

Trajektorienprädiktion für das automatisierte Fahren

**Entwicklung und Evaluierung von Verfahren zur Trajektorienprädiktion für
beobachtete Verkehrsteilnehmer in Autobahnszenarien**

DISSERTATION

eingereicht zur Erlangung
des akademischen Grades

Doktor-Ingenieur

an der

Fakultät für Elektrotechnik und Informationstechnik
Technische Universität Dortmund

von

Christian Wissing, M. Sc.

aus Dorsten

Tag der Einreichung: 8. Mai 2020

Erster Gutachter: Univ.-Prof. Dr.-Ing. Prof. h.c. Dr. h.c. Torsten Bertram
Zweiter Gutachter: Univ.-Prof. Dr.-Ing. Ulrich Konigorski

Tag des Kolloquiums: 6. Oktober 2020

Vorwort

Als ich mich nach der Masterarbeit im Bereich Robotik nach der Gelegenheit einer Promotion in eben diesem erkundigte, bekam ich die Möglichkeit mein Wissen im Bereich des Automatisierten Fahrens zu vertiefen. Gerade wenn es um das automatisierte Fahren gehe, seien *Autos ja schließlich auch Roboter*. Ein knappes Jahr später kam ich in die glückliche Situation meine Forschung im Kooperationsprojekt mit der ZF Group beginnen und schlussendlich diese Arbeit abschließen zu können. Eine ganze Reihe von Menschen haben mich hierbei begleitet, unterstützt und motiviert.

Ich danke Herrn Univ.-Prof. Dr.-Ing. Prof. h.c. Dr. h.c. Torsten Bertram für alle Freiheiten in meiner wissenschaftlichen Laufbahn und die Hinweise sowie Denkanstöße zu den richtigen Zeitpunkten, für die Möglichkeiten meine Ergebnisse weltweit zu präsentieren und für die außergewöhnliche Atmosphäre und Arbeitsumgebung am Lehrstuhl für Regelungssystemtechnik.

Ich danke Herrn Univ.-Prof. Dr.-Ing. Ulrich Konigorski für das Interesse an meiner Arbeit und die Übernahme des Zweitgutachtens.

Außerdem möchte ich Herrn Univ.-Prof. Dr. rer. nat. habil. Christian Wöhler als drittem Prüfer und Herrn Univ.-Prof. Dr.-Ing. Martin Pfof für die Übernahme des Prüfungsvorsitzes danken.

Einen besonderen Dank möchte ich an alle Mitarbeiter des Lehrstuhls für Regelungssystemtechnik aussprechen. Es waren besondere Jahre, an die ich jederzeit gerne zurückdenke. Insbesondere möchte ich mich bei Herrn Dr.-Ing. Christoph Rösman für die inspirierenden Diskussionen und die tolle Zusammenarbeit über das Studium hinaus bedanken. Mein Dank gilt ebenfalls Herrn apl. Prof. Dr. rer. nat. Frank Hoffmann für die guten Ratschläge und weiterführenden Ideen. Zusätzlich geht ein besonderer Dank an Dr.-Ing. Martin Keller, Christian Lienke, Manuel Schmidt, Andreas Homann, Niklas Stannartz und Martin Krüger, die als wissenschaftliche Mitarbeiter in der Kooperation mit ZF meine Arbeit an vielen Stellen unterstützt haben, sowie allen Studierenden, die ich in meiner Zeit am Lehrstuhl betreuen durfte und die meine Arbeit vorangebracht haben.

Diese Arbeit wäre ohne die Unterstützung und Zuarbeit der Mitarbeiter des Projektpartners ZF nicht möglich gewesen. Hier gilt mein Dank insbesondere Dr. rer. nat. Till Nattermann für die Betreuung des Projektes.

Einen ganz besonderen Dank möchte ich sowohl meinen Eltern als auch meinen Schwiegereltern aussprechen, die mich während der gesamten Zeit Unterstützt haben und mir immer hilfsbereit zur Seite stehen.

Zu guter Letzt danke ich meiner wunderbaren Frau Vanessa, ohne die meine wissenschaftliche Arbeit nicht möglich gewesen wäre. Vielen Dank für deine Motivation in schwierigen Zeiten, für dein Verständnis für auch mal längere Abende und dafür, dass du immer an mich glaubst.

Kurzfassung

Moderne Fahrerassistenzsysteme können den Fahrer teilweise von der Fahraufgabe entbinden und das Fahrzeug in einfachen Situationen sicher durch den Straßenverkehr führen. Um den Fahrer vollständig aus der Verantwortung zu entlassen und das Fahrzeug automatisiert zu steuern, ist unter anderem ein umfassendes Verständnis der aktuellen Fahrsituation und eine möglichst gute Vorhersage der weiteren Entwicklung notwendig. Die vorliegende Arbeit beschreibt drei Ansätze zur Prädiktion der Trajektorien von benachbarten Verkehrsteilnehmern in Autobahnszenarien. Dazu wird zunächst eine Simulationsumgebung vorgestellt, die auf die Anforderungen der Entwicklung eines Verfahrens zur Trajektorienprädiktion zugeschnitten ist. Innerhalb der Simulation werden zum einen auftretende Unsicherheiten und Effekte der Sensorwahrnehmung modelliert. Zum anderen bilden stochastische Fahrermodelle das Verhalten der umgebenden Verkehrsteilnehmer ab, sodass realitätsnahe Szenarien erzeugt werden können.

Mit Hilfe der Simulationsumgebung werden drei Verfahren zur Trajektorienprädiktion entwickelt. Zunächst wird die Schätzung des aktuellen Fahrmanövers eines beobachteten Verkehrsteilnehmers mit einer effizienten Repräsentation der prädizierten Trajektorie kombiniert. Der Ansatz bildet die jeweils wahrscheinlichste Trajektorie für die betrachteten Manöver mit einer normalverteilten Unsicherheit ab. Im Falle eines Spurwechsels ist für das automatisierte Fahrzeug allerdings nicht nur die wahrscheinlichste Trajektorie sondern vor allem kritische Manöver von Interesse. Um diese in der Prädiktion explizit zu berücksichtigen, wird der manöverbasierte Ansatz um die Schätzung der Verteilung des Spurwechselzeitpunktes erweitert. Da diese nicht immer symmetrisch ist und sich in Abhängigkeit von der Verkehrssituation ändern kann, werden verschiedene Quantile der Verteilung mit einem datenbasierten Schätzverfahren bestimmt. Mit den bedingten Quantilen werden anschließend Trajektorien für unterschiedlich kritische Manöver repräsentiert, sodass diese direkt innerhalb der Planung des automatisierten Fahrzeugs berücksichtigt werden können. Beide Verfahren zur Trajektorienprädiktion betrachten jeden Verkehrsteilnehmer individuell, ohne die Interaktion zwischen einzelnen Fahrzeugen zu berücksichtigen. Gerade für eine lange Prädiktionsdauer von mehr als fünf Sekunden haben Interaktionen einen entscheidenden Einfluss auf das Verhalten der Verkehrsteilnehmer. Daher wird als dritter Ansatz ein Verfahren vorgestellt, das parametrisierte Fahrermodelle innerhalb einer Monte Carlo Simulation nutzt, um die Interaktionen zwischen einzelnen Fahrzeugen explizit zu modellieren und somit eine zuverlässige Prädiktion für einen langen Prädiktionshorizont ermöglicht. Die Auswertung stellt die jeweiligen Vor- und Nachteile der drei vorgestellten Verfahren heraus und evaluiert die Anwendbarkeit in einem Versuchsfahrzeug.

Inhaltsverzeichnis

| | |
|--|------------|
| Nomenklatur | iii |
| 1. Einführung | 1 |
| 1.1. Motivation | 1 |
| 1.2. Stand der Technik | 2 |
| 1.3. Beitrag und Gliederung | 12 |
| 2. Trajektorienprädiktion für beobachtete Fahrzeuge | 14 |
| 2.1. Funktionale Architektur automatisierter Fahrzeuge | 14 |
| 2.2. Problemstellung der Trajektorienprädiktion | 17 |
| 2.3. Frenet-Serret Koordinaten | 18 |
| 2.4. Entwicklung in virtueller Umgebung | 19 |
| 3. Umgebungssimulation | 21 |
| 3.1. Abbildung der Straßentopologie und Visualisierung | 21 |
| 3.2. Sensorsimulation | 22 |
| 3.3. Objekte in der Simulationsumgebung | 28 |
| 3.4. Bewertung der Simulationsmodelle | 34 |
| 3.5. Zusammenfassung und Diskussion | 39 |
| 4. Manöverklassifikation | 41 |
| 4.1. Fahrmanövervorhersage auf Autobahnen | 41 |
| 4.2. Merkmale für die Manöverklassifikation | 42 |
| 4.3. Support Vektor Maschine als probabilistischer Klassifikator | 44 |
| 4.4. Auswertung der Spurwechselklassifikation | 45 |
| 5. Manöverbasierte Trajektorienprädiktion | 55 |
| 5.1. Vorhersage auf Basis geschätzter Fahrmanöver | 55 |
| 5.2. Kubische Splines als Prädiktionsmodell | 56 |
| 5.3. Genauigkeit der vorhergesagten Trajektorien | 59 |
| 5.4. Diskussion der simulationsbasierten Entwicklung | 66 |
| 6. Schätzung zeitlicher Manövereigenschaften | 69 |
| 6.1. Zeitliche Eigenschaften eines Spurwechsels | 70 |
| 6.2. Schätzung des Spurwechselzeitpunktes als Regressionsproblem | 71 |
| 6.3. Quantile Regression Forest | 72 |
| 6.4. Auswertung des geschätzten Spurwechselzeitpunktes | 73 |
| 7. Sicherheitskritische Trajektorienprädiktion | 77 |
| 7.1. Kritische Trajektorien auf Autobahnen | 77 |

| | |
|--|------------|
| 7.2. Trajektorienprädiktion mit zeitlichen Manövereigenschaften | 79 |
| 7.3. Evaluation der sicherheitskritischen Trajektorienprädiktion | 80 |
| 8. Interaktionsbasierte Trajektorienprädiktion | 85 |
| 8.1. Interaktionen zwischen Verkehrsteilnehmern | 85 |
| 8.2. Modellierung von Interaktionen | 87 |
| 8.3. Verbesserung bei einem unvollständigen Umgebungsmodell | 93 |
| 8.4. Evaluation der interaktionsbasierten Trajektorienprädiktion | 94 |
| 9. Zusammenfassung und Ausblick | 100 |
| Literatur | 104 |
| A. Anhang | 115 |
| A.1. Entwicklung in virtueller Umgebung | 115 |
| A.1.1. Anforderungen an Simulationsumgebungen | 115 |
| A.1.2. Stand der Technik | 116 |
| A.2. Driving Environment Simulation | 122 |
| A.2.1. Modellierung der Straßentopologie und Visualisierung | 122 |
| A.2.2. Laterales Fahrermodell | 123 |
| A.3. Definitionen | 126 |
| A.3.1. Verteilungsfunktionen | 126 |
| A.3.2. Die Indikatorfunktion | 126 |
| A.3.3. Trajektorienprädiktion mit konstanter Geschwindigkeit | 127 |
| A.4. Datensätze | 127 |
| A.4.1. Datensatz aus der Simulation | 127 |
| A.4.2. Datensatz aus dem Versuchsfahrzeug | 128 |
| A.5. Beispiel für eine fehlerhafte Manöverklassifikation | 129 |
| A.6. Monte Carlo Simulation | 130 |

Nomenklatur

Abkürzungen und Akronyme

| | |
|----------------------------|--|
| acc^{MK} | Klassifikationsgenauigkeit |
| acc^{SKTP} | Prädiktionsgenauigkeit der sicherheitskritischen Trajektorienprädiktion |
| AUC | Area Under the Curve |
| bac^{MK} | Ausbalancierte Klassifikationsgenauigkeit |
| tpr^{MK} | Korrekt Positiv Rate der Manöverklassifikation |
| fpr^{MK} | Falsch Positive Rate der Manöverklassifikation |
| IQR | Inter Quartil Range |
| MAE | Mittlerer absoluter Fehler (M ean A bsolute E rror) |
| MAE^{tlc} | Mittlerer absoluter Fehler des geschätzten Spurwechselzeitpunktes |
| \mathcal{GP} | G auß P rozess |
| QRF | Q uantile R egression F orests |
| ROC | R eciever O perator C haractersitic |
| CV | Konstante Geschwindigkeit (C onstant V elocity) |
| CVCL | Konstante Geschwindigkeit in kurvilinearen Koordinaten (C onstant V elocity in C urvilinear coordinates) |
| DBSCAN | D ensity- B ased S patial C lustering of A pplications with N oise |
| DESIM | D riving E nvironment S imulation |
| FN | Falsch Negativ (F alse N egative) |
| FP | Falsch Positiv (F alse P ositive) |
| HMM | H idden M arkov M odel |
| IBTP | I nteraktions b asierte T rajektorien p rädiktion |
| IDM | I ntelligent D river M odel |
| KF | K alman F ilter |
| KL | K ullback- L eibler |
| LCL | Spurwechsel Links (L ane C hange L eft) |
| LCR | Spurwechsel Rechts (L ane C hange R ight) |
| LK | Spurhalten (L ane K eeping) |
| MBTP | M anöver b asierte T rajektorien p rädiktion |
| MOBIL | M inimal O verall B raking I nduced by L ane change |
| SKTP | S icherheitskritische T rajektorien p rädiktion |
| StVO | S traßenverkehrsordnung |
| SVM | S upport V ektor M aschine |
| TN | Korrekt Negativ (T ruer N egative) |
| TP | Korrekt Positiv (T ruer P ositive) |

Griechische Symbole

| | |
|--------------------|---|
| α_i | Gewichtungsfaktor der Unsicherheitsschätzung |
| β | Parametervektor eines linearen Quantilschätzers |
| μ | Mittelwert einer Normalverteilung |
| μ_C | Mittelwert des von Kamerasensoren gemessenen Zustands |
| μ_R | Mittelwert des von Radarsensoren gemessenen Zustands |
| ν | Vektor von Schlupfvariablen der SVM |
| Σ | Kovarianzmatrix einer Normalverteilung |
| Σ_R | Kovarianzmatrix des von Radarsensoren gemessenen Zustands |
| ζ | Klassifikationsbeispiel |
| l | Klassifikationslabel |
| Ψ | Kollisionsfunktion |
| δ | Parameter des IDM |
| $\Delta v_x^{(k)}$ | Relative Geschwindigkeit des Fahrzeugs k zum vorausfahrenden Fahrzeug |
| ϵ_{Rand} | Zufällige Änderung der Unsicherheit |
| \mathcal{B} | Untermenge aller Merkmale |
| $\xi_{GP,m}$ | Stichprobe aus einem Gauß Prozess |
| κ | Anzahl von Spline Segmenten |
| \mathcal{X} | Merkmalsvektor der Manöverklassifikation |
| Γ | Sequenz von Fahrmanövern |
| ρ | Höflichkeitsfaktor des Fahrermodells MOBIL |
| θ_{Lat} | Parametervektor des lateralen Fahrermodells |
| θ_{Long} | Parametervektor des longitudinalen Fahrermodells |
| Φ | Kernelfunktion |
| ψ | Gierwinkel eines Fahrzeugs |
| $\psi^{(k)}$ | Gierwinkel des Fahrzeugs k |
| η | Quantil |
| Ω_{η_i} | Schätzer für Quantil η_i |
| Λ | Menge aller Quantile |
| ρ | Geneigte Absolutwertfunktion |
| θ_H | Hyper-Parameter des Gauß Prozesses |
| Θ_{Time} | Menge der Parameter der zeitabhängigen Unsicherheit |
| σ_{des} | Variation der Wunschgeschwindigkeit |
| Σ_C | Kovarianzmatrix des von Kamerasensoren gemessenen Zustands |
| $\sigma_{i,j}$ | Kovarianz der gemessenen Zustände i und j |
| σ_i | Varianz des gemessenen Zustands i |

Lateinische Symbole

| | |
|------------|--|
| a_x | Beschleunigung in x -Richtung im Ego-Koordinatensystem |
| a_y | Beschleunigung in y -Richtung im Ego-Koordinatensystem |
| a_{lat} | Laterale Beschleunigung |
| a_{long} | Longitudinale Beschleunigung |
| a_{max} | Maximale longitudinale Beschleunigung |
| a_{min} | Minimale longitudinale Beschleunigung |

| | |
|---|---|
| $a_{LC}^{(k)}$ | Longitudinale Beschleunigung des k -ten Agenten im Falle eines Spurwechsel |
| a_{LC}^F | Longitudinale Beschleunigung des Folgefahrzeugs auf der aktuellen Spur im Falle eines Spurwechsel |
| a_{LC}^{LF} | Longitudinale Beschleunigung des Folgefahrzeugs auf der Zielspur im Falle eines Spurwechsel |
| $\Delta a_{\text{bias,mobil}}$ | Bias für einen Spurwechsel nach rechts (Parameter des Fahrermodells MOBIL) |
| $\Delta a_{\text{th,mobil}}$ | Schwellwert für die Durchführung eines Spurwechsels (Parameter des Fahrermodells MOBIL) |
| $b_{\text{safe,mobil}}$ | Sichere Verzögerung (Parameter des Fahrermodells MOBIL) |
| b | Komfortable Verzögerung des IDM |
| $c_{l,0}, c_{l,1}, c_{l,2}, c_{l,3}$ | Koeffizienten des l -ten Spline Segments |
| $c_{m,0}, c_{m,1}, c_{m,2}, c_{m,3}$ | Koeffizienten des Basispfads einer Manöverausführung |
| d_{lat}^c | Lateraler Schwellwert für die Bewertung einer Kollision |
| d_{long}^c | Longitudinaler Schwellwert für die Bewertung einer Kollision |
| \mathbf{d}_{rel} | Vektor mit relativen Abständen zu den Umgebungsfahrzeugen |
| d_{lat} | Laterale Distanz zur Spurmitte |
| d_{LM} | Distanz zur Spurmarkierung |
| d_{min} | Minimaler Abstand |
| e_x | Absoluter Fehler der x -Koordinate |
| e_y | Absoluter Fehler der y -Koordinate |
| $a_{\text{Time}}, b_{\text{Time}}, c_{\text{Time}}$ | Parameter der zeitabhängigen Unsicherheit |
| I_{80} | Intervall zwischen dem 90 % und 10 % Quantil |
| K | Anzahl von Fahrzeugen in der aktuellen Szene |
| l | Longitudinale Koordinate im kurvilinearen Koordinatensystem |
| l_i | Längenkomponente der i -ten Komponente des Gauß Prozesses |
| $n_{\mathcal{X}}$ | Merkmalsdimension der Manöverklassifikation |
| m | Fahrmanöver |
| \hat{m} | Geschätztes Manöver |
| \hat{m} | Manöverlabel |
| n | Laterale Koordinate im kurvilinearen Koordinatensystem |
| n_F^{ORF} | Dimension der Untermenge \mathcal{B} |
| n_N^{ORF} | Minimale Anzahl von Beispielen pro Blatt |
| $n_{\text{tree}}^{\text{ORF}}$ | Anzahl von Entscheidungsbäumen |
| n^c | Anzahl an prädizierten Kollisionen |
| $n_{LC, \text{crit}}$ | Anzahl von Beispielen bis zu $t_{LC, \text{crit}}$ s vor einem Spurwechsel |
| $n_{S,TP}$ | Anzahl von Beispielen für die Trajektorienprädiktion |
| $m_{\mathcal{C}}$ | Merkmalsdimension des Klassifikationsbeispiels |
| n_{Γ} | Anzahl von Fahrmanövern in Γ |
| N_i | Fahrzeug i |
| n_p | Länge des Manöverpfads |
| $n_{\mathcal{C}}$ | Anzahl von Beispielen für die Klassifikation |
| $n_{\mathcal{GP}}$ | Anzahl von Komponenten im Gauß Prozess |

| | |
|---------------------------------------|---|
| n_c | Anzahl von Trajektorien, die der Situationsentwicklung c zugeordnet sind |
| $n_{\text{dist},x}$ | Ordnung der x -Komponente in $P_{n_{\text{dist},x},n_{\text{dist},y}}$ |
| $n_{\text{dist},y}$ | Ordnung der y -Komponente in $P_{n_{\text{dist},x},n_{\text{dist},y}}$ |
| n_{miss} | Anzahl der nicht erkannten Spurwechselmanöver |
| n_p | Anzahl von Zeitschritten im Prädiktionshorizont |
| $c_{\mathbf{p}_m}^{(k)}$ | Basispfad eines Manövers in kurvilinearen Koordinaten für Fahrzeug k |
| $c_{\check{\mathbf{p}}_m}^{(k)}$ | Manöverpfad des k -ten Fahrzeugs in kurvilinearen Koordinaten |
| p_c | Wahrscheinlichkeit der Situationsentwicklung c |
| q | Bias Parameter der SVM |
| \mathcal{S} | Verkehrsszene |
| s^* | Effektiver Astand |
| $s^{(k)}$ | Abstand des Fahrzeugs k zum vorausfahrenden Fahrzeug |
| $s_{f,i}$ | Standardabweichung der i -ten Komponente des Gauß Prozesses |
| ΔT_H | Zeitschritt der im Merkmalsvektor der Manöverklassifikation betrachteten Historie |
| ΔT | Zeitliche Schrittweite zwischen diskreten Zeitpunkten |
| $T_H^{(k)}$ | Zeitlicher Abstand des Fahrzeugs k zum vorausfahrenden Fahrzeug |
| T_p | Prädiktionshorizont |
| τ | Prädiktionszeit |
| $\hat{t}_{\text{LC} \eta=i}$ | Geschätztes Quantil i der Verteilung des Spurwechselzeitpunktes |
| t_n | Diskreter Zeitpunkt |
| t_{CLC} | Verbleibende Zeit bis zum Ende eines Spurwechselmanövers |
| $t_{\text{LC,crit}}$ | Kritische Zeit bis zum Spurwechsel |
| $t_{\text{LC,d}}$ | Durchschnittliche Spurwechseldauer |
| $t_{\text{LC,det}}$ | Zeitpunkt der ersten Vorhersage eines Spurwechselmanövers |
| \hat{t}_{LC} | Geschätzter Spurwechselzeitpunkt |
| $t_{\text{LC},m}$ | Gesamtdauer eines Spurwechsels |
| $\tilde{t}_{\text{LC},m}$ | Spurwechseldauer in aufgenommenen Daten |
| $\tilde{t}_{\text{LC},m \eta=\eta_i}$ | Quantil η_i der Verteilung $p(\tilde{t}_{\text{LC},m})$ |
| \dot{t}_{LC} | Tatsächlicher Spurwechselzeitpunkt |
| t_{pred} | Prädiktionszeit |
| t_H | Länge der im Merkmalsvektor der Manöverklassifikation betrachteten Historie |
| t_{init} | Zeitpunkt der ersten Detektion |
| u_l | Anstieg der longitudinalen Unsicherheit pro prädiziertem Zeitintervall |
| u_n | Anstieg der lateralen Unsicherheit pro prädiziertem Zeitintervall |
| \mathbf{v}_{rel} | Vektor mit relativen Geschwindigkeiten zu den Umgebungsfahrzeugen |

| | |
|--------------------------------|---|
| $v_{\text{des}}^{(k)}$ | Wunschgeschwindigkeit des Fahrzeugs k |
| v | Absolute Geschwindigkeit |
| v_x | Geschwindigkeit in x -Richtung im Ego-Koordinatensystem |
| v_y | Geschwindigkeit in y -Richtung im Ego-Koordinatensystem |
| v_l | Geschwindigkeit in l -Richtung im kurvilinearen Koordinatensystem |
| v_n | Geschwindigkeit in n -Richtung im kurvilinearen Koordinatensystem |
| v_{lat} | Geschwindigkeit normal zum Straßenverlauf |
| v_{long} | Geschwindigkeit entlang des Straßenverlaufs |
| \mathbf{w} | Normalenvektor der SVM-Hyperebene |
| w | Fahrspurbreite |
| $\hat{\mathbf{x}}(\tau)$ | Prädizierte Trajektorie |
| $\hat{\mathbf{x}}$ | Prädizierter Zustand |
| $\dot{\hat{\mathbf{x}}}(\tau)$ | Referenztrajektorie |
| \mathbf{x} | Zustandsvektor |
| $\mathbf{x}^{(i)}(t_n)$ | Zustandsvektor des Fahrzeugs i zum Zeitpunkt t_n |
| $\mathbf{x}^{(i)}$ | Zustandsvektor des Fahrzeugs i |
| $\mathbf{x}(t_n)$ | Zustandsvektor zum Zeitpunkt t_n |
| x | X-Position im Ego-Koordinatensystem |
| y | Y-Position im Ego-Koordinatensystem |
| z | Z-Position im Ego-Koordinatensystem |
| \mathbf{A}_{CV} | Systemmatrix eines Modells mit konstanter Geschwindigkeit |
| \mathbf{B} | Eingangsmatrix für die Unsicherheitsfortpflanzung |
| \mathcal{M}_{Sim} | Menge aller Manöver innerhalb der Simulationsumgebung |
| \mathbb{R} | Menge aller reellen Zahlen |
| \mathbb{R}_{0+} | Menge aller reellen Zahlen größer gleich Null |
| \mathbb{N}_+ | Menge der natürlichen Zahlen größer Null |
| \mathbb{N}_0 | Menge der natürlichen Zahlen |
| \mathcal{Z} | Menge aller Fahrzeuge |
| \mathcal{Z}_i | Menge aller Fahrzeuge ohne Fahrzeug i |
| \mathcal{C}_{\square} | Kurvilineare Koordinaten |
| \mathcal{W}_{\square} | Weltkoordinaten |

Mathematische Ausdrücke und Funktionen

| | |
|---------------------------------------|--|
| $D_{\text{KL}}(\tilde{p} \tilde{q})$ | Kullback-Leibler Divergenz |
| f_{Pos} | Funtion zur Beschreibung der positionsabhängigen Änderung der Unsicherheit |
| f_{Time} | Funtion zur Beschreibung der zeitabhängigen Änderung der Unsicherheit |
| $h(t_n)$ | Kubischer Spline |
| $\mathbb{I}_{\{x\}}$ | Indikatorfunktion |
| $\mathcal{K}(x, x')$ | Radial Basis Funktionskernel |
| $k(\mathbf{x}, \mathbf{x}')$ | Kovarianzfunktion des Gauß Prozesses |
| $\mathcal{L}(x)$ | Likelihood |

| | |
|--|--|
| m | Mittelwertfunktion des Gauß Prozesses |
| $P_{n_{\text{dist},x}, n_{\text{dist},y}}$ | Zweidimensionales Polynom der Ordnung $n_{\text{dist},x}$ und $n_{\text{dist},y}$ |
| $z_l(t_n)$ | l -tes Spline Segment |
| $\tilde{p}(x)$ | Diskrete Wahrscheinlichkeitsdichteverteilung der Zufallszahl x |
| $\mathcal{N}(\boldsymbol{\mu}, \boldsymbol{\Sigma})$ | Normalverteilung mit dem Mittelwert $\boldsymbol{\mu}$ und der Kovarianzmatrix $\boldsymbol{\Sigma}$ |
| $\mathcal{U}(r_1, r_2)$ | Gleichverteilung im Intervall von r_1 bis r_2 |
| $P(x)$ | Kumulative Wahrscheinlichkeitsverteilung der Zufallszahl x |
| $p(x)$ | Wahrscheinlichkeitsdichteverteilung der Zufallszahl x |

1

Einführung

1.1. Motivation

In den vergangenen Jahren ist die Entwicklung von automatisierten Fahrzeugen stetig vorangeschritten. Erste Prototypen werden bereits auf öffentlichen Straßen getestet und verkörpern die Vision der vollständigen Vermeidung Verkehrstoter im Straßenverkehr sowie einer unabhängigen Mobilität bis ins hohe Alter. Automobilhersteller und Technologiekonzerne überbieten sich mit Versprechungen über eine schnelle Realisierung dieser Vorstellung. Trotz allem schreitet die Einführung von automatisierten Systemen in Serienfahrzeugen nur langsam voran. In aktuellen Fahrzeugen beschränkt sich die Funktionalität auf Assistenzsysteme, die den Fahrer in bestimmten Situationen unterstützen und unter ständiger Kontrolle des Menschen zeitweise die Fahrzeugführung übernehmen können. Allerdings ist der Fahrer zu jeder Zeit in der vollen Verantwortung und muss das System dauerhaft überwachen, sodass er keine fahrfremden Aufgaben oder Tätigkeiten ausführen kann. Nach der in [SAE18] vorgestellten Taxonomie automatisierter Fahrfunktionen entsprechen diese Funktionen den Automatisierungslevel eins und zwei. Generell werden sechs Level der Automatisierung definiert. Dabei entspricht Level null keiner Automatisierung, sodass der Fahrer die Fahraufgabe dauerhaft selbst übernimmt und entsprechend jederzeit in der Verantwortung ist. Level fünf stellt die vollständige Automatisierung dar, in der das System in der Lage ist, jede Situation zu beherrschen und der Fahrer zu keiner Zeit die Kontrolle übernehmen muss oder in der Verantwortung ist. Ab dem Automatisierungsgrad drei ist das Fahrzeug in bestimmten Situationen in der Lage, die Fahraufgabe zu übernehmen und den Fahrer aus der Verantwortung zu entlassen. Dieser muss allerdings bereit sein, innerhalb einer gewissen Übergabezeit die Kontrolle wieder zu übernehmen. Das heißt, dass für Systeme ab Level drei die Anforderungen in Bezug auf Sicherheit und Zuverlässigkeit steigen, sodass für die Realisierung solcher Funktionen eine genaue Kenntnis der aktuellen Verkehrsszene zu jeder Zeit gegeben sein muss. Diese wird mit verschiedensten Sensortechnologien wahrgenommen und zu einem einheitlichen Umgebungsmodell zusammengefasst. Um allerdings auch in komplexen Verkehrssituationen das optimale Manöver für die zukünftige Fortbewegung des Ego-Fahrzeugs zu bestimmen, ist die alleinige Beschreibung der aktuellen Szene nicht mehr ausreichend. Vielmehr muss die zukünftige Entwicklung der Verkehrssituation

für die Planung des Ego-Manövers berücksichtigt werden. Vor allem für eine komfortable Fahrweise ist eine genaue Schätzung der zukünftigen Manöver der umgebenden Fahrzeuge von Vorteil. Als Beispiel hierfür kann ein Einfädelvorgang eines Verkehrsteilnehmers vor ein automatisiert fahrendes Fahrzeug auf der linken Fahrspur einer Autobahn betrachtet werden. Vor dem Spurwechsel des einfädelnden Fahrzeugs kann das automatisierte Fahrzeug der aktuellen Wunschgeschwindigkeit entsprechend frei auf der Spur fahren. Wird in der Manöverplanung die Entwicklung der Situation vernachlässigt, erfolgt die Reaktion auf den Spurwechsel erst nachdem das Fahrzeug bereits auf der linken Spur ist, sodass eine starke und unkomfortable Verzögerung durchgeführt werden muss, um eine Kollision zu verhindern und den gesetzlichen Mindestabstand wiederherzustellen. Wenn im gleichen Szenario die wahrscheinliche Entwicklung der Situation betrachtet wird, kann zum einen durch eine frühzeitige Verringerung der Geschwindigkeit eine unkomfortable Verzögerung verhindert werden. Zum anderen kann auf Basis der geschätzten Bewegung der Mindestabstand schrittweise aufgebaut und damit ebenfalls unkomfortable Verzögerungen vermieden werden. Es zeigt sich, dass für einen hohen Automatisierungsgrad und komfortable Fahrmanöver eine Prädiktion der aktuellen Verkehrssituation unumgänglich ist. Solange sich allerdings nicht alle Fahrzeuge automatisiert fortbewegen und mit Fahrzeug zu Fahrzeug Kommunikation ausgerüstet sind, ist die Prädiktion der Verkehrssituation mit vielen Unsicherheiten behaftet. Im Gegensatz zu den aktuellen fahrdynamischen Größen kann die Intention eines Fahrers von den Sensoren eines automatisierten Fahrzeugs nicht gemessen werden. Somit können lediglich Annahmen über das aktuelle und zukünftige Manöver getroffen werden. Zusätzlich ist die Ausführung eines Manövers fahrerindividuell, sodass diese Varianz innerhalb der Prädiktion berücksichtigt werden muss. Schließlich werden die Entscheidungen eines beobachteten Fahrzeugs durch Manöver der anderen Verkehrsteilnehmer sowie des automatisierten Fahrzeugs und die Straßentopologie beeinflusst. Um eine genaue und nachvollziehbare Prädiktion der Verkehrssituation zu bestimmen, dürfen diese Punkte nicht vernachlässigt werden. Die vorliegende Arbeit schlägt Verfahren zur Lösung des Trajektorienprädiktionsproblems für beobachtete Verkehrsteilnehmer in beliebigen Autobahnsszenarien vor und wertet diese auf Basis ihrer Genauigkeit und Abbildung der Entwicklung der Verkehrssituation aus.

1.2. Stand der Technik

Im Folgenden wird der aktuelle Stand der Technik für die Trajektorienprädiktion von Fahrzeugen, die von der Sensorkonfiguration des Ego-Fahrzeugs wahrgenommen werden, vorgestellt. Dazu werden Trajektorienprädiktionsverfahren aus der Literatur entsprechend der Darstellung von Lefèvre und Christian Laugier [LC14] in drei Kategorien eingeteilt:

1. Physikalische Trajektorienprädiktion,
2. Manöverbasierte Trajektorienprädiktion,
3. Interaktionsbasierte Trajektorienprädiktion.

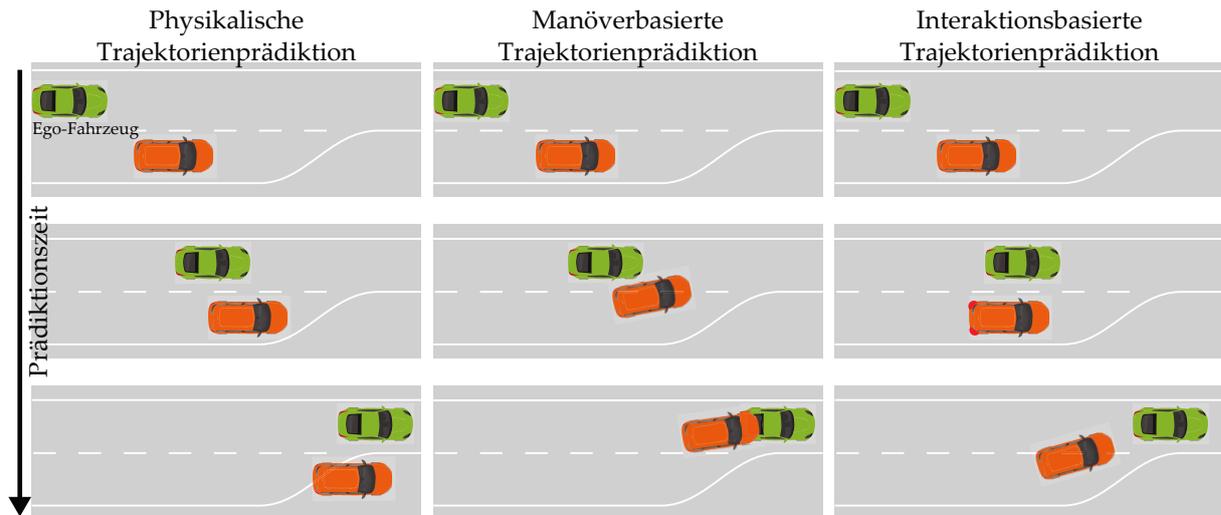


Abbildung 1.1.: Taxonomie für Verfahren zur Prädiktion von Trajektorien von beobachteten Verkehrsteilnehmern auf Autobahnen (analog zu [LC14]).

