
- [100] KLENKE, A.: *Wahrscheinlichkeitstheorie*. Springer, Berlin, 1. Aufl., 2006.

- [101] KLOEDEN, H., N. BROUWER, S. RIES und R. H. RASSHOFFER: *Potenzial der Kopfpo-senerkennung zur Absichtsvorhersage von Fußgängern im urbanen Verkehr*. In: FÄRBER, B., K. DIETMAYER, K. BENGLER, M. MAURER, C. STILLER und H. WINNER (Hrsg.): *9. Workshop Fahrerassistenzsysteme (FAS 2014)*, S. 67–77, 2014.
- [102] KOHLHAAS, R., T. BITTNER, T. SCHAMM und M. ZÖLLNER: *Semantic state space for high-level maneuver planning in structured traffic scenes*. In: *Proceedings of the 17th International IEEE Conference on Intelligent Transportation Systems (ITSC 2014)*, S. 1060–1065, 2014.
- [103] KOHLHAAS, R., D. HAMMANN, T. SCHAMM und M. ZÖLLNER: *Planning of High-Level Maneuver Sequences on Semantic State Spaces*. In: *Proceedings of the IEEE 18th International Conference on Intelligent Transportation Systems (ITSC 2015)*, S. 2090–2096, 2015.
- [104] KRETZ, T., J. LOHMILLER und J. SCHLAICH: *The Social Force Model and its Relation to the Kladek Formula*. In: THE TRANSPORTATION RESEARCH BOARD (Hrsg.): *95st TRB Annual Meeting*, 2015.
- [105] KUMARASWAMY, P.: *A generalized probability density function for double-bounded random processes*. *Journal of Hydrology*, 46(1-2):79–88, 1980.
- [106] KUWATA, Y., S. KARAMAN, J. TEO, E. FRAZZOLI, J. P. HOW und G. FIORE: *Real-Time Motion Planning With Applications to Autonomous Urban Driving*. *IEEE Transactions on Control Systems Technology*, 17(5):1105–1118, 2009.
- [107] LABAKHUA, L., U. NUNES, R. RODRIGUES und F. S. LEITE: *Smooth Trajectory Planning for Fully Automated Passengers Vehicles: Spline and Clothoid Based Methods and Its Simulation*. In: *Informatics in Control Automation and Robotics*, Bd. 15 d. Reihe *Lecture Notes Electrical Engineering*, S. 169–182. Springer Berlin Heidelberg, Berlin, Heidelberg, 2008.
- [108] LAMIRAUX, F., E. FERRE und E. VALLEE: *Kinodynamic motion planning: Connecting exploration trees using trajectory optimization Methods*. In: *Proceedings of the International Conference on Robotics and Automation (ICRA 2004)*, S. 3987–3992 Vol.4, 2004.
- [109] LAN, L. W. und C.-W. CHANG: *Inhomogeneous cellular automata modeling for mixed traffic with cars and motorcycles*. *Journal of Advanced Transportation*, 39(3):323–349, 2005.

- [110] LAUX, H.: *Entscheidungstheorie*. Springer-Verlag, 2014.
- [111] LAVALLE, S. M.: *Planning algorithms*. Cambridge University Press, Cambridge, New York, 2006.
- [112] LAVALLE, S. M. und J. J. KUFFNER: *Randomized Kinodynamic Planning*. The International Journal of Robotics Research, 20(5):378–400, 2001.
- [113] LEAL-TAIXÉ, L. und B. ROSENHAHN: *Pedestrian Interaction in Tracking: The Social Force Model and Global Optimization Methods*. In: *Modeling, simulation and visual analysis of crowds*, Bd. 11 d. Reihe *The International Series in Video Computing*, S. 267–294. Springer, New York, 2013.
- [114] LEE, T.-C., R. L. KASHYAP und C.-N. CHU: *Building Skeleton Models via 3-D Medial Surface Axis Thinning Algorithms*. CVGIP: Graphical Models and Image Processing, 56(6):462–478, 1994.
- [115] LEMMER, K. (Hrsg.): *Neue autoMobilität: Automatisierter Straßenverkehr der Zukunft*. Acatech Position. Herbert Utz Verlag GmbH, München, 2016.
- [116] LENZ, D., T. KESSLER und A. KNOLL: *Stochastic model predictive controller with chance constraints for comfortable and safe driving behavior of autonomous vehicles*. In: *Proceedings of the IEEE Intelligent Vehicles Symposium (IV 2015)*, S. 292–297, 2015.
- [117] LENZ, H., C. K. WAGNER und R. SOLLACHER: *Multi-anticipative car-following model*. The European Physical Journal B - Condensed Matter and Complex Systems, 7(2):331–335, 1999.
- [118] LIKHACHEV, M. und D. FERGUSON: *Planning Long Dynamically Feasible Maneuvers for Autonomous Vehicles*. The International Journal of Robotics Research, 28(8):933–945, 2009.
- [119] LIMA, P. F.: *Predictive control for autonomous driving: with experimental evaluation on a heavy-duty construction truck*. Dissertation, KTH Royal Institute of Technology, Stockholm, Sweden, May 2016.
- [120] MALINOWSKA, A. B. und D. F. M. TORRES: *Quantum variational calculus*. Springer Briefs in Electrical and Computer Engineering. Control, Automation and Robotics. Springer, Cham, op. 2014.