Die prinzipielle Wirkungsweise der drei Arten ist in Abbildung 1.1 dargestellt. Für die physikalische Prädiktion werden die kinematischen Größen eines beobachteten Fahrzeugs als Grundlage der Prädiktion genutzt und keinerlei Informationen der Straßentopologie oder des umgebenden Verkehrs verwendet. In dem exemplarischen Szenario werden für das beobachtete Fahrzeug eine konstante Geschwindigkeit sowie Orientierung angenommen und weder die endende Spur noch das Ego-Fahrzeug berücksichtigt, sodass die prädizierte Trajektorie neben die Straße prädiziert wird. Im Gegensatz hierzu wird in der manöverbasierten Trajektorienprädiktion die Bewegung eines Fahrzeugs als eine Sequenz von distinkten Fahrmanövern modelliert, wobei die Art der Manöver je nach Anwendungsfall variieren kann. In der mittleren Spalte von Abbildung 1.1 wird aufgrund der endenden Spur ein Spurwechsel nach links prädiziert, sodass das beobachtete Fahrzeug dem Straßenverlauf weiter folgen kann. Allerdings wird jedes Fahrzeug individuell betrachtet und Interaktionen zwischen einzelnen Verkehrsteilnehmern nicht explizit berücksichtigt, sodass der Spurwechsel zu einer Kollision mit dem Ego-Fahrzeug führen würde. In der interaktionsbasierten Trajektorienprädiktion, die auf der rechten Seite der Abbildung dargestellt ist, werden diese Interaktionen explizit modelliert und somit in der Prädiktion berücksichtigt. Um den erforderlichen Platz auf der Zielspur zu erhalten, verringert das beobachtete Fahrzeug in der gezeigten Szene aufgrund des Ego-Fahrzeugs zunächst die Geschwindigkeit und führt anschließend das Spurwechselmanöver durch. Anhand der resultierenden Prädiktion wird deutlich, dass die interaktionsbasierten Verfahren eine konsistente Schätzung ermöglichen und damit vor allem für die Prädiktion mit einem langen Prädiktionshorizont am besten geeignet sind. Allerdings steigt durch die Berücksichtigung der umgebenden Verkehrsteilnehmer auch die Dimension des zu lösenden Problems, da die zukünftigen Zustände aller Fahrzeuge und die Auswirkungen aufeinander modelliert werden müssen. In der Anwendung muss die Qualität der Prädiktion der Komplexität des zu lösenden Problems gegenübergestellt werden. Zusätzlich zu den drei vorgestellten Kategorien wird auf die Anwendung von Neuro-

nalen Netzen zur Trajektorienprädiktion eingegangen. Da eine eindeutige Einordnung der Verfahren in eine der Kategorien häufig nicht möglich ist, werden diese gesondert betrachtet. Außerdem werden aktuelle Arbeiten vorgestellt, die die Planung des Ego-Manövers und die Prädiktion der anderen Verkehrsteilnehmer als eine kombinierte Problemstellung formulieren. Der Ansatz ergibt sich direkt aus Überlegungen zu der interaktionsbasierten Trajektorienprädiktion. Da nicht nur die beobachteten Verkehrsteilnehmer untereinander Einfluss nehmen, sondern die Aktion des Ego-Fahrzeugs die Verkehrssituation ebenfalls beeinflussen kann, wird die interaktionsbasierte Prädiktion direkt in die Planung des Ego-Manövers einbezogen. Im Folgenden wird der Stand der Technik zunächst für die physikalische, die manöverbasierte und die interaktionsbasierte Trajektorienprädiktion dargelegt. Abschließend werden Arbeiten, die das kombinierte Problem der Prädiktion und Planung betrachten, vorgestellt.

Physikalische Trajektorienprädiktion

In der physikalischen Trajektorienprädiktion werden die zukünftigen Zustände eines beobachteten Fahrzeugs auf Basis des gemessenen Zustands und mit Hilfe von kinematischen oder dynamischen Bewegungsmodellen berechnet. Zusätzlich können weitere Fahrzeugeigenschaften oder die Beschaffenheit der Straße berücksichtigt werden. Die Verwendung von dynamischen Modellen ist im Bereich der Trajektorienprädiktion nicht verbreitet, da die Modelle häufig Parameter verwenden, die von den fahrzeug-internen Sensoren nicht erfasst werden können. Ein Sonderfall ist die Prädiktion der Bewegung des Ego-Fahrzeugs, um in einem Gefahrenfall Manöver zu finden, welche die Verhinderung einer Kollision ermöglichen.

In [Bra+10] verwenden die Autoren ein lineares Einspurmodell mit einer Rechteckapproximation des Fahrzeugs, um die zukünftigen Zustände bei verschiedenen Eingangsgrößen zu präzisieren und auf Kollisionsfreiheit zu überprüfen. Der Prädiktionshorizont beträgt drei Sekunden, wobei keinerlei Unsicherheit für die geschätzten Zustände betrachtet wird. Für den gleichen Anwendungsfall verwenden C.-F. Lin u. a. [Lin+00] ebenfalls ein linearisiertes Einspurmodell, für das alle Parameter als bekannt vorausgesetzt werden. Allerdings wird durch die Schätzung mit Hilfe eines Kalman Filters eine normalverteilte Unsicherheit für die präzisierten Zustände berücksichtigt. Kaempchen u. a. [Kae+09] verwenden präzisierete Trajektorien als Auslösekriterium für ein automatisiertes Notbremssystem. Dabei werden Trajektorien im physikalischen Grenzbereich des Ego-Fahrzeugs sowie des beobachteten Fahrzeugs betrachtet und eine Notbremsung ausgelöst, wenn alle präzisiereten Trajektorien in einer Kollision enden. Die Grenzen der Kombination aus Längs- und Querbeschleunigung lassen sich auf Basis des Kammschen Kreises bestimmen, wobei die Berechnung der zukünftigen Positionen auf Basis eines kinematischen Modells durchgeführt wird. Insgesamt ist der Anwendungsbereich von dynamischen Modellen in der Trajektorienprädiktion auf bestimmte Bereiche beschränkt, in denen die notwendigen Parameter bekannt sind.

In der Mehrzahl der Ansätze zur physikalischen Trajektorienprädiktion werden die Kräfte, die auf ein beobachtetes Fahrzeug wirken, vernachlässigt und die Prädiktion auf Basis von kinematischen Modellen durchgeführt. Diese beschreiben die Fahrzeugbewegung mit ausreichender Genauigkeit, da zum einen die Fahrzeugparameter nicht

gemessen werden können und zum anderen die Unsicherheit der Eingangsgrößen einen größeren Einfluss auf die Prädiktionsgenauigkeit als das Bewegungsmodell hat. Ein Vergleich von kinematischen Bewegungsmodellen für die Anwendung des Fahrzeugtrackings ist in [Sch+08a] gegeben. Hier werden unterschiedliche Komplexitätsstufen der Modelle betrachtet. Im einfachsten Fall lassen sich die zukünftigen Zustände mit der Annahme einer konstanten Geschwindigkeit und Orientierung bestimmen. Für eine Steigerung der Genauigkeit kann zusätzlich die longitudinale Beschleunigung oder die Drehrate des beobachteten Fahrzeugs berücksichtigt werden, sodass eine Änderung der Geschwindigkeit und Orientierung prädiziert wird. Um auch die kinematischen Eigenschaften eines Fahrzeugs zu modellieren, können die Modelle um die Betrachtung des Lenkwinkels erweitert werden. Die Annahme einer konstanten Beschleunigung und Orientierung wird in [Hil+06] und [AN09] zur Einschätzung der Gefahr einer Kollision des Ego-Fahrzeugs mit anderen Verkehrsteilnehmern genutzt. Dabei werden entweder keine oder normalverteilte Unsicherheiten betrachtet. In beiden Fällen wird argumentiert, dass die Absicht des Fahrers der anderen Fahrzeuge nicht beobachtbar sei, sodass eine einfache Modellierung der zukünftigen Trajektorie ausreichend sei. In [BF08] wird zusätzlich die Drehrate des beobachteten Fahrzeugs modelliert, um die Bewegung entgegenkommender Fahrzeuge zu schätzen.

Die Verfahren zur physikalischen Prädiktion von Trajektorien unterscheiden sich zusätzlich in der Modellierung von Unsicherheiten. In einigen Fällen wird keinerlei Unsicherheit der Prädiktion betrachtet, sondern lediglich die wahrscheinlichste Trajektorie bestimmt ([Bra+10; Kae+09]). Eine weit verbreitete Methode stellt die Modellierung der einzelnen prädizierten Zustände als Normalverteilung dar. Diese wird häufig in Verbindung mit Varianten des Kalman Filters genutzt. Nach der Korrektur des aktuellen Zustands mit der letzten Sensormessung wird der Prädiktionsschritt des Filters wiederholt ausgeführt, um die zukünftigen Zustände zu bestimmen. So wächst die Unsicherheit abhängig von der Modellgenauigkeit. Dieses Vorgehen wird beispielsweise in [AN09] und [BF08] verwendet. Der größte Nachteil der Normalverteilung kann in der Beschränkung auf eine unimodale Wahrscheinlichkeitsverteilung gesehen werden, da lediglich eine mögliche Bewegung des Fahrzeugs modelliert werden kann. Abhilfe schafft hier das sogenannte *Switching Kalman Filter*, der von Dyckmanns u. a. [Dyc+11] für das Tracking von Fahrzeugen an einer Kreuzung eingesetzt wird. Dabei werden drei kinematische Modelle gleichzeitig für die Prädiktion genutzt, zwischen denen je nach Situation gewechselt wird. Alternativ kann ein *Interacting Multiple Model Filter* eingesetzt werden, um unterschiedliche Manöver zu berücksichtigen. Kaempchen u. a. [Kae+04] verwenden verschiedene longitudinale und laterale kinematische Modelle, um *Stop and Go* Manöver an Kreuzungen zu erkennen. Beide Verfahren nutzen die Prädiktion im Rahmen eines Objekt Trackings, sodass ein kurzer Prädiktionshorizont ausreichend ist. Eine andere Möglichkeit, Variationen bei der Ausführung eines Manövers in der Prädiktion zu berücksichtigen, stellt die Anwendung einer *Monte Carlo* Simulation dar. Dabei werden die Eingangsgrößen des Bewegungsmodells aus Wahrscheinlichkeitsverteilungen gezogen und für die Prädiktiondauer konstant gehalten. Anschließend wird die Situation vorwärts simuliert, sodass daraus eine einzelne Trajektorie des beobachteten Verkehrsteilnehmers resultiert. Durch die wiederholte Simulation und das Variieren der Eingangsgrößen entsteht eine diskrete

Verteilung der zukünftigen Zustände. Zusätzlich können Trajektorien, die dynamische Beschränkungen verletzen oder nicht mit der Straßentopologie übereinstimmen, nachträglich gefiltert werden. M. Althoff und Mergel [AM11] verwenden die *Monte Carlo Simulation* für die Prädiktion von Fahrzeugen, um das Risiko einer Kollision mit dem Ego-Fahrzeug zu bewerten.

Insgesamt sind alle physikalischen Verfahren auf einen kurzen Prädiktionshorizont beschränkt, da weder vollständige Manöver einzelner Verkehrsteilnehmer noch die Interaktion zwischen mehreren Fahrzeugen berücksichtigt werden. Somit ist die Prädiktion einer Änderung der lateralen oder longitudinalen Geschwindigkeit aufgrund eines Manövers oder anderen Fahrzeugs nicht möglich. Allerdings sind die verwendeten Methoden sehr effizient zu berechnen und erfordern nur wenig Kenntnis über die Umgebung.

Manöverbasierte Trajektorienprädiktion

Die manöverbasierte Trajektorienprädiktion basiert auf der Annahme, dass die Bewegung eines Fahrzeugs als eine Sequenz von distinkten Fahrmanövern dargestellt werden kann. Ein Fahrzeug führt zu jedem Zeitpunkt ein bestimmtes Manöver aus einer beschränkten Menge von Manövern aus. Hierbei wird jedes Fahrzeug unabhängig voneinander betrachtet. Für die Prädiktion der weiteren Bewegung bietet sich somit zunächst eine Schätzung des aktuellen sowie zukünftigen Manövers und eine anschließende Prädiktion der Trajektorie entsprechend der Ausführung dieses Manövers an. Die strukturierte Umgebung im Straßenverkehr begrenzt dabei die Anzahl der möglichen Manöver. Die Modellierung der Trajektorien einzelner Manöver kann in Form einer Prototypentrajektorie a priori aus Daten abgeleitet werden. Die vorgestellten Verfahren unterscheiden sich zum einen in der Repräsentation der Trajektorien und zum anderen in der Methode zur Schätzung des jeweiligen Manövers. Zunächst werden Ansätze präsentiert, in denen das wahrscheinlichste Manöver über die Ähnlichkeit zu der Prototypentrajektorie des entsprechenden Manövers bestimmt werden.

Eine frühe Arbeit im Bereich der manöverbasierten Trajektorienprädiktion befasst sich mit der Vorhersage von Trajektorien von Menschen in einer Büroumgebung. Auch hier ist durch die möglichen Ziele die Anzahl an Klassen begrenzt. Die Autoren von [VF04] nutzen Clusterverfahren mit der euklidischen Distanz als Maß, um die verschiedenen Klassen zu extrahieren. Einzelne Trajektorien werden dann durch den Mittelwert und die Varianz der zeitlichen Zustände repräsentiert. Um eine teilweise beobachtete Trajektorie einem Cluster zuzuweisen und den weiteren Verlauf zu prädizieren, wird die Likelihood der partiellen Distanz zu allen Clustern bestimmt und das Cluster mit der maximalen Likelihood gewählt. In [Her+09] wird ein Manöver nicht durch eine einzelne sondern durch eine Menge von Trajektorien repräsentiert, um die Varianz in der Manöverausführung zu modellieren. Die Zuordnung einer teilweise beobachteten Trajektorie erfolgt durch ein *Radial Basis Function Network*, welches die Distanzen der beobachteten zu der Menge von Trajektorien des jeweiligen Manövers als Eingangsgrößen verwendet und Manöverwahrscheinlichkeiten bestimmt. Die Schätzung der Verteilung zukünftiger Zustände für Fahrzeuge an einer T-Kreuzung wird anschließend mit Hilfe eines Partikelfilters umgesetzt, in dem die Partikel mit der jeweiligen

Klassenwahrscheinlichkeit gewichtet werden. Die Autoren [Wie+13] erweitern das Vorgehen um kategorische Variablen für die Schätzung der Manöverklasse. Auf diese Weise können zusätzlich Informationen über die Kreuzungstopologie berücksichtigt werden. Augustin u. a. [Aug+18] setzen ein ähnliches Verfahren für die Prädiktion von Spurwechseln auf Autobahnen ein. Die Manöver werden durch eine geringe Anzahl von Trajektorien-Clustern repräsentiert. Zur Detektion wird die Distanz zwischen den Clustern und der beobachteten Trajektorie ausgewertet. Die Autoren erweitern das Verfahren in [Aug+19a] um einen *Boosted Decision Tree* Klassifikationsalgorithmus, um die Genauigkeit der Manövererkennung zu verbessern. Eine weitere verbreitete Darstellungsform der Trajektorien sind Gauß Prozesse, welche als Verallgemeinerung von Normalverteilungen angesehen werden können. Ein Gauß Prozess (\mathcal{GP}) ist dabei eine Menge von Zufallszahlen, von denen jede endliche Menge normalverteilt ist (siehe [RW05]). Für die Modellierung von Trajektorien wird jede Klasse durch einen \mathcal{GP} repräsentiert, wobei jede Trajektorie im Trainingsdatensatz als eine Beispielfunktion des \mathcal{GP} gesehen wird. Durch die Anpassung der Parameter auf Basis der Trainingsdaten kann der \mathcal{GP} Variationen in der Ausführung eines Manövers abbilden. In [Tay09] werden \mathcal{GP} zur Prädiktion von Trajektorien von Personen innerhalb eines Gebäudes eingesetzt. Joseph u. a. [Jos+11] und Aoude u. a. [Aou+11b] setzten \mathcal{GP} zur Repräsentation von Bewegungsmustern ein und in [TF14] werden Abbiegemanöver an einer Kreuzung mit \mathcal{GP} modelliert. Für die Zuordnung zu einer Klasse kann die Likelihood der beobachteten Teiltrajektorie des jeweiligen \mathcal{GP} bestimmt werden. Ein Nachteil der \mathcal{GP} stellt der hohe Berechnungsaufwand dar, wenn viele Trainingsbeispiele berücksichtigt werden.

Die bisher betrachteten Verfahren verwenden jeweils die Ähnlichkeit zu der Prototypentrajektorie in der genutzten Repräsentation. Eine weitere Möglichkeit ist die Formulierung der Manöverschätzung als ein Klassifikationsproblem, sodass verschiedene Klassifikationsalgorithmen zur Lösung genutzt werden können. Im Gegensatz zu der Bewertung der Ähnlichkeit zu den vorhandenen Trajektorien können für die Klassifikation verschiedene Arten von Merkmalen herangezogen werden. Neben dem dynamischen Zustand des Fahrzeugs (Position, Geschwindigkeit, Drehrate, ...) können weitere Eigenschaften, wie der Blinker oder die Bremsleuchten, als Merkmal für eine genauere Bestimmung des Manövers verwendet werden. Zusätzlich ist die Verwendung von Informationen über den Straßenverlauf oder eine Änderung der Straßentopologie sowie Geschwindigkeitsbegrenzungen und Verkehrsregeln möglich. Im Falle der Manöverprädiktion für das Ego-Fahrzeug sind außerdem die Blickrichtung und Kopfbewegung des Fahrers gute Indikatoren für ein bevorstehendes Manöver. Als Klassifikationstechniken kommen unter anderem Neuronale Netze ([Gar+11; Kru+16]) und die Erweiterung mit *Long Short Term Memory* ([Zyn+17]) zum Einsatz. Außerdem werden häufig Support Vektor Maschinen für die Klassifikation eingesetzt ([Wis+17b] und [Aou+10]). In [Mor+11] wird die Bayesche Erweiterung zu einer *Relevance Vector Machine* untersucht und in [Kum+13] wird die Support Vektor Maschine (SVM) mit einem Bayes Filter kombiniert, um eine zeitlich konsistente Schätzung zu erhalten. Eine weitere verbreitete Technik sind Bayes Netze, da sich durch die vorzugebende Struktur einfach Expertenwissen in die Klassifikationsaufgabe integrieren lässt (siehe [Kli+14; Pla+12]). In [Kas+12] wird außerdem eine Erweiterung zu objektorientierten Bayes

Netzen vorgenommen, mit denen sich Abhängigkeiten von der Sensorwahrnehmung bis zur Trajektorienprädiktion modellieren lassen. Als weitere Alternative ist der *Random Forest* Ansatz zu nennen, der von den Autoren in [Sch+15] für die Prädiktion von Fahrmanövern auf Autobahnen verwendet wird. Außerdem kann eine Erweiterung der Bayes Netze auf die Modellierung von zeitlichen Abhängigkeiten vorgenommen werden ([Lef+12; Mey+09b]). Ein Spezialfall der dynamischen Bayes Netze sind die *Hidden Markov Modelle* (HMM), mit denen ein Manöver als eine Sequenz von aufeinander folgenden Zustände modelliert werden kann. Die Übergangswahrscheinlichkeiten können dabei auf Basis von Trainingsdaten gelernt werden, sodass für die Entscheidung, welches Manöver von dem beobachteten Fahrzeug aktuell durchgeführt wird, die Likelihood der HMM für den beobachteten Zustand genutzt werden kann ([Ber+08; Aou+11a; SH14; Mey+09a]).

Nach der Schätzung des aktuellen Manövers wird die Verteilung auf Basis einer Prototypentrajektorie prädiziert. Prinzipiell kommen dazu alle bereits vorgestellten Verfahren zur Repräsentation der Trajektorie in Frage. Lienke u. a. [Lie+19a] verwenden eine Manöverklassifikation mit SVMs und eine effiziente Repräsentation der Manöver durch kubische Splines mit einer Gaußschen Unsicherheitsfortpflanzung. In [Lau+11] werden einzelne Manöverklassen durch \mathcal{GP} repräsentiert und für die Risikobewertung des Ego-Fahrzeugs verwendet. Dazu werden für das wahrscheinlichste Manöver Stichproben aus dem \mathcal{GP} gezogen. Anhand der Anzahl der Stichproben, die mit dem Ego-Fahrzeug kollidiert, wird ein Maß für das Risiko in der betrachteten Situation abgeleitet. Die Autoren von [Sch+15] verwenden den *Random Forest* Klassifikator in einem *Mixture of Experts* Verfahren, um die möglichen Manöver mit dem probabilistischen Klassifikationsergebnis zu gewichten. Für die Repräsentation der Trajektorien kommt ein *Gaussian Mixture Model* zum Einsatz. Insgesamt werden die Trajektorien über einen Prädiktionshorizont von fünf Sekunden prädiziert. In [Sch+16] wird für jedes Manöver ein individuelles probabilistisches Modell hergeleitet, das die Unsicherheit der Prädiktion für das jeweilige Manöver repräsentiert. Alle Verfahren treffen die Annahme, dass einzelne Fahrzeuge unabhängig voneinander agieren und individuelle Manöver ausführen. In der Praxis ist dies allerdings nicht der Fall. Die Manöver der Fahrzeuge beeinflussen sich gegenseitig. Diese Interaktion wird in einigen Verfahren implizit durch entsprechende Merkmale in der Manöverklassifikation berücksichtigt, allerdings nicht explizit modelliert. Daher ist die resultierende Prädiktion nicht für einen Prädiktionshorizont geeignet, der über die Ausführung eines Manövers hinaus geht.

Interaktionsbasierte Trajektorienprädiktion

Die vernachlässigte Interaktion in den bisher vorgestellten Ansätzen führt zu einer unzuverlässigen Prädiktion über ein einzelnes Manöver hinaus. Um auch für einen entsprechend langen Prädiktionshorizont ein konsistentes Ergebnis zu erhalten, müssen zum einen die Interaktionen der Verkehrsteilnehmer mit der Umgebung aber auch die Interaktionen untereinander explizit berücksichtigt werden. Allerdings steigt die Problemkomplexität exponentiell mit der Anzahl von Fahrzeugen in der aktuellen Verkehrssituation, sodass eine direkte Lösung häufig nicht möglich ist. Außerdem

ist für die Modellierung einer Interaktion zwischen zwei Fahrzeugen entscheidend, dass die Zustände beider Fahrzeuge bekannt oder zumindest messbar sind. Im Falle eines unvollständigen Umgebungsmodells kann eine interaktionsbasierte Prädiktion ungenauer sein als ein Verfahren, das jedes Fahrzeug individuell und unabhängig von anderen betrachtet. Daher werden interaktionsbasierte Verfahren häufig um manöverbasierte oder physikalische Modelle erweitert, sodass ein unvollständiges Umgebungsmodell kompensiert werden kann. Als Beispiel kann hier [Wis+18a] genannt werden. Die Autoren verwenden Fahrermodelle aus mikroskopischen Verkehrssimulationen in Kombination mit einem kinematischen Bewegungsmodell in einer *Monte Carlo* Simulation, um die Interaktion zwischen Verkehrsteilnehmern in Autobahn-szenarien zu modellieren. Die Parameter der Fahrermodelle werden dabei in jeder Simulationsiteration variiert, sodass verschiedene Fahrertypen abgebildet werden und die Unsicherheit in der Prädiktion berücksichtigt wird. Zusätzlich wird die geschätzte Verteilung des aktuellen Manövers jedes Fahrzeugs als initiales Fahrmanöver in der Vorwärtssimulation genutzt, um Manöver zu berücksichtigen, die nicht durch eine Interaktion mit einem anderen Verkehrsteilnehmer entsteht. In [Bah+16a] schlagen die Autoren ebenfalls eine Kombination aus einer interaktionsbasierten Trajektorienprädiktion und einer Manöverschätzung vor. Dabei werden die Fahrzeuge in einer Multi-Agenten-Simulation entlang eines Potentialfeldes bewegt, welches anhand von Expertenwissen die Interaktion zwischen den Fahrzeugen modelliert. Im Potentialfeld sind zum einen die Straßentopologie und zum anderen Verkehrsregeln, wie das linksseitige Überholen, abgebildet. Aufgrund der einmaligen Simulation können in dem Ansatz allerdings keine unterschiedlichen Entwicklungen der Gesamtsituation abgebildet werden, sodass lediglich eine mögliche interaktionsbasierte Situationsprädiktion entsteht. Eine Kombination aus einer physikalischen und einer interaktionsbasierten Prädiktion schlagen González u. a. [Gon+17] vor. Dabei werden ebenfalls Fahrermodelle für eine Vorwärtssimulation der aktuellen Situation eingesetzt und mit einer physikalischen Prädiktion auf Basis eines *Switching State Space Models* kombiniert. Um ein realistisches Fahrverhalten auf Autobahnen zu erhalten, wird ein Spurwechselmodell durch ein verstärkendes Lernverfahren trainiert. Die Kombination der physikalischen und interaktionsbasierten Trajektorien wird über ein Bayes Netz vorgenommen. In [Sch+18b] wird eine interaktionsbasierte Trajektorienprädiktion für unterschiedliche Kreuzungstopologien vorgestellt. Dazu werden alle Verkehrsteilnehmer, deren Routen und geplanten Manöver sowie die daraus resultierenden Interaktionen untereinander in einem dynamischen Bayes Netz modelliert. Die Struktur des Netzes ist abhängig von der Fahrzeuganzahl in der aktuellen Situation veränderbar. Für die Prädiktion wird das Netz vorwärts simuliert, wobei Stichproben aus den Manöververteilungen gezogen werden, um verschiedene Entwicklungen der Situation zu berücksichtigen. Eine Voraussetzung für die Anwendung dieses Ansatzes ist die vollständige Information über alle Routen an den betrachteten Kreuzungen, die nur auf Basis einer digitalen Karte gewonnen werden können. Außerdem werden in dem vorgestellten Verfahren keine Spurwechsel betrachtet. Anstatt die Verteilung der zukünftigen Zustände im Raum zu schätzen, wird in [KA17a] eine Überapproximation des von den beobachteten Fahrzeugen belegten Raumes durchgeführt, um die Sicherheit des vom Ego-Fahrzeug geplanten Manövers zu gewährleisten. Die Begrenzungen des Raumes werden

durch Beschränkungen der Fahrdynamik sowie durch Verkehrsregeln bestimmt. Im Gegensatz zu der Arbeit in [KA17b] wird zusätzlich die Interaktion zwischen einzelnen Fahrzeugen und die Interaktion mit dem Ego-Fahrzeug modelliert, um den belegten Raum einzugrenzen. Allerdings wird in der Prädiktion kein Spurwechsel auf Autobahnen berücksichtigt, da durch die ständige Möglichkeit des Spurwechsels eines beobachteten Fahrzeugs die Nachbarspur dauerhaft belegt und damit der für das Ego-Fahrzeug zur Verfügung stehende Raum zur Navigation sehr eingeschränkt wäre. Hier werden die Nachteile der Überapproximierung des belegten Raums deutlich. Anhand der vorgestellten Ansätze zeigt sich die Komplexität des Prädiktionsproblems, sobald die Interaktionen berücksichtigt werden sollen. Gleichzeitig ist dies für eine zuverlässige Prädiktion mit langem Zeithorizont notwendig.

Tiefe neuronale Netze

Als weitere Methode, Trajektorien von beobachteten Verkehrsteilnehmern zu prädictieren, werden an dieser Stelle tiefe Neuronale Netze betrachtet. In den letzten Jahren hat sich die Anwendung der Neuronalen Netze stark verbreitet, sodass diese im Kontext der Trajektorienprädiktion nicht mehr nur noch für die Schätzung des aktuellen Manövers (siehe zum Beispiel [Kru+16]) eingesetzt werden, sondern für die Lösung des Trajektorienprädiktionsproblems im Allgemeinen. Dabei wird angenommen, dass einzelne Fahrmanöver oder die Interaktion zwischen Verkehrsteilnehmern nicht explizit modelliert werden müssen, sondern durch die große Anzahl an Parametern und Trainingsdaten eine implizite Modellierung stattfindet und sich diese auf neue Situationen übertragen lässt. In [Len+17] werden dazu unterschiedliche Architekturen von tiefen Neuronalen Netzen für die Prädiktion von Trajektorien auf Autobahnen verglichen. Als Merkmale kommen Distanzen und relative Geschwindigkeiten zu den Umgebungsfahrzeugen sowie der Fahrzeugtyp und die Länge der Fahrspuren zum Einsatz. Die prädictierten Trajektorien werden über ein *Gaussian Mixture Model* dargestellt. Das Netz wird für eine Ein-Schritt-Prädiktion trainiert, sodass für eine Prädiktion mit langem Horizont eine vorwärts Simulation der Situation ausgeführt werden muss. Ein Nachteil der rein datenbasierten Modellierung zeigen die Ergebnisse. Durch ein fehlendes Bewegungsmodell können beliebige prädictierte Bewegungen entstehen, die kinematisch und dynamisch nicht umsetzbar sind. Eine mögliche Repräsentation der Situation wird in [Kim+17] vorgestellt. Die Autoren verwenden eine Belegungskarte, in der alle Fahrzeuge der Situation eingetragen sind, und reichern diese mit Informationen über die longitudinale und laterale Geschwindigkeit an. Die Repräsentation ist damit einem Bild ähnlich, sodass Strukturen der Bildverarbeitung für tiefe Neuronale Netze eingesetzt werden können. Zusätzlich werden rekurrente Strukturen verwendet, um zeitliche Abhängigkeiten zu modellieren. In den Ergebnissen zeigen sich ähnliche Probleme wie in [Len+17], sodass die Trajektorien keiner realistischen Bewegung entsprechen.

Kombinierte Prädiktion und Planung

Zusätzlich zu den reinen Trajektorienprädiktionsverfahren werden Ansätze mit einer Kombination aus der Prädiktion anderer Verkehrsteilnehmer und der gleichzeitigen Planung des Ego-Manövers dargestellt. Die Motivation hierfür ergibt sich aus der interaktionsbasierten Trajektorienprädiktion. Innerhalb einer Verkehrssituation interagieren nicht nur die beobachteten Fahrzeuge untereinander, sie reagieren auch unmittelbar auf die Manöver des Ego-Fahrzeugs. Durch die kombinierte Prädiktion und Planung, können die Auswirkungen einzelner Manöver auf die Verkehrssituation direkt bewertet werden. Dazu verwenden die Autoren von [Bah+16b] ein iteratives Verfahren, in dem die Prädiktion und Planung im Sinne der Spieltheorie als sequentielles Spiel modelliert wird. Dabei stellen die Verkehrsteilnehmer die Spieler dar, die in jeder Iteration Aktionen (Bremsen, Beschleunigen und Spurwechsel) ausführen können, um die Situation zu beeinflussen. Für die Prädiktion wird angenommen, dass jeder Spieler seine Aktionen so auswählt, dass die Situation in einen sicheren Zustand überführt wird. Um die erforderliche Berechnungsdauer zu reduzieren, wird die Modellierung allerdings auf die direkte Interaktion mit dem Ego-Fahrzeug reduziert, sodass Interaktionen zwischen zwei beobachteten Fahrzeugen nicht berücksichtigt werden. In [Hub+18] wird das Problem der Prädiktion und Planung als ein *Partially Observable Markov Decision Process* formuliert. Dabei sind die Route und die Intention eines Verkehrsteilnehmers nicht beobachtbare Zustände. Als Lösung ergibt sich die optimale Beschleunigung des Ego-Fahrzeugs entlang eines vorab geplanten Pfades unter Berücksichtigung der wahrscheinlichsten Trajektorien der anderen Verkehrsteilnehmer. Allerdings werden diese nur auf ebenfalls a priori definierten Routen prädiziert, sodass eine Übertragung auf Autobahnen und Spurwechselmanöver nicht ohne weiteres möglich ist, da diese jederzeit stattfinden können. Die Autoren von [Gal+17] verwenden die gleiche Problemformulierung wie in [Hub+18]. Allerdings wird für die Lösung der Handlungsraum der beobachteten Fahrzeuge eingeschränkt, indem eine Menge von händisch definierten Strategien angenommen wird. Für jedes Fahrzeug wird die Wahrscheinlichkeitsverteilung über die Strategien geschätzt, sodass während einer Vorwärtssimulation eine Strategie aus dieser Verteilung gezogen werden kann. Durch die wiederholte Simulation können die Interaktionen bei verschiedenen Ego-Manövern bewertet werden, sodass das beste Manöver ausgewählt werden kann. Für die Berechnung wird ein vollständiges Umgebungsmodell angenommen und nicht darauf eingegangen, wie mit der Verdeckung einzelner Teilnehmer umgegangen wird. Augustin u. a. [Aug+19b] nutzen eine Kombination aus einem modell-freien verstärkenden Lernverfahren für die longitudinale Planung und einem modellbasierten Planungsansatz für das laterale Manöver. Der modellbasierte Ansatz simuliert die zukünftige Entwicklung der Situation und berücksichtigt dabei die Interaktion zwischen den Umgebungsfahrzeugen sowie dem Ego-Fahrzeug. Das optimale Ego-Manöver wird anhand einer Kostenfunktion bestimmt, die zum einen die Abweichung von den Zielen des Ego-Fahrzeugs und zum anderen die Sicherheitsabstände zu den prädizierten Verkehrsteilnehmern berücksichtigt. In [Sch+19a] wird die interaktionsbasierte Prädiktion aus [Wis+18a] verwendet, um mögliche Manövervarianten zu identifizieren. Anschließend werden Ego-Manöver, die dynamische und sicherheitskritische Bedin-

gungen erfüllen, auf Basis der prädizierten Interaktionen bewertet, um so ein für die aktuelle Verkehrssituation optimales Manöver auszuwählen.

1.3. Beitrag und Gliederung

Die Prädiktion von Trajektorien für benachbarte Verkehrsteilnehmer ist ein grundlegender Baustein für die Umsetzung von automatisierten Fahrfunktionen, die den Fahrer teilweise aus der Verantwortung entlassen können. Die Literatur zeigt eine Vielzahl von möglichen Herangehensweisen zur Lösung des Problems. Dabei steigt die Komplexität je weiter die aktuelle Verkehrssituation in die Zukunft prädiziert werden soll. Gleichzeitig wird häufig vollständiges Wissen über die umgebenden Verkehrsteilnehmer, den Straßenverlauf sowie die Straßentopologie vorausgesetzt. Dieses steht aufgrund von Verdeckung und begrenzter Reichweite der fahrzeugeigenen Sensorik allerdings nicht immer zur Verfügung, sodass die Anwendung der vorgestellten Ansätze nicht ohne Einschränkungen möglich ist. Um das unvollständige Wissen über die direkte Umgebung bei der Entwicklung zu berücksichtigen, wird in der vorliegenden Arbeit zunächst eine Simulationsumgebung vorgestellt, die zum einen die Wahrnehmung eines automatisierten Fahrzeugs abbildet und zum anderen menschliche Verkehrsteilnehmer simuliert. Mit Hilfe der Simulation werden drei Verfahren zur Trajektorienprädiktion für Umgebungsfahrzeuge auf Autobahnen entwickelt:

1. eine manöverbasierte Trajektorienprädiktion (MBTP),
2. eine Erweiterung der MBTP zu einer sicherheitskritischen Trajektorienprädiktion (SKTP),
3. und eine interaktionsbasierte Trajektorienprädiktion (IBTP).

Neben einer ausführlichen Analyse der Genauigkeit der verschiedenen Trajektorienprädiktionsverfahren werden die Anforderungen, die eine komplexere Modellierung innerhalb der Prädiktion an das Umgebungsmodell stellt, dargelegt sowie die Einflüsse eines unvollständigen Umgebungsmodells auf die Güte der Prädiktion diskutiert.

Kapitel 2: Die Trajektorienprädiktion ist ein einzelner Baustein innerhalb der funktionalen Architektur eines automatisierten Fahrzeugs. In diesem Kapitel wird die Prädiktion zunächst in die Gesamtarchitektur eingeordnet und die direkten Abhängigkeiten zu anderen Teilbereichen dargestellt. Anschließend wird das Problem der Trajektorienprädiktion auf Autobahnen mathematisch definiert und die verwendeten Koordinatensysteme dargelegt.

Kapitel 3: Das unvollständige Wissen über die benachbarten Fahrzeuge und die ungenaue Repräsentation der Umgebung sind Einflussfaktoren, die bereits in der Entwicklung eines Verfahrens zur Trajektorienprädiktion berücksichtigt werden müssen. Daher wird hier eine Umgebungssimulation vorgestellt, die die Eigenschaften der Wahrnehmung des automatisierten Fahrzeugs abbildet und gleichzeitig eine realistische Simulation der anderen Verkehrsteilnehmer ermöglicht. Die Simulationsumgebung wird

außerdem anhand von Daten, die mit einem Versuchsfahrzeug aufgenommen wurden, evaluiert.

Kapitel 4: Die beiden Verfahren $MBTP$ und $SKTP$ basieren auf einer initialen Schätzung des aktuellen Fahrmanövers eines beobachteten Fahrzeugs. In diesem Kapitel wird ein auf einer Support Vektor Maschine basierender Ansatz zur Manöverklassifikation präsentiert, der für die Trajektorienprädiktion genutzt wird.

Kapitel 5: In diesem Kapitel wird der erste Ansatz zur Trajektorienprädiktion für beobachtete Fahrzeuge auf Autobahnen dargestellt. Die Manöverschätzung aus dem vorherigen Kapitel wird dazu mit einer effizienten Repräsentation der einzelnen Manöver sowie deren Unsicherheit ergänzt. Das Verfahren wird zunächst auf Basis der in der Simulation erzeugten Daten und anschließend mit Daten aus dem Versuchsfahrzeug evaluiert. Dabei steht insbesondere der Einfluss des Umgebungsmodells auf die Genauigkeit der prädizierten Trajektorien im Fokus.

Kapitel 6: In Kapitel 6 wird ein Verfahren zur Schätzung der Manöverdynamik von Spurwechseln auf Autobahnen vorgestellt. Dabei wird die Annahme einer nicht symmetrischen Verteilung des Spurwechselzeitpunktes und die Schätzung einzelner Quantile dieser Verteilung mittels eines Regressionsverfahrens thematisiert.

Kapitel 7: Mit Hilfe des geschätzten Manövers und der zugehörigen Manöverdynamik wird in diesem Kapitel ein Ansatz zu Prädiktion von sicherheitskritischen Trajektorien entwickelt. Gerade bei Einfädelvorgängen unmittelbar vor dem automatisierten Fahrzeug ist die Betrachtung von unerwartet schnellen Spurwechseln entscheidend für eine sichere Planung des nächsten Manövers. Die Berücksichtigung der durch die geschätzten Quantile repräsentierten Verteilung der Manöverdynamik erlaubt eine explizite Betrachtung von kritischen Manövern in der Trajektorienprädiktion.