- [121] MALLIKARJUNA, C. und K. R. RAO: *Cellular automata model for heterogeneous traffic*. Journal of Advanced Transportation, 43(3):321–345, 2009.
- [122] MANETTI, M. (Hrsg.): *Topology*. UNITEXT. Springer International Publishing, Cham, 2015.
- [123] MCKINSEY & COMPANY, INC.: *McKinsey-Studie: Autonomes Fahren verändert Autoindustrie und Städte*, 03. März 2015. Online verfügbar unter https://www.mckinsey.de/files/150303_pm_av.pdf, zuletzt geprüft am 13. November 2017.
- [124] MCNAUGHTON, M., C. URMSON, J. M. DOLAN und J.-W. LEE: *Motion Planning for Autonomous Driving with a Conformal Spatiotemporal Lattice*. In: *Proceedings of the IEEE International Conference on Robotics and Automation (ICRA 2011)*, S. 4889–4895, 2011.
- [125] MEHLHORN, K. und P. SANDERS: *Algorithms and data structures: The basic toolbox*. Springer, Berlin, 2008.
- [126] MINISTERIUM FÜR WISSENSCHAFT, FORSCHUNG UND KUNST: *2,5 Millionen Euro für Forschung auf dem Testfeld Autonomes Fahren*. Online verfügbar unter <https://www.baden-wuerttemberg.de/de/service/presse/pressemitteilung/pid/25-millionen-euro-fuer-forschung-auf-dem-testfeld-autonomes-fahren>, zuletzt geprüft am 13. November 2017.
- [127] MONTEMERLO, M., J. BECKER, S. BHAT, H. DAHLKAMP, D. DOLGOV, S. ETTINGER, D. HAHNEL, T. HILDEN, G. HOFFMANN, B. HUHNKE, D. JOHNSTON, S. KLUMPP, D. LANGER, A. LEVANDOWSKI, J. LEVINSON, J. MARCIL, D. ORENSTEIN, J. PAEFGEN, I. PENNY, A. PETROVSKAYA, M. PFLUEGER, G. STANEK, D. STAVENS, A. VOGT und S. THRUN: *Junior: The Stanford entry in the Urban Challenge*. Journal of Field Robotics, 25(9):569–597, 2008.
- [128] MOSLER, K. und F. SCHMID: *Wahrscheinlichkeitsrechnung und schließende Statistik*. Springer, Berlin, 2. Aufl., 2006.
- [129] MOUSAVI, M. A., Z. HESHMATI und B. MOSHIRI: *LTV-MPC based path planning of an autonomous vehicle via convex optimization*. In: *Proceedings of the 21st Iranian Conference on Electrical Engineering (ICEE 2013)*, S. 1–7, 2013.

- [130] NAGATA, A., K. NONAKA und K. SEKIGUCHI: *Model predictive obstacle avoidance control for omni-directional mobile robots based on fuzzy potential method*. In: *Proceedings of the European Control Conference (ECC 2014)*, S. 352–357, 2014.
- [131] NAGEL, K. und M. SCHRECKENBERG: *A cellular automaton model for freeway traffic*. *Journal de Physique I*, 2(12):2221–2229, 1992.
- [132] NOCEDAL, J. und S. J. WRIGHT: *Numerical optimization*. Springer series in operations research and financial engineering. Springer, New York, 2. Aufl., 2006.
- [133] NVIDIA: *DRIVE PX*. Online verfügbar unter <https://www.nvidia.de/self-driving-cars/drive-px>, zuletzt geprüft am 13. November 2017.
- [134] PACEJKA, H.: *Tire and Vehicle Dynamics*. Elsevier Science, San Diego, 3. Aufl., 2012.
- [135] PADEN, B., M. CAP, S. Z. YONG, D. YERSHOV und E. FRAZZOLI: *A Survey of Motion Planning and Control Techniques for Self-Driving Urban Vehicles*. *IEEE Transactions on Intelligent Vehicles*, 1(1):33–55, 2016.
- [136] PAUGAM, F.: *Towards the Mathematics of Quantum Field Theory*, Bd. 59 d. Reihe *Ergebnisse der Mathematik und ihrer Grenzgebiete*. Springer Science + Business Media, New York und London, 1. Aufl., 2014.
- [137] PETEREIT, J.: *Adaptive State \times Time Lattices: A Contribution to Mobile Robot Motion Planning in Unstructured Dynamic Environments*, Bd. 27 d. Reihe *Karlsruher Schriften zur Anthropomatik*. KIT Scientific Publishing, Karlsruhe, 2017.
- [138] PETROV, P. und F. NASHASHIBI: *Modeling and Nonlinear Adaptive Control for Autonomous Vehicle Overtaking*. *IEEE Transactions on Intelligent Transportation Systems*, 15(4):1643–1656, 2014.
- [139] PHILIPPSEN, R. und R. SIEGWART: *Smooth and Efficient Obstacle Avoidance for a Tour Guide Robot*. In: *Proceedings of the IEEE International Conference on Robotics and Automation (ICRA 2003)*, S. 446–451, 2003.
- [140] PIAZZI, A., C. LO BIANCO, M. BERTOZZI, A. FASCIOLI und A. BROGGI: *Quintic G2-Splines for the Iterative Steering of Vision-Based Autonomous Vehicles*. *IEEE Transactions on Intelligent Transportation Systems*, 3(1):27–36, 2002.

- [141] PIVTORAIKO, M. und A. KELLY: *Efficient constrained Path Planning via Search in State Lattices*. In: *Proceedings of the 8th International Symposium on Artificial Intelligence, Robotics and Automation in Space (i-SAIRAS 2005)*, 2005.
- [142] QIAN, X., F. ALTICHE, P. BENDER, C. STILLER und A. DE LA FORTELLE: *Optimal trajectory planning for autonomous driving integrating logical constraints: An MIQP perspective*. In: *Proceedings of the IEEE 19th International Conference on Intelligent Transportation Systems (ITSC 2016)*, S. 205–210, 2016.
- [143] QUINLAN, S.: *Real-time Modification of Collision-free Paths*. Dissertation, Stanford University, 1994.
- [144] QUINLAN, S. und O. KHATIB: *Elastic Bands: Connecting Path Planning and Control*. In: *Proceedings of the IEEE International Conference on Robotics and Automation (ICRA 2013)*, S. 802–807, 1993.
- [145] RASTELLI, J. P., R. LATTARULO und F. NASHASHIBI: *Dynamic trajectory generation using continuous-curvature algorithms for door to door assistance vehicles*. In: *Proceedings of the Intelligent Vehicles Symposium (IV 2014)*, S. 510–515, 2014.
- [146] REEDS, J. A. und L. A. SHEPP: *Optimal paths for a car that goes both forwards and backwards*. *Pacific Journal Mathematics*, 145(2):367–393, 1990.
- [147] RIEMER, M., J. WAUER und W. WEDIG: *Mathematische Methoden der Technischen Mechanik*. Morgan Kaufmann, 2015.
- [148] RÖSMANN, C., W. FEITEN, T. WÖSCH, F. HOFFMANN und T. BERTRAM: *Trajectory modification considering dynamic constraints of autonomous robots*. In: *Proceedings of the ROBOTIK 2012 - 7th German Conference on Robotics*, S. 74–79. VDE Verlag, 2012.
- [149] RÖSMANN, C., F. HOFFMANN und T. BERTRAM: *Timed-Elastic-Bands for time-optimal point-to-point nonlinear model predictive control*. In: *Proceedings of the European Control Conference (ECC 2015)*, S. 3352–3357, 2015.
- [150] RUCCO, A., G. NOTARSTEFANO und J. HAUSER: *Computing minimum lap-time trajectories for a single-track car with load transfer*. In: *Proceedings of the 51st IEEE Conference on Decision and Control (CDC 2012)*, S. 6321–6326, 2012.