Kapitel 8: In diesem Kapitel liegt der Fokus auf einem interaktionsbasierten Ansatz zur Trajektorienprädiktion, in dem die Interaktionen zwischen einzelnen Verkehrsteilnehmern mit Hilfe von mikroskopischen Fahrermodellen modelliert werden. Die Parameter der Modelle werden in jedem Zyklus einer *Monte Carlo* Simulation variiert, um unterschiedliche Fahrertypen abzubilden und damit die Verteilung über verschiedene Entwicklungen der aktuellen Verkehrssituation zu erhalten. Das Verfahren wird insbesondere im Hinblick auf das unvollständige Umgebungsmodell erweitert und ausgewertet.

Kapitel 9: Abschließend werden die Erkenntnisse der vorliegenden Arbeit zusammengefasst und ein Ausblick auf aufbauende Forschungsthemen und -arbeiten gegeben.

2

Trajektorienprädiktion für beobachtete Fahrzeuge

Die Prädiktion der Bewegung beobachteter Verkehrsteilnehmer ist ein entscheidender Baustein eines automatisierten Fahrzeugs. Um Abhängigkeiten zu weiteren Teilbereichen der Architektur herauszuarbeiten, wird die Trajektorienprädiktion in diesem Kapitel zunächst in die funktionale Architektur eines automatisierten Fahrzeugs eingeordnet. Anschließend wird die in der vorliegenden Arbeit untersuchte Problemstellung der Trajektorienprädiktion mathematisch definiert sowie die verwendeten Koordinatensysteme eingeführt. Schließlich werden die Anforderungen an die für die Entwicklung genutzte Simulationsumgebung, die sich aus der funktionalen Architektur sowie der Problemstellung ergeben, dargestellt.

2.1. Funktionale Architektur automatisierter Fahrzeuge

Die funktionale Architektur eines automatisierten Fahrzeugs ist grundsätzlich nicht standardisiert und wird in jedem Entwicklungsprozess individuell an die Anforderungen angepasst. Allerdings lassen sich einige grundlegende Gemeinsamkeiten zwischen verschiedenen funktionalen Architekturen finden, sodass an dieser Stelle eine grobe Übersicht gegeben wird. Die Funktionsarchitektur beschreibt dabei die Struktur von Funktionen, welche die einzelnen Bausteine, deren Eigenschaften und Schnittstellen umfasst ([Ahr16]).

Wird das automatisierte Fahrzeug als ein kognitives System betrachtet, kann die Verarbeitung von Sensordaten bis hin zu der Berechnung der eigentlichen Stellgrößen nach [Taş+16] als eine Kette von drei Hauptbausteinen aufgefasst werden:

1. Wahrnehmung,
2. Planung,
3. Handlung.

Im ersten Schritt wird mit Hilfe von verschiedenen Sensoren und Sensortechnologien die Umgebung wahrgenommen. Aktuell werden hierzu hauptsächlich verschiedene Ausprägungen von Kamera-, Radar-, Lidar- und Ultraschallsensoren verwendet. Jede

Sensortechnologie hat ihre eigenen Vor- und Nachteile, die nicht im Fokus dieser Arbeit stehen und auf die daher nicht weiter eingegangen wird. Anschließend werden auf Basis der gewonnenen Informationen die weiteren Handlungen des Ego-Fahrzeugs geplant und schlussendlich ausgeführt. Dieser dreischrittige Prozess findet sich in vielen Architekturen wieder.

In Abbildung 2.1 ist eine beispielhafte Darstellung einer Funktionsarchitektur für ein automatisiertes Fahrzeug gezeigt. Für die drei einzelnen Schritte sind jeweils enthaltene Unterfunktionen dargestellt. Neben den oben angesprochenen Sensoren beinhaltet die Wahrnehmung Module für die Fusion von Objektbeschreibungen einzelner Sensoren zu einer gemeinsamen Repräsentation. Gleichzeitig werden Objekte, die in einem Zyklus detektiert werden, über die folgenden Zyklen getrackt, um die zeitliche Veränderung des Objektzustandes zu beobachten. Zusätzlich zu der Objektdetektion wird während der Wahrnehmung eine Repräsentation der aktuellen Straßentopologie generiert. Dazu werden die Kamerasensoren des Fahrzeugs genutzt, um Fahrspuren oder andere Straßenelemente zu detektieren. Die Beschreibung kann zusätzlich mit einer digitalen Karte erweitert werden, wodurch sich besonders für Bereiche in größerer Distanz (> 100 m) Vorteile ergeben. Als letzter Schritt im Wahrnehmungsprozess muss das Fahrzeug zum einen auf der Straße, auf der es sich befindet, und zum anderen in der digitalen Karte lokalisiert werden.

Aus allen Informationen wird ein Umgebungsmodell erstellt, das die aktuelle Verkehrsszene mit allen Verkehrsteilnehmern und der Straßentopologie beschreibt. An dieser Stelle wird zwischen einer Verkehrsszene und der Verkehrssituation unterschieden:

- Die **Verkehrsszene** beschreibt alle direkt messbaren Eigenschaften in der Umgebung des Ego-Fahrzeugs. Das beinhaltet die aktuellen Zustände der umgebenden Fahrzeuge, deren Ausdehnung und Position in der Spur. Zusätzlich enthält die Verkehrsszene eine Beschreibung der aktuellen Straßentopologie.
- Die **Verkehrssituation** umfasst zusätzlich eine Interpretation der Verkehrsszene, durch die auf nicht beobachtbare Größen geschlossen werden kann. Als Beispiel kann die Intention eines Fahrers in einer Verkehrssituation genannt werden. Auf Basis der beobachteten Bewegung ist eine Schätzung des aktuellen Manövers und damit der zukünftigen Bewegung des Fahrzeugs möglich.

Das Umgebungsmodell beinhaltet nach der Wahrnehmung die Schätzung aller Zustände der benachbarten Fahrzeuge und Objekte sowie eine einheitliche Repräsentation der Straßentopologie. Innerhalb der Planung werden anschließend zwei Schritte durchlaufen. Zunächst wird eine Analyse der Verkehrssituation durchgeführt, in der die Intention der beobachteten Fahrzeuge geschätzt und auf Basis dessen der weitere Verlauf der Situation prädiziert wird. Anschließend kann die Handlung des Ego-Fahrzeugs geplant werden. Die Situationsanalyse kann nochmals in die Detektion von Manövern, die Schätzung der jeweiligen Eigenschaften und der Prädiktion von Zustandstrajektorien aufgeteilt werden. Die prädizierten Trajektorien komplettieren das Umgebungsmodell zu einem prädiktiven Umgebungsmodell, auf dessen Basis die Manöverplanung durchgeführt wird. Mit Hilfe eines Trajektorienplanungsverfahrens

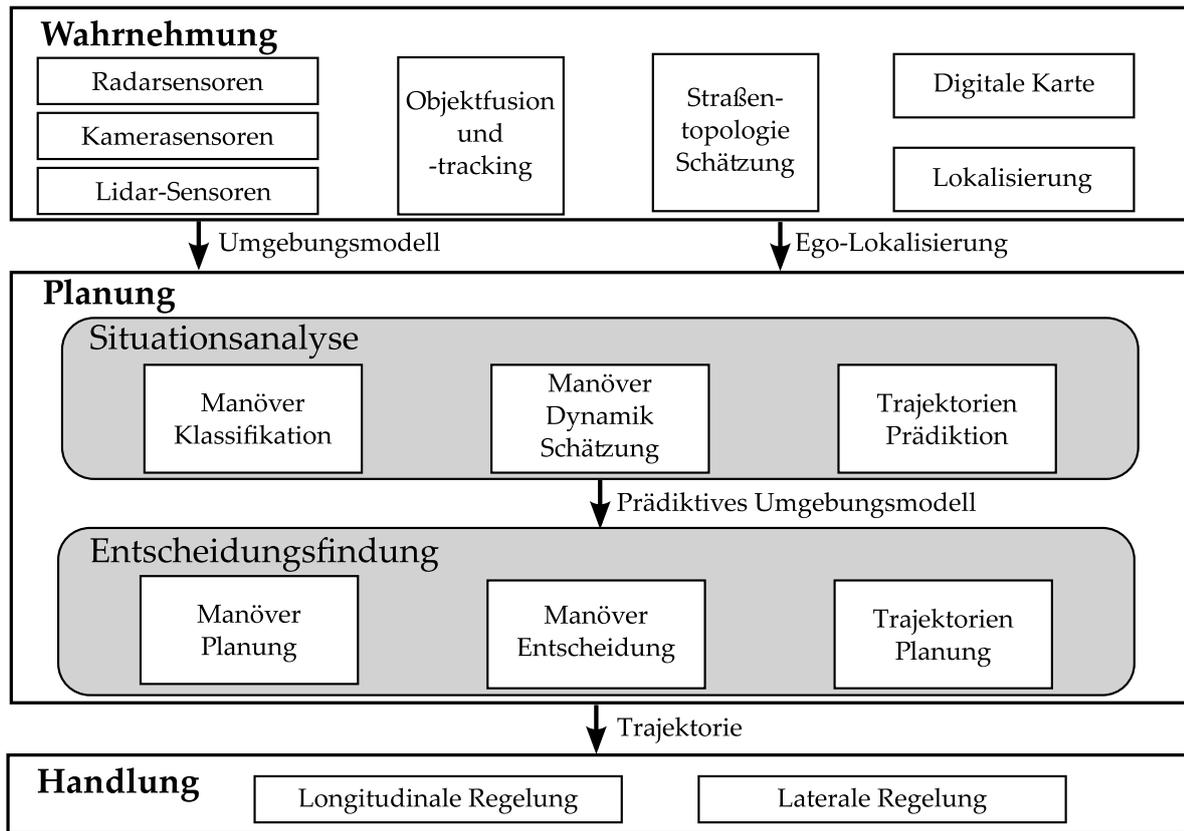


Abbildung 2.1.: Beispiel einer funktionalen Architektur eines automatisierten Fahrzeugs.

kann das Manöver in eine Trajektorie überführt werden. Als letzter Schritt wird die Trajektorie von einem lateralen sowie longitudinalen Regler und mit Hilfe der Stellglieder umgesetzt.

Die vorliegende Arbeit befasst sich mit dem Problem der Situationsanalyse; insbesondere der Prädiktion von Zustandstrajektorien für beobachtete Fahrzeuge. Entsprechend stellt das Umgebungsmodell den Ausgangspunkt dar, auf dem die vorgestellten Ansätze aufbauen. Es enthält eine holistische Beschreibung der dynamischen Objekte, die durch einen Fusions- und Trackingalgorithmus gewonnen wird. Alle Objekte liegen in Form einer Objektliste vor. Zusätzlich ist eine Beschreibung der Straßentopologie verfügbar, die mit Hilfe einer nach vorne gerichteten Kamera erstellt wird. Es sind keine weiteren Informationen in Form einer digitalen Karte vorhanden, sodass eine zuverlässige Aussage über den Straßenverlauf häufig nur im nahen Sichtbereich der Kamera möglich ist. Die Spuren werden über die jeweiligen Spurmarkierungen in Form eines Polynoms dritter Ordnung repräsentiert und enthalten Informationen, die eine Unterscheidung zwischen Spurtypen zulassen (beispielsweise: Normale Fahrspur und Autobahnauffahrten).

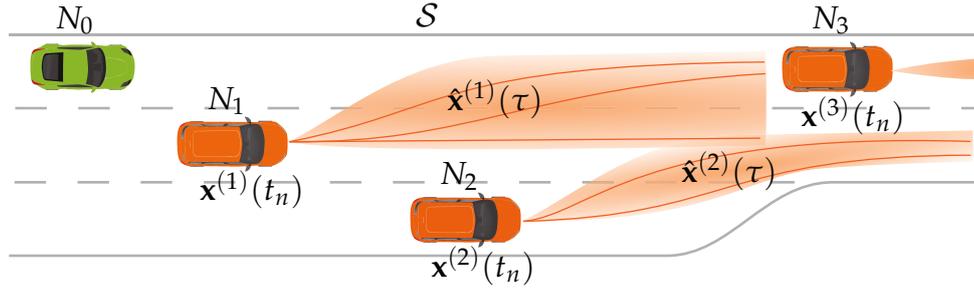


Abbildung 2.2.: Beispielhafte Autobahnsituation, in der die rechte Spur endet, sodass das Fahrzeug auf der rechten Spur einen Spurwechsel nach links durchführen muss, um weiter der Straße zu folgen. Die anderen Fahrzeuge müssen entsprechend auf das Manöver reagieren.

2.2. Problemstellung der Trajektorienprädiktion

Zur sicheren und komfortablen Bewältigung aller auftretenden Situationen auf Autobahnen müssen automatisierte Fahrzeuge nicht nur die aktuelle Verkehrssituation erfassen können, sondern auch die zukünftige Entwicklung dieser berücksichtigen. Dabei ist das Verhalten und damit die zukünftige Bewegung der umgebenden Verkehrsteilnehmer eine wichtige Information, da die übrige Umgebung als statisch angesehen werden kann. Somit ist das Ziel der Trajektorienprädiktion eine möglichst genaue Vorhersage der Zustände aller Fahrzeuge in der direkten Umgebung. Dies wird in Abbildung 2.2 anhand einer Beispielsituation verdeutlicht. Das Ego-Fahrzeug (N_0) bewegt sich auf einer dreispurigen Autobahn, bei der die rechte Spur endet. Das Fahrzeug (N_2) auf der rechten Spur muss einen Spurwechsel auf die mittlere Spur durchführen, um weiter der Straße folgen zu können. Dieser beeinflusst das Fahrzeug (N_1) auf der mittleren Spur, welches abhängig von seiner Geschwindigkeit ebenfalls einen Spurwechsel durchführen kann oder verzögern muss. Es ergeben sich eine Vielzahl von möglichen Entwicklungen, die bei der Planung des Manövers des Ego-Fahrzeugs berücksichtigt werden müssen. Die Aufgabe der Trajektorienprädiktion besteht in der Vorhersage des weiteren Verlaufs der aktuellen Verkehrssituation und diesen den nachfolgenden Algorithmen zur Entscheidungsfindung und Trajektorienplanung zur Verfügung zu stellen.

Im Folgenden wird das Problem der Trajektorienprädiktion mathematisch formuliert. Gegeben sei eine Menge von $K \in \mathbb{N}_+$ beobachteten Fahrzeugen in der aktuellen Verkehrssituation $\mathcal{Z} = \{N_0, N_1, \dots, N_K\}$, wobei N_0 das Ego-Fahrzeug repräsentiert. Jedes Fahrzeug wird zum Zeitpunkt $t_n \in \mathbb{R}_{0+}$ durch den normalverteilten Zustand $\mathbf{x}^{(k)}(t_n) = \mathcal{N}(\boldsymbol{\mu}^{(k)}(t_n), \boldsymbol{\Sigma}^{(k)}(t_n)) \in \mathbb{R}^4$ für $k \in \{1, 2, \dots, K\}$ beschrieben. Dabei ist der Zeitpunkt auf einem festen Raster

$$t_0 \leq t_1 \leq \dots \leq t_n \leq \dots \quad (2.2.1)$$

mit der Schrittweite $t_{n+1} - t_n = \Delta T$ für $n \in \mathbb{N}_0$ definiert. Der Zustand kann direkt dem Umgebungsmodell entnommen werden, welches in einem vorherigen Schritt der Architektur generiert wird (vgl. Abschnitt 2.1). Das Ego-Fahrzeug und alle weiteren Verkehrsteilnehmer befinden sich in einer beliebigen Verkehrsszene \mathcal{S} , welche

die Straßentopologie und weiteren verkehrsrelevanten Kontext umfasst. Neben dem Verlauf und der Anzahl der Spuren sind zusätzlich Informationen über aktuell gültige Verkehrsregeln sowie Verkehrszeichen in \mathcal{S} enthalten. Die Informationen können dabei einerseits von der fahrzeugeigenen Sensorik stammen oder andererseits als digitale (hochgenaue) Karte vorliegen. Jedes Fahrzeug k führt eine Sequenz von Fahrmanövern $\Gamma^{(k)} = (m_0^{(k)}, m_1^{(k)}, \dots, m_{n_\Gamma}^{(k)})$, $n_\Gamma \in \mathbb{N}_+$ aus, um sich innerhalb der Szene fortzubewegen. In der vorliegenden Arbeit werden Verfahren zur Trajektorienprädiktion für Autobahnscenarien vorgestellt, sodass die gewählte Repräsentation an den Anwendungsfall angepasst ist. Das Ziel der Trajektorienprädiktion ist die Schätzung der zukünftigen Zustände aller Fahrzeuge $\hat{\mathbf{x}}^{(k)}(\tau)$ innerhalb des Prädiktionsintervalls $\tau \in [t_n, t_n + T_p]$ mit dem Prädiktionshorizont $T_p = n_p \Delta T$ und $n_p \in \mathbb{N}_+$. Dabei unterliegt die Schätzung drei Arten von Unsicherheiten:

1. Der Zustand eines Fahrzeugs ist unbekannt und durch die Verteilung $p(\mathbf{x}^{(k)}(t_n))$ repräsentiert.
2. Die während der Prädiktionszeit ausgeführten Fahrmanöver sind nicht beobachtbar.
3. Die Ausführung der Fahrmanöver ist fahrerindividuell und somit ebenfalls unbekannt.

Die prädizierte Trajektorie wird daher durch eine Verteilung über die zukünftigen Zustände beschrieben

$$\hat{\mathbf{x}}^{(k)}(\tau) \sim p(\hat{\mathbf{x}}^{(k)}(\tau) \mid \mathbf{x}^{(k)}(t_n), \Gamma^{(k)}, \mathcal{Z}_k, \mathcal{S}), \quad (2.2.2)$$

welche von dem aktuellen Zustand $\mathbf{x}^{(k)}(t_n)$, der Sequenz von ausgeführten Manövern $\Gamma^{(k)}$ sowie den anderen Fahrzeugen innerhalb der Situation $\mathcal{Z}_k = \mathcal{Z} \setminus N_k$ und der Verkehrsszene abhängt.

2.3. Frenet-Serret Koordinaten

An dieser Stelle werden die verwendeten Koordinatensysteme erläutert und die Transformation zwischen diesen beschrieben. Zunächst wird ein kartesisches globales Koordinatensystem definiert. Der Ursprung ist dabei ortsfest, sodass die Bewegung des Ego-Fahrzeugs in diesem System beschrieben werden kann. Koordinaten im globalen System werden durch ein vorangestelltes ${}^W \square$ repräsentiert. Als weiteres kartesisches System wird das Fahrzeugkoordinatensystem mit dem Ursprung in der Mitte der Frontstoßstange des Ego-Fahrzeugs verwendet. In diesem System wird das Umgebungsmodell auf Basis der Sensormesswerte erstellt, sodass es den Ausgangspunkt der Trajektorienprädiktion darstellt. Alle zu prädizierenden Agenten werden zunächst im Fahrzeugkoordinatensystem durch ihren Zustand $\mathbf{x}^{(k)}(t_n)$ mit der Position $[x, y]^T$ und den entsprechenden Geschwindigkeiten $[v_x, v_y]^T$ repräsentiert.

Als drittes System wird das Frenet-Serret Koordinatensystem verwendet. Es handelt sich um kein kartesisches System, da die longitudinale Koordinate entlang einer beliebigen Referenzlinie definiert ist. Dadurch eignet es sich besonders für die Nutzung in

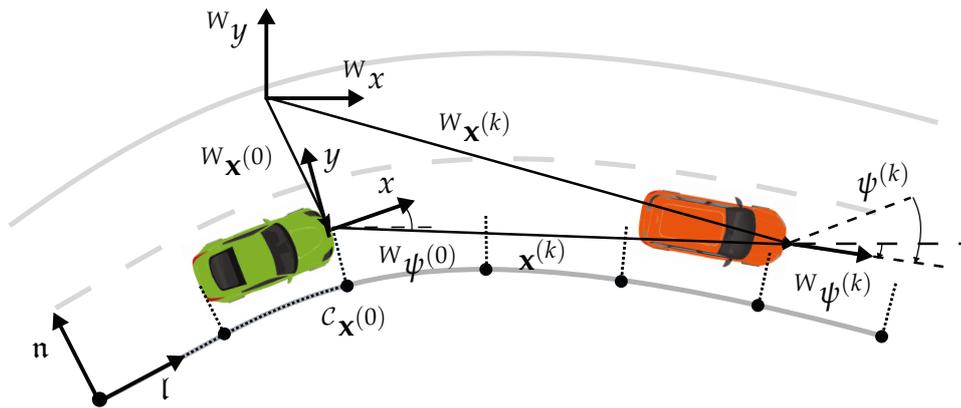


Abbildung 2.3.: Darstellung der verwendeten Koordinatensysteme [Lie+19a]. Neben einem ortsfesten globalen Koordinatensystem werden die Fahrzeugkoordinaten und ein Frenet-Serret System, das entlang einer Referenzlinie definiert ist, verwendet.

kurvigen Szenarien. Wird der Kurvenverlauf als Referenzlinie verwendet, entspricht die Straße im Frenet-Serret Koordinatensystem einer Geraden, sodass es auch als kurvilineares Koordinatensystem beschrieben werden kann. Das System wird im Folgenden über ein vorangestelltes c gekennzeichnet. Dabei ist eine Position innerhalb des Systems über die longitudinale Koordinate entlang der Referenzlinie l und eine Koordinate n normal zu dieser beschrieben. Die Geschwindigkeit longitudinal und lateral zur Referenzlinie ist definiert als $[v_l, v_n]^T$. Diese Definition verallgemeinert die Trajektorienprädiktion für einen geraden Straßenabschnitt auf kurvige Szenarien. Dazu werden die Objekte zunächst in das Frenet-Serret System überführt. Die Prädiktion kann anschließend für eine gerade Straße durchgeführt und abschließend in das kartesische System zurück transformiert werden. Allerdings ist die Umrechnung zwischen einem kartesischen und einem Frenet-Serret System eine nichtlineare Transformation, für die der minimale Abstand einer Position zu der Referenzlinie gefunden werden muss. Abhängig von der Repräsentation beinhaltet die Berechnung eine Optimierung, die wiederum einen erhöhten Rechenaufwand impliziert. Für die Transformation zwischen kurvilinearen und kartesischen Koordinaten wird die in [Ben+14] vorgestellte Lanelet Transformation verwendet.

2.4. Entwicklung in virtueller Umgebung

Für die Entwicklung und Untersuchung von Ansätzen für die Trajektorienprädiktion ergeben sich spezielle Anforderungen an die genutzte Entwicklungsumgebung. Wird für die Entwicklung ausschließlich eine Simulationsumgebung mit einem idealen Umgebungsmodell verwendet, kann sich die Güte bei der Anwendung in einem Testfahrzeug deutlich verschlechtern. Wenn die Entwicklung lediglich in einem Testfahrzeug vorgenommen wird, kann durch eine fehlerhafte Wahrnehmung das Potential des untersuchten Ansatzes nicht unabhängig vom Umgebungsmodell bewertet werden. Daher wird eine Entwicklungsumgebung benötigt, die eine realitätsnahe Modellierung des Wahrnehmungsprozesses umsetzt und damit die Analyse eines Verfahrens

für ein suboptimales Umgebungsmodell erlaubt. Eine detaillierte Ausführung der Anforderungen an die genutzte Simulationsumgebung ist im Anhang in Abschnitt A.1.1 zu finden. Außerdem werden verfügbare Umgebungen sowie der aktuelle Stand der Technik auf Eignung für den vorliegenden Anwendungsfall untersucht (siehe Abschnitt A.1.2). Nachfolgend werden die Anforderungen kurz zusammengefasst. Für die vorliegende Arbeit müssen Autobahnszenarien mit verschiedenen Krümmungsradien sowie Straßentopologien simuliert werden. Dabei muss neben dem Ego-Fahrzeug der umgebende Verkehr mit einer variablen Dichte abgebildet werden. Eine entscheidende Anforderung ist das annähernd menschliche sowie stochastische Verhalten der weiteren Verkehrsteilnehmer, da die Trajektorienprädiktion für diese aus Sicht des Ego-Fahrzeugs vorgenommen wird. Dies umfasst sowohl die Manöverentscheidungen als auch deren Ausführung. Ein weiteres Kriterium ist das zur Verfügung gestellte Umgebungsmodell, welches in der Qualität sowie der Repräsentation dem des Testfahrzeuges entsprechen muss.

Die Übersicht in Tabelle A.1 zeigt, dass keine der verfügbaren Simulationsumgebungen alle Anforderungen vollständig erfüllt. Gerade die Darstellung eines realistischen Fahrverhaltens des umgebenden Verkehrs wird häufig nicht ausreichend umgesetzt, um die Simulation in der Entwicklung einer Trajektorienprädiktion zu nutzen. Die Betrachtung des aktuellen Forschungsstandes zeigt allerdings, dass es viele Ansätze zur Modellierung menschlichen Fahrverhaltens für mikroskopische Verkehrssimulationen gibt. Daher wird im Rahmen dieser Arbeit die *Driving Environment Simulation* (DESIM) entwickelt. DESIM kann verschiedene Autobahnszenarien darstellen und simuliert dabei ein realistisches Verhalten der anderen Verkehrsteilnehmer. Gleichzeitig wird das für die Entwicklung benötigte Umgebungsmodell auf Basis von datenbasierten Sensormodellen generiert. Hierbei werden vor allem Effekte beachtet, die für die Prädiktion von Trajektorien von Bedeutung sind. Der Vorteil liegt in der einfachen Erweiterung der quelloffenen Simulationsumgebung im Falle von Änderungen in der Sensorkonfiguration oder für spezifische Anwendungsszenarien. Für die Entwicklung der Trajektorienprädiktion mit Hilfe der Simulationsumgebung werden zunächst aufgenommene Daten aus einem Testfahrzeug genutzt, um zum einen das datenbasierte Sensormodell an die vorhandene Sensorkonfiguration sowie die Datenfusion im Testfahrzeug anzupassen und zum anderen die Modelle zur Abbildung des Fahrverhaltens zu parametrieren. Mit Hilfe von DESIM werden unterschiedliche Autobahnszenarien generiert, auf deren Basis ein Konzept zur Prädiktion von Trajektorien erarbeitet werden kann. Abschließend wird die entwickelte Trajektorienprädiktion mit aufgenommenen Daten aus dem Testfahrzeug validiert.

3

Umgebungssimulation

Nachdem im vorherigen Kapitel die Notwendigkeit einer spezialisierten Simulationsumgebung für die Entwicklung der Trajektorienprädiktion dargelegt wurde, beschreibt das Folgende den Aufbau der Simulation und die eingesetzten Modelle zur Abbildung des menschlichen Fahrverhaltens und die Generierung des Umgebungsmodells. Dabei wird zunächst kurz auf die Modellierung der Straßentopologie eingegangen, mit der verschiedenste Autobahnszenarien abgebildet werden können. Anschließend werden das Umgebungsmodell sowie die Abbildung des Fahrverhaltens detailliert erläutert und die genutzten Modelle evaluiert. Das Kapitel schließt mit einer Diskussion der Ergebnisse.

3.1. Abbildung der Straßentopologie und Visualisierung

Die vorgestellte Simulationsumgebung ist vollständig auf die Darstellung von Autobahnszenarien ausgerichtet. Dazu wird die Straßentopologie des jeweiligen Szenarios mit einer Graphen-basierten Struktur dargestellt, die den Spurverlauf sowie die Relationen einzelner Spuren zueinander abbildet. In den Kanten zwischen einzelnen Spurknoten sind Informationen über die Art der Spurmarkierung und die damit verbundene Möglichkeit eines Spurwechsels von einer auf die andere Spur enthalten. Die Vorgehensweise erlaubt die Darstellung einer Vielzahl von Autobahnszenarien. Dies umfasst unter anderem Auf- und Abfahrten, beliebig viele parallele oder endende und sich öffnende Spuren. Neben der Struktur der Szenarien ist die Visualisierung an die Anforderungen angepasst. Eine detaillierte dreidimensionale Darstellung ist nicht erforderlich, da die Interaktion mit einem menschlichen Bediener nicht vorgesehen ist. Die Situation wird aus der Vogelperspektive mit allen Verkehrsteilnehmern dargestellt. Zusätzlich wird das simulierte Umgebungsmodell visualisiert. Eine detaillierte Erklärung der Struktur und eine Abbildung der Visualisierung ist im Anhang A.2 zu finden.

3.2. Sensorsimulation

Ein entscheidender Faktor für die Entwicklung von Verfahren zur Trajektorienprädiktion ist die Qualität des zur Verfügung stehenden Umgebungsmodells. Dieses wird aus der Fusion von Messungen verschiedener am Fahrzeug verbauter Sensoren erzeugt. Der Prozess zur Generierung des Umgebungsmodells muss von der Simulationsumgebung abgebildet werden, um ein realitätsnahes Umgebungsmodell zu erhalten. Im Gegensatz zu der Entwicklung von Algorithmen für die Sensordatenverarbeitung oder -fusion ist hier eine genaue Abbildung der physikalischen Eigenschaften einzelner Sensoren nicht entscheidend. Die Genauigkeit der gesamten Verarbeitungskette muss qualitativ abgebildet werden. Daher wird in diesem Abschnitt ein Ansatz vorgestellt, der die Wahrnehmung aller Radarsensoren sowie einzelne Kamerasensoren berücksichtigt. Die simulierten Messungen der einzelnen Sensortypen werden zu einem vollständigen Umgebungsmodell fusioniert, um Eingangsdaten für die Situationsanalyse bereit zu stellen. Ein Aspekt mit großem Einfluss auf die Güte einer Trajektorienprädiktion, ist die Verdeckung von Fahrzeugen oder Spurmarkierungen durch Objekte innerhalb der Simulation. Für beide Arten von Sensoren wird daher eine Verdeckung berechnet, indem die Sichtlinie zwischen Objekt und Sensor auf etwaige Unterbrechungen durch andere Objekte überprüft wird. Sollte dies der Fall sein, wird das verdeckte Objekt nicht mehr vom Sensor wahrgenommen. Die gesamte Wahrnehmung wird im Fahrzeugkoordinatensystem durchgeführt. Hierbei befindet sich der Koordinatenursprung in der Mitte der vorderen Stoßstange, die x -Achse ist entlang der Fahrtrichtung orientiert und die z -Achse senkrecht zur Straße. Die y -Achse komplettiert das rechts-händische Koordinatensystem. Im Folgenden wird zunächst auf die Modellierung der Radarsensoren eingegangen. Anschließend wird die Wahrnehmung der Objekte und Spurmarkierungen mittels Kamerasensoren dargelegt, um abschließend die Fusion zum vollständigen Umgebungsmodell herauszuarbeiten.

Radarbasierte Wahrnehmung

In der vorgestellten Simulationsumgebung stehen bei der Modellierung von Radarsensoren nicht die physikalischen Wirkprinzipien im Fokus. Es sind hauptsächlich die Unsicherheit der fusionierten Messung aller verbauten Sensoren und spezifische Effekte, die Einfluss auf die Trajektorienprädiktion haben können, von Interesse. Daher wird ein datenbasiertes Modell für die Abbildung der Unsicherheit von Objekten innerhalb des Sichtbereichs der Radarsensoren vorgestellt. Im Gegensatz zu dem Vorgehen in [Wis+16] wird ein rekursives Modell erstellt, das die Korrelation der Unsicherheit über die Zeit berücksichtigt. Weitere Effekte werden nicht explizit modelliert, sondern sind implizit in der modellierten Unsicherheit enthalten.

Der mit den Radarsensoren gemessene Zustand $\mathbf{x}_R^{(k)}(t_n)$ des k -ten Fahrzeugs zum Zeitpunkt t_n folgt einer vierdimensionalen Normalverteilung $\mathcal{N}\left(\boldsymbol{\mu}_R^{(k)}(t_n), \boldsymbol{\Sigma}_R^{(k)}(t_n)\right)$

mit dem Mittelwert $\boldsymbol{\mu}_R^{(k)}(t_n)$ und der Kovarianzmatrix $\boldsymbol{\Sigma}_R^{(k)}(t_n)$

$$\mathbf{x}_R^{(k)}(t_n) \sim \mathcal{N}\left(\boldsymbol{\mu}_R^{(k)}(t_n), \boldsymbol{\Sigma}_R^{(k)}(t_n)\right), \boldsymbol{\mu}_R^{(k)}(t_n) = \begin{bmatrix} x \\ y \\ v \\ \psi \end{bmatrix}, \boldsymbol{\Sigma}_R^{(k)}(t_n) = \begin{bmatrix} \sigma_x & \sigma_{x,y} & \sigma_{x,v} & \sigma_{x,\psi} \\ & \sigma_y & \sigma_{y,v} & \sigma_{y,\psi} \\ & & \sigma_v & \sigma_{v,\psi} \\ \text{Sym.} & & & \sigma_\psi \end{bmatrix}. \quad (3.2.1)$$

Hierbei ist x, y die Position, ψ der Gierwinkel im Fahrzeugkoordinatensystem und v beschreibt die Geschwindigkeit des Objekts in einem ortsfesten Koordinatensystem. Der Übersicht halber wird die Zeitabhängigkeit der einzelnen Größen in Formel (3.2.1) nicht dargestellt. Die Genauigkeit der Messung wird durch die Kovarianzmatrix $\boldsymbol{\Sigma}_R^{(k)}(t_n) \in \mathbb{R}^{4 \times 4}$ repräsentiert. Für ein Objekt, das von Radarsensoren wahrgenommen und über mehrere Zyklen getrackt wird, kann sich die Unsicherheit abhängig von verschiedenen Einflussfaktoren ändern. Die relevanten Einflussgrößen sind hierbei zum einen die Distanz zum Ego-Fahrzeug und zum anderen die Anzahl der Zyklen, in denen das Objekt detektiert wird. In dem Modell unterliegen Objekte, die eine kleinere Entfernung zum Sensor aufweisen, einer geringeren Messungengenauigkeit als weiter entfernte Objekte. Außerdem kann die Unsicherheit eines Objekts durch wiederholte Detektionen verringert werden. Grundsätzlich hängt die Unsicherheit zum Zeitpunkt t_n immer von der des vorherigen Zyklus ab. Um die genannten Eigenschaften zu berücksichtigen, wird ein rekursives Model, das die Änderung der Unsicherheit über die Zeit abbildet, erstellt. Analog zu dem Vorgehen in [Wis+17a] werden die einzelnen Elemente der Kovarianzmatrix $\boldsymbol{\Sigma}_R^{(k)}(t_n)$ beziehungsweise die Änderung dieser unabhängig voneinander betrachtet. Da lediglich eine qualitative Abbildung der Sensorfehler von Interesse ist, kann die Korrelation zwischen einzelnen Elementen von $\boldsymbol{\Sigma}_R^{(k)}(t_n)$ vernachlässigt werden. Entsprechend wird die Entwicklung der Komponente $i, j \in \{x, y, v, \psi\}^1$ der Unsicherheit $\boldsymbol{\Sigma}_R^{(k)}(t_n)$ über die Zeit abgebildet durch

$$\sigma_{i,j}(t_{n+1}) = \frac{1}{\sum_{k=1}^3 \alpha_k} (\alpha_1 f_{\text{Time}}(t_n) + \alpha_2 f_{\text{Pos}}(\mathbf{x}(t_{n+1}), \mathbf{x}(t_n)) + \alpha_3 \varepsilon_{\text{Rand}}) \sigma_{i,j}(t_n). \quad (3.2.2)$$

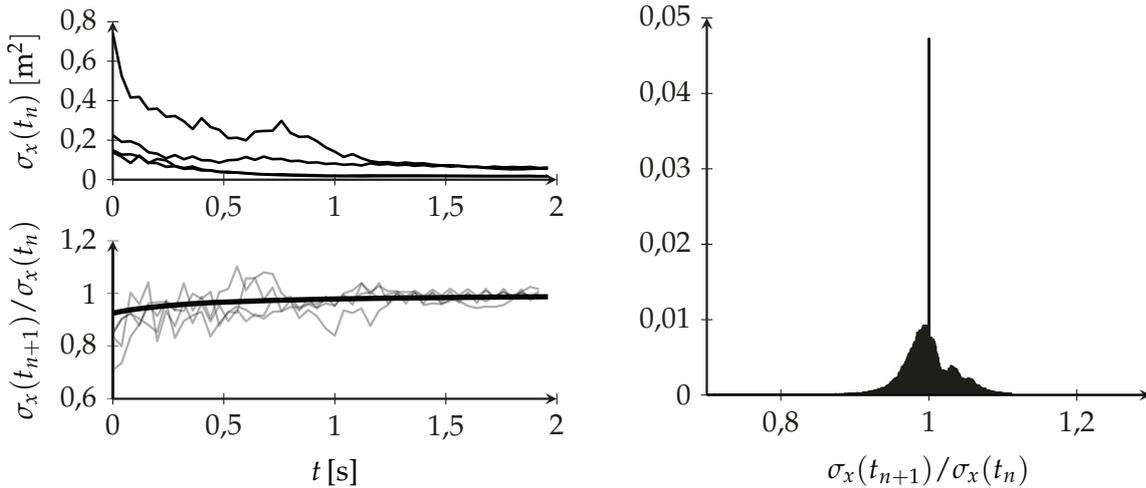
Die Funktion f_{Time} bewirkt eine Verringerung der Unsicherheit durch wiederholte Detektion eines Objekts, wie es zum Beispiel durch ein häufig eingesetztes filterbasiertes Tracking erreicht werden kann. Mathematisch ist die Funktion definiert durch

$$f_{\text{Time}}(t_n) = 1 - \frac{a_{\text{Time}}}{b_{\text{Time}} t_n + c_{\text{Time}}}, \quad (3.2.3)$$

wobei die Parameter $\Theta_{\text{Time}} = \{a_{\text{Time}}, b_{\text{Time}}, c_{\text{Time}}\}$ durch Minimierung des Fehlers zu gemessenen Daten geschätzt werden können

$$\Theta_{\text{Time}}^* = \arg \min_{\Theta_{\text{Time}}} \sum_k \left\| \frac{\sigma_{i,j}(t_{n+1})}{\sigma_{i,j}(t_n)} - \left(1 - \frac{a_{\text{Time}}}{b_{\text{Time}} t_n + c_{\text{Time}}} \right) \right\|^2. \quad (3.2.4)$$

¹Die Indizes i und j sind an dieser Stelle nicht als Elemente einer mathematischen Menge zu verstehen, sondern referenzieren die einzelnen Elemente der Kovarianzmatrix.



(a) Abbildung der Änderung der Varianz σ_x über die Zeit. Oben: Vier Beispielverläufe der Varianz. Unten: Verlauf des Verhältnisses $\sigma_x(t_{n+1})/\sigma_x(t_n)$ für vier Beispiele in grau und das geschätzte Modell in schwarz.

(b) Zusätzliche stochastische Änderung der Unsicherheit σ_x

Abbildung 3.1.: Zeitliche und zufällige Änderung der Unsicherheit.

In Abbildung 3.1a sind im oberen Bereich beispielhafte Verläufe der Varianz in der x -Komponente zu sehen. In dem Moment, in dem das entsprechende Objekt detektiert wird, ist die Varianz verhältnismäßig groß. Durch die mehrfache Detektion desselben Objekts kann die Varianz verringert werden. Im unteren Teil der Abbildung ist das Verhältnis der Varianz $\sigma_x(t_{n+1})/\sigma_x(t_n)$ für die jeweiligen Objekte und der durch das Modell abgebildete Verlauf.

Die Funktion f_{Pos} beschreibt die Abhängigkeit der Varianz von der relativen Position des Objekts zum Ego-Fahrzeug. Die Datenpunkte in Abbildung 3.2 zeigen, dass die Varianz mit betragsmäßig wachsender y -Koordinate ebenfalls größer wird. Um dies abzubilden, wird ein zweidimensionales Polynom $P_{n_{\text{dist},x}, n_{\text{dist},y}} : \mathbb{R}^2 \rightarrow \mathbb{R}$ des Grades $n_{\text{dist},x}, n_{\text{dist},y} \in \mathbb{N}_0$ an die Daten angepasst. Mithilfe des Polynoms wird anschließend die Änderung der Varianz aufgrund der Änderung der relativen Position durch

$$f_{\text{Pos}}(\mathbf{x}(t_{n+1}), \mathbf{x}(t_n)) = \frac{P_{n_{\text{dist},x}, n_{\text{dist},y}}(\mathbf{x}(t_{n+1}))}{P_{n_{\text{dist},x}, n_{\text{dist},y}}(\mathbf{x}(t_n))} \quad (3.2.5)$$

modelliert. So wird eine den Daten entsprechende Steigerung der Unsicherheit für sich entfernende Fahrzeuge umgesetzt. Hierbei wird die Ordnung des Polynoms empirisch und unabhängig für jeden Eintrag der Kovarianzmatrix bestimmt. In Abbildung 3.2 ist das geschätzte Polynom für die Varianz σ_x mit Polynomgrad $n_{\text{dist},x} = 0, n_{\text{dist},y} = 2$ dargestellt.

Die Genauigkeit der radarbasierten Messung wird durch eine Vielzahl von weiteren Faktoren beeinflusst, die nicht durch die beiden beschriebenen Teilmodelle erklärt werden. Da das Modell mit einfachen mathematischen Formulierungen die wichtigsten Effekte beschreiben soll, andere Einflüsse allerdings nicht grundsätzlich vernachlässigt werden können, wird durch den zusätzlichen Term $\varepsilon_{\text{Rand}}$ im Sensormodell eine

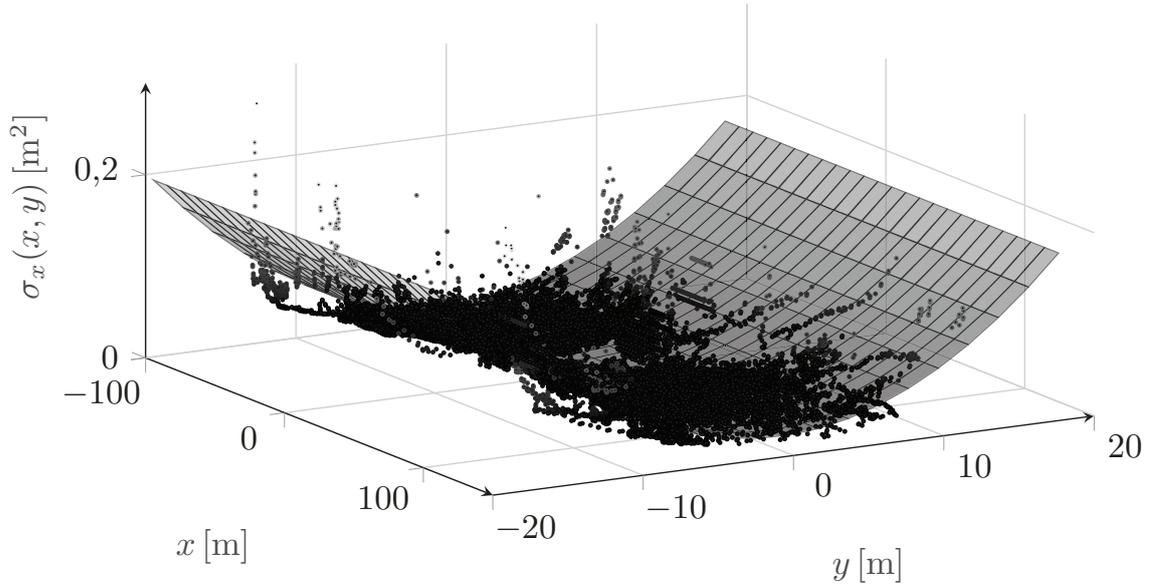


Abbildung 3.2.: Positionsabhängigkeit der Varianz σ_x und die geschätzte polynomiale Abbildung.

stochastische Änderung der Unsicherheit abgebildet. Diese wird durch eine diskrete Wahrscheinlichkeitsverteilung \tilde{p} aus den aufgenommenen Daten repräsentiert

$$\varepsilon_{\text{Rand}} \sim \tilde{p} \left(\frac{\sigma_{i,j}(t_{n+1})}{\sigma_{i,j}(t_n)} \right). \quad (3.2.6)$$

Die Verteilung für die stochastische Änderung der Varianz σ_x ist in Abbildung 3.1b dargestellt. Es zeigt sich, dass sich die Unsicherheit in zwei aufeinander folgenden Zeitschritten häufig nicht ändert ($\varepsilon_{\text{Rand}} = 1$). Die weiteren Änderungen entsprechen näherungsweise einer Normalverteilung mit einem Mittelwert von eins.

Für eine rekursive Berechnung muss bei der ersten Detektion t_{init} ein initialer Wert für die Unsicherheit bestimmt werden. Wie bei der stochastischen Änderung (3.2.6) lässt sich eine diskrete Wahrscheinlichkeitsverteilung aus den aufgenommenen Daten ableiten

$$\sigma_{i,j}(t_n = t_{\text{init}}) \sim \tilde{p}(\sigma_{i,j}(t_{\text{init}})), \quad (3.2.7)$$

wobei $\tilde{p}(\sigma_{i,j}(t_{\text{init}}))$ die diskrete Verteilung von $\sigma_{i,j}$ zum Zeitpunkt $t_n = t_{\text{init}}$ darstellt. Da die Unsicherheit generell stark von der relativen Position des Objekts zum Ego-Fahrzeug abhängt, wird die initiale Unsicherheit zusätzlich mit einem an die aufgenommenen Daten angepassten zweidimensionalen Polynom skaliert (vergleichbar mit dem Vorgehen in Gleichung (3.2.5)). Durch die Skalierung wird verhindert, dass einem weit entfernten Objekt eine statistisch kleinere Unsicherheit als einem nahen Objekt zugewiesen wird. Dazu wird die initiale Varianz zunächst aus der empirischen Verteilung gezogen und anschließend mit dem Polynom skaliert. In Abbildung 3.3 ist die Verteilung der initialen Unsicherheit vor (links) und nach (rechts) der Skalierung dargestellt.

Für die Bestimmung der Unsicherheit eines detektierten Objekts wird zunächst eine initiale Varianz aus der empirischen Verteilung 3.2.7 gezogen und skaliert. In den

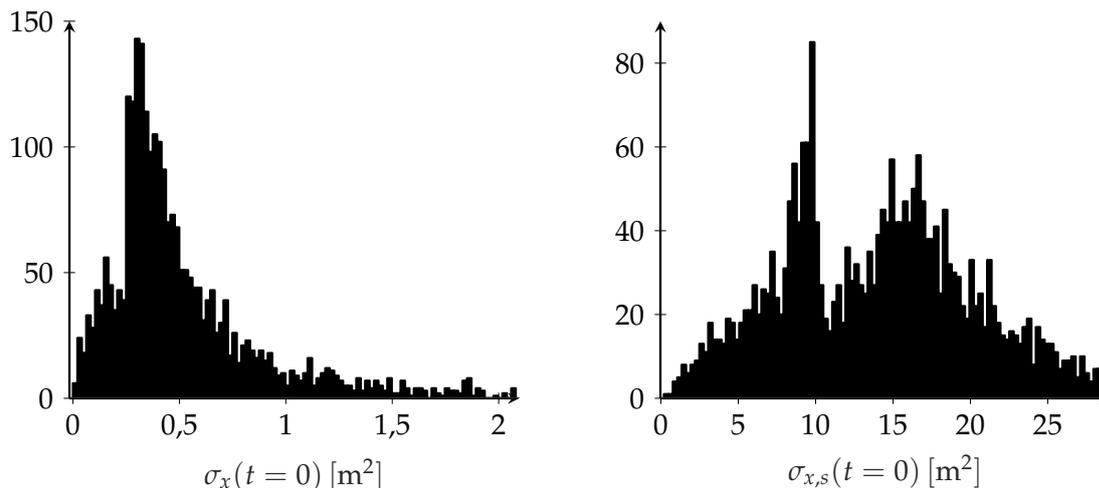


Abbildung 3.3.: Links: Initiale Varianz in x in den aufgenommenen Daten. Rechts: Skalierte initiale Varianz.

folgenden Zyklen wird diese durch Anwendung der Gleichung 3.2.2 unter Berücksichtigung der relativen Position aktualisiert.

Zusätzlich zu der Varianz einer Messung zeigt die radarbasierte Wahrnehmung weitere Effekte, die für die Entwicklung einer Trajektorienprädiktion von Bedeutung sein können. Ein entscheidender Effekt ist die Häufung von Radarreflexionen an bestimmten Punkten auf der Objektoberfläche. Für ein wahrgenommenes Objekt wird nicht der Schwerpunkt als Position bestimmt, sondern ein sich ändernder Punkt auf der Hülle. Ändert sich dieser Punkt von der Rückseite eines Fahrzeugs zu einer der beiden Seiten, ist eine laterale und longitudinale Änderung der wahrgenommenen Position zu beobachten. Dies kann einen bedeutenden Einfluss auf die Vorhersage von Spurwechselmanövern haben, da diese entscheidend von der lateralen Bewegung des Fahrzeugs abhängt (siehe Abschnitt 4). Um den Effekt in der Simulation zu berücksichtigen, wird für jedes Fahrzeug ein Reflexionsmodell mit einer beliebigen Anzahl an Reflexionspunkten erstellt. Ein Beispielmmodell für einen PKW ist in Abbildung 3.4 zu sehen. Die Reflexionspunkte befinden sich an Positionen, an denen die Radarwellen besonders gut reflektiert werden. Dies sind zum einen die Nummernschilder und zum anderen die Radkästen der vier Räder. In der Simulation befindet sich der Radartrack jeweils auf dem Reflexionspunkt mit der minimalen Distanz zum Ego-Fahrzeug. Bei einem Wechsel des Reflexionspunktes wird zwischen den einzelnen Punkten ein fließender Übergang mittels linearer Interpolation generiert.

Kamerabasierte Wahrnehmung

Zusätzlich zu der Wahrnehmung mit Radarsensoren wird ein nach vorne ausgerichteter Kamerasensor in der Simulationsumgebung umgesetzt. Neben der Detektion von Objekten im Sichtbereich der Kamera ist vor allem die Erkennung von Spurmarkierung von entscheidender Bedeutung für die Entwicklung von Algorithmen im Bereich der Trajektorienprädiktion, da diese in Abwesenheit von genauen digitalen Karten und einer entsprechenden Lokalisierung die einzige Information über den Straßenverlauf

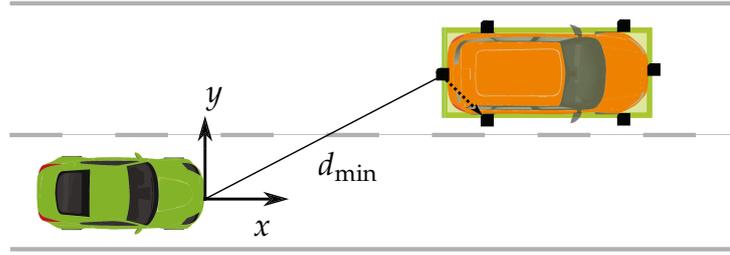


Abbildung 3.4.: Modellierung von Reflexionspunkten auf der Fahrzeugkarosserie, an denen eine gehäufte Reflexion der Radarwellen stattfindet.

darstellen. Hierzu wird für die Kamera ein kegelförmiger Sichtbereich angenommen, der durch die minimale und maximale Sichtweite sowie durch den Öffnungswinkel definiert wird.

Da für die Objektdetektion des vorhandenen Kamerasensors im Testfahrzeug lediglich eine statische Unsicherheit angegeben ist, wird diese in der Simulationsumgebung ebenfalls als statisch angenommen. Der gemessene Zustand eines von der Kamera detektierten Objektes lässt sich mit

$$\mathbf{x}_C^{(k)}(t_n) \sim \mathcal{N}\left(\boldsymbol{\mu}_C^{(k)}(t_n), \boldsymbol{\Sigma}_C^{(k)}(t_n)\right), \boldsymbol{\mu}_C^{(k)}(t_n) = \begin{bmatrix} x \\ y \\ v_x \\ v_y \end{bmatrix}, \boldsymbol{\Sigma}_C^{(k)}(t_n) = \begin{bmatrix} \sigma_x & 0 & 0 & 0 \\ & \sigma_y & 0 & 0 \\ & & \text{Sym.} & \sigma_{v_x} \\ & & & \sigma_{v_y} \end{bmatrix} \quad (3.2.8)$$

beschreiben. Der Übersicht halber wird in Gleichung (3.2.8) auf die Darstellung der Zeitabhängigkeit verzichtet. Die Varianzen der einzelnen Zustände werden als konstant angenommen². Zusätzlich zum Zustand können mit einem Kamerasensor die Breite und Länge des detektierten Objekts bestimmt werden.

Um eine kompakte, parametrische Beschreibung der Spurmarkierungen zu erhalten, wird häufig ein Polynom dritter Ordnung verwendet (siehe zum Beispiel [Fat+14]). Für die Detektion werden die Koeffizienten des Polynoms dritter Ordnung auf Basis aller Punkte der Spurmarkierung, die sich innerhalb des Sichtbereichs der Kamera befinden, mittels einer gewichteten Schätzung mit der Methode der kleinsten Quadrate bestimmt. In diesem Zusammenhang werden Punkte mit steigender Distanz zum Ego-Fahrzeug schwächer gewichtet, um eine gute Übereinstimmung der berechneten mit der tatsächlichen Spurmarkierung in der direkten Umgebung des Fahrzeugs zu erhalten. Da neben Objekten auch Teile der Spurmarkierung von anderen Simulationsobjekten verdeckt sein können, ist das bestimmte Polynom jeweils nur für einen begrenzten Bereich gültig. Insgesamt kann die simulierte Kamera vier Spurmarkierungen detektieren; die rechte und linke Markierung der Ego-Spur sowie die linke Markierung der linken und die rechte Markierung der rechten Nachbarspur.

²Die Werte werden aus der Masterarbeit von Manuel Schmidt mit dem Titel „Online-Kalibrierung eines Kamerasystems in Straßenverkehrsszenarien zur Validierung automatisierter Fahrfunktionen“ übernommen.

Sensorfusion

Die Schnittstelle zwischen der Simulationsumgebung und der Situationsanalyse ist ein vollständiges Umgebungsmodell auf Basis aller verfügbaren Sensorinformationen. Dazu müssen die Messungen der simulierten Radarsensoren und der Kamera zu einem kombinierten Objekt zusammengefasst werden. Für jedes Objekt im Sichtbereich der Sensoren wird ein Kalman Filter (siehe [Kal60]) erstellt, das Objekte über die Zeit verfolgt und Messungen unterschiedlicher Sensoren für ein Objekt zu einem gemeinsamen Zustandsvektor $\mathbf{x}^{(k)}(t_n) = [x(t_n), y(t_n), v_x(t_n), v_y(t_n)]^T$ fusioniert. Für das Bewegungsmodell wird eine konstante Geschwindigkeit und Orientierung mit der Systemmatrix \mathbf{A}_{CV}

$$\mathbf{A}_{CV} = \begin{bmatrix} 1 & 0 & \Delta T & 0 \\ 0 & 1 & 0 & \Delta T \\ 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 1 \end{bmatrix} \quad (3.2.9)$$

angenommen. Da der Zustand vom Kamerasensor direkt gemessen wird, ergibt sich die Beobachtungsmatrix als Einheitsmatrix. Die Radarmessungen liegen zunächst als Winkel und absolute Geschwindigkeit vor und werden mit Hilfe der *Unscented Transformation* [Uhl95] in die gleiche Form umgewandelt. Anschließend kann der Zustand eines Objekts im Sichtbereich der Sensoren mit Hilfe der Kalman Filter Gleichungen geschätzt werden. Für ein sowohl von den Radarsensoren als auch von der Kamera wahrgenommenes Objekt, wird der Korrekturschritt des Filters für beide Messungen durchgeführt. Die Zuordnung einer Messung zu einem Objekt wird als bekannt angenommen.

3.3. Objekte in der Simulationsumgebung

Neben der Wahrnehmung von Objekten und der Umgebung ist für die Entwicklung einer Trajektorienprädiktion vor allem eine realistische Bewegung und ein nachvollziehbares Verhalten der anderen Verkehrsteilnehmer von großer Bedeutung. Da in der Anwendung die Trajektorien von menschlichen Fahrern prädiziert werden sollen, ist ein annähernd menschliches Verhalten wünschenswert. Um die Funktion außerdem in vielen möglichen Szenarien zu gewährleisten, müssen diese in der Simulationsumgebung zur Verfügung stehen. Dabei sind insbesondere verschiedene Fahrertypen notwendig, die in Fahrsituationen unterschiedliche Entscheidungen treffen, um Robustheit gegenüber variierenden menschlichen Verhaltensweisen zu erreichen. Im Folgenden werden zunächst die in der Simulationsumgebung enthaltenen Fahrzeugmodelle vorgestellt. Anschließend wird dargelegt, welche Fahrermodelle verwendet werden, um ein menschliches und damit stochastisches Verhalten der Fahrzeuge zu erzeugen. Schließlich wird auf die Umsetzung einer stochastischen Manöverausführung eingegangen.

Fahrzeugmodelle

Bei der vorgestellten Simulationsumgebung handelt es sich um eine mikroskopische Simulation. Daher wird jeder Verkehrsteilnehmer als einzelne Instanz mit einem separaten Fahrer- und Bewegungsmodell aufgefasst. Für alle Verkehrsteilnehmer wird ein Punktmasse-Modell eingesetzt, da eine fahrdynamisch exakte Bewegung nicht erforderlich ist. Das verwendete Punktmasse-Modell ist mathematisch definiert durch

$$\mathbf{x}^{(k)}(t_{n+1}) = \mathbf{A}_{CV}\mathbf{x}^{(k)}(t_n) + \begin{bmatrix} \frac{\Delta T^2}{2} & 0 \\ 0 & \frac{\Delta T^2}{2} \\ \Delta T & 0 \\ 0 & \Delta T \end{bmatrix} \begin{bmatrix} a_x^{(k)}(t_n) \\ a_y^{(k)}(t_n) \end{bmatrix}, \quad (3.3.1)$$

wobei $a_x^{(k)}(t_n)$ und $a_y^{(k)}(t_n)$ jeweils die longitudinale und laterale Beschleunigung von Objekt k darstellen.

Zusätzlich werden für Fremdfahrzeuge neben Personenkraftwagen mit unterschiedlichen Abmessungen ebenfalls einige Lastkraftwagentypen zur Verfügung gestellt. Diese unterscheiden sich zum einen in der Größe des Objekts und zum anderen in der Anzahl und Anordnung der Radar-Reflexpunkte, die in Abschnitt 3.2 beschrieben sind.

Fahrermodelle

Um ein nachvollziehbares Verhalten einzelner Verkehrsteilnehmer zu erreichen, müssen geeignete Stellgrößen für das Bewegungsmodell in (3.3.1) bestimmt werden. Die Fahrzeuge müssen dabei sowohl miteinander interagieren als auch auf Fahrmanöver des Ego-Fahrzeugs reagieren können. Um dies zu erreichen, werden aus mikroskopischen Simulationen bekannte Fahrermodelle zur Bestimmung der longitudinalen Beschleunigung $a_x^{(k)}(t_n)$ und des lateralen Manövers $m^{(k)}(t_n)$ verwendet. Auf Basis des lateralen Manövers wird anschließend ein Pfad und die laterale Beschleunigung $a_y^{(k)}(t_n)$ bestimmt.

Als longitudinales Fahrermodell wird in der vorgestellten Simulationsumgebung das *Intelligent Driver Model* (IDM) aus [Tre+00] verwendet, welches die Beschleunigung eines Fahrzeugs sowohl abhängig von der Wunschgeschwindigkeit als auch von der aktuellen Verkehrssituation bestimmt. Die Interaktion zwischen zwei Fahrzeugen beeinflusst somit direkt die gestellte Beschleunigung eines Verkehrsteilnehmers. Mathematisch besteht das IDM aus zwei Termen, die diese zwei Komponenten beschreiben:

$$a_x^{(k)}(t_n) = \underbrace{a_{\max}^{(k)} \left[1 - \left(\frac{v_x^{(k)}(t_n)}{v_{\text{des}}^{(k)}} \right)^\delta \right]}_{\text{Freie Fahrt}} - \underbrace{a_{\max}^{(k)} \left(\frac{s^*(v_x^{(k)}(t_n), \Delta v_x^{(k)}(t_n))}{s^{(k)}(t_n)} \right)^2}_{\text{Interaktion}}. \quad (3.3.2)$$

Dabei beschreibt der erste Teil die Beschleunigung auf die Wunschgeschwindigkeit, wenn kein langsames Führungsfahrzeug vorhanden ist. Der zweite Teil bewirkt eine Verzögerung, sobald der Abstand zum Führungsfahrzeug $s^{(k)}(t_n)$ nicht mehr signifikant größer ist als der angestrebte effektive Abstand $s^*(v_x^{(k)}(t_n), \Delta v_x^{(k)}(t_n))$. Hierbei

Tabelle 3.1.: Standard Parameter des *Intelligent Driver Models*.

| Parameter | $a_{\max}^{(k)}$ | $b^{(k)}$ | $s_0^{(k)}$ | $T_H^{(k)}$ | δ |
|-----------|----------------------|--------------------|-------------|-------------|----------|
| Wert | 1,4 m/s ² | 2 m/s ² | 2 m | 1 s | 4 |

beschreibt $\Delta v_x^{(k)}(t_n)$ die relative Geschwindigkeit zum Führungsfahrzeug. Im ersten Fall wird das Verhalten des Fahrzeugs stark von der definierten Wunschgeschwindigkeit $v_{\text{des}}^{(k)}$ beeinflusst. Außerdem haben die maximale Beschleunigung $a_{\max}^{(k)}$ und der Parameter δ Einfluss auf die Beschleunigung. Parameter δ skaliert die Verringerung der Beschleunigung je näher sich die tatsächliche Geschwindigkeit der Wunschgeschwindigkeit annähert. Sobald ein langsames Führungsfahrzeug existiert, steigt der Einfluss des zweiten Teils von Gleichung (3.3.2). Dabei ist der effektive Abstand definiert durch

$$s^*(v_x^{(k)}(t_n), \Delta v_x^{(k)}(t_n)) = s_0^{(k)} + v_x^{(k)}(t_n)T_H^{(k)} + \frac{v_x^{(k)}(t_n)\Delta v_x^{(k)}(t_n)}{2\sqrt{a_{\max}^{(k)}b^{(k)}}}, \quad (3.3.3)$$

wobei $s_0^{(k)}$ den Mindestabstand bei kleinen Geschwindigkeiten und $T_H^{(k)}$ den minimalen zeitlichen Abstand beschreibt. Der letzte Teil von Gleichung (3.3.3) ändert den angestrebten Abstand für $\Delta v_x^{(k)}(t_n) \neq 0$, wobei $b^{(k)}$ eine komfortable Verzögerung definiert. Damit bremst das Fahrzeug in den meisten Situationen mit einer moderaten Verzögerung. Das Modell ist zu jeder Zeit kollisionsfrei, da die Beschleunigung nicht begrenzt wird (siehe [Tre+00]).

Um ein stochastisches Verhalten der Verkehrsteilnehmer zu erhalten, kann jedes Fahrzeug innerhalb der Simulationsumgebung einzeln parametrisiert werden. Die Parameter des IDM können als Verteilungen definiert werden, sodass Fahrzeuge für jede Ausführung der Simulation variierende Parameter erhalten. Da die Simulationsumgebung für Autobahnszenarien ausgelegt wird, sind die relevanten Parameter zum einen die Wunschgeschwindigkeit und zum anderen der minimale zeitliche Abstand zum Führungsfahrzeug für Folgefahrten. Eine mögliche Parametrierung des IDMs ist zum Beispiel in [Kes+10] sowie [Sch+12] zu finden und ist in Tabelle 3.1 dargestellt. Die Wunschgeschwindigkeit wird für jedes Fahrzeug individuell konfiguriert.

Das laterale Fahrermodell wählt in jedem Simulationsschritt ein Manöver aus einer Menge von möglichen Manövern \mathcal{M}_{Sim} . Für die Simulation von Autobahnszenarien ist die Menge auf die Basismanöver Spurwechsel nach links (LCL), Spurhalten (LK) sowie Spurwechsel nach rechts (LCR) beschränkt. Alle komplexeren Fahrmanöver, wie zum Beispiel Überhol- und Einfädelvorgänge, können aus den Basismanövern zusammengesetzt werden. Entsprechend gilt für die vorgestellte Simulationsumgebung $\mathcal{M}_{\text{Sim}} = \{\text{LCL}, \text{LK}, \text{LCR}\}$. Weitere Anforderungen ergeben sich aus der deutschen Straßenverkehrsordnung (StVO). So sind auf Autobahnen nach §5 StVO Überholvorgänge nur auf der linken Seite erlaubt. Außerdem muss bei mehreren Fahrstreifen der rechte genutzt werden, sobald die Verkehrsdichte es zulässt (§2 und §7 StVO).

Um dieses Verhalten für alle Verkehrsteilnehmer zu erzeugen, wird ein zweistufiges laterales Fahrermodell eingesetzt (siehe [Wis+17a]). Zunächst wird anhand eines Ent-

scheidungsbaumes überprüft, ob ein Spurwechsel in der aktuellen Verkehrssituation notwendig oder wünschenswert ist. Anschließend wird der zur Verfügung stehende Platz auf der Zielspur hinsichtlich eines sicheren Spurwechsels ausgewertet. Es wird zwischen einem notwendigen Spurwechsel und einem wünschenswerten Spurwechsel unterschieden, wobei im ersten Fall die Fahrt auf der aktuellen Spur nicht weiter möglich ist und im zweiten ein Spurwechsel lediglich die Fahrsituation verbessert. Für die Entscheidungsfindung wird zunächst überprüft, ob die Spur des Fahrzeugs innerhalb einer bestimmten Distanz endet oder ein stehendes Hindernis die Spur blockiert. Sobald sich ein Fahrzeug mit der aktuellen Geschwindigkeit nur noch für kurze Zeit auf der Spur fortbewegen kann, wird ein notwendiger Spurwechsel eingeleitet. Andernfalls wird überprüft, ob ein langsames Führungsfahrzeug die Fahrt mit der Wunschgeschwindigkeit verhindert. Um einen Überholvorgang mit sehr kleinen Geschwindigkeitsdifferenzen zu verhindern, muss ein zusätzlicher Schwellwert überschritten werden, um einen wünschenswerten Spurwechsel nach links anzustreben. Abschließend wird das Rechtsfahrgebot umgesetzt, wenn eine ungehinderte Fahrt auf der rechten Spur möglich ist.

Bevor der eigentliche Spurwechsel umgesetzt werden kann, muss überprüft werden, ob die erforderliche Lücke auf der Zielspur vorhanden ist. Die benötigte Lücke hängt dabei von der relativen Geschwindigkeit zum Führungs- und Folgefahrzeug sowie von der Geschwindigkeit des eigenen Fahrzeugs ab. Dabei wird für höhere Geschwindigkeiten sowie für große Relativgeschwindigkeiten eine größere Lücke benötigt. Für einen notwendigen Spurwechsel wird die erforderliche Lückengröße zusätzlich mit einem Faktor skaliert, sodass im Falle eines dringenden Spurwechsels kleine Lücken akzeptiert werden. Eine detaillierte Beschreibung des Spurwechselmodells, die mathematische Definition der erforderlichen Lücken und der Parameter ist im Anhang A.2 aufgeführt. Die Parameter können für jedes Fahrzeug individuell festgelegt oder aus einer vorab konfigurierten Verteilung gezogen werden, sodass ein stochastisches Verhalten der Verkehrsteilnehmer erzeugt wird.

Manöverausführung

Das Resultat des lateralen Fahrermodells ist ein Manöver $m^{(k)}(t_n) \in \mathcal{M}_{Sim}$ zum Zeitpunkt t_n . Um ein realistisches Verhalten der simulierten Verkehrsteilnehmer zu erzeugen, sollte die Ausführung eines Manövers variieren. In der Simulationsumgebung wird dazu zunächst auf Basis des Manövers ein Pfad entlang der Straßentopologie generiert $\mathcal{C}_{\mathbf{p}_m^{(k)}} = \{(l_0, n_0), (l_1, n_1), \dots, (l_{n_p}, n_{n_p})\}$ der Länge $n_p \in \mathbb{N}_+$. Dieser wird anschließend mit einer Stichprobe aus einem Zufallsprozess überlagert, um eine stochastische Abweichung vom Pfad und somit eine leicht veränderte Manöverausführung zu generieren.

Für die Generierung des Basispfads $\mathcal{C}_{\mathbf{p}_m^{(k)}}$ an den Stützstellen $i \in [0, n_p]$ wird ein Polynom dritter Ordnung im Frenet-Serret Koordinatensystem entlang der Straße verwendet. Die Polynomkoeffizienten lassen sich über den aktuellen Zustand als Startbedingung und die Position auf der Zielspur mit Orientierung entlang der Spur als Endbedingung eindeutig bestimmen. Die Zielspur variiert mit dem vom lateralen

Fahrermodell bestimmten Manöver, sodass sich für die laterale Komponente

$$\mathbf{n}_i = c_{m,3}l_i^3 + c_{m,2}l_i^2 + c_{m,1}l_i + c_{m,0} \quad (3.3.4)$$

ergibt. Die Parameter $\{c_{m,0}, c_{m,1}, c_{m,2}, c_{m,3}\}$ beschreiben die Koeffizienten des Polynoms. Dem lateralen Anteil des Basispfads wird eine Stichprobe $\xi_{GP,m}$ aus einem Gauß Prozess überlagert.

Ein Gauß Prozess \mathcal{GP} ist definiert als eine Menge aus Zufallsvariablen, bei der jede beliebige endliche Teilmenge mehrdimensional normalverteilt ist. Er ist vollständig definiert über eine Mittelwertfunktion $m(\mathbf{x})$ und eine Kovarianzfunktion $k(\mathbf{x}, \mathbf{x}')$ für die Zustände $\mathbf{x}, \mathbf{x}' \in \mathbb{R}^4$. Ein Gauß Prozess $f(\mathbf{x}) \propto \mathcal{GP}(m(\mathbf{x}), k(\mathbf{x}, \mathbf{x}'))$ kann somit als Verallgemeinerung einer Normalverteilung für einen unendlich-dimensionalen Raum gesehen werden. Für eine ausführliche Definition wird auf [RW05] verwiesen.

In dem vorliegenden Anwendungsfall repräsentiert der Gauß Prozess die Abweichung von dem Basismanöverpfad in lateraler Richtung, sodass der Erwartungswert der modellierten Verteilung Null ist. Entsprechend gilt für die Mittelwertfunktion

$$m(\mathbf{x}) = 0. \quad (3.3.5)$$

Über die Kovarianzfunktion wird die Änderung der Abweichung entlang der longitudinalen Komponente gesteuert. Diese sollte sich einerseits nicht abrupt ändern, andererseits gewisse Änderungen während der Ausführung des Manövers zulassen. Bei menschlichen Fahrern lässt sich häufig eine Schwankung um die Spurmitte mit unterschiedlichen Frequenzen und Amplituden beobachten. Um dies abzubilden, wird als Kovarianzfunktion eine Summe aus $n_{GP} \in \mathbb{N}_+$ quadratischen Exponentialfunktionen gewählt:

$$k(\mathbf{x}, \mathbf{x}') = \sum_{i=1}^{n_{GP}} s_{f,i}^2 \exp\left(\frac{-(\mathbf{x} - \mathbf{x}')^2}{2l_i^2}\right). \quad (3.3.6)$$

Hierbei ist $s_{f,i}$ die Standardabweichung der Funktion, die von der i -ten Komponente erzeugt wird. l_i beschreibt, wie stark der Zustand \mathbf{x}' die Varianz am Zustand \mathbf{x} beeinflusst. Somit ergeben sich für den Gauß Prozess die so genannten Hyper-Parameter $\theta_H = \{s_{f,1}, l_1, s_{f,2}, l_2, \dots, s_{f,n_{GP}}, l_{n_{GP}}\}$. Diese bestimmen maßgeblich den Verlauf einer Stichprobe und sind von zentraler Bedeutung für die Generierung realistischer Abweichungen vom Basismanöver. Um die Hyper-Parameter zu bestimmen, werden daher mit einem Testfahrzeug aufgenommene Daten herangezogen. Hierbei wird zwischen den Manövern Spurwechsel und Spurhalten unterschieden, sodass zwei Parametersätze $\theta_{H,LC}$ und $\theta_{H,LK}$ identifiziert werden. Die aufgenommenen Trajektorien werden mit einem Mittelwertfilter geglättet, um Einflüsse durch Messungenauigkeiten zu minimieren. Für Spurhalte-Manöver wird von beobachteten Fahrzeugen die laterale Abweichung über die Zeit extrahiert und mittels Gauß Prozess mit $n_{GP} = 2$ modelliert. Die optimalen Hyper-Parameter lassen sich durch Maximierung der logarithmischen marginalen Likelihood bestimmen (siehe hierzu auch [RW05]). Für Spurwechsel-Manöver wird ebenfalls $n_{GP} = 2$ gewählt. Allerdings wird zunächst ein Polynom dritter Ordnung auf Basis des Start- und Endpunktes der Trajektorie bestimmt, um den Basispfad des Manövers abzubilden. Anschließend wird die laterale Abweichung zu diesem

Tabelle 3.2.: \mathcal{GP} Hyper-Parameter nach der Maximierung der logarithmischen marginalen Wahrscheinlichkeit.

| | l_1 | $s_{f,1}$ | l_2 | $s_{f,2}$ |
|-------------|----------|-----------|---------|-----------|
| Spurwechsel | 199,99 m | 0,01 m | 46,77 m | 0,46 m |
| Spurhalten | 1881,5 m | 0,30 m | 97,81 m | 0,34 m |

analog zum Spurhaltenmanöver mittels Gauß Prozess modelliert. Sobald die optimalen Parameter gefunden sind, kann mittels des Gauß Prozesses eine Stichprobe $\xi_{GP,m}$ generiert und diese dem Basispfad überlagert werden. Die optimalen Parameter, sowohl für Spurwechsel als auch für Spurhaltenmanöver, sind in Tabelle 3.2 dargestellt. Für Spurhaltenmanöver zeigt sich hier eine langsame und eine schnellere Pendelbewegung mit in etwa der gleichen Amplitude um die Spurmitte. Bei Spurwechseln hingegen ergibt sich eine deutliche Abweichung mit hoher Frequenz und eine langsamere mit einer schwachen Amplitude.