- [151] RUDLOFF, C., R. SCHÖNAUER und M. FELLENDORF: *Comparing Calibrated Shared Space Simulation Model with Real-Life Data*. Transportation Research Record: Journal of the Transportation Research Board, 2390:44–52, 2013.
- [152] RÜSCHENDORF, L.: *Mathematische Statistik*. Springer-Lehrbuch Masterclass. Springer Spektrum, Berlin, 2014.
- [153] RYU, J.-H., D. OGAY, S. BULAVINTSEV, H. KIM und J.-S. PARK: *Development and Experiences of an Autonomous Vehicle for High-Speed Navigation and Obstacle Avoidance*. In: LEE, S., K.-J. YOON und J. LEE (Hrsg.): *Frontiers of Intelligent Autonomous Systems*, Studies in Computational Intelligence, S. 105–116. Springer, Berlin und Heidelberg, 2013.
- [154] SAE INTERNATIONAL: *Automated Driving: Levels of Driving Automation are Defined in new SAE International Standard J3016*, 2014. Online verfügbar unter http://www.sae.org/misc/pdfs/automated_driving.pdf, zuletzt geprüft am 24. Oktober 2017.
- [155] SAMMUT, C. und G. I. WEBB (Hrsg.): *Encyclopedia of machine learning and data mining*. Springer, New York, 2. Aufl., 2017.
- [156] SATTEL, T. und T. BRANDT: *Ground vehicle guidance along collision-free trajectories using elastic bands*. In: *American Control Conference (ACC 2005)*, S. 4991–4996, 2005.
- [157] SCHLECHTRIEMEN, J., K. P. WABERSICH und K.-D. KUHNERT: *Wiggling through complex traffic: Planning trajectories constrained by predictions*. In: *2016 IEEE Intelligent Vehicles Symposium (IV 2016)*, S. 1293–1300, 2016.
- [158] SCHMERLING, E., L. JANSON und M. PAVONE: *Optimal Sampling-Based Motion Planning under Differential Constraints: The Driftless Case*. In: *IEEE Robotics and Automation (ICRA 2015)*, S. 2368–2375, 2015.
- [159] SCHMIDT, S. und R. KASPER: *Ein hierarchischer Ansatz zur optimalen Bahnplanung und Bahnregelung für ein autonomes Fahrzeug*. at - Automatisierungstechnik, 60(12):743–754, 2012.
- [160] SCHRAMM, D., M. HILLER und R. BARDINI: *Modellbildung und Simulation der Dynamik von Kraftfahrzeugen*. Springer Berlin Heidelberg, Berlin und Heidelberg, 2010.

- [161] SHILLER, Z. und Y.-R. GWO: *Dynamic motion planning of autonomous vehicles*. IEEE Transactions on Robotics and Automation, 7(2):241–249, 1991.
- [162] SPEHR, J.: *On Hierarchical Models for Visual Recognition and Learning of Objects, Scenes, and Activities*, Bd. 11 d. Reihe *Studies in Systems, Decision and Control*. Springer International Publishing and Imprint and Springer, Cham, 2015.
- [163] STATISTISCHES BUNDESAMT: *Unfallentwicklung auf deutschen Straße 2012: Begleitmaterial zur Pressekonferenz am 10. Juli 2013 in Berlin*.
- [164] STATISTISCHES BUNDESAMT: *Unfallentwicklung auf deutschen Straße 2015: Begleitmaterial zur Pressekonferenz am 12. Juli 2016 in Berlin*.
- [165] STRUIK, D. J.: *Lectures on classical differential geometry*. Dover Publications, New York, 2. Aufl., 1988.
- [166] SUCAR, L. E.: *Probabilistic graphical models: Principles and applications*. Springer, London, 2015.
- [167] SWIFT NAVIGATION: *Piksi Multi GNSS Module*. Online verfügbar unter <https://www.swiftnav.com/piksi-multi>, zuletzt geprüft am 13. November 2017.
- [168] THRUN, S., M. MONTEMERLO, H. DAHLKAMP, D. STAVENS, A. ARON, J. DIEBEL, P. FONG, J. GALE, M. HALPENNY, G. HOFFMANN, K. LAU, C. OAKLEY, M. PALATUCCI, V. PRATT, P. STANG, S. STROHBAND, C. DUPONT, L.-E. JENDROSSEK, C. KOELEN, C. MARKEY, C. RUMMEL, J. VAN NIEKERK, E. JENSEN, P. ALESSANDRINI, G. BRADSKI, B. DAVIES, S. ETTINGER, A. KAEHLER, A. NEFIAN und P. MAHONEY: *Stanley: The Robot that Won the DARPA Grand Challenge*. Journal of Field Robotics, 23(9):661–692, 2006.
- [169] TRAUFFETTER, G.: *In der Geisterbahn*. DER SPIEGEL, (41):67–77, 2016.
- [170] TROUTMAN, J. L.: *Variational calculus and optimal control: Optimization with elementary convexity*. Undergraduate texts in mathematics. New York und Berlin, 2. Aufl., 1996.
- [171] TURRI, V., A. CARVALHO, H. E. TSENG, K. H. JOHANSSON und F. BORRELLI: *Linear model predictive control for lane keeping and obstacle avoidance on low curvature roads*. In: *Proceedings of the 16th International IEEE Conference on Intelligent Transportation Systems (ITSC 2013)*, S. 378–383, 2013.