So ergibt sich für den finalen Manöverpfad in kurvilinearen Koordinaten

$$\mathbf{c}_m^{(k)} = \mathbf{c}_m + \xi_{GP,m}. \quad (3.3.7)$$

Schließlich wird der generierte Pfad in kartesische Koordinaten transformiert und im Simulationsobjekt abgelegt. Abbildung 3.5 zeigt das Ergebnis der Überlagerung der Basispfade (schwarz) für Spurhalten sowie einen Spurwechsel nach links mit Stichproben aus den entsprechenden Gauß Prozessen (grau). Es lassen sich teilweise deutliche Abweichungen vom Basispfad erkennen, sodass eine Vielzahl von Variationen möglich ist.

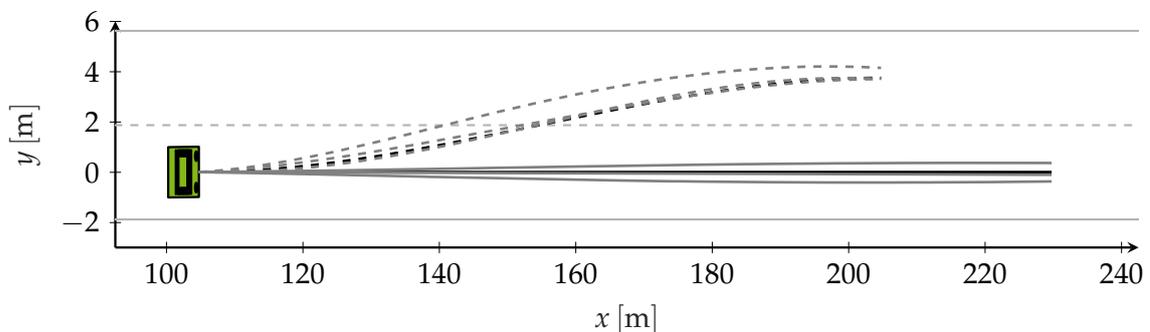


Abbildung 3.5.: Beispielhafte Manöverpfade für Spurhalte- und Spurwechselmanöver. Die schwarzen Linien repräsentieren die Manöverausrührung ohne zusätzliche Überlagerung mit Beispielen des Gauss Prozesses, die grauen Linien zeigen das jeweilige Manöver mit verschiedenen überlagerten Stichproben.

3.4. Bewertung der Simulationsmodelle

Nachdem die Teilbereiche der Simulationsumgebung in den vorherigen Abschnitten beschrieben wurden, wird im Folgenden eine grundlegende Evaluation der implementierten Modelle dargestellt. Dazu wird zunächst eine exemplarische Verkehrssituation gezeigt, in der die Nachvollziehbarkeit der Entscheidungen aller Verkehrsteilnehmer in der Simulationsumgebung gezeigt wird. Außerdem wird auf die Sensorungenauigkeit sowie die modellierten Effekte verschiedener Sensoren und den daraus resultierenden Qualitätsverlusten des Umgebungsmodells eingegangen. Anschließend werden einige fahrdynamische Größen des Ego-Fahrzeugs aus der Simulation aufgenommen und den Daten aus dem Versuchsfahrzeug gegenübergestellt. Abgesehen von den gemessenen dynamischen Größen sind für die Trajektorienprädiktion vor allem Merkmale, die für die Klassifikation von Fahrmanövern genutzt werden (siehe Abschnitt 4.2), von Bedeutung. Daher werden die in der Simulation generierten Daten bezüglich dieser Merkmale ebenfalls evaluiert.

Exemplarische Simulation einer Verkehrssituation

Zur Visualisierung und Plausibilisierung einzelner Teilbereiche der Simulation wird ein Szenario mit einer Autobahnauffahrt dargestellt (siehe Abbildung 3.6). Dabei ist die Entwicklung der Situation von oben nach unten fortschreitend dargestellt. Das Ego-Fahrzeug (N_0) startet auf der Auffahrt einer dreispurigen Autobahn mit einer Geschwindigkeit von etwa 88 km/h bei $t = 0$ s. Gleichzeitig befinden sich zwei weitere Fahrzeuge auf der Auffahrt (N_1, N_4). Die hervorgehobenen schwarzen Linien vor dem Ego-Fahrzeug repräsentieren die wahrgenommenen Spurmarkierungen. Diese werden von der Sichtweite der simulierten Kamera beeinflusst und können gleichzeitig durch Objekte innerhalb der Situation verdeckt sein. Im ersten Zeitschritt wird unmittelbar ein Nachteil der Repräsentation der Spurmarkierungen als Polynom dritter Ordnung ersichtlich. Am Ende des Sichtbereiches weicht das Modell der Spurmarkierungen von der eigentlichen Markierung deutlich ab. Dies ist durch die begrenzten Freiheitsgrade des Modells zu erklären und kann bei der Kamera im Testfahrzeug ebenfalls beobachtet werden. Im zweiten Zeitschritt ($t = 3$ s) ist das Ego-Fahrzeug bereits auf der Beschleunigungsspur und hat die Geschwindigkeit leicht erhöht. Das Fahrzeug N_1 führt einen Spurwechsel durch, um auf die Autobahn aufzufahren und auf seine Wunschgeschwindigkeit zu beschleunigen. Außerdem ist die unterschiedliche Sichtweite für die einzelnen Spurmarkierungen zu erkennen, die durch Fahrzeug N_4 verursacht wird. Zum darauffolgenden Zeitpunkt ist das Ego-Fahrzeug auf der Auffahrt, sodass ein Spurwechsel auf die rechte Spur der Autobahn notwendig ist. Das Fahrzeug N_5 , welches sich zum Zeitpunkt $t = 3$ s noch auf der rechten Spur befindet, hat zu diesem Zeitpunkt bereits einen Spurwechsel nach links durchgeführt, um das auffahrende Fahrzeug N_4 zu überholen und so seine Geschwindigkeit beizubehalten. Die Simulationsumgebung bildet damit ein häufig beobachtetes Phänomen an Autobahnauffahrten ab, bei dem Fahrzeuge auf freie Spuren wechseln, um ausreichend Platz auf der rechten Spur zu generieren. Daher ist die rechte Spur frei und das Ego-Fahrzeug kann den Spurwechsel nach links ausführen. Bei $t = 9$ s hat das

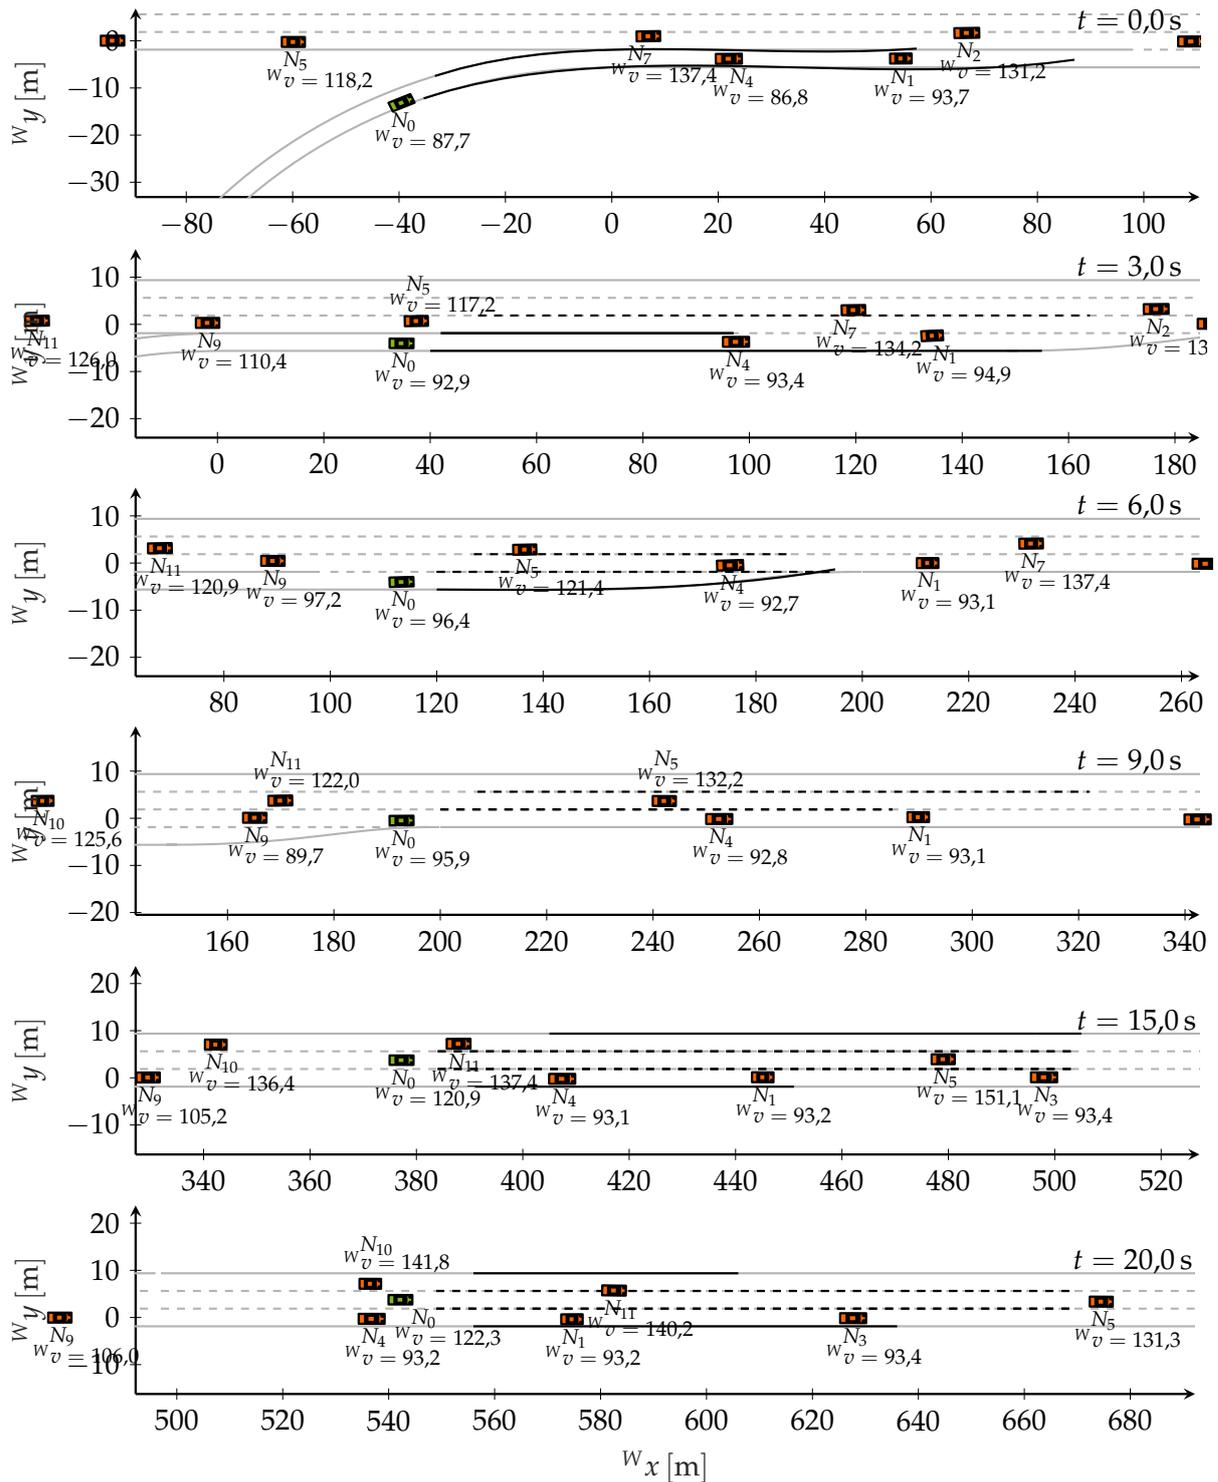


Abbildung 3.6.: Beispielhaftes Szenario innerhalb der entwickelten Simulationsumgebung. Zu Beginn fährt das Ego-Fahrzeug (N_0) zusammen mit zwei weiteren Fahrzeugen (N_1, N_4) auf einer Auffahrt zu einer dreispurigen Autobahn ($t = 0$ s). Die zeitliche Entwicklung der Situation ist von oben nach unten fortschreitend dargestellt. Im weiteren Verlauf fährt das Ego-Fahrzeug auf die Autobahn auf und führt einige Überholmanöver aus, um die vorab definierte Wunschgeschwindigkeit von 130 km/h zu erreichen. Alle Geschwindigkeiten sind in Kilometer pro Stunde angegeben.

Ego-Fahrzeug das Manöver abgeschlossen und versucht die eigene Wunschgeschwindigkeit zu erreichen. Aufgrund des langsamen Führungsfahrzeugs N_4 in der rechten Spur ist ein weiterer Spurwechsel notwendig, welcher das schnellere Folgefahrzeug auf der mittleren Spur N_{11} ebenfalls zu einem Spurwechsel nach links zwingt. In den darauffolgenden Zeitschritten kann das Ego-Fahrzeug weiter beschleunigen und damit das Fahrzeug N_4 überholen. Gleichzeitig schließt N_{11} das Überholmanöver mit einem Spurwechsel nach rechts auf die mittlere Spur ab und setzt damit das Rechtsfahrgebot um. In den unteren beiden Abbildungen wird außerdem die Darstellung des Umgebungsmodells mit maximal vier Spurmarkierungen deutlich, die von der verwendeten Kamera erfasst werden können.

Anhand der Beispielsituation ist die Vielseitigkeit der Simulationsumgebung zu erkennen. Dabei muss keine der Trajektorien für einzelne Verkehrsteilnehmer vorgegeben werden. Gleichzeitig ist es möglich durch Variation der Parameter der Fahrermodelle, die in Abschnitt 3.3 beschrieben wurden, unterschiedliche Entwicklungen einer Situation mit identischen Startwerten zu erzeugen. So kann zum Beispiel dasselbe Szenario mit einer höheren Verkehrsdichte oder mit Fahrzeugen mit größerer Differenzgeschwindigkeit auf der rechten Fahrspur simuliert werden. Durch die verwendeten Fahrermodelle ergibt sich in jedem Fall ein nachvollziehbares Fahrverhalten.

Zusätzlich verdeutlicht das gezeigte Szenario qualitativ, welche Sensoreigenschaften in der Simulation abgebildet sind. Hierbei ist vor allem der Einfluss der Verdeckung entscheidend, da in diesem Fall aus den Sensordaten lediglich ein unvollständiges Umgebungsmodell erzeugt werden kann. Dieses hat entscheidenden Einfluss auf die Güte aller vorgestellter Verfahren zur Trajektorienprädiktion, wie in Kapitel 5, 7 und 8 dargestellt wird.

Statistische Auswertung

Neben der qualitativen Evaluierung anhand einer Beispielsituation werden im Folgenden in der Simulation erzeugte Stichproben von einzelnen Variablen mit aufgenommenen Daten aus dem Versuchsfahrzeug verglichen. Zunächst werden auftretende longitudinale Beschleunigungen in verschiedenen Autobahnszenarien ausgewertet. Um einen Vergleich zu ermöglichen, werden in der Simulationsumgebung Szenarien mit verschiedenen Krümmungsradien, sowie unterschiedlichen Verkehrsdichten erzeugt. Werden die empirischen Verteilungsdichten der longitudinalen Beschleunigungen a_{long} in Abbildung 3.7 für die Daten, die mit dem Versuchsfahrzeug aufgenommen wurden $\tilde{p}(a_{\text{long, real}})$ (schwarz), mit den in der Simulation erzeugten Beispielen $\tilde{p}(a_{\text{long, sim}})$ (grau) verglichen, zeigt sich eine gute Übereinstimmung. Beide Verteilungen liegen im Intervall von $a_{\text{long}} \in [-2 \text{ m/s}^2, 2 \text{ m/s}^2]$ und somit in einem sowohl für den Fahrer als auch den Beifahrer [WM41] als komfortabel wahrgenommenen Bereich. Außerdem ergibt sich in beiden Fällen eine große Anzahl von betragsmäßig sehr kleinen Beschleunigungen ($|a_{\text{long}}| < 0,03 \text{ m/s}^2$). Dies lässt sich durch die erreichte Wunschgeschwindigkeit erklären, bei der eine zusätzliche Beschleunigung oder Verzögerung nicht notwendig ist, solange die Verkehrssituation es nicht erfordert. Ein menschlicher Fahrer akzeptiert dabei allerdings leichte Abweichungen von der Wunschgeschwindigkeit, ohne diese unmittelbar anzupassen, sodass im Vergleich

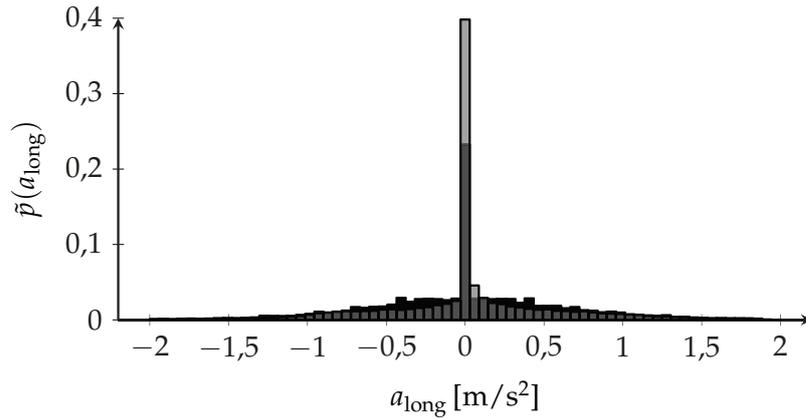


Abbildung 3.7.: Vergleich von longitudinalen Beschleunigungen in Daten aus dem Versuchsfahrzeug (schwarz) und simulierten Daten (grau).

größere Beschleunigungen notwendig sind, um die Zielgeschwindigkeit wieder zu erreichen. In der Simulationsumgebung wird eine vorgegebene Wunschgeschwindigkeit, insofern möglich, jederzeit mit nur kleinen Abweichungen erreicht, sodass die relative Häufigkeit der kleinen Beschleunigungen in diesen Daten etwas höher ist. Generell kann eine gute Übereinstimmung zwischen beiden Verteilungen beobachtet werden, die sich auch in einer geringen Kullback-Leibler (KL) Divergenz widerspiegelt. Die Kullback-Leibler Divergenz $D_{\text{KL}}(\tilde{p}||\tilde{q})$ ist ein Maß dafür, wie stark sich eine diskrete Verteilungsfunktion \tilde{p} von einer anderen \tilde{q} unterscheidet [Mac03] und ist definiert als

$$D_{\text{KL}}(\tilde{p}||\tilde{q}) = \sum_x \tilde{p}(x) \log \frac{\tilde{p}(x)}{\tilde{q}(x)}. \quad (3.4.1)$$

Bei identischen Verteilungsfunktionen ergibt sich eine KL Divergenz von $D_{\text{KL}}(\tilde{p}||\tilde{q}) = 0$. Für die longitudinale Beschleunigung zeigt sich eine gute Übereinstimmung der beiden Verteilungen $D_{\text{KL}}(\tilde{p}(a_{\text{long, sim}})||\tilde{p}(a_{\text{long, real}})) = 0,167$.

Zusätzlich zu der longitudinalen Beschleunigung werden die auftretenden Gierraten sowie die daraus resultierenden lateralen Beschleunigungen aus der Simulation mit aufgenommenen Daten verglichen. Es wird vor allem die Auswirkung der Überlagerung der Fahrzeugbewegungen mit Stichproben aus den Gauß Prozessen (siehe Abschnitt 3.3) auf die erzeugten Daten betrachtet. Die empirischen Wahrscheinlichkeitsdichtefunktionen der Gierrate $\dot{\psi}$ sowie der lateralen Beschleunigung a_{lat} des Ego-Fahrzeugs sind in Abbildung 3.8 zu sehen. Auf der linken Seite sind jeweils die in der Simulation aufgenommenen Daten ohne und auf der rechten Seite mit einer zusätzlichen Überlagerung des Gauß Prozesses dargestellt. In allen Abbildungen ist die Verteilungsdichte der aufgenommenen Daten in schwarz hinterlegt. Die Dichte der Gierrate ohne Überlagerung weist einige Häufungen bei diskreten Werten aus, die sich aus der Krümmung der generierten Szenarien ergeben. Da die Fahrzeuge exakt der Spurmitte ohne weitere Abweichungen folgen, ergibt sich bei einer konstanten Krümmung eine konstante Gierrate während des Szenarios. Im Gegensatz dazu sind diese Häufungen bei der Überlagerung mit Stichproben eines Gauß Prozesses nicht deutlich zu erkennen, da eine zusätzliche laterale Bewegung aufgeprägt wird. So ergibt sich eine deutlich größere Ähnlichkeit der Verteilungsfunktionen von simulierten

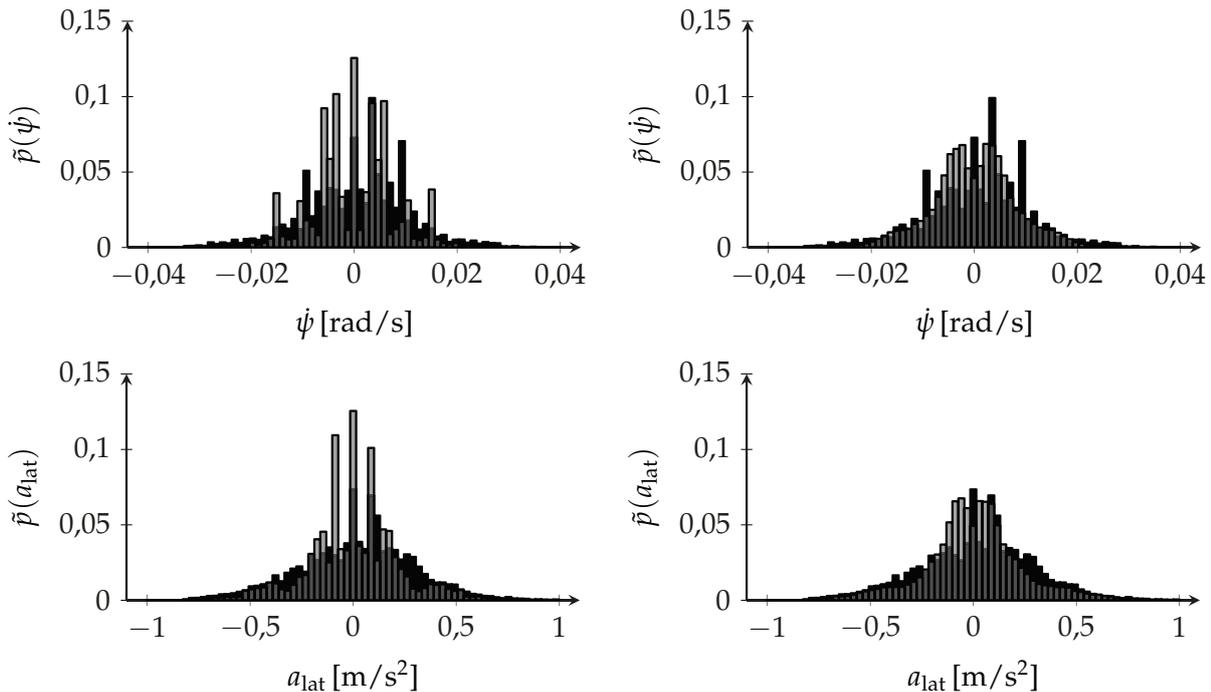


Abbildung 3.8.: Diskrete Verteilungen der Gierrate und der lateralen Beschleunigung in simulierten Szenarien ohne (links) und mit (rechts) einer Überlagerung mit Stichproben aus einem Gauß Prozess.

und aufgenommenen Daten. Ein ähnliches Verhalten ergibt sich bei der Betrachtung der lateralen Beschleunigung. Die höhere Übereinstimmung mit den Daten aus dem Versuchsfahrzeug spiegeln sich auch in der kleineren KL Divergenz wider, wenn die Überlagerung angewendet wird (siehe Tabelle 3.3).

Weil die Simulationsumgebung maßgeblich für die Entwicklung einer Trajektorienprädiktion eingesetzt wird, ist die Betrachtung von Daten, die in diesem Bereich verwendet werden, von besonderem Interesse. Als Beispiel wird die laterale Abweichung eines beobachteten Fahrzeugs von der Spurmittle verwendet. Die Größe ist eines der entscheidenden Merkmale für die Manöverklassifikation, wie in Abschnitt 4 vorgestellt wird. Ein lateraler Abstand von einer halben Spurbreite bedeutet, dass sich ein Fahrzeug zu gleichen Teilen auf der aktuellen und der Nachbarspur befindet und somit mit großer Wahrscheinlichkeit einen Spurwechsel durchführt. Gleichzeitig treten auch bei dem Halten der aktuellen Fahrspur durch ungenaues Spurfolgen laterale Abweichungen auf. Würde in der Simulationsumgebung ein präzises Spurfolgen umgesetzt werden, unterscheiden sich die erzeugten Beispiele stark von den in der Realität auftretenden Daten, wie es im linken Teil von Abbildung 3.9 zu sehen ist. Die Daten aus der Simulation sind hauptsächlich nahe um Null verteilt, wobei kleine Abweichungen durch gekrümmte Straßen auftreten. Zusätzlich entstehen laterale Abstände von bis zu zwei Metern durch Spurwechsel, die jedoch im Vergleich zu Spurhaltenmanövern deutlich seltener auftreten und damit in der Abbildung nicht zu erkennen sind. Werden die Manöver mit einer zusätzlichen Überlagerung eines Gauß-Prozesses durchgeführt, zeigt sich eine deutlich breitere Verteilung (Abbildung 3.9 rechts), da die Fahrzeuge auch in Spurhaltenmanövern nicht mehr exakt dem Spurverlauf folgen. Der

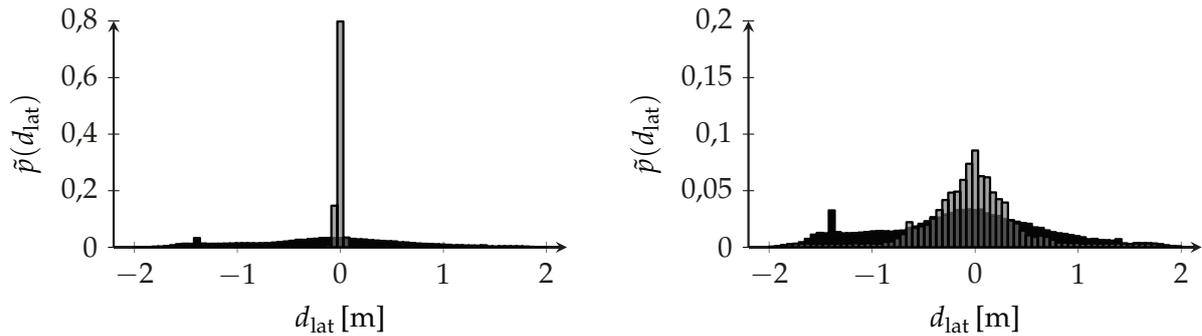


Abbildung 3.9.: Diskrete Verteilung der lateralen Distanz in simulierten Szenarien ohne (links) und mit (rechts) einer Überlagerung mit Stichproben aus einem Gauß Prozess in grau. Zum Vergleich die laterale Distanz in den Daten, die mit dem Versuchsfahrzeug aufgenommen wurden.

Tabelle 3.3.: Kullback-Leibler Divergenz zwischen Verteilungen der Daten aus dem Versuchsfahrzeug und in der Simulation generierten Daten.

| $D_{\text{KL}}(\tilde{p}(x_{\text{sim}}) \tilde{p}(x_{\text{real}}))$ | Ohne Gauß Prozess | Mit Gauß Prozess |
|--|-------------------|------------------|
| ψ | 0,402 | 0,172 |
| a_{lat} | 0,177 | 0,114 |
| d_{lat} | 2,715 | 0,232 |

verbleibende Unterschied zwischen den Daten aus der Simulationsumgebung und aus dem Testfahrzeug resultiert aus fehlerhaften Sensordaten. Für die Berechnung des lateralen Abstandes zur Spurmitte wird der geschätzte Verlauf der Spurmarkierungen verwendet. Da diese nur innerhalb eines sehr begrenzten Bereichs detektiert werden und beobachtete Fahrzeuge sich häufig außerhalb dieses Bereiches befinden, muss die Berechnung auf Basis der extrapolierten Spurmarkierungen durchgeführt werden. Aufgrund der Extrapolationseigenschaften der Spurpolynome entstehen so starke Abweichungen der lateralen Distanz, welche sich in der schwarzen Verteilung in Abbildung 3.9 widerspiegeln. Es lässt sich allerdings sagen, dass die Verteilung der simulierten Daten mit Gauß Prozessen eine größere Ähnlichkeit zu den Daten aus dem Versuchsfahrzeug aufweisen als ohne Gauß Prozess. Dies zeigt auch die entsprechende KL Divergenz der Verteilungen in Tabelle 3.3.

3.5. Zusammenfassung und Diskussion

Die vorgestellte Simulationsumgebung ermöglicht die Simulation von unterschiedlichen Autobahnszenarien und generiert dabei ein Umgebungsmodell, welches für die Entwicklung einer Trajektorienprädiktion eingesetzt werden kann. Dabei wird eine datenbasierte Abbildung der Sensorwahrnehmung und der anschließenden Fusion umgesetzt, die mit einzelnen sensorspezifischen Effekten erweitert wird. Durch den Einsatz von variabel parametrisierten Fahrermodellen können für ein einmalig definiertes Szenario unterschiedliche Entwicklungen der Verkehrssituation generiert werden, sodass ein Algorithmus in einem breiten Feld von Szenarien getestet werden kann.

Es wurde gezeigt, dass die betrachteten dynamischen Größen denen aus einem Versuchsfahrzeug in nicht kritischen Fahrsituationen entsprechen. Um die menschliche Fahrweise besonders lateral zur Spur abzubilden, werden den Fahrmanövern Stichproben aus einem Gauß Prozess überlagert. Die so erzeugten simulierten Daten zeigen eine deutlich bessere Übereinstimmung mit Aufnahmen aus dem Versuchsfahrzeug als ohne diese zusätzliche Überlagerung.

Gleichzeitig bleiben Unterschiede zwischen den simulierten Daten und denen aus dem Testfahrzeug bestehen, sodass eine Funktion, die ausschließlich mit der Simulationsumgebung entwickelt wird, im Testfahrzeug nicht ohne weitere Adaption einsetzbar ist. Dies zeigt sich insbesondere bei der detektierten lateralen Distanz zur Spurmitte, bei der sowohl Fehler in der Positionsschätzung als auch in der Schätzung des Straßenverlaufs einen großen Einfluss haben. Die Simulationsumgebung eignet sich nicht für die Entwicklung von Funktionen im Bereich der Sensorfusion oder die Generierung eines Umgebungsmodells aus Sensordaten, da Effekte einzelner Sensoren vernachlässigt werden und lediglich das Ergebnis einer Fusion modelliert wird. Außerdem ist die Beschreibung der Bewegung des Ego-Fahrzeugs als Punktmasse Modell nicht mehr ausreichend, sobald der Bereich komfortabler Beschleunigungen verlassen wird oder die Regelung des eigenen Fahrzeugs Gegenstand der Untersuchung ist. Für die Entwicklung einer Trajektorienprädiktion ist die Bewegung des Ego-Fahrzeugs nicht relevant, da die Prädiktion der Bewegung beobachteter Fahrzeuge im Fokus steht. Insgesamt erfüllt die vorgestellte Simulationsumgebung alle in Abschnitt A.1.1 definierten Anforderungen und wird somit im Folgenden für die Entwicklung und Bewertung von Algorithmen zur Trajektorienprädiktion verwendet.

4

Manöverklassifikation

In der vorliegenden Arbeit werden drei unterschiedliche Ansätze zur Prädiktion von Trajektorien der Umgebungsfahrzeuge umgesetzt. Dabei basieren zwei der drei Verfahren auf der vorherigen Erkennung des aktuellen Fahrmanövers und zählen daher zu den manöverbasierten Verfahren der Trajektorienprädiktion. Für ein beobachtetes Fahrzeug wird zunächst das wahrscheinlichste Fahrmanöver bestimmt und auf dessen Basis eine Trajektorie prädiziert. Diese Vorgehensweise ist dabei nicht auf die Anwendung in Autobahnscenarien limitiert, sondern lässt sich durch eine Anpassung der zu detektierenden Manöver auf urbane Situationen wie beispielsweise Kreuzungen übertragen. Da sich die vorliegende Arbeit allerdings mit der Trajektorienprädiktion auf Autobahnen befasst, wird im Folgenden ein Verfahren zur Schätzung des aktuellen Fahrmanövers auf Autobahnen vorgestellt.

4.1. Fahrmanövervorhersage auf Autobahnen

Im Allgemeinen ist das Ziel der Manöverdetektion die Vorhersage des aktuellen und zukünftigen Manövers eines Verkehrsteilnehmers, der sich in unmittelbarer Umgebung des Ego-Fahrzeugs befindet, mit größtmöglicher Sicherheit und zu einem frühestmöglichen Zeitpunkt. Dem liegt die Annahme zu Grunde, dass sich die Bewegung eines Fahrzeugs für einen begrenzten Zeitraum in eindeutige Manöverklassen \mathcal{M} unterteilen lässt, von denen zu einem Zeitpunkt t_n jeweils immer nur ein Manöver ausgeführt wird. Autobahnen können generell als strukturierte Umgebungen angesehen werden, in denen sich die laterale Bewegung des k -ten Objektes während der Normalfahrt durch das Manöver

$$m^{(k)}(t_n) \in \mathcal{M} := \{\text{LCL}, \text{LK}, \text{LCR}\} \quad (4.1.1)$$

beschreiben lässt. Dabei steht LCL für einen Spurwechsel nach links, LK für Spurhalten und LCR beschreibt einen Spurwechsel auf die rechte Fahrspur relativ zur aktuellen Spur von Objekt k . Prinzipiell sind auch komplexere Bewegungsmuster wie beispielsweise ein Überholvorgang denkbar. Allerdings können diese aus den hier verwendeten Basismanövern in \mathcal{M} zusammengesetzt werden. Die Absicht des Fahrers ein spezielles Manöver auszuführen, lässt sich im Allgemeinen mit Hilfe von Fahrzeugsensoren nicht beobachten, sodass die Vorhersage des Manövers einer Unsicherheit

laterale Geschwindigkeit relativ zur Spur $v_{\text{lat}}(t_n)$ erreicht bereits zu Beginn des Manövers aussagekräftige Werte und erlaubt so eine frühere Klassifikation. Als drittes objektbasiertes Merkmal wird die longitudinale Geschwindigkeit $v_{\text{long}}(t_n)$ ¹ entlang der Spur hinzugezogen. Da die Merkmale relativ zu der detektierten Spur bestimmt werden, stehen diese nur für Fahrzeuge, die sich vor dem Ego-Fahrzeug befinden zur Verfügung.

Um die Dynamik eines Spurwechsels zu berücksichtigen, wird zusätzlich die Historie der drei beschriebenen Merkmale in den Merkmalsvektor aufgenommen. Dabei werden die Werte zu den Zeitpunkten $t_i \in \{t_n - t_H, t_n - (t_H - \Delta T_H), t_n - (t_H - 2\Delta T_H), \dots, t_n\}$ ausgewertet und für die Klassifikation herangezogen. t_H beschreibt die Länge der zeitlichen Historie und ΔT_H die Zeitdifferenz zwischen zwei aufeinander folgenden Werten. Für jedes verwendete Merkmal entsteht so ein aggregierter Vektor, der die Merkmalswerte der vergangenen Zeitpunkte enthält

$$\begin{aligned} \mathbf{d}_{\text{lat}}(t_n) &= [d_{\text{lat}}(t_i)]^T, \\ \mathbf{v}_{\text{lat}}(t_n) &= [v_{\text{lat}}(t_i)]^T \text{ und} \\ \mathbf{v}_{\text{long}}(t_n) &= [v_{\text{long}}(t_i)]^T. \end{aligned} \quad (4.2.1)$$

Situationsbasierte Merkmale

Die objektbasierten Merkmale lassen eine Aussage über einen bevorstehenden Spurwechsel zu, sobald das beobachtete Fahrzeug das Manöver beginnt und sich in Richtung der Zielspur bewegt. Zum einen kann hierbei mit großer Sicherheit tatsächlich von einem Spurwechsel ausgegangen werden, zum anderen wird die Zeitspanne, die zwischen der Prädiktion und dem eigentlichen Manöver liegt, allerdings inhärent begrenzt, da das Manöver bereits begonnen haben muss. Der menschliche Fahrer ist in einigen Situationen bereits deutlich früher dazu in der Lage einen zukünftigen Spurwechsel vorherzusagen. Eine beispielhafte Situation ist ein beobachtetes Fahrzeug, das sich auf der rechten Spur einer Autobahn einem langsameren Lastkraftwagen nähert. In den meisten Fällen wird der Fahrer einen Spurwechsel nach links anstreben, um eine Verzögerung zu vermeiden und die aktuelle Geschwindigkeit beizubehalten. Um solche Interaktionen in der Vorhersage von Fahrmanövern zu berücksichtigen, werden zusätzlich die sogenannten situationsbasierten Merkmale in den Merkmalsvektor aufgenommen. Diese beschreiben die Relationen zwischen dem beobachteten Fahrzeug und den umgebenden Fahrzeugen (Abbildung 4.2). Generell sind die relativen Abstände $\mathbf{d}_{\text{rel}}(t_n)$ und relativen Geschwindigkeiten $\mathbf{v}_{\text{rel}}(t_n)$ zu den sechs Umgebungsfahrzeugen als Merkmale enthalten. Die beschriebene Situation würde sich in dem relativen Abstand zum direkten Führungsfahrzeug und der entsprechenden relativen Geschwindigkeit widerspiegeln. Gleichzeitig geht der zur Verfügung stehende Platz auf den Nachbarspuren mit in die Manöverklassifikation ein.

Der vollständige Merkmalsvektor setzt sich somit als

$$\boldsymbol{\mathcal{X}}(t) = [\mathbf{d}_{\text{lat}}(t_n)^T, \mathbf{v}_{\text{lat}}(t_n)^T, \mathbf{v}_{\text{long}}(t_n)^T, \mathbf{d}_{\text{rel}}(t_n)^T, \mathbf{v}_{\text{rel}}(t_n)^T]^T \in \mathbb{R}^{n_x} \quad (4.2.2)$$

¹Wird der Straßenverlauf als Referenz für ein kurvilineares Koordinatensystem verwendet, entspricht v_{long} der Geschwindigkeit entlang der longitudinalen Koordinate v_l und entsprechend v_{lat} der Geschwindigkeit v_n .

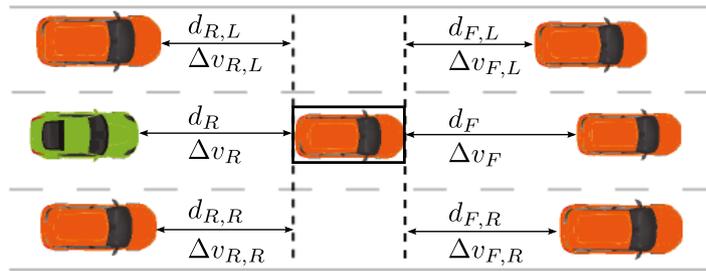


Abbildung 4.2.: Situationsbasierte Merkmale der Manöverklassifikation.

zusammen. In der vorliegenden Arbeit wurde die Länge der zeitlichen Historie der objektbasierten Merkmale zu $t_H = 0,8\text{ s}$ und die Zeitdifferenz als $\Delta T_H = 0,2\text{ s}$ gewählt. Die Werte wurden mit Hilfe der Kreuzvalidierung auf den verwendeten Datensätzen und dem Klassifikationsalgorithmus aus Abschnitt 4.3 bestimmt. Damit ergibt sich für den Merkmalsvektor eine Dimension von $n_{\mathcal{X}} = 27$.

4.3. Support Vektor Maschine als probabilistischer Klassifikator

Auf Basis der berechneten Merkmale muss nun mit Hilfe eines geeigneten Klassifikationsalgorithmus zwischen den drei Manöverklassen unterschieden werden. Für die Anwendung in der Trajektorienprädiktion für automatisierte Fahrzeuge ist es allerdings nicht ausreichend lediglich die wahrscheinlichste Klasse zu bestimmen, da für die weitere Verarbeitung der Prädiktion die Konfidenz einer prädizierten Klasse ebenfalls von Bedeutung ist. Mathematisch muss damit die bedingte Verteilung der möglichen Manöver $p(m^{(k)}(t_n) | \mathcal{X}(t))$ bestimmt werden.

In der vorliegenden Arbeit wird die Support Vektor Maschine (SVM) als Klassifikator herangezogen. Die SVM stellt ein überwachtes Lernverfahren dar, welches sich für die Klassifikation von Spurwechseln auf Autobahnen eignet (siehe [Kum+13; Wis+17b]). Für ein binäres Klassifikationsproblem mit den Beispielen $\zeta_i \in \mathbb{R}^{m_c}$ der Dimension $m_c \in \mathbb{N}_+$ und den entsprechenden Labeln $\iota_i \in \{-1, 1\}$ für $i = 1, 2, \dots, n_c$ mit $n_c \in \mathbb{N}_+$ findet eine SVM die Entscheidungsgrenze mit einem maximalen Abstand zu den Beispielen beider Klassen. Um auch für linear nicht separierbare Klassifikationsprobleme eine Entscheidungsgrenze zu finden, wird der so genannte Kernel-Trick angewendet. Dabei werden die Daten in einen höherdimensionalen Raum transformiert, in dem eine bessere Separierbarkeit erwartet wird. Hier wird ein Radialer Basis Funktionskernel $\mathcal{K}(\zeta_i, \zeta_j) = \Phi^T(\zeta_i)\Phi(\zeta_j) = \exp(-\gamma\|\zeta_i - \zeta_j\|^2)$ mit $\gamma > 0$ gewählt. Im Training der

SVM wird die konvexe Gütefunktion

$$\begin{aligned} \min_{\mathbf{w}, q, \nu} \quad & \frac{1}{2} \mathbf{w}^T \mathbf{w} + C \sum_{i=1}^{n_C} \nu_i \\ \text{u. d. Nb.} \quad & \iota_i(\mathbf{w}^T \Phi(\zeta_i) + q) \geq 1 - \nu_i \\ & \nu_i \geq 0, i = 1, 2, \dots, n_C. \end{aligned} \quad (4.3.1)$$

minimiert, um die optimalen Parameter des Normalenvektors $\mathbf{w} \in \mathbb{R}^{m_C}$, des Bias $q \in \mathbb{R}$ und des Vektors von Schlupfvariablen $\nu \in \mathbb{R}^{n_C}$ zu bestimmen (siehe auch [Hsu+03; Tso+04]). Die Klassifikationsentscheidung kann anschließend durch die Auswertung von

$$f(\zeta_i) = \text{sign}(\mathbf{w}^T \Phi(\zeta_i) + q) \quad (4.3.2)$$

bestimmt werden.

Mit Gleichung (4.3.2) wird eine binäre Klassenentscheidung getroffen. Für die multimodale Verteilung der prädizierten Trajektorien werden allerdings die Klassenwahrscheinlichkeiten aller möglichen Manöver benötigt. Aus diesem Grund werden während des Trainings zusätzlich die Parameter einer Sigmoidfunktion bestimmt, mit der der Abstand eines Beispiels zu der Entscheidungsebene in die entsprechende Klassenwahrscheinlichkeit überführt wird. Hierfür wird das Verfahren nach Platt [Pla99] angewandt, sodass eine probabilistische Unterscheidung zweier Klassen durchgeführt werden kann.

Für die Klassifikation von mehr als zwei Klassen mit SVMs gibt es grundsätzlich zwei Herangehensweisen. Einerseits kann pro zu klassifizierender Klasse eine SVM trainiert werden, bei der alle Beispiele, die nicht der Klasse entsprechen, als Negativbeispiele ($\iota_i = -1$) betrachtet werden (*one-vs-all* Ansatz). Die einzelnen Klassenwahrscheinlichkeiten werden abschließend normiert, um die finale Wahrscheinlichkeitsverteilung zu erhalten. Alternativ können für ein n_K -Klassenproblem $\binom{n_K}{2}$ paarweise SVMs trainiert werden, bei denen jeweils alle Datenpunkte von Klasse i als positiv und von Klasse j als negativ Beispiele verwendet werden (*one-vs-one* Ansatz). Die Verteilung über alle Klassenwahrscheinlichkeiten kann auf verschiedene Weise ermittelt werden. In der vorliegenden Arbeit wird das Verfahren aus [Wu+04] angewendet, sodass lediglich ein lineares Gleichungssystem gelöst werden muss, um die Klassenwahrscheinlichkeiten zu erhalten. Für die Klassifikation von Fahrmanövern wird hier der *one-vs-one* Ansatz gewählt, bei dem für die drei Manöver $\binom{3}{2} = 3$ SVMs trainiert werden müssen. Dieser Ansatz hat den Vorteil, dass die einzelnen Klassifikatoren weniger komplex sind und somit häufig über weniger Parametern verfügen. Dies ist besonders im Kontext der Anwendung im Testfahrzeug wünschenswert, da die verfügbare Rechenleistung der verbauten Hardware limitiert ist. Mit den trainierten SVMs kann nun die Verteilung $p(m^{(k)}(t_n) | \mathcal{X}(t))$ aller Manöver von Objekt k zum aktuellen Zeitpunkt bestimmt werden.

4.4. Auswertung der Spurwechselklassifikation

Die vorgestellte Manöverklassifikation wird im Folgenden mit verschiedenen Datensätzen ausgewertet. Da zur Entwicklung der Trajektorienprädiktion die in Kapitel 3

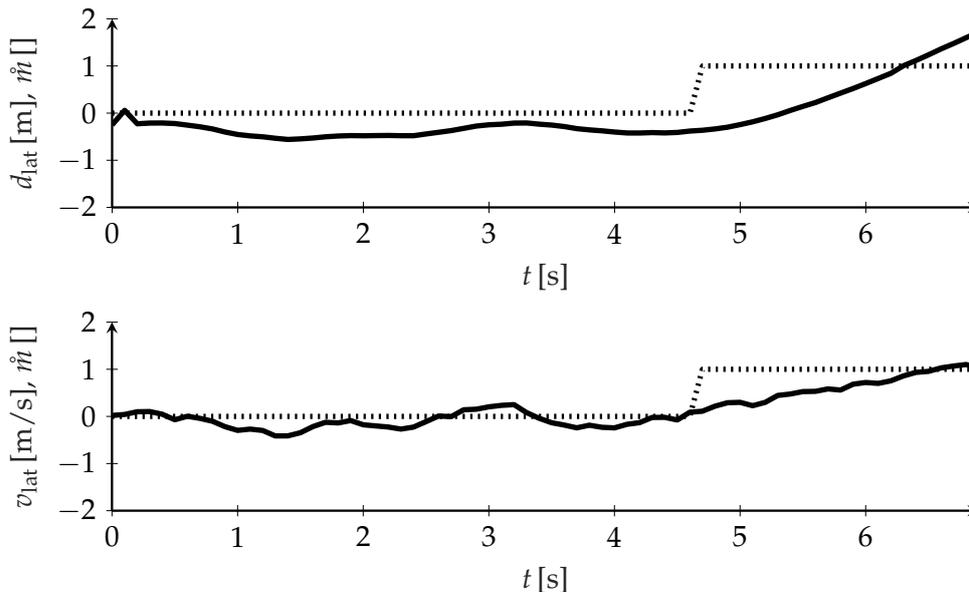


Abbildung 4.3.: Beispielverlauf der lateralen Distanz zur Spurmitte d_{lat} (oben) und der lateralen Geschwindigkeit relativ zur Spur v_{lat} (unten) sowie dem Spurwechsellabel (gepunktet).

vorgestellte Simulationsumgebung genutzt wird, wird diese ebenfalls zur Evaluation der Manövervorhersage herangezogen. Dazu werden in verschiedenen Szenarien Daten von Umgebungsfahrzeugen aufgenommen, die für das Training und die anschließende Auswertung genutzt werden. Um auch die Funktionsweise in der Anwendung im realen Straßenverkehr zu evaluieren, wird zusätzlich ein Datensatz mit dem Testfahrzeug aufgenommen. Hierbei wird auf die Sensordatenverarbeitung im Testfahrzeug zurückgegriffen, um die erforderlichen Merkmale für die Manöverklassifikation zu berechnen. Die Genauigkeit wird zum einen mit Klassifikationsmetriken bewertet und zum anderen anhand von Kriterien evaluiert, die für den Anwendungsfall der Spurwechseldetektion relevant sind.

Datenannotierung

Vor dem eigentlichen Training der einzelnen SVMs müssen die vorhandenen Daten annotiert werden, um zwischen Beispielen für die einzelnen Klassen zu unterscheiden. Dafür wird zunächst die Überquerung der Spurmarkierung des Schwerpunktes des beobachteten Fahrzeugs als Spurwechselzeitpunkt t_{LC} definiert, da das Fahrzeug zu diesem Zeitpunkt der Zielspur zugeordnet wird. Das Manöver an sich beginnt bereits einige Sekunden früher, wobei die Länge dieses Zeitraums von der Ausführung abhängt. Die Einpendelbewegung auf der Zielspur wird nicht mehr dem zu klassifizierenden Spurwechselmanöver zugeordnet. Bei den in der Simulation gewonnenen Daten kann dieser Prozess vollständig automatisiert werden, da zu jeder Zeit bekannt ist, welches Manöver das beobachtete Fahrzeug aktuell ausführt. Diese Information kann direkt für die Generierung des Labels verwendet werden. Im Falle der mit dem Testfahrzeug aufgenommenen Daten ist ein automatisierter Prozess nur schwer umzusetzen. Eine Möglichkeit wäre die Annahme einer konstanten Spurwechseldauer,

mit der das Label abhängig vom Spurwechselzeitpunkt gesetzt werden kann. Allerdings unterscheiden sich die Ausführungszeiten der Spurwechsel abhängig von der aktuellen Verkehrssituation stark, sodass diese Annahme zu teilweise falschen Labels führen würde. Eine andere Möglichkeit ist die Betrachtung der Bewegung des Fahrzeugs in Richtung der Zielspur. Hier ergibt sich der Nachteil, dass ein Manöver immer erst nach Beginn der lateralen Bewegung klassifiziert werden kann. Damit können Informationen aus der aktuellen Verkehrssituation keine vorzeitige Manövererkennung bewirken. Außerdem unterliegen die Merkmale, die die laterale Bewegung des Fahrzeugs beschreiben, teilweise starkem Rauschen, das ebenfalls zu falschen Labels führen könnte. Aus diesen Gründen werden die Daten aus dem Testfahrzeug händisch mit Hilfe der aufgenommenen Kamerabilder gelabelt. Sobald ein Spurwechsel von einem menschlichen Fahrer antizipiert werden kann, wird das Label gesetzt. Ein Beispiellabel mit dem zeitlichen Verlauf der lateralen Distanz zur Spurmitte und der lateralen Geschwindigkeit ist in Abbildung 4.3 dargestellt. Das beobachtete Fahrzeug fährt in diesem Fall etwas nach rechts versetzt in der aktuellen Spur ($d_{\text{lat}} < 0$), bevor es den Spurwechsel auf die linke Spur durchführt. Das Label (gepunktete Linie) beginnt zeitgleich mit dem Beginn der lateralen Bewegung nach links ($v_{\text{lat}} > 0$).

Evaluationsmetriken

Für die Evaluation der Manöverklassifikation werden zwei Arten von Metriken herangezogen. Die Erste evaluiert die Güte der SVMs als Klassifikator auf Basis aller Beispiele im verwendeten Testdatensatz mit bekannten Metriken für Klassifikationsprobleme. Diese werten unter anderem aus, wie viele Beispiele als Korrekt Positiv (TP), Korrekt Negativ (TN), Falsch Positiv (FP) und Falsch Negativ (FN) klassifiziert werden. Für die Verwendung innerhalb der Trajektorienprädiktion wird grundsätzlich die Wahrscheinlichkeitsverteilung über alle Klassen verwendet. Um die Genauigkeit der Klassifikation zu beurteilen, muss eine Klassenentscheidung getroffen werden, sodass hier der Maximumklassifikator verwendet wird

$$\hat{m}(t_n) = \arg \max_{m(t_n)} p(m(t_n) | \mathcal{X}(t)). \quad (4.4.1)$$

Die folgenden Metriken werden zur Bewertung der Klassifikationsgüte herangezogen:

- **Genauigkeit:**

$$\text{acc}^{\text{MK}} = \frac{\text{TP} + \text{TN}}{\text{TP} + \text{TN} + \text{FP} + \text{FN}} \quad (4.4.2)$$

Die Genauigkeit beschreibt das Verhältnis der korrekt klassifizierten Beispiele zu allen Beispielen und damit die Genauigkeit des zu untersuchenden Klassifikators.

- **Ausbalancierte Genauigkeit:**

$$\text{bac}^{\text{MK}} = \frac{1}{|\mathcal{M}|} \sum_{m \in \mathcal{M}} \text{acc}_m^{\text{MK}} \quad (4.4.3)$$

In Datensätzen, in denen sich die Anzahl an zur Verfügung stehenden Beispielen zwischen den verschiedenen Klassen stark unterscheidet, wird die Genauigkeit

von der häufiger vertretenen Klasse stark beeinflusst. Somit ist die Aussagekraft der einfachen Genauigkeit acc^{MK} begrenzt. Die ausbalancierte Genauigkeit ist der Mittelwert der klassenweise gebildeten Genauigkeit acc_m^{MK} mit $m \in \mathcal{M}$ und wird somit von jeder Klasse gleich beeinflusst.

- **Receiver Operator Characteristic (ROC)/Area under the Curve (AUC):** Um nicht nur die eigentliche Klassenentscheidung sondern auch die Konfidenz der Entscheidung (Wahrscheinlichkeit für die vorhergesagte Klasse) zu bewerten, wird zusätzlich die ROC-Kurve und die Fläche unter dieser ausgewertet. Um die Kurve zu erzeugen, wird der Entscheidungsschwellwert zwischen null und eins variiert und die Korrekt-Positiv-Rate (tpr^{MK}) gegenüber der Falsch-Positiv-Rate (fpr^{MK}) aufgetragen. Ein idealer Klassifikationsalgorithmus wird durch den Punkt (0|1) repräsentiert, also eine 100 prozentige Korrekt-Positiv-Rate mit gleichzeitig 0% Fehlklassifikationen. Ein Klassifikator, der beide Klassen mit gleicher Wahrscheinlichkeit vorhersagt, wird für ein ausbalanciertes Problem durch die Diagonale mit der Steigung 1 repräsentiert. Um die Güte unabhängig vom Schwellwert zu bewerten, wird die Fläche unter dieser Kurve herangezogen (AUC). Für diese gilt $0 \leq \text{AUC} \leq 1$, wobei 1 auch hier für einen perfekten Klassifikationsalgorithmus steht.

Zusätzlich zu den Metriken, die ausschließlich die Klassifikationsgenauigkeit auswerten, werden anwendungsbezogene Kriterien definiert. Diese beziehen sich auf Aspekte, die im praktischen Einsatz des Algorithmus relevant sind und nicht durch die vorherigen Metriken dargestellt werden.

- **Verpasste Spurwechsel:** Ein Spurwechselmanöver wird je nach Dauer durch eine Reihe aufeinander folgender Beispiele repräsentiert. Klassifikationsmetriken betrachten dabei jedes Beispiel unabhängig voneinander und lassen somit keine Aussage darüber zu, ob ein Spurwechsel detektiert wurde. Im Kontext der Manöverklassifikation wird daher ein Spurwechsel als nicht erkannt definiert, wenn keines der zu diesem Manöver gehörenden Beispiele als entsprechender Spurwechsel klassifiziert wird. Die Anzahl der nicht erkannten Manöver wird durch n_{miss} beschrieben.
- **Prädiktionszeit:** Für die Anwendung der Manöverklassifikation eines Assistenzsystems auf Autobahnen ist neben der zuverlässigen Erkennung der Manöver der Zeitpunkt von Interesse, zu dem dieses detektiert wird. Dabei spielt insbesondere die Prädiktionszeit, also die Zeitspanne zwischen der ersten Detektion $t_{\text{LC,det}}$ und dem Spurwechselzeitpunkt, eine große Rolle

$$t_{\text{pred}} = \hat{t}_{\text{LC}} - t_{\text{LC,det}}. \quad (4.4.4)$$

Grundsätzlich ist eine möglichst große Prädiktionszeit wünschenswert, da so mehr Zeit für eine eventuelle Reaktion des Ego-Fahrzeugs auf das detektierte Manöver zur Verfügung steht.

Mit den vorgestellten Metriken wird nun die Manöverklassifikation auf einem Datensatz aus der Simulationsumgebung aus Kapitel 3 und einem Datensatz, der mit einem Testfahrzeug aufgenommen wurde, ausgewertet.

Tabelle 4.1.: Anzahl und Verteilung der Beispiele im Simulations- und Testfahrzeugdatensatz.

| | Spurhalten | Spurwechsel links | Spurwechsel rechts |
|-------------------------|------------|-------------------|--------------------|
| #Beispiele Simulation | 127989 | 47247 | 37177 |
| #Beispiele Testfahrzeug | 378165 | 1900 | 3209 |

Auswertung mit Simulationsdaten

Zur ersten Auswertung der Manöverklassifikation wird der Datensatz herangezogen, der mit der Simulationsumgebung erzeugt wurde. Dieser enthält insgesamt 2107 Spurwechselmanöver, welche sich in 913 Manöver nach rechts und 1194 nach links aufteilen. Jedem Spurwechsel geht eine unterschiedlich lange Phase des Spurhaltens voran. Diese ist in den meisten Fällen länger als das eigentliche Spurwechselmanöver, sodass sich eine Unausgeglichenheit bei der Verteilung der Beispiele pro Klasse ergibt. Die vollständige Verteilung ist in Tabelle 4.1 dargestellt. Beide Spurwechselklassen sind in etwa gleich häufig repräsentiert, die Klasse Spurhalten ist hingegen deutlich überrepräsentiert.

Ein beispielhafter Verlauf der Wahrscheinlichkeit ist in Abbildung 4.4 dargestellt. Die schwarze gepunktete Linie zeigt das Label und somit die Zielvorhersage. Hierbei repräsentiert ein Wert von 1 und -1 einen Spurwechsel nach links respektive rechts und ein Wert von 0 Spurhalten. Die schwarze Linie repräsentiert die Wahrscheinlichkeit für einen Spurwechsel nach links $p(m(t_n) = \text{LCL})$ und die graue Linie entsprechend ein Spurwechselmanöver auf die rechte Spur $p(m(t_n) = \text{LCR})$. Die Wahrscheinlichkeit für das Halten der aktuellen Spur ergibt sich direkt aus der Bedingung

$$\sum_{m \in \mathcal{M}} p(m(t_n)) \stackrel{!}{=} 1. \quad (4.4.5)$$

Im ersten Teil des dargestellten Verlaufs wird deutlich, dass der Spurwechsel nach links gut erkannt wird. Die Wahrscheinlichkeit steigt kurz nach dem Start des Manövers kontinuierlich auf eine Konfidenz von 100%. Allerdings wird der Spurwechsel eine halbe Sekunde später erkannt als vom Label vorgegeben. Das Label wird gesetzt, sobald das Spurwechselmodell der Simulationsumgebung (siehe Abschnitt 3.3) einen Spurwechsel beginnt. Zu diesem Zeitpunkt kann das Manöver nicht anhand der objektbasierten Merkmale geschätzt werden, da die laterale Bewegung noch nicht begonnen hat. Gleichzeitig erlaubt die wahrgenommene Situation an dieser Stelle keine Rückschlüsse auf einen Spurwechsel. Hier zeigt sich ein Problem der situationsbasierten Merkmale für die Klassifikation. In vielen Fällen befindet sich das beobachtete Fahrzeug vor dem Ego-Fahrzeug, sodass die Detektion des Fahrzeugs vor dem beobachteten Fahrzeug mit fahrzeuginternen Sensoren nicht möglich ist. Auf Basis des resultierenden Umfeldmodells wird angenommen, dass kein Führungsfahrzeug existiert und damit auch keine Motivation für einen Spurwechsel des beobachteten Fahrzeugs auf die linke Fahrspur vorhanden ist. Der zeitliche Vorteil für die Klassifikation eines solchen Manövers kann somit nicht ausgenutzt werden.

Nach dem Spurwechsel nach links folgt ein Wechsel auf die relativ zum beobachteten Fahrzeug rechte Spur. Auch dieser wird zuverlässig mit einer hohen Konfidenz

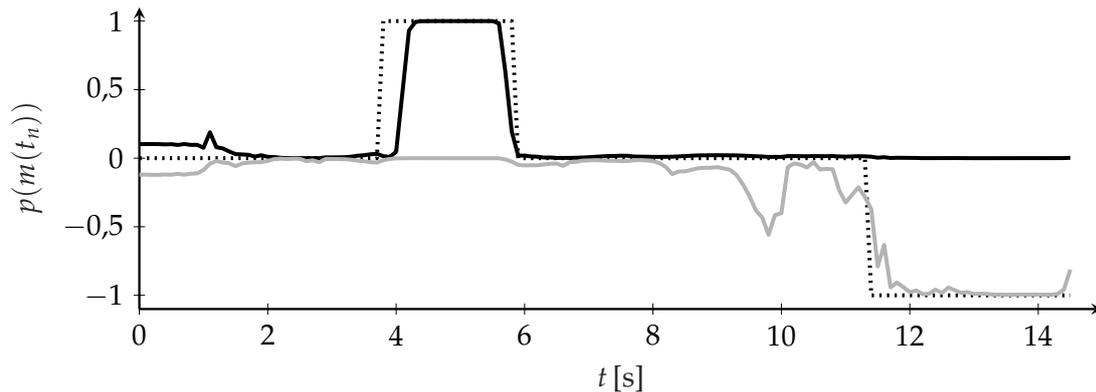


Abbildung 4.4.: Beispielverlauf für die Manöverwahrscheinlichkeit eines Spurwechsels nach links und rechts. Die schwarze gepunktete Linie repräsentiert das Label der Daten. Die schwarze und graue Linie zeigen jeweils den Verlauf der Wahrscheinlichkeiten $p(m(t_n) = \text{LCL})$ und $p(m(t_n) = \text{LCR})$.

über die komplette Dauer erkannt. Die Wahrscheinlichkeit steigt in diesem Fall direkt nach Beginn des Manövers. Im Zeitintervall $t \in [9\text{ s}, 10\text{ s}]$ ist ein leichter Anstieg der Wahrscheinlichkeit für einen Spurwechsel nach rechts zu erkennen, der durch eine Bewegung des Fahrzeugs in Richtung der rechten Spur zu Stande kommt. Hierbei handelt es sich um eine Fehlklassifikation, da das Fahrzeug zunächst wieder zurück in die ursprüngliche Spur fährt und erst anschließend nach 11 s den Spurwechsel durchführt.

Für eine generelle Aussage der Klassifikationsgüte wird der zur Verfügung stehende Datensatz in 70% Trainingsdaten und 30% Testdaten aufgeteilt. Die Konfusionsmatrix in Tabelle 4.2 zeigt die Ergebnisse für alle Beispiele im Testdatensatz. Dabei ist zum einen die absolute Zahl der Beispiele pro Eintrag angegeben, wie auch der Anteil im Bezug zu allen Beispielen einer Klasse. So ist direkt ersichtlich, wie viele Beispiele einer Klasse korrekt klassifiziert wurden. Zusätzlich sind in Tabelle 4.3 die vorab beschriebenen Metriken dargestellt. Der verwendete Klassifikationsalgorithmus erreicht insgesamt eine gute Genauigkeit von 95% für alle Beispiele in dem Testdatensatz. Da auch die bac^{MK} einen Wert von 94% erreicht, werden alle drei Klassen sehr gut erkannt. Die Ungleichverteilung der Daten in Bezug auf die einzelnen Klassen wird aus der Konfusionsmatrix ersichtlich. Das Manöver Spurhalten ist häufiger vertreten als die beiden Spurwechselklassen. Die Konfusionsmatrix zeigt außerdem, dass es kaum Verwechslungen der beiden Spurwechselklassen gibt. Dies ist mit der unterschiedlichen Ausprägung der objektbasierten Merkmale für beide Klassen zu erklären, sodass eine falsche Klassifikation nach Beginn der lateralen Bewegung unwahrscheinlich ist. Eine solche Fehlklassifikation kann unter anderem bei Fahrzeugen entstehen, die vor einem Spurwechsel eine kurze Bewegung in die entgegengesetzte Richtung ausführen. Ein Beispiel ist im Anhang A.5 dargestellt. Die häufigsten Fehler sind nicht erkannte Spurwechselbeispiele. Diese befinden sich häufig am Anfang des Spurwechsels, da die Manöver nicht anhand der objektbasierten Merkmale klassifiziert werden können und die situationsbasierten Merkmale oftmals auf einem unvollständigen Umgebungsmodell basieren.

Tabelle 4.2.: Konfusionsmatrix des Klassifikationsalgorithmus.

| | | Label | | |
|------------|-----|--------------|--------------|--------------|
| | | LCL | LCR | LK |
| Vorhersage | LCL | 12905(0,891) | 4(0,000) | 507(0,011) |
| | LCR | 0(0,000) | 10150(0,887) | 337(0,008) |
| | LK | 1586(0,109) | 985(0,112) | 43735(0,981) |

Tabelle 4.3.: Evaluationsmetriken

| Metrik | Wert |
|---------------------------|---------------------------|
| acc^{MK} | 0,95 |
| bac^{MK} | 0,94 |
| AUC_{LCL} | 0,98 |
| AUC_{LCR} | 0,99 |
| AUC_{LK} | 0,98 |
| n_{miss} | 0 |
| t_{pred} | $2,60 \pm 0,56 \text{ s}$ |

Für die Auswertung der Klassifikationsalgorithmen auf Basis der Konfidenz werden die in Abbildung 4.5a dargestellten ROC-Kurven herangezogen. Diese werden klassenweise generiert, sodass in die schwarze, durchgezogene Linie die Klasse Spurwechsel nach links, die hellgraue Linie nach rechts und die dunkelgraue Linie die Klasse Spurhalten repräsentiert. Zusätzlich ist durch die gepunktete Linie ein Klassifikationsalgorithmus dargestellt, der jede Klasse entsprechend ihrer a priori Verteilung vorhersagt. Anhand des großen Abstands zu diesem und der Nähe zum idealen Punkt (0|1) wird deutlich, dass alle Klassen mit einer hohen Genauigkeit vorhergesagt werden. Dabei bieten die Klassifikatoren für die beiden Spurwechselklassen eine höhere tpr^{MK} bei einer gleichzeitig geringeren fpr^{MK} . Es können viele Beispiele korrekt klassifiziert werden wobei die Anzahl der Fehlklassifikationen niedrig bleibt. Im Gegensatz hierzu nähert sich die Vorhersage für das Spurhaltenmanöver schneller der 100 prozentigen korrekt positiv Rate. Zusätzlich sind die Punkte, die einem Schwellwert von 1/3 entsprechen, auf der Kurve markiert. Es ist zu erkennen, dass sich für beide Spurwechselklassen weniger *Falsch-Positiv* Vorhersagen ergeben, während für die Klasse Spurhalten nahezu alle positiven Beispiel als Spurhalten erkannt werden. Insgesamt erreicht der Klassifikationsalgorithmus für alle drei Klassen ein sehr gutes Ergebnis, welches sich auch in den AUC-Werten in Tabelle 4.3 widerspiegelt.

Anhand der anwendungsbasierten Metriken ist ebenfalls abzuleiten, dass der Klassifikator für die Simulationsdaten ein gutes Ergebnis erzeugt. Von 2107 Spurwechselmanövern wird jedes Manöver erkannt. Für die Prädiktionszeit wird ein Wert von $t_{\text{pred}} = 2,60 \text{ s}$ erreicht. Ein Manöver wird im Schnitt mehr als zweieinhalb Sekunden vor dem Überqueren der Spurmarkierung erkannt, was den nachfolgenden Algorithmen ausreichend Zeit für eine Reaktion erlaubt.

Zusammenfassend zeigt die Manöverklassifikation für Daten aus der Simulationsumgebung ein vielversprechendes Ergebnis, auf Basis dessen eine manöverbasierte Trajektorienprädiktion umgesetzt werden kann. Zusätzlich steigt die Konfidenz für eine Klassifikation je stärker sich das beobachtete Fahrzeug der Zielspur nähert, sodass eine korrekte Klassifikation immer wahrscheinlicher wird.

Auswertung mit Daten aus dem Testfahrzeug

Für die Bestimmung der Güte der Manöverklassifikation bei der Anwendung im Testfahrzeug wird der vorgestellte Ansatz zusätzlich mit einem Datensatz, der mit

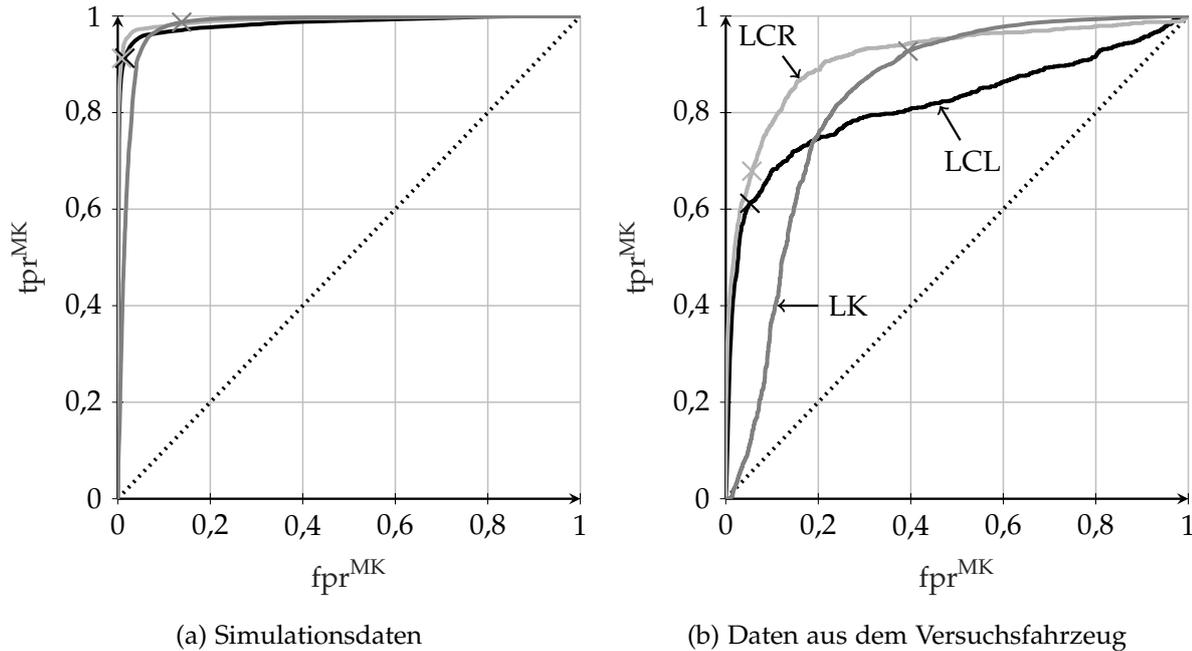


Abbildung 4.5.: Receiver Operator Characteristic-Kurven für die drei Manöverklassen: Spurwechsel links (schwarz), Spurwechsel rechts (helles grau) und Spurhalten (dunkles grau).

dem Fahrzeug in verschiedenen Autobahnsituationen aufgenommen wurde, evaluiert. In [Wis+17a] wurde untersucht, ob sich ein Ansatz zur Manövererkennung, der mit Hilfe von Simulationsdaten trainiert wurde, für die direkte Anwendung im Testfahrzeug eignet. Es stellt sich heraus, dass die Simulation nicht genügend Variation bietet, um eine direkte Übertragung der gelernten Parameter zu ermöglichen. Daher wird auch dieser Datensatz in Trainings- und Testdaten unterteilt, sodass die SVMs zunächst trainiert werden können. Anschließend kann auf Basis der Testdaten der Generalisierungsfehler bestimmt werden. Der Datensatz besteht aus 10 Stunden und 38 Minuten aufgezeichneten Autobahnszenarien und enthält insgesamt 309 Spurwechsel, die sich in 115 Manöver nach links und 194 nach rechts aufteilen. Die Verteilung der Beispiele ist in Tabelle 4.1 dargestellt. Es zeigt sich eine deutlich stärkere Ungleichverteilung zwischen den Spurwechsel und den Spurhalten Beispielen als bei den Daten aus der Simulationsumgebung.

In Abbildung 4.6 ist ein beispielhafter Verlauf der Wahrscheinlichkeiten für einen Spurwechsel nach links $p(m(t_n) = LCL)$ (schwarz) und rechts $p(m(t_n) = LCR)$ (grau) dargestellt. Im Gegensatz zu dem Verlauf der Wahrscheinlichkeit für die Simulationsdaten (vergleiche Abbildung 4.4) sind einige falsche Vorhersagen zwischen den Spurwechseln zu erkennen. Der bei $t = 16,9\text{ s}$ stattfindende Spurwechsel nach links wird korrekt und bereits kurz bevor das Label für den Spurwechsel gesetzt ist erkannt. Die Wahrscheinlichkeit steigt auf nahezu 100% an und im Vorhinein sind lediglich kleine Anstiege der Wahrscheinlichkeit, die in keiner Fehlklassifikation resultieren, zu erkennen. Zwischen dem Spurwechsel nach links und dem Manöver nach rechts sind falsche Vorhersagen in beide Richtungen zu sehen. Sowohl die Wahrscheinlichkeit für einen Spurwechsel nach rechts als auch nach links steigen mehrfach an, obwohl kein Spurwechselmanöver durchgeführt wird. Am Ende des gezeigten Verlaufes wird der

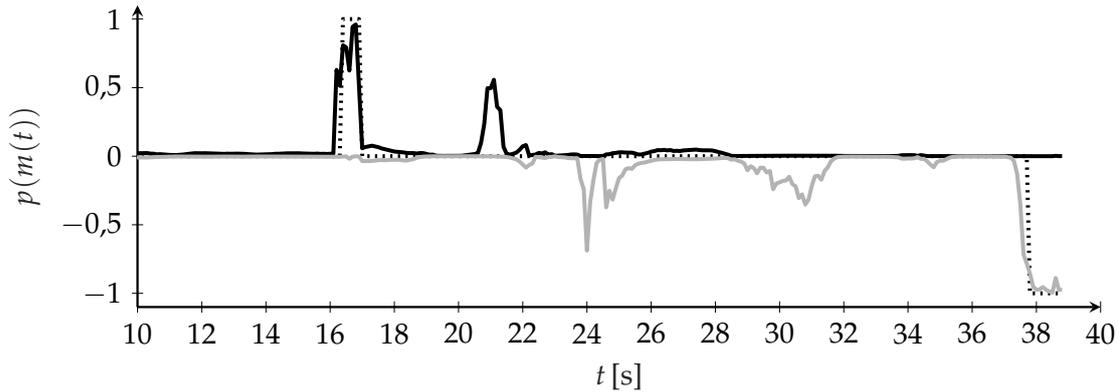


Abbildung 4.6.: Beispielverlauf der Manöverwahrscheinlichkeit eines Spurwechsels nach links und rechts. Die schwarze gepunktete Linie repräsentiert das Label der Daten. Die schwarze und graue Linie zeigen jeweils den Verlauf der Wahrscheinlichkeiten $p(m(t_n) = \text{LCL})$ und $p(m(t_n) = \text{LCR})$.