- [172] ULBRICH, F., D. GOEHRING, T. LANGNER, Z. BOROUJENI und R. ROJAS: *Stable timed elastic bands with loose ends*. In: *Proceedings of the IEEE Intelligent Vehicles Symposium (IV 2017)*, S. 186–192, 2017.
- [173] URMSON, C., J. ANHALT, D. BAGNELL, C. BAKER, R. BITTNER, M. N. CLARK, J. DOLAN, D. DUGGINS, T. GALATALI, C. GEYER, M. GITTLEMAN, S. HARBAUGH, M. HERBERT, T. M. HOWARD, S. KOLSKI, A. KELLY, M. LIKHACHEV, M. MCNAUGHTON, N. MILLER, K. PETERSON, B. PILNICK, R. RAJKUMAR, P. RYBSKI, B. SALESKY, Y.-W. SEO, S. SINGH, J. SNIDER, A. STENTZ, W. R. WHITTAKER, Z. WOLKOWICKI, J. ZIGLAR, H. BAE, T. BROWN, D. DEMITRISH, B. LITKOUHI, J. NICKOLAOU, V. SADEKAR, W. ZHANG, J. STRUBLE, M. TAYLOR, M. DARMS und D. FERGUSON: *Autonomous driving in urban environments: Boss and the Urban Challenge*. *Journal of Field Robotics*, 25(8):425–466, 2008.
- [174] VAN BRUNT, B.: *The Calculus of Variations*. Universitext. Springer, New York, 2004.
- [175] WALDMANN, K.-H. und U. M. STOCKER: *Stochastische Modelle: Eine anwendungsorientierte Einführung*. *EMIL@A-stat*. Springer Berlin Heidelberg and Imprint and Springer, Berlin, Heidelberg, 2004.
- [176] WANG, S.: *State Lattice-based Motion Planning for Autonomous On-Road Driving*. Dissertation, Freie Universität Berlin, Berlin, 2015.
- [177] WANNINGER, L.: *Netz-RTK*. In: *GPS und Galileo – Methoden, Lösungen und neueste Entwicklungen*, DVW-Schriftenreihe, S. 59–69. Wißner-Verlag, Augsburg, 2006.
- [178] WEINSTOCK, R.: *Calculus of variations: With applications to physics and engineering*. Dover Publications, Mineola, 1974.
- [179] WEINZIERL, S.: *Handbuch der Audiotechnik*. VDI-Buch. Springer Berlin Heidelberg, Berlin, Heidelberg, 2008.
- [180] WERLING, M., T. GINDELE, D. JAGSZENT und L. GRÖLL: *A robust algorithm for handling moving traffic in urban scenarios*. In: *Proceedings of the IEEE Intelligent Vehicles Symposium (IV 2008)*, S. 1108–1112, 2008.

- [181] WERLING, M., S. KAMMEL, J. ZIEGLER UND L. GRÖLL: *Optimal trajectories for time-critical street scenarios using discretized terminal manifolds*. The International Journal of Robotics Research, 31(3):346–359, 2012.
- [182] WERLING, M., J. ZIEGLER, S. KAMMEL UND S. THRUN: *Optimal Trajectory Generation for Dynamic Street Scenarios in a Frenet Frame*. In: *Proceedings of the IEEE International Conference on Robotics and Automation (ICRA 2010)*, S. 987–993, 2010.
- [183] WESSLER, M.: *Entscheidungstheorie*. Gabler Verlag, Wiesbaden, 2012.
- [184] WIEDEMANN, R.: *Simulation des Straßenverkehrsflusses*, Bd. 8 d. Reihe Schriftenreihe am Institut für Verkehrswesen, Institut für Verkehrswesen, Universität Karlsruhe (TH). 1974.
- [185] WILLE, J. M., F. SAUST UND M. MAURER: *Comprehensive Treated Sections in a Trajectory Planner for Realizing Autonomous Driving in Braunschweig's Urban Traffic*. In: *Proceedings of the 13th International IEEE Conference on Intelligent Transportation Systems (ITSC 2010)*, S. 647–652, 2010.
- [186] XU, W., J. WEI, J. M. DOLAN, H. ZHAO UND H. ZHA: *A real-time motion planner with trajectory optimization for autonomous vehicles*. In: *Proceedings of the IEEE International Conference on Robotics and Automation (ICRA 2012)*, S. 2061–2067, 2012.
- [187] YI, B., S. GOTTSCHLING, J. FERDINAND, N. SIMM, F. BONARENS UND C. STILLER: *Real time integrated vehicle dynamics control and trajectory planning with MPC for critical maneuvers*. In: *2016 IEEE Intelligent Vehicles Symposium (IV 2016)*, S. 584–589, 2016.
- [188] YOON, Y., J. SHIN, H. J. KIM, Y. PARK UND S. SASTRY: *Model-predictive active steering and obstacle avoidance for autonomous ground vehicles*. Control Engineering Practice, 17(7):741–750, 2009.
- [189] ZEIDLER, E.: *Springer-Taschenbuch der Mathematik*. Springer Fachmedien Wiesbaden, Wiesbaden, 2013.
- [190] ZIEGLER, J., P. BENDER, T. DANG UND C. STILLER: *Trajectory Planning for BERTHA - a Local, Continuous Method*. In: *Proceedings of the Intelligent Vehicles Symposium (IV 2014)*, S. 450–457, 2014.

- [191] ZIEGLER, J., P. BENDER, H. LATEGAHN, M. SCHREIBER, T. STRAUSS, T. DANG und C. STILLER: *Kartengestütztes automatisiertes Fahren auf der Bertha-Benz-Route von Mannheim nach Pforzheim*. In: FÄRBER, B., K. DIETMAYER, K. BENGLER, M. MAURER, C. STILLER und H. WINNER (Hrsg.): *9. Workshop Fahrerassistenzsysteme (FAS 2014)*, S. 79–93, 2014.
- [192] ZIEGLER, J., P. BENDER, M. SCHREIBER, H. LATEGAHN, T. STRAUSS, C. STILLER, T. DANG, U. FRANKE, N. APPENRODT, C. G. KELLER, E. KAUS, R. G. HERRTWICH, C. RABE, D. PFEIFFER, F. LINDNER, F. STEIN, F. ERBS, M. ENZWEILER, C. KNOPPEL, J. HIPPEL, M. HAUEIS, M. TREPPE, C. BRENNK, A. TAMKE, M. GHANAAT, M. BRAUN, A. JOOS, H. FRITZ, H. MOCK, M. HEIN und E. ZEEB: *Making Bertha Drive—An Autonomous Journey on a Historic Route*. *IEEE Intelligent Transportation Systems Magazine*, 6(2):8–20, 2014.
- [193] ZIEGLER, J. und C. STILLER: *Spatiotemporal state lattices for fast trajectory planning in dynamic on-road driving scenarios*. In: *Proceedings of the IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS 2009)*, S. 1879–1884, 2009.
- [194] ZIEGLER, J. und M. WERLING: *Navigating car-like robots in unstructured environments using an obstacle sensitive cost function*. In: *Proceedings of the IEEE Intelligent Vehicles Symposium (IV 2008)*, S. 787–791, 2008.
- [195] ZIEHN, J. R.: *Energy-based collision avoidance for autonomous vehicles*. Masterarbeit, Leibniz Universität Hannover, 2012.
- [196] ZIMMERMANN, W. und R. SCHMIDGALL: *Kommunikation zwischen Fahrzeugen*. In: ZIMMERMANN, W. und R. SCHMIDGALL (Hrsg.): *Bussysteme in der Fahrzeugtechnik*, S. 483–489. Springer Fachmedien Wiesbaden, Wiesbaden, 2014.