Spurwechsel nach rechts korrekt erkannt. Auch hier steigt $p(m(t_n) = \text{LCR})$ bereits vor Beginn des Labels an und erreicht eine Konfidenz von 100%.

Als Grund für die auftretenden Fehlklassifikationen ist zum einen die fehlerhafte Positionsschätzung der beobachteten Fahrzeuge und die daraus resultierenden Merkmale zu nennen. Zum anderen ist die Spurzuordnung von detektierten Fahrzeugen zu den mit Hilfe der Kamera geschätzten Spuren zeitlich häufig nicht konsistent. Die beobachteten Fahrzeuge befinden sich in vielen Fällen außerhalb der für die Kamera sichtbaren Spurmarkierungen, sodass diese für die Spurzuordnung extrapoliert werden müssen. Durch leichte Abweichungen der Polynomkoeffizienten ergeben sich allerdings starke Änderungen in den extrapolierten Bereichen der Spuren, wodurch eine konsistente Zuordnung schwierig ist. Der resultierende Verlauf der lateralen Geschwindigkeit und des lateralen Abstandes zur Spurmitte ist beispielhaft im Anhang in Abbildung A.7 dargestellt. Durch die wechselnde Spurzuordnung des beobachteten Fahrzeugs ergibt sich jeweils eine sprunghafte Änderung des lateralen Abstandes, welche wiederum zu einer falschen Vorhersage des aktuellen Manövers führen kann. Zusätzlich resultieren aus Fehlern im Tracking einzelner Fahrzeuge Inkonsistenzen in der Merkmalshistorie. Die Fehler der Wahrnehmung wirken sich direkt auf die Güte der Manöverklassifikation für den Datensatz des Testfahrzeugs aus. Dies zeigt sich zum einen in der Konfusionsmatrix in Tabelle 4.4 und zum anderen in den Metriken in Tabelle 4.5. Die Konfusionsmatrix zeigt zusätzlich das starke Ungleichgewicht in der Verteilung der Beispiele auf die drei betrachteten Klassen. So enthält die Klasse Spurhalten fast hundertmal so viele Beispiele wie die beiden Spurwechselklassen. Entsprechend ist die Aussagekraft der Genauigkeit acc^{MK} in Tabelle 4.5 begrenzt, da diese hauptsächlich die Genauigkeit für die Prädiktion der Spurhalten Klasse widerspiegelt. Eine bessere Aussage erlaubt die ausbalancierte Genauigkeit bac^{MK} als Mittel über die Klassengenauigkeit. Mit $\text{bac}^{\text{MK}} = 0,77$ ist diese deutlich schlechter als für die mit der Simulationsumgebung generierten Daten. Spurwechselbeispiele werden häufiger nicht erkannt und es entstehen mehr falsche Vorhersagen. Auch hier wirkt sich der Einfluss der Perzeption negativ aus. Durch die inkonsistente Schätzung der Polynomkoeff-

Tabelle 4.4.: Konfusionsmatrix des Klassifikationsalgorithmus.

| | | Label | | |
|------------|-----|------------|------------|--------------|
| | | LCL | LCR | LK |
| Vorhersage | LCL | 451(0,581) | 15(0,017) | 3048(0,042) |
| | LCR | 4(0,005) | 578(0,652) | 3402(0,047) |
| | LK | 321(0,414) | 294(0,331) | 66520(0,912) |

Tabelle 4.5.: Evaluationsmetriken

| Metrik | Wert |
|---------------------------|---------------------------|
| acc^{MK} | 0,91 |
| bac^{MK} | 0,77 |
| AUC_{LCL} | 0,82 |
| AUC_{LCR} | 0,91 |
| AUC_{LK} | 0,83 |
| n_{miss} | 5 |
| t_{pred} | $1,60 \pm 0,90 \text{ s}$ |

fizienten in aufeinanderfolgenden Zyklen werden starke Änderungen des lateralen Abstandes generiert, die wiederum in hohe laterale Geschwindigkeiten resultieren. Dadurch ergibt sich eine Evidenz für einen Spurwechsel des beobachteten Fahrzeugs, der zu dieser Zeit allerdings nicht stattfindet. Zusätzlich werden einige Manöver überhaupt nicht als Spurwechsel erkannt. Es handelt sich entweder um Manöver, die sehr langsam ausgeführt werden, sodass keine signifikante laterale Geschwindigkeit gemessen wird, oder Spurwechsel, bei denen innerhalb des Manövers eine Bewegung in die entgegengesetzte Richtung wahrgenommen wird. Ein solches Beispiel ist im Anhang in Abbildung A.6 dargestellt. Für die erkannten Spurwechsel ist die Prädiktionszeit in etwa eine Sekunde kürzer als bei Daten aus der Simulation. Somit haben die Spurwechsel häufig bereits begonnen, bevor der Klassifikator die entsprechende Klasse erkennt. Dies hat wiederum direkte Auswirkungen auf die anschließende Trajektorienprädiktion, wie in Kapitel 5 erläutert wird.

Die Degradation der Güte kann auch an den in Abbildung 4.5b dargestellten ROC Kurven festgestellt werden. Für die beiden Klassen Spurwechsel links (schwarz) und rechts (helles grau) ist zunächst ein steiler Anstieg zu erkennen, der allerdings bei niedrigeren Schwellwerten zu einer erhöhten *Falsch-Positiv* Rate führt. Die Klasse Spurhalten ist überdurchschnittlich häufig vertreten, sodass bereits eine geringe falsch-positiv-Rate viele fälschlich als Spurwechsel klassifizierte Beispiele im Verhältnis zu den *Korrekt-Positiv* klassifizierten Beispielen repräsentiert. Entsprechend bedeutet eine *Falsch-Positiv* Rate für die Klasse Spurhalten in absoluten Zahlen wenige Beispiele der Spurwechselklassen, die als Spurhalten klassifiziert werden.

Insgesamt zeigt sich eine deutliche Abnahme sowohl in den Klassifikationsmetriken als auch in den anwendungsspezifischen Metriken für den Datensatz, der mit dem Testfahrzeug aufgenommen wurde, im Gegensatz zu den Daten, die mit der Simulationsumgebung erzeugt wurden. Insbesondere die inkonsistente Schätzung der Spurmarkierung beeinflusst stark das erzielte Ergebnis, da sich die beobachteten Fahrzeuge häufig außerhalb der von der Kamera wahrgenommenen Reichweite befinden.

5

Manöverbasierte Trajektorienprädiktion

In diesem Kapitel wird ein erster Ansatz zur Prädiktion von Trajektorien für benachbarte Verkehrsteilnehmer vorgestellt. Der Ansatz basiert auf der eingeführten Manöverklassifikation aus Kapitel 4. Dazu wird der verwendete Ansatz zunächst erklärt und die formale Repräsentation der prädizierten Trajektorien dargelegt. Anschließend wird das eingesetzte Verfahren auf Basis von Simulationsdaten sowie Daten aus einem Testfahrzeug evaluiert.

5.1. Vorhersage auf Basis geschätzter Fahrmanöver

Wie bereits in Abschnitt 1.2 dargelegt, können Ansätze zur Prädiktion von Trajektorien in drei Kategorien eingeteilt werden. Neben der Prädiktion auf Basis von physikalischen Bewegungsmodellen können Ansätze in manöverbasierte und interaktionsbasierte Techniken unterteilt werden. Bei manöverbasierten Ansätzen wird angenommen, dass ein Fahrer zu jedem Zeitpunkt nur ein bestimmtes Manöver aus einer endlichen Menge von Manövern ausführt und dieses für die Dauer der Prädiktion beibehält: $\Gamma^{(k)} = m^{(k)}(t_n)$. Diese Annahme erlaubt die Formulierung von Gleichung (2.2.2) als Produkt

$$\hat{\mathbf{x}}^{(k)}(\tau) \sim p\left(\hat{\mathbf{x}}^{(k)}(\tau) \mid \mathbf{x}^{(k)}(t_n), m^{(k)}(t_n), \mathcal{S}\right) p\left(m^{(k)}(t_n) \mid \mathcal{X}^{(k)}(t_n)\right). \quad (5.1.1)$$

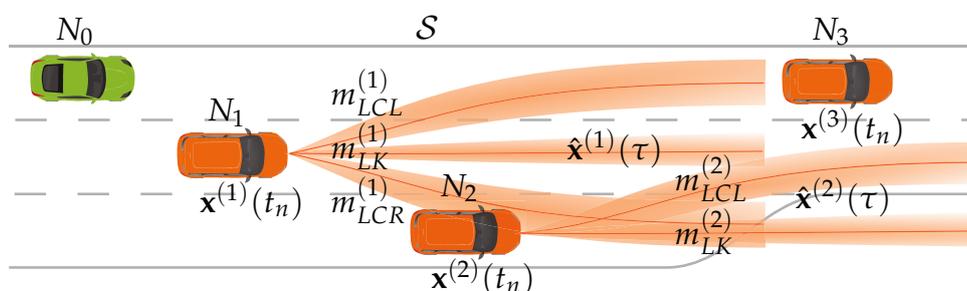


Abbildung 5.1.: Konzeptionelle Darstellung der manöverbasierten Trajektorienprädiktion. Für jedes mögliche Manöver wird eine Prototypentrajektorie als Prädiktion genutzt und diese mit der jeweiligen Manöverwahrscheinlichkeit gewichtet.

Damit kann die Prädiktion der Trajektorien in die Bestimmung der Wahrscheinlichkeitsverteilung über alle möglichen Manöver und die jeweilige Repräsentation der Zustandsverteilung jedes Manövers aufgeteilt werden (siehe Abbildung 5.1). Die Verteilung der Zustände wird als Prototypentrajektorie bezeichnet. Da jeder Fahrer ein Manöver unterschiedlich ausführt, muss durch den zweiten Teil die Unsicherheit der unbekanntem Manöverausführung berücksichtigt werden. In der manöverbasierten Trajektorienprädiktion wird die Interaktion zwischen einzelnen Fahrzeugen nicht explizit betrachtet, sondern lediglich implizit durch die Wahl von geeigneten Merkmalen in der Manöverklassifikation berücksichtigt. Durch die genannten Vereinfachungen ist eine sehr effiziente Umsetzung der Trajektorienprädiktion möglich, da als Prototypentrajektorien oft einfache parametrische Modelle ausreichen. Gleichzeitig erlaubt die Betrachtung von Fahrmanövern eine längere Prädiktionszeit als die Prädiktion ausschließlich auf Basis von physikalischen Größen (siehe dazu auch [LC14]).

Der hier vorgestellte Ansatz zur Trajektorienprädiktion stellt eine manöverbasierte Umsetzung dar und entspricht dem Vorgehen in [Lie+19a]. Für die Schätzung der Manöververteilung $p(m^{(k)}(t_n) | \mathcal{X}^{(k)}(t_n))$ von Fahrzeug k wird dabei der Klassifikationsansatz aus Kapitel 4 verwendet. Um den Einsatz auf typischer Weise in Fahrzeugen verbauten Steuergeräten zu ermöglichen, muss für die Repräsentation der Prototypentrajektorien ein sehr effizienter Ansatz gewählt werden. Gleichzeitig sollte das Modell die Möglichkeit bieten, die Bewegung des beobachteten Fahrzeugs möglichst genau abzubilden. Daher wird eine Repräsentation mittels kubischen Splines gewählt. Diese bieten eine parametrische Beschreibung der Trajektorie, wobei sich die Parameter leicht aus Randbedingungen bestimmen lassen (siehe Abschnitt 5.2). Durch eine Erhöhung der Anzahl an Stützstellen sind auch komplexe Manöver oder Kombinationen abbildbar. Da die Spline Repräsentation keine Unsicherheiten abbildet, wird diese durch lineare Unsicherheitsfortpflanzung der Zustandsnormalverteilung modelliert. Das Verfahren der manöverbasierten Trajektorienprädiktion wird im Folgenden mit MBTP bezeichnet. Im nächsten Abschnitt wird die verwendete Spline Repräsentation mathematisch definiert.

Bevor die Trajektorie für einzelne Fahrzeuge prädiziert wird, wird der aktuelle Zustand in ein kurvilineares Koordinatensystem transformiert (siehe Abschnitt 2.3), das als Referenzlinie den geschätzten Straßenverlauf verwendet. Somit kann für die Prädiktion ein gerader Straßenverlauf angenommen werden, während durch die Transformation der Verlauf der Straße explizit berücksichtigt wird. Nach der Berechnung der Trajektorie wird diese mit den zugehörigen Unsicherheiten zurück in das kartesische System transformiert.

5.2. Kubische Splines als Prädiktionsmodell

Für jedes mögliche Manöver muss die Bewegung des beobachteten Fahrzeugs räumlich und zeitlich beschrieben werden. Dafür wird die Trajektorie von Fahrzeug N_k in der zweidimensionalen Ebene durch eine Abfolge von Zuständen ${}^C\hat{\mathbf{x}}^{(k)}(\tau) = [\hat{l}(\tau), \hat{n}(\tau)]^T$ im Intervall $\tau \in [t_n, t_n + T_p]$ in kuvilinearen Koordinaten beschrieben. Beide Komponenten werden unabhängig voneinander durch kubische Splines repräsentiert. Da

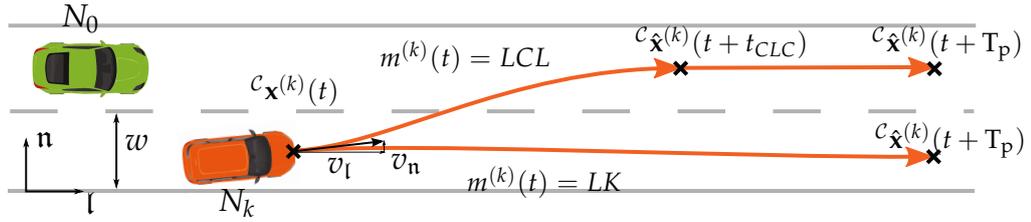


Abbildung 5.2.: Darstellung der Manöverprototypen als Splines. Um eine Prädiktion über den gesamten Prädiktionshorizont zu ermöglichen, wird nach dem Spurwechsel ein anschließendes Spurhaltemanöver angenommen.

die Prädiktion zu jeder Zeit von Fahrmanövern im fahrdynamischen Komfortbereich ausgeht, ist die Vernachlässigung der Kopplung von Längs- und Querdynamik keine Einschränkung der Gültigkeit.

Ein kubischer Spline $h(t_n)$ ist definiert durch

$$h(t_n) = \begin{cases} z_l(t_n) & t_l \leq t_n \leq t_{l+1} \\ 0 & \text{sonst.} \end{cases} \quad (5.2.1)$$

Wenn κ die Anzahl an Kontrollpunkten beschreibt und $t_n \in [t_l, t_{l+1}]$ gilt, besteht der Spline aus $\kappa - 1$ Segmenten der Form

$$z_l(t_n) = c_{l,3}(t_n - t_l)^3 + c_{l,2}(t_n - t_l)^2 + c_{l,1}(t_n - t_l) + c_{l,0}. \quad (5.2.2)$$

Um die Parameter $\{c_{l,0}, c_{l,1}, c_{l,2}, c_{l,3}\}$ eindeutig zu bestimmen, müssen die Anfangs- und Endbedingungen $\{z_0, \dot{z}_0, z_l, \dot{z}_l\}$ für $l = 0, 1, \dots, \kappa - 1$ aufgestellt werden.

Für die Modellierung von Spurfolgetrajektorien werden die longitudinale $l(\tau)$ und die laterale Komponente $n(\tau)$ jeweils durch einen Spline mit $\kappa = 2$ Kontrollpunkten modelliert. Dabei ist der erste Kontrollpunkt für $t_0 = t_n$ durch den Mittelwert des aktuellen Zustands $c_{x^{(k)}}(t_n)$ von Fahrzeug k gegeben. Aufgrund der Annahme, dass ein beobachteter Fahrer grundsätzlich der Spurmitte folgen möchte, kann der zweite Kontrollpunkt in die Mitte der aktuellen Spur für $t_1 = t_n + T_p$ gelegt werden. Daraus ergeben sich die Randbedingungen

$$\hat{l}(t_0) = l(t_n), \quad \dot{\hat{l}}(t_0) = v_l(t_n), \quad (5.2.3)$$

$$\hat{n}(t_0) = n(t_n), \quad \dot{\hat{n}}(t_0) = v_n(t_n), \quad (5.2.4)$$

$$\hat{l}(t_1) = l(t_n) + v_l(t) (t_1 - t_n), \quad \dot{\hat{l}}(t_1) = v_l(t_n), \quad (5.2.5)$$

$$\hat{n}(t_1) = w/2, \quad \dot{\hat{n}}(t_1) = 0, \quad (5.2.6)$$

wobei w die Breite der aktuellen Spur des beobachteten Fahrzeugs ist. In Abbildung 5.2 sind die Randbedingungen sowohl für ein Spurhalte- als auch für ein Spurwechselmanöver dargestellt. Da die angestrebte Wunschgeschwindigkeit des Fahrers nicht beobachtbar ist und die Messungen der Beschleunigung einem starken Rauschen unterliegt, wird mit Gleichung (5.2.5) die Annahme konstanter longitudinaler Geschwindigkeit umgesetzt. Zusätzlich wird angenommen, dass der Fahrer dem Straßenverlauf ohne signifikante laterale Geschwindigkeit folgen möchte (Gleichung (5.2.6)).

Im Falle eines Spurwechselmanövers wird der zweite Kontrollpunkt abhängig von der Richtung auf die Zielspur gesetzt. Zusätzlich muss beachtet werden, dass ein Spurwechselmanöver nur für eine begrenzte Zeit durchgeführt wird, welche häufig unter der zu prädizierenden Dauer T_p liegt. Dies trifft insbesondere zu, wenn das Spurwechselmanöver bereits begonnen hat und nur noch für die Zeit t_{CLC} durchgeführt wird (siehe Abbildung 5.2). Aus diesem Grund wird im Anschluss an den Spurwechsel ein Spurhaltenmanöver für die verbleibende Zeit $T_p - t_{CLC}$ prädiziert. Die Darstellung kann durch einen zusätzlichen Kontrollpunkt des Splines umgesetzt werden. Dabei bleiben die Gleichungen für die Anfangsbedingung sowie die longitudinale Bedingung für den Zeitpunkt $t_1 = t_{CLC}$ unverändert. Lediglich die laterale Komponente (5.2.6) ändert sich zu

$$\hat{n}(t_1) = \frac{3w}{2}, \quad \dot{\hat{n}}(t_1) = 0, \quad (5.2.7)$$

für einen Spurwechsel nach links. Hierbei werden Spuren mit identischer Breite angenommen. Die Endbedingung für $t_2 = T_p$ lassen sich analog zu Gleichung (5.2.5) und (5.2.7) aufstellen.

Für die Dauer eines vollständigen Spurwechsels wird eine Standardzeit angenommen, die für Manöver in beide Richtungen identisch ist. Diese wurde aus aufgenommenen Spurwechseltrajektorien im realen Straßenverkehr bestimmt und ergibt sich im Mittel zu $t_{LC,d} = 4,5$ s. Um auch angefangene Spurwechsel korrekt zu berücksichtigen, wird das Manöver in einen Teil vor der Überquerung der Spurmarkierung und einen Teil auf der Zielspur aufgeteilt. Die verbleibende Zeit auf der aktuellen Spur wird in diesem Ansatz durch

$$\hat{t}_{LC} = \frac{d_{LM}}{|v_n|} \quad (5.2.8)$$

bestimmt, wobei d_{LM} den Abstand zu der zu überquerenden Spurmarkierung darstellt. Bei Annahme eines symmetrischen Spurwechselmanövers ergibt sich die Zeit bis zum Ende des Spurwechselmanövers zu $t_{CLC} = \hat{t}_{LC} + t_{LC,d}/2$.

Um die Unsicherheit der Prädiktion darzustellen wird eine lineare Unsicherheitsfortpflanzung umgesetzt, bei der ein zusätzlicher Term die Vergrößerung der Unsicherheit für steigende Prädiktionszeit beschreibt. Die Verteilung des ins kurvilineare Koordinatensystem transformierten Zustands wird als initiale Unsicherheit genutzt. Um die Varianz für die prädizierten Zustände zu bestimmen, wird die Gleichung

$${}^C\hat{\Sigma}^{(k)}(t_{n+1}) = \mathbf{A}_{CV} {}^C\hat{\Sigma}^{(k)}(t_n) \mathbf{A}_{CV}^T + \mathbf{B}^C \Sigma_u \mathbf{B}^T, \quad (5.2.9)$$

ausgewertet, wobei

$$\mathbf{A}_{CV} = \begin{bmatrix} 1 & 0 & \Delta T^2 & 0 \\ 0 & 1 & 0 & \Delta T^2 \\ 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 1 \end{bmatrix} \quad \text{und} \quad \mathbf{B} = \begin{bmatrix} \frac{\Delta T^4}{4} & 0 \\ 0 & \frac{\Delta T^4}{4} \\ \frac{\Delta T^2}{2} & 0 \\ 0 & \frac{\Delta T^2}{2} \end{bmatrix} \quad (5.2.10)$$

gilt. ${}^C\Sigma_u = \text{diag}(u_l, u_n)$ definiert hier den Anstieg der Unsicherheit pro prädiziertem Zeitintervall ΔT in longitudinaler sowie lateraler Komponente und ist ein einstellbarer Parameter.

5.3. Genauigkeit der vorhergesagten Trajektorien

Das vorgestellte Verfahren wird im Folgenden auf Basis der Datensätze aus der Simulationsumgebung und dem Testfahrzeug bewertet. Um die Abweichung der prädizierten Trajektorie von der Referenz zu bestimmen, wird die Prädiktion zum Zeitpunkt t_n mit den tatsächlichen Positionen im Intervall $[t_n, t_n + T_p]$ verglichen. Diese können nach der Aufnahme aus den Daten extrahiert werden. Im Falle der Simulation wird auf die bekannte Referenzposition im globalen Koordinatensystem zurückgegriffen, die in der Simulationsumgebung zu jedem Zeitpunkt bekannt ist. So kann der Fehler sehr präzise bestimmt werden und unterliegt keinerlei Ungenauigkeiten bei der Wahrnehmung. Für die mit einem Testfahrzeug aufgenommenen Daten ist die Bestimmung des Fehlers aufwendiger, da kein Referenzsystem zur Verfügung steht, das die exakte Position eines beobachteten Fahrzeugs in einem globalen Koordinatensystem bestimmen kann. Daher wird ein Fahrzeug, für das der Fehler der prädizierten Trajektorie bestimmt werden soll, über mehrere Zeitschritte beobachtet und die im Ego-Koordinatensystem gemessenen Zustände aus dem Intervall $[t_n, t_n + T_p]$ mit Hilfe der Eigenbewegung des Ego-Fahrzeugs in das Fahrzeug-Koordinatensystem zum Zeitpunkt t_n transformiert. So kann die Bewegung des beobachteten Fahrzeugs mit der zum Zeitpunkt t_n prädizierten Trajektorie verglichen werden. Durch diese Vorgehensweise fließen in die Fehlerberechnung allerdings zusätzliche Ungenauigkeiten ein. Zum einen ist der gemessene Zustand des beobachteten Fahrzeugs nur eine Schätzung des tatsächlichen Zustands, die mit Hilfe von unterschiedlichen Sensoren und einem Tracking Algorithmus erstellt wird. Zusätzlich wird die Fahrzeugeigenbewegung nur auf Basis der fahrzeuginternen Größen ohne ein externes Messsystem, wie etwa ein hoch genaues GPS, geschätzt. Damit akkumuliert sich der Schätzfehler über die Prädiktionsdauer und hat ebenfalls einen Einfluss auf den resultierenden Fehler der Trajektorienprädiktion.

Um eine Einschätzung der Güte der prädizierten Trajektorien zu erhalten, wird das Verfahren mit zwei weiteren Ansätzen, die eine konstante Geschwindigkeitsschätzung umsetzen, verglichen. Zunächst wird die zukünftige Trajektorie auf Basis der aktuellen Geschwindigkeit und Orientierung im Ego-Koordinatensystem bestimmt. Dazu werden die zukünftigen Zustände auf Basis des aktuellen Zustands und eines Bewegungsmodells berechnet. Das Verfahren ist im Anhang in Abschnitt A.3.3 genauer erläutert und wird im Folgenden mit CV bezeichnet. Zusätzlich wird eine Vorhersage auf Basis der aktuellen Geschwindigkeit in kurvilinearen Koordinaten als Vergleich herangezogen. Dazu werden erkannte Fahrzeuge zunächst in das in Abschnitt 2.3 vorgestellte Koordinatensystem überführt. Anschließend werden die zukünftigen Zustände anhand der Geschwindigkeit in kurvilinearen Koordinaten mit Hilfe des Bewegungsmodells bestimmt und zurück in das kartesische Ego-Koordinatensystem transformiert. Aufgrund der kurvilinearen Transformation wird der Ansatz mit CVCL bezeichnet. Anhand der Vergleiche mit diesen beiden Verfahren werden zum einen die Vor- und Nachteile der kurvilinearen Betrachtung und zum anderen der Einfluss der manöverbasierten Vorhersage deutlich.

Nachfolgend werden zunächst die Kriterien zur Bewertung der Trajektorienprädiktion vorgestellt. Daraufhin wird das vorgestellte Verfahren auf Simulationsdaten ausgewer-

tet und anschließend die Güte auf Basis von Daten aus dem Testfahrzeug bestimmt.

Bewertungskriterien für prädizierte Trajektorien

Bei der Bewertung von prädizierten Trajektorien ist das natürlichste Kriterium der Abstand zwischen zueinander korrespondierenden Zuständen der Prädiktion und der Referenztrajektorie $\hat{\mathbf{x}}(\tau)$. Die entsprechende Metrik bewertet die Wurzel des mittleren quadratischen Abstands zwischen der Referenztrajektorie und der wahrscheinlichsten Trajektorie der geschätzten Verteilung. Durch die Modellierung der prädizierten Trajektorie als eine Abfolge von Zuständen mit einer normalverteilten Unsicherheit in dem vorgestellten Ansatz kann die wahrscheinlichste Trajektorie über die Mittelwerte der Prototypentrajektorie, die dem Manöver mit der größten Wahrscheinlichkeit entspricht, bestimmt werden. Allerdings ist bei der Verwendung der euklidischen Distanz die unterschiedliche Größenordnung des erwarteten Fehlers in longitudinaler und lateraler Richtung zu beachten. In den betrachteten Autobahnszenarien ist eine deutlich größere longitudinale als laterale Geschwindigkeit $v_y \ll v_x$ zu erwarten, sodass ein entsprechend größerer Fehler entsteht. Eine kombinierte Betrachtung von Längs- und Querrichtung wird daher nicht vorgenommen. Vielmehr ist es für eine detaillierte Analyse sinnvoll, die Fehlerbetrachtung in lateraler und longitudinaler Komponente voneinander zu trennen. Daher wird der absolute Fehler in beiden Komponenten

$$e_{x,i}(\tau) = |\hat{x}_i(\tau) - \hat{x}_i(\tau)| \text{ und } e_{y,i}(\tau) = |\hat{y}_i(\tau) - \hat{y}_i(\tau)| \quad (5.3.1)$$

sowie deren Mittelwerte

$$\text{MAE}_x(\tau) = \frac{1}{n_{S,TP}} \sum_{i=1}^{n_{S,TP}} e_{x,i}(\tau) \text{ und } \text{MAE}_y(\tau) = \frac{1}{n_{S,TP}} \sum_{i=1}^{n_{S,TP}} e_{y,i}(\tau) \quad (5.3.2)$$

für $n_{S,TP} \in \mathbb{N}_+$ Beispiele betrachtet. Dabei ist aufgrund der unterschiedlichen Wertebereiche der Geschwindigkeit $\text{MAE}_y(\tau) < \text{MAE}_x(\tau)$ zu erwarten. Besonders der MAE_y ist im Kontext des Autobahnszenarios leicht zu interpretieren, da eine Prädiktion mit einem Fehler größer als die halbe Spurbreite das beobachtete Fahrzeug der falschen Spur zuordnet.

Die reine Betrachtung des Abstandes zwischen der Prädiktion und der Referenz berücksichtigt keine Informationen über die Verteilung der prädizierten Trajektorien. Um diese in der Auswertung zu betrachten, wird zusätzlich die mittlere Likelihood der Referenztrajektorie für die geschätzte Verteilungsfunktion bestimmt

$$\mathcal{L}(\tau) = \frac{1}{n_{S,TP}} \sum_{i=1}^{n_{S,TP}} \prod_{m \in \mathcal{M}} p(m(\tau)) p(\hat{\mathbf{x}}_i(\tau) | \hat{\mathbf{x}}_i(\tau)). \quad (5.3.3)$$

Generell gilt: Je größer die Likelihood desto besser stimmt die Referenztrajektorie mit der geschätzten Verteilung überein.

Auswertung mit Simulationsdaten

Für die Auswertung mit der Simulationsumgebung werden Szenarien mit einer unterschiedlichen Anzahl an Spuren und verschiedenen Krümmungen des Straßenverlaufs

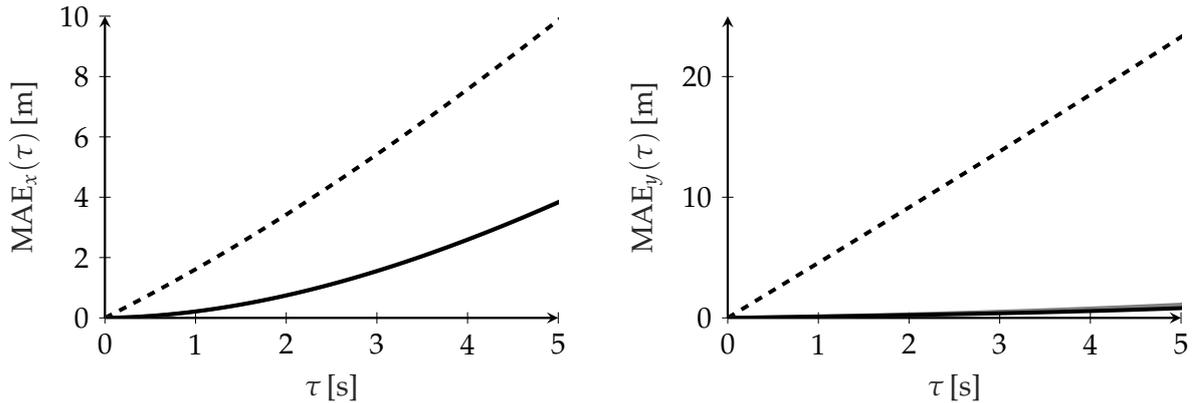


Abbildung 5.3.: Vergleich des longitudinalen (links) und lateralen (rechts) Fehlers für CV (gestrichelt), CVCL (grau) und MBTP (schwarz).

betrachtet. Zusätzlich wird in den Szenarien eine variable Verkehrsdichte abgebildet. Weitere Informationen über die verwendeten Szenarien sind im Anhang in Abschnitt A.4.1 zu finden. Für die Auswertung werden lediglich Fahrzeuge betrachtet, die sich vor dem Ego-Fahrzeug befinden und einer der detektierten Fahrspuren zugeordnet werden können, da nur für diese eine Manöverklassifikation vorliegt.

Zunächst wird der Vergleich der drei Verfahren in allen verwendeten Szenarien betrachtet. In Abbildung 5.3 ist der longitudinale und laterale Fehler über die Prädiktionszeit τ aufgetragen. Hierbei schneidet die Prädiktion mit konstanter Geschwindigkeit in kartesischen Koordinaten am schlechtesten ab. Besonders der laterale Fehler beträgt bereits bei 2 s Prädiktionszeit nahezu 10 m, womit die Trajektorie deutlich neben der eigentlichen Fahrbahn liegen würde. Der große Fehler resultiert vor allem aus den simulierten Szenarien mit kleinen Krümmungsradien. Mit der Annahme konstanter Geschwindigkeit und Orientierung wird in jedem Fall lediglich eine geradeaus Fahrt prädiziert, sodass ein detektierter Kurvenverlauf nicht berücksichtigt wird. Durch die Anwendung der kurvilinearen Transformation profitieren die beiden anderen betrachteten Verfahren von der Repräsentation des Straßenverlaufs im Umgebungsmodell. Außerdem resultiert jeder Fehler der gemessenen Orientierung direkt in einem großen Fehler der prädizierten Trajektorie.

Aufgrund des deutlich größeren Fehlers der Prädiktion in kartesischen Koordinaten wird dieser Ansatz im Folgenden nicht weiter als Vergleich herangezogen, sodass lediglich die beiden Verfahren in kurvilinearere Form betrachtet werden. Für beide Ansätze sind in Abbildung 5.4 die einzelnen Komponenten des Zustandsfehlers dargestellt. Die Fehler in der longitudinalen Position und Geschwindigkeit zeigen keinen statistisch signifikanten Unterschied. Dies lässt sich durch die Gemeinsamkeit der Annahme einer konstanten Geschwindigkeit über die Prädiktionszeit und während des prädizierten Manövers begründen. Entsprechend verwenden beide Ansätze die gleiche Vorgehensweise, um die Geschwindigkeit zu bestimmen. Kleine Unterschiede können durch die Betrachtung von Fahrmanövern für die Prädiktion bei gekrümmten Straßenverläufen entstehen, da Zustände mit einer ähnlichen longitudinalen Komponente entlang des Straßenverlaufs, die einen Unterschied in der lateralen Komponente aufweisen, durch die Transformation in kartesische Koordinaten eine deutliche Ab-

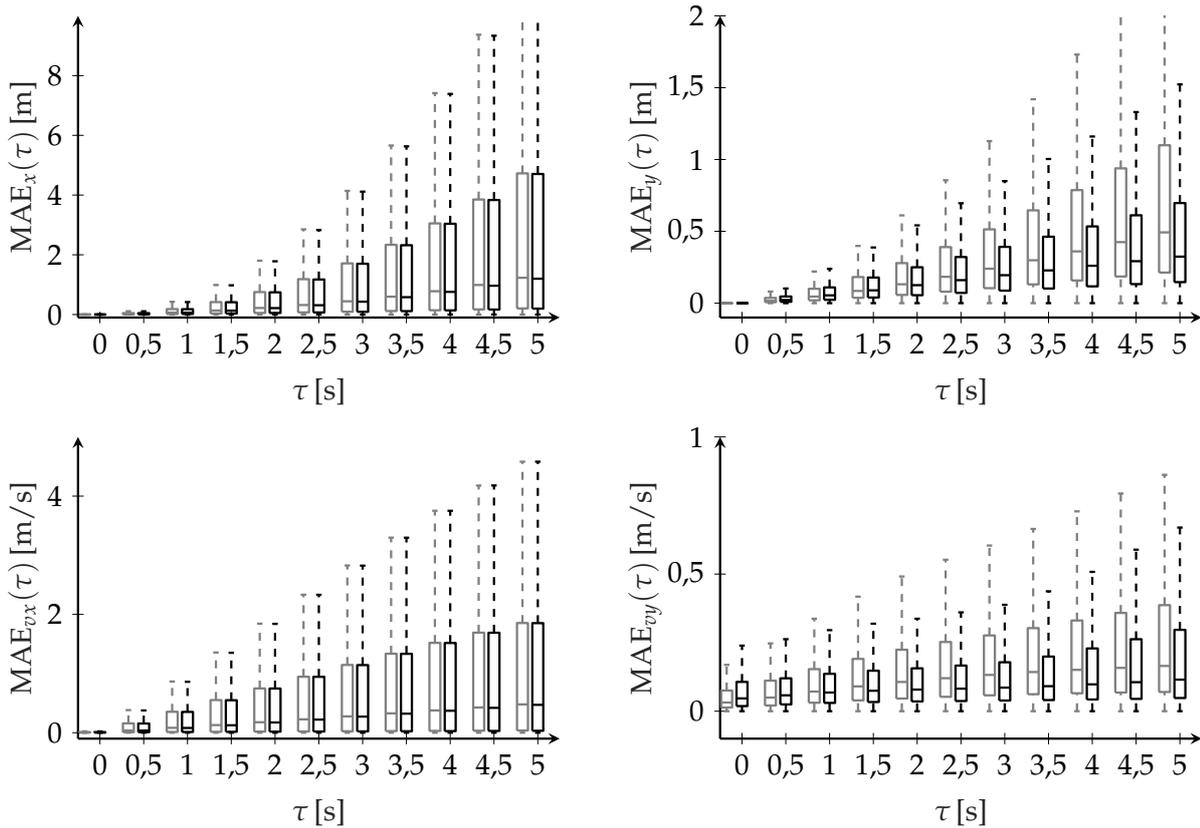
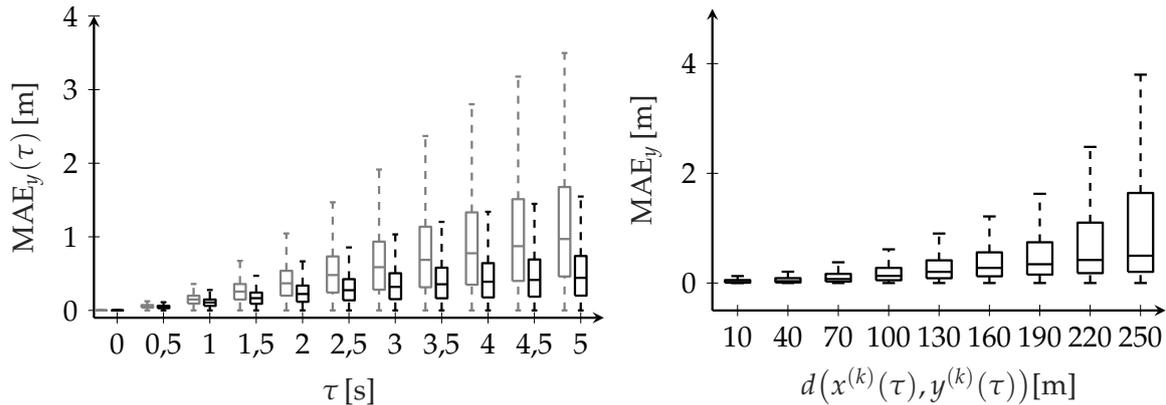


Abbildung 5.4.: Boxplot des Zustandsfehlers für CVCL (grau) und MBTP (schwarz) über die Prädiktionszeit für alle Simulationsdaten. Oben links ist der Fehler der longitudinalen Positionsschätzung, unten links der longitudinalen Geschwindigkeitsschätzung, oben rechts der lateralen Position und unten rechts der lateralen Geschwindigkeit. Die waagerechte Linie innerhalb der Boxen ist der Median des Fehlers, die unteren und oberen Grenzen der Boxen sind das 25% und 75% Quantil des Fehlers und die gestrichelten Linien beschreiben den Bereich, in dem 99,3% aller Fehler liegen.

weichung in der x Komponente haben können. Insgesamt liegt der mittlere Fehler für die geschätzte longitudinale Geschwindigkeit unter einem Meter pro Sekunde, sodass sich für eine Prädiktionszeit von fünf Sekunden ein longitudinaler Positionsfehler von unter zwei Metern im Mittel ergibt. Bei drei Sekunden Prädiktionszeit liegen 99,3% aller Fehler unter vier Metern, also in etwa einer Autolänge. Für eine größere Prädiktionsdauer steigt der Fehler der geschätzten longitudinalen Geschwindigkeit linear an, sodass sich der Positionsfehler quadratisch entwickelt und die obere Grenze des Fehlerintervalls 10 m übersteigt. Allerdings liegt auch für diese Prädiktionsdauer ein Großteil der Fehler unterhalb von vier Metern. Insgesamt zeigt sich, dass die Annahme einer konstanten longitudinalen Geschwindigkeit bei der Verwendung einer kurvilinearen Darstellung gut für die Prädiktion in Autobahnscenarien geeignet ist.