Karlsruher Schriftenreihe zur Anthropomatik (ISSN 1863-6489)

Herausgeber: Prof. Dr.-Ing. habil. Jürgen Beyerer

- Band 1** Jürgen Geisler
Leistung des Menschen am Bildschirmarbeitsplatz. 2006
ISBN 3-86644-070-7
- Band 2** Elisabeth Peinsipp-Byma
Leistungserhöhung durch Assistenz in interaktiven Systemen zur Szenenanalyse. 2007
ISBN 978-3-86644-149-1
- Band 3** Jürgen Geisler, Jürgen Beyerer (Hrsg.)
Mensch-Maschine-Systeme. 2010
ISBN 978-3-86644-457-7
- Band 4** Jürgen Beyerer, Marco Huber (Hrsg.)
Proceedings of the 2009 Joint Workshop of Fraunhofer IOSB and Institute for Anthropomatics, Vision and Fusion Laboratory. 2010
ISBN 978-3-86644-469-0
- Band 5** Thomas Usländer
Service-oriented design of environmental information systems. 2010
ISBN 978-3-86644-499-7
- Band 6** Giulio Milighetti
Multisensorielle diskret-kontinuierliche Überwachung und Regelung humanoider Roboter. 2010
ISBN 978-3-86644-568-0
- Band 7** Jürgen Beyerer, Marco Huber (Hrsg.)
Proceedings of the 2010 Joint Workshop of Fraunhofer IOSB and Institute for Anthropomatics, Vision and Fusion Laboratory. 2011
ISBN 978-3-86644-609-0
- Band 8** Eduardo Monari
Dynamische Sensorselektion zur auftragsorientierten Objektverfolgung in Kameranetzwerken. 2011
ISBN 978-3-86644-729-5

- Band 9** Thomas Bader
Multimodale Interaktion in Multi-Display-Umgebungen. 2011
ISBN 3-86644-760-8
- Band 10** Christian Frese
Planung kooperativer Fahrmanöver für kognitive Automobile. 2012
ISBN 978-3-86644-798-1
- Band 11** Jürgen Beyerer, Alexey Pak (Hrsg.)
Proceedings of the 2011 Joint Workshop of Fraunhofer IOSB and Institute for Anthropomatics, Vision and Fusion Laboratory. 2012
ISBN 978-3-86644-855-1
- Band 12** Miriam Schleipen
Adaptivität und Interoperabilität von Manufacturing Execution Systemen (MES). 2013
ISBN 978-3-86644-955-8
- Band 13** Jürgen Beyerer, Alexey Pak (Hrsg.)
Proceedings of the 2012 Joint Workshop of Fraunhofer IOSB and Institute for Anthropomatics, Vision and Fusion Laboratory. 2013
ISBN 978-3-86644-988-6
- Band 14** Hauke-Hendrik Vagts
Privatheit und Datenschutz in der intelligenten Überwachung: Ein datenschutzgewährendes System, entworfen nach dem „Privacy by Design“ Prinzip. 2013
ISBN 978-3-7315-0041-4
- Band 15** Christian Kühnert
Data-driven Methods for Fault Localization in Process Technology. 2013
ISBN 978-3-7315-0098-8
- Band 16** Alexander Bauer
Probabilistische Szenenmodelle für die Luftbildauswertung. 2014
ISBN 978-3-7315-0167-1
- Band 17** Jürgen Beyerer, Alexey Pak (Hrsg.)
Proceedings of the 2013 Joint Workshop of Fraunhofer IOSB and Institute for Anthropomatics, Vision and Fusion Laboratory. 2014
ISBN 978-3-7315-0212-8

- Band 18** Michael Teutsch
Moving Object Detection and Segmentation for Remote Aerial Video Surveillance. 2015
ISBN 978-3-7315-0320-0
- Band 19** Marco Huber
Nonlinear Gaussian Filtering: Theory, Algorithms, and Applications. 2015
ISBN 978-3-7315-0338-5
- Band 20** Jürgen Beyerer, Alexey Pak (Hrsg.)
Proceedings of the 2014 Joint Workshop of Fraunhofer IOSB and Institute for Anthropomatics, Vision and Fusion Laboratory. 2014
ISBN 978-3-7315-0401-6
- Band 21** Todor Dimitrov
Permanente Optimierung dynamischer Probleme der Fertigungssteuerung unter Einbeziehung von Benutzerinteraktionen. 2015
ISBN 978-3-7315-0426-9
- Band 22** Benjamin Kühn
Interessengetriebene audiovisuelle Szenenexploration. 2016
ISBN 978-3-7315-0457-3
- Band 23** Yvonne Fischer
Wissensbasierte probabilistische Modellierung für die Situationsanalyse am Beispiel der maritimen Überwachung. 2016
ISBN 978-3-7315-0460-3
- Band 24** Jürgen Beyerer, Alexey Pak (Hrsg.)
Proceedings of the 2015 Joint Workshop of Fraunhofer IOSB and Institute for Anthropomatics, Vision and Fusion Laboratory. 2016
ISBN 978-3-7315-0519-8
- Band 25** Pascal Birnstill
Privacy-Respecting Smart Video Surveillance Based on Usage Control Enforcement. 2016
ISBN 978-3-7315-0538-9
- Band 26** Philipp Woock
Umgebungskartenschätzung aus Sidescan-Sonardaten für ein autonomes Unterwasserfahrzeug. 2016
ISBN 978-3-7315-0541-9

- Band 27** Janko Petereit
Adaptive State × Time Lattices: A Contribution to Mobile Robot Motion Planning in Unstructured Dynamic Environments. 2017
ISBN 978-3-7315-0580-8
- Band 28** Erik Ludwig Krempel
Steigerung der Akzeptanz von intelligenter Videoüberwachung in öffentlichen Räumen. 2017
ISBN 978-3-7315-0598-3
- Band 29** Jürgen Moßgraber
Ein Rahmenwerk für die Architektur von Frühwarnsystemen. 2017
ISBN 978-3-7315-0638-6
- Band 30** Andrey Belkin
World Modeling for Intelligent Autonomous Systems. 2017
ISBN 978-3-7315-0641-6
- Band 31** Chettapong Janya-Anurak
Framework for Analysis and Identification of Nonlinear Distributed Parameter Systems using Bayesian Uncertainty Quantification based on Generalized Polynomial Chaos. 2017
ISBN 978-3-7315-0642-3
- Band 32** David Münch
Begriffliche Situationsanalyse aus Videodaten bei unvollständiger und fehlerhafter Information. 2017
ISBN 978-3-7315-0644-7
- Band 33** Jürgen Beyerer, Alexey Pak (Eds.)
Proceedings of the 2016 Joint Workshop of Fraunhofer IOSB and Institute for Anthropomatics, Vision and Fusion Laboratory. 2017
ISBN 978-3-7315-0678-2
- Band 34** Jürgen Beyerer, Alexey Pak and Miro Taphanel (Eds.)
Proceedings of the 2017 Joint Workshop of Fraunhofer IOSB and Institute for Anthropomatics, Vision and Fusion Laboratory. 2018
ISBN 978-3-7315-0779-6
- Band 35** Michael Grinberg
Feature-Based Probabilistic Data Association for Video-Based Multi-Object Tracking. 2018
ISBN 978-3-7315-0781-9

- Band 36** Christian Herrmann
**Video-to-Video Face Recognition for
Low-Quality Surveillance Data.** 2018
ISBN 978-3-7315-0799-4
- Band 37** Chengchao Qu
**Facial Texture Super-Resolution
by Fitting 3D Face Models.** 2018
ISBN 978-3-7315-0828-1
- Band 38** Miriam Ruf
**Geometrie und Topologie von Trajektorienoptimierung
für vollautomatisches Fahren.** 2018
ISBN 978-3-7315-0832-8

Lehrstuhl für Interaktive Echtzeitsysteme
Karlsruher Institut für Technologie

Fraunhofer-Institut für Optronik, Systemtechnik
und Bildauswertung IOSB Karlsruhe

In der Arbeit werden allgemeine Aussagen über das Themenfeld der Bewegungsplanung für vollautomatisches Fahren entwickelt. Hierfür wird zunächst eine intuitive Problemformulierung abgeleitet, woraus sich das Euler-Lagrange-Modell zur Trajektorienplanung ergibt. Aufgrund der Nachteile iterativer Optimierung wird eine Korrespondenz mit dem Hidden-Markov-Modell hergeleitet. Die globale Optimierung wird zur topologischen Analyse des Trajektorienraums anhand synthetisierter Räume und realer Beispielsituationen eingesetzt. Für die geometrische Analyse des Trajektorienraums wird eine probabilistische Beschreibung der Umgebung des Ego-Fahrzeugs mit ihrer Prädiktion in die Zukunft und das inverse C^2 -Modell hergeleitet. Damit können Unsicherheiten in einer gemeinsamen Bewertungsfunktion vereint werden mit intrinsischen Trajektorieneigenschaften. Die Ergebnisse zeigen eine hohe Komplexität des Trajektorienraums realen Verkehrsgeschehens mit einer Vielzahl an lokalen Optima deutlich unterschiedlicher Güte und geben damit Aufschluss über Anforderungen an zukünftige Trajektorienplanungsverfahren.

ISSN 1863-6489
ISBN 978-3-7315-0832-8