Anhand des lateralen Fehlers zeigt sich sowohl in der Geschwindigkeit also auch bei dem Positionsfehler ein deutlicher Unterschied zwischen den beiden Verfahren. Ab einer Prädiktionszeit von $\tau = 2$ s ist der Fehler des manöverbasierten Ansatzes signifikant kleiner. Für $\tau = 5$ s ergibt sich ein Median des lateralen Positionsfehlers für



(a) Fehler in der lateralen Positionsschätzung für korrekt erkannte Spurwechselmanöver für CVCL (grau) sowie MBTP (schwarz). (b) Lateraler Positionsfehler von der MBTP über die Distanz zum Ego-Fahrzeug.

Abbildung 5.5.: Lateraler Positionsfehler für Spurwechselmanöver (rechts) und Distanzabhängigkeit des lateralen Fehlers (links).

den CVCL Ansatz von in etwa einem halben Meter und für MBTP ein Median von $MAE_y(\tau = 5 \text{ s}) = 0,32 \text{ m}$. Vor allem die Fehlerverteilung des manöverbasierten Ansatzes zeigt eine deutliche Verbesserung, da hier 99,3 % aller Fehler geringer als 1,6 m sind. Damit sind nahezu alle Fehler kleiner als die reguläre Spurbreite einer Deutschen Autobahn (siehe [BAS14]). Hier werden die Vorteile des manöverbasierten Ansatzes gegenüber der Annahme einer konstanten Geschwindigkeit und Orientierung deutlich. Die explizite Betrachtung von Fahrmanövern erlaubt eine Prädiktion entlang einer erkannten Fahrspur oder im Falle eines detektierten Spurwechsels auf die jeweilige Zielspur. Dem gegenüber ist die Prädiktion einer geradeaus Fahrt lediglich in Szenarien mit einer kleinen oder ohne Krümmung sinnvoll. Abbildung 5.4 zeigt dabei den Gesamtfehler beider Verfahren. Das schließt ebenfalls die Situationen mit ein, in denen der Ansatz zur Manöverklassifikation aus Kapitel 4 eine fehlerhafte Klassifikation durchführt. In einem solchen Fall ist ein großer lateraler Fehler zu erwarten, da die Trajektorie auf die falsche Fahrspur prädiert wird. Allerdings sind diese Fälle im Vergleich zu den restlichen untersuchten Beispielen selten, sodass sie wenig Einfluss auf die Gesamtgüte haben.

Der Unterschied zwischen beiden Verfahren wird bei dem Vergleich des lateralen Fehlers für Situationen, in denen die verwendete Manöverprädiktion eine korrekte Vorhersage für Spurwechselvorgänge ergibt, noch deutlicher (siehe Abbildung 5.5a). Der Fehler der CVCL ist in diesen Fällen sichtbar größer, sodass der Median bei nahezu einem Meter für eine Prädiktionszeit von $\tau = 5 \text{ s}$ liegt. Damit ist dieser mehr als doppelt so groß wie der Fehler des manöverbasierten Ansatzes für die gleiche Prädiktionszeit. Es zeigen sich deutlich die Vorteile der expliziten Betrachtung des Fahrmanövers für die Prädiktion der Trajektorien.

Die Güte der prädierten Trajektorien hängt nicht nur von der Prädiktionsdauer sondern auch von der euklidischen Distanz des zu prädiierenden Fahrzeugs zum Ego-Fahrzeug ab $d(x^{(k)}(\tau), y^{(k)}(\tau))$. Der Zusammenhang ist in Abbildung 5.5b dargestellt und zeigt einen steigenden Fehler für wachsende Distanzen. Der Grund liegt zum

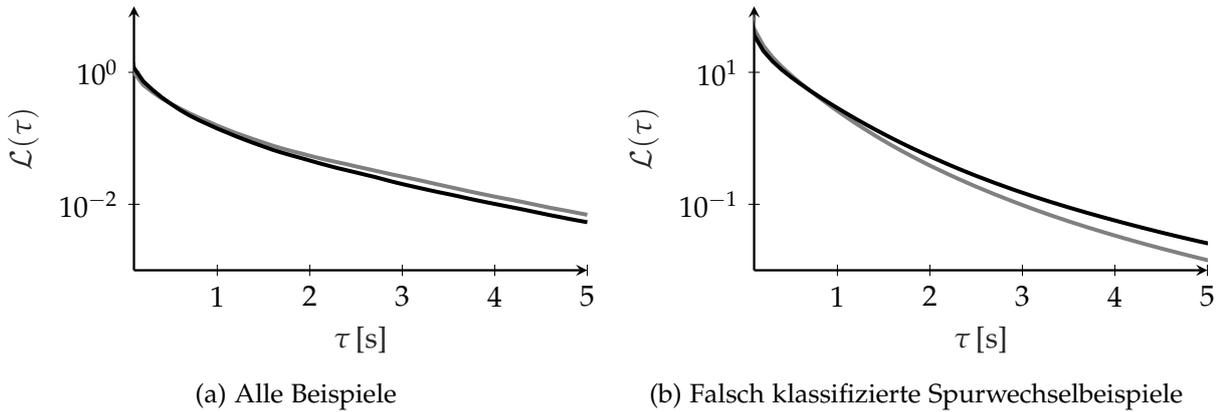


Abbildung 5.6.: Vergleich der Likelihood für die Verfahren CVCL (grau) sowie MBTP (schwarz).

einen in der weniger gut geschätzten Verteilung des aktuellen Zustandes und damit der Ausgangsgröße der Trajektorienprädiktion. Zum anderen ist das Umgebungsmodell und insbesondere die Abbildung des Verlaufs der Straße für große Distanzen sehr ungenau. Da die Kamera nur einen sehr kurzen Teil der Spurmarkierungen erfassen kann, muss der weitere Straßenverlauf extrapoliert werden. Hierbei entsteht durch die Extrapolation mit konstanter Krümmung ein großer Fehler, sobald sich die tatsächliche Krümmung ändert. Der Fehler kann durch den Einsatz einer digitalen Karte, die den weiteren Straßenverlauf enthält, deutlich verringert werden.

Neben den absoluten Abweichungen des Mittelwertes soll die Abbildung der Verteilungen beider Verfahren verglichen werden. Hierzu ist in Abbildung 5.6a die mittlere Likelihood der Referenztrajektorie für die geschätzten Zustandsverteilung über die Prädiktionszeit aufgetragen. Auf der linken Seite ist das Ergebnis für alle genutzten Beispiele dargestellt. Für beide Verfahren verringert sich die Likelihood für große Prädiktionszeiten deutlich. Dies resultiert aus der Modellierung der Unsicherheit und deren Propagierung über die Prädiktionszeit. Ausgehend von der Unsicherheit im Umgebungsmodell vergrößert sich diese mit jedem Prädiktionsschritt, sodass die Verteilung insgesamt breiter wird und damit die Likelihood auch für vergleichbare kleine Fehler bei beiden Verfahren abnimmt. Ein Vorteil der manöverbasierten Trajektorienprädiktion ist die Darstellung der prädizierten Trajektorien als multimodale Verteilung mit den verschiedenen Manöverklassen als Moden. Mit Hilfe der probabilistischen Manöverklassifikation können auch weniger wahrscheinliche Trajektorien innerhalb der Prädiktion berücksichtigt werden. Gleichzeitig ist die Wahrscheinlichkeit für einen Spurwechsel auch während Spurhaltenmanövern nicht immer exakt Null, was in Verbindung mit der deutlich häufiger auftretenden Klasse Spurhalten zu einer leicht verringerten Likelihood für den gesamten Datensatz in Abbildung 5.6a führt. Allerdings erreicht der manöverbasierte Ansatz in Spurwechselsituationen eine höhere Likelihood. Dies zeigt sich insbesondere in der in Abbildung 5.6b dargestellten Likelihood für falsch klassifizierte Spurwechselbeispiele. In diesem Fall führt das beobachtete Fahrzeug ein Spurwechselmanöver $m_i^{(k)}$ aus, während die Manöverklassifikation ein anderes Manöver $p(m_i^{(k)}) < p(m_j^{(k)})$ klassifiziert. Wenn allerdings $p(m_i^{(k)}) > 0$ gilt, wird neben der wahrscheinlichsten auch eine Trajektorie für Manöver $m_i^{(k)}$ prädiziert,

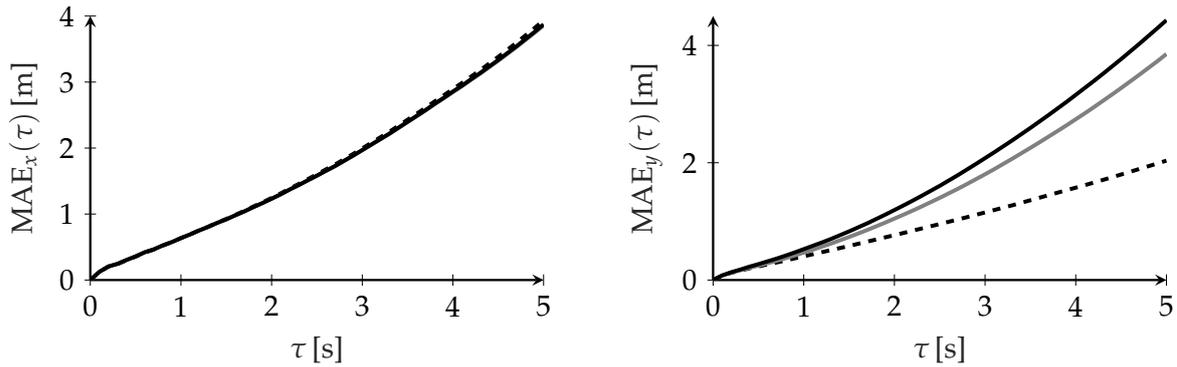


Abbildung 5.7.: Vergleich des longitudinalen (links) und lateralen (rechts) Fehlers für die Verfahren CV (gestrichelt), CVCL (grau) und die manöverbasierten Prädiktion in kurvilinearen Koordinaten (schwarz) für Daten, die mit dem Testfahrzeug aufgenommen wurden.

womit die Likelihood der Referenztrajektorie steigt. Entsprechend ist die Likelihood des manöverbasierten Ansatzes in Abbildung 5.6b ab einer Prädiktionszeit von $\tau = 1$ s größer als die des unimodalen Ansatzes CVCL.

Die Vorteile der manöverbasierten Trajektorienprädiktion werden anhand der Auswertung auf Basis der Simulationsdaten deutlich. Gerade in kurvigen Szenarien und in Situationen, in denen die beobachteten Fahrzeuge Spurwechsel ausführen, ist die Güte deutlich höher als bei Ansätzen, die eine konstante Geschwindigkeit und Orientierung annehmen. Durch die Verwendung einer probabilistischen Manöverklassifikation können zusätzlich weniger wahrscheinliche Manöver in der Prädiktion berücksichtigt werden.

Auswertung mit Daten aus dem Testfahrzeug

Die vorgestellten Ansätze werden zusätzlich mit Daten evaluiert, die mit dem Testfahrzeug in Autobahnszenarien aufgenommen wurden. In Abbildung 5.7 ist der longitudinale und laterale Positionsfehler für CV (gestrichelt), CVCL (grau) und MBTP (schwarz) dargestellt. Der longitudinale Fehler (links) zeigt nur geringe Unterschiede zwischen den einzelnen Ansätzen. Durch die gemeinsame Annahme einer konstanten Geschwindigkeit sind alle Prädiktionen sehr ähnlich. Für eine Prädiktionszeit $\tau > 3$ s ist der Fehler in kurvilinearen Koordinaten etwas kleiner als in kartesischen. Ein deutlich größerer Unterschied ist im Vergleich des lateralen Fehlers (Abbildung 5.7 rechts) der Ansätze zu erkennen. Entgegen der Ergebnisse für Daten, die mit der Simulationsumgebung erzeugt wurden, zeigt sich für die beiden Verfahren, die eine Prädiktion in kurvilinearen Koordinaten vornehmen, ein deutlich schlechteres Ergebnis als für eine Prädiktion im kartesischen Ego-Koordinatensystem. Ab einer Prädiktionszeit von $\tau = 1$ s steigt der Fehler des manöverbasierten Ansatzes am stärksten bis auf nahezu 4,5 m an. Der Fehler der CVCL ist etwas geringer, liegt allerdings über der einfachen Prädiktion in kartesischen Koordinaten.

Die niedrigere Güte der kurvilinearen Ansätze hat verschiedene Gründe, die im Folgenden detailliert beschrieben werden. Zum einen enthalten die Daten, die mit dem Testfahrzeug aufgenommen wurden, nur Szenarien mit einer sehr geringen Krüm-

mung. Der überwiegende Anteil der Daten wurde auf nahezu geraden Straßenabschnitten aufgenommen, sodass der größte Vorteil der kurvilinearen Transformation keinen positiven Einfluss auf die Ergebnisse der Trajektorienprädiktion hat. Da in den Daten der Simulation Szenarien mit einer höheren Krümmung enthalten sind, werden hier die Vorteile der Transformation deutlich. Zum anderen ist die Schätzung der Spurmarkierungen nur auf kurze Distanz zuverlässig und neigt besonders am Ende des wahrgenommenen Bereiches zur Überschätzung der tatsächlichen Krümmung. Für die Transformation in das kurvilineare Koordinatensystem ist eine Extrapolation des Spurverlaufes notwendig, da sich die beobachteten Fahrzeuge häufig außerhalb des detektierten Bereiches der Spurmarkierungen bewegen. Um auch in kurvigen Szenarien eine Extrapolation zu ermöglichen, wird eine konstante Krümmung am Ende des sichtbaren Spurpolynoms angenommen. Durch Ungenauigkeiten in der Wahrnehmung weisen auch gerade Straßenabschnitte eine Krümmung auf, sodass der Straßenverlauf nicht als Gerade extrapoliert wird. In Abbildung 5.8 ist eine entsprechende Situation dargestellt. Anhand der detektierten Fahrzeuge und deren Referenztrajektorien (schwarze Linien mit Kreuzen) wird deutlich, dass der Straßenverlauf näherungsweise gerade ist. Der extrapolierte Verlauf zeigt allerdings eine deutliche Krümmung nach rechts. Da dieser als Referenz für die Transformation in das kurvilineare Koordinatensystem verwendet wird, hat die schlechte Schätzung des Straßenverlaufs einen großen Einfluss auf die prädizierte Trajektorie. Anhand Abbildung 5.7 wird deutlich, dass die fehlerhafte Modellierung der Straße einen größeren Fehler verursacht als die Annahme einer konstanten Geschwindigkeit und Orientierung.

Aus Abbildung 5.8 wird auch der kleinere Fehler des Ansatzes CVCL gegenüber der manöverbasierten Trajektorienprädiktion ersichtlich. Durch die Annahme einer konstanten Orientierung bewegt sich das Fahrzeug nicht ausschließlich entlang der extrapolierten Spur, sondern kann eine laterale Geschwindigkeit relativ zur Spur aufweisen. Bei der manöverbasierten Prädiktion wird angenommen, dass das Fahrzeug der Spurmitte folgt und somit keine laterale Geschwindigkeit relativ zur Spur aufweist. Der schlecht extrapolierte Spurverlauf wirkt sich somit stärker auf die prädizierte Trajektorie aus.

Insgesamt zeigt sich, dass die Verwendung der manöverbasierten Trajektorienprädiktion in Verbindung mit der kurvilinearen Darstellung bei der Qualität des Umgebungsmodells, die die verwendeten Daten aus dem Testfahrzeug aufweisen, nicht gerechtfertigt ist. Durch die schlechte Abbildung des Spurverlaufes entstehen große Fehler in den prädizierten Zuständen der beobachteten Verkehrsteilnehmer, sodass eine Prädiktion mit der Annahme einer konstanten Geschwindigkeit und Orientierung ein genaueres Ergebnis erzeugt. Die Ergebnisse der Simulationsdaten zeigen allerdings auch, dass die kurvilineare Darstellung und insbesondere der manöverbasierte Ansatz stark von einem guten Umgebungsmodell profitiert.

5.4. Diskussion der simulationsbasierten Entwicklung

Die Auswertung des vorgestellten manöverbasierten Ansatzes zur Trajektorienprädiktion zeigt, dass die Betrachtung von einzelnen Fahrmanövern bei einer ausreichenden

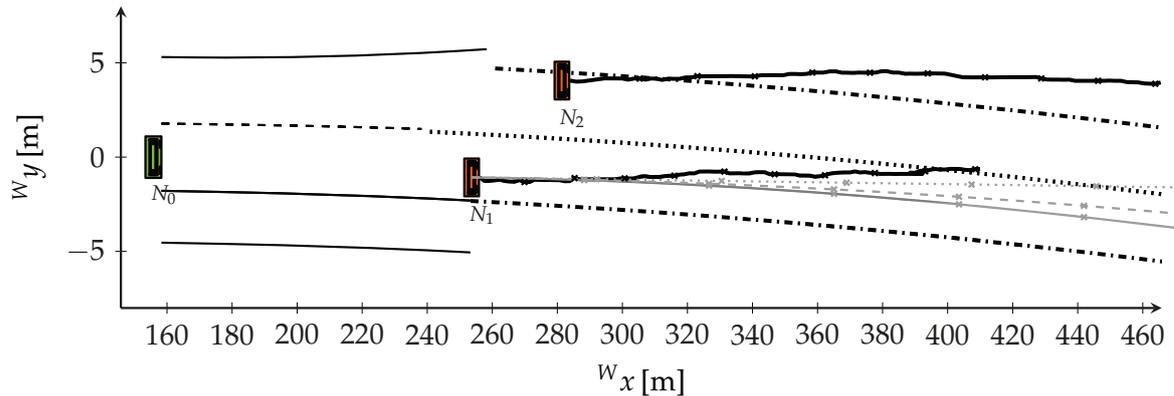


Abbildung 5.8.: Darstellung der extrapolierten Spurmarkierungen für ein Szenario mit einem geraden Spurverlauf und der daraus resultierenden Trajektorienprädiktion für das Fahrzeug N_1 mit den Verfahren: CV (grau, gepunktet), CVCL (grau, gestrichelt), MBTP (grau, durchgezogene Linie). Zusätzlich ist die Referenztrajektorie dargestellt (schwarz, durchgezogene Linie).

Güte des Umgebungsmodells eine Steigerung der Genauigkeit der prädizierten Trajektorien erreichen kann. Die verwendete kurvilineare Darstellung erlaubt auch bei Straßenverläufen mit einer signifikanten Krümmung eine gute Prädiktion mit einfachen Prädiktionsmodellen und bietet damit einen Gewinn gegenüber der Betrachtung in kartesischen Koordinaten. Die Transformation setzt allerdings eine gute Beschreibung des Straßenverlaufes voraus, um anhand dessen alle detektierten Objekte in kurvilineare Koordinaten zu überführen. Bei der Auswertung der Daten, die mit einem Testfahrzeug aufgenommen wurden, stellt sich heraus, dass die wahrgenommenen Spurmarkierung den Straßenverlauf nicht ausreichend genau abbilden, sodass bei einer Extrapolation falsche Krümmungswerte angenommen werden. Die auf dieser Basis durchgeführte Transformation bewirkt einen starken Anstieg des Prädiktionsfehlers und somit ein schlechteres Ergebnis als die Annahme einer konstanten Geschwindigkeit und Orientierung zur Prädiktion der Trajektorie. Entsprechend unterscheiden sich die Ergebnisse, die auf Basis der Simulationsdaten erzeugt wurden, systematisch von denen, die mit den Daten aus dem Testfahrzeug gewonnen wurden. Die Erkenntnisse, die mit Hilfe der Simulationsumgebung gewonnen wurden, können im vorliegenden Fall nicht direkt auf die Anwendung im Testfahrzeug übertragen werden.

Allerdings zeigt die Verwendung der Simulation deutlich die Potentiale, die einen komplexerer Ansatz zur Trajektorienprädiktion bietet und welche Voraussetzungen das zur Verfügung stehende Umgebungsmodell erfüllen muss. In diesem Fall ist eine Verbesserung des Prädiktionsfehlers durch eine bessere Abbildung des Straßenverlaufes möglich. Diese könnte auf unterschiedliche Weise erreicht werden. Die Verwendung einer hoch genauen digitalen Karte bietet bei einer guten Lokalisierung in dieser präzise Informationen über den weiteren Straßenverlauf weit über die Sensorsichtweite hinaus und eignet sich damit sehr gut als Referenz für die Transformation in das kurvilineare Koordinatensystem (siehe [Sch+13]). Eine weitere Möglichkeit wäre die Verwendung von detektierten Leitplanken und Fahrzeugen, um ein konsistentes Umgebungsmodell mit einer guten Schätzung des Straßenverlaufes zu erhalten (siehe [Ham+16]).

Aufgrund der schlechten Abbildung des Straßenverlaufes im Umgebungsmodell in

den Daten aus dem Testfahrzeug und den daraus resultierenden Ergebnissen der manöverbasierten Trajektorienprädiktion werden die Daten aus dem Testfahrzeug für die Verfahren in den nachfolgenden Kapiteln nicht weiter betrachtet. Da die in den Kapiteln 7 und 8 vorgestellten Ansätze eine starke Abhängigkeit von einem guten Umgebungsmodell aufweisen, sind für die zur Verfügung stehenden Daten keine aussagekräftigen Ergebnisse zu erwarten.

6

Schätzung zeitlicher Manövereigenschaften

Der im letzten Kapitel vorgestellte Ansatz zur Trajektorienprädiktion nutzt die Manöverklassifikation, um auf Basis der geschätzten Manöver die Verteilung der zukünftigen Zustände zu präzisieren. Allerdings lässt die alleinige Information, welches Manöver mit größter Wahrscheinlichkeit ausgeführt wird, keinerlei Rückschluss auf die jeweilige Manöverdynamik zu. Gerade für *cut-in* Manöver auf Autobahnen hat die laterale Geschwindigkeit, mit der der Spurwechsel durchgeführt wird und die damit verbundene Spurwechselfdauer, einen entscheidenden Einfluss auf die notwendige Reaktion des Ego-Fahrzeugs. Im Falle eines schnellen Spurwechsels des beobachteten Fahrzeugs ist eine frühere und unter Umständen stärkere Anpassung der Geschwindigkeit des Ego-Fahrzeugs erforderlich. Daher wird in diesem Kapitel ein Verfahren zur Schätzung der verbleibenden Zeit bis zum Spurwechsel vorgestellt. In diesem Zusammenhang werden zunächst die zeitlichen Eigenschaften eines Spurwechselmanövers dargelegt und das Problem der Schätzung dieser definiert. Anschließend wird das verwendete Schätzverfahren näher erläutert. Schließlich wird die Genauigkeit auf Basis des Datensatzes aus der Simulationsumgebung evaluiert.

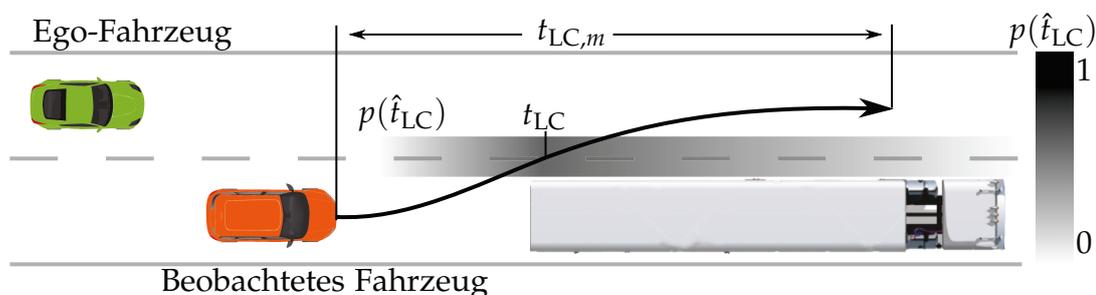


Abbildung 6.1.: Visualisierung der verbleibenden Zeit bis zum Spurwechsel und der unsicheren Schätzung.

6.1. Zeitliche Eigenschaften eines Spurwechsels

Neben dem Zeitpunkt eines Spurwechsels kann sich die Ausführung abhängig vom Fahrer und der Verkehrssituation deutlich unterscheiden. Ein langsames Führungsfahrzeug bewirkt häufig einen schnelleren Spurwechsel, während ein Wechsel auf die rechte Spur, um das Rechtsfahrgebot umzusetzen, eher langsam ausgeführt wird. Außerdem neigen sportliche Fahrer zu einer schnelleren Ausführung eines Spurwechsels. Dies motiviert die Betrachtung der Manöverdynamik für eine Prädiktion der zukünftigen Bewegung. Da die Länge der gefahrenen Spurwechseltrajektorie von der Fahrzeuggeschwindigkeit abhängt, wird die Dynamik über die Manöverdauer $t_{LC,m}$ beschrieben. $t_{LC,m}$ repräsentiert die Gesamtdauer eines Spurwechselmanövers sowohl auf der aktuellen als auch auf der Zielspur und ist in Abbildung 6.1 visualisiert. Für das Ego-Fahrzeug ist in dieser Situation besonders der Zeitpunkt von Interesse, zu dem das beobachtete Fahrzeug die Spurmarkierung überquert t_{LC} ¹. Spätestens von diesem Zeitpunkt an muss dieses unabhängig von der Position innerhalb der Spur als neues Führungsfahrzeug betrachtet werden. Daher wird in diesem Kapitel ein Ansatz vorgestellt, der die Zeit bis zum Überqueren der Spurmarkierung \hat{t}_{LC} schätzt. Da der Fahrertyp eines beobachteten Fahrzeugs mit Sensoren des Ego-Fahrzeugs nicht messbar ist und dieser die Ausführung eines Spurwechsels stark beeinflusst, kann die Schätzung von \hat{t}_{LC} nicht als Punktschätzung vorgenommen werden. Das verwendete Verfahren muss eine entsprechende Unsicherheit der Schätzung modellieren, welche die Verteilung des Spurwechselzeitpunktes $p(\hat{t}_{LC})$ berücksichtigt. Dabei können über die Ausprägung der Verteilung keine Annahmen gemacht werden, da sich die Form abhängig von der Situation verändert. Zu Beginn des Manövers zeigt sich eine stark unsymmetrische Verteilung, die für spätere Zeitpunkte langsam und flacher abfällt. Dies resultiert aus einer möglichen langsameren Ausführung oder einem potentiellen Abbruch des Manövers, zu dem sich ein Fahrer zu jeder Zeit entscheiden kann. Für kurze Zeitpunkte ist die Verteilung hingegen begrenzt, da ein Spurwechsel im Normalverkehr nur mit einer begrenzten Dynamik ausgeführt wird. Außerdem existiert eine fahrdynamische Grenze für die schnellere Ausführung des Manövers. Diese stellt in diesem Fall gleichzeitig die *worst-case* Annahme des Ego-Fahrzeugs dar. Eine Beispielveilung ist in Abbildung 6.2 links dargestellt. Kurz vor dem Spurwechsel verändert sich die Form der Verteilung. Da das Manöver fast abgeschlossen ist, entscheiden sich nur wenige Fahrer von dem Spurwechsel abzusehen, sodass die Verteilung nahezu symmetrisch um den wahrscheinlichsten Wert ist (siehe Abbildung 6.2 rechts). Die Darstellung mittels einer festen parametrischen Verteilungsform ist daher nicht möglich. Um trotzdem eine möglichst genaue Repräsentation zu erhalten, wird in dem vorgestellten Verfahren die Verteilung über eine Menge von bedingten Quantilen $\eta_i \in \Lambda$ approximiert. Die Schätzung einzelner bedingter Quantile kann dabei als Regressionsproblem formuliert werden und wird im nächsten Abschnitt näher erläutert.

Das Problem der Schätzung der verbleibenden Zeit bis zum Spurwechsel kann als eine Erweiterung der Manöverklassifikation auf Autobahnen angesehen werden. Grund-

¹Im weiteren Verlauf wird der tatsächliche Zeitpunkt des Spurwechsels analog zu \hat{x} mit \hat{t}_{LC} bezeichnet.

sätzlich wird zwischen Spurhalten und Spurwechseln in die jeweilige Richtung unterschieden. Daher werden für die Regression die gleichen Merkmale \mathcal{X} , wie bei der Klassifikation von Spurwechseln in Abschnitt 4.2 genutzt. Durch die Verwendung der Historie der Merkmale wird die Dynamik des Manövers erfasst und durch die situationsbasierten Merkmale wird die aktuelle Verkehrssituation berücksichtigt.

6.2. Schätzung des Spurwechselzeitpunktes als Regressionsproblem

Die bekannteste und häufig eingesetzte Form der Regression ist die Bestimmung eines funktionalen Zusammenhangs zwischen dem bedingten Mittelwert $\mathbb{E}[\hat{t}_{LC}]$ und gegebenen Merkmalen \mathcal{X} durch die Minimierung der quadratischen Residuen. Dies kann allerdings nur als die beste Schätzung angesehen werden, solange die Variable \hat{t}_{LC} normalverteilt ist. Im Fall von nicht-symmetrischen Verteilungen, deren Form sich abhängig von der Regressorvariable \mathcal{X} ändern kann, ist der Mittelwert mit einem normalverteilten Fehler nicht mehr ausreichend, um die Verteilung zu beschreiben. Die Quantil-Regression ermöglicht hingegen differenziertere Aussagen über die zugrunde liegende Verteilung, ohne dabei Annahmen über eine parametrische Form zu treffen [KB78].

Ein Quantil unterteilt generell eine Menge von Beispielen in zwei Untermengen, wobei links vom η -Quantil $100 \eta\%$ der Beispiele liegen. Das bekannteste Beispiel eines Quantils ist der Median ($\eta = 0,5$), der eine Menge in zwei exakt gleich große Teile aufteilt. Im Falle einer Wahrscheinlichkeitsdichte unterteilt das Quantil die Fläche unter dieser Kurve in zwei Abschnitte und ist definiert als

$$\hat{t}_{LC|\eta_i} = \inf\{\hat{t}_{LC} : p(\hat{t}_{LC}|\mathcal{X}) \geq \eta_i\}, \quad (6.2.1)$$

wobei $0 \leq \eta_i \leq 1$ gilt. Die Quantil-Regression verallgemeinert das Problem der Schätzung des bedingten Mittelwertes auf die Schätzung beliebiger Quantile der bedingten Verteilung. Anstatt die Summe der quadratischen Residuen zu minimieren wird für eine Menge von gegebenen Beispielen $\{\mathcal{X}_1, \mathcal{X}_2, \dots, \mathcal{X}_{n_S}\}$ die Summe der gewichteten absoluten Residuen

$$\Omega_{\eta_i}^* = \arg \min_{\Omega_{\eta_i}} \sum_{j=1}^{n_S} \rho_{\eta_i}(\hat{t}_{LC} - \Omega_{\eta_i}(\mathcal{X}_j)) \quad (6.2.2)$$

minimiert, um den optimalen Schätzer $\Omega_{\eta_i}^*$ des η -Quantils zu erhalten [KH01]. Dabei beschreibt $\rho_{\eta_i}(u)$ die geneigte Absolutwertfunktion

$$\rho_{\eta_i}(u) = \begin{cases} \eta_i u & u \geq 0 \\ (\eta_i - 1)u & u < 0 \end{cases}. \quad (6.2.3)$$

In Abbildung 6.2 sind beispielhaft drei Quantile der Verteilung für die verbleibende Zeit bis zum Spurwechsel illustriert. Zum einen ist der Median dargestellt, der gleichzeitig die wahrscheinlichste Schätzung des Spurwechselzeitpunktes repräsentiert. Zum anderen ist jeweils das 10 % und das 90 % Quantil abgebildet. Es ist zu

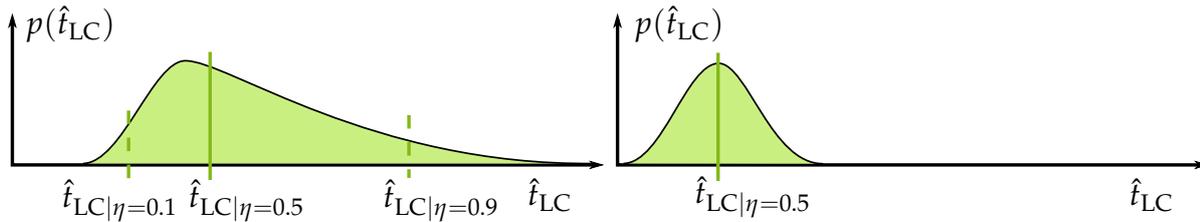


Abbildung 6.2.: Beispielhafte Verteilungen der geschätzten Zeit bis zum Spurwechsel mit verschiedenen Quantilen der Verteilung. Links einige Sekunden vor dem Spurwechsel, rechts unmittelbar vor dem Spurwechsel.

erkennen, dass diese durch die lange Ausprägung der Verteilung in Richtung späterer Zeitpunkte unterschiedlich weit vom Median entfernt sind. Mit Hilfe von Quantilen lassen sich dementsprechend auch nicht symmetrische Verteilungen beschreiben. Daher eignet sich die Quantil-Regression insbesondere für die Anwendung zur Schätzung der verbleibenden Zeit bis zum Spurwechsel. Sowohl die flach abfallende Seite in Richtung späterer Zeitpunkte als auch die sich ändernde Form der Verteilung kann mit Hilfe von Quantilen beschrieben werden. Dabei kann die Verteilung mit einer größeren Anzahl und damit einem geringeren Abstand zwischen den einzelnen Quantilen genauer beschrieben werden. Gleichzeitig wird allerdings je nach Regressionsverfahren jedes Quantil unabhängig voneinander geschätzt, sodass eine Erweiterung der Menge von Quantilen Λ direkt einen größeren Aufwand in der Berechnung bedeutet. In [Wis+17c] wurde daher untersucht, welche Verfahren sich für die Schätzung der Quantile der Verteilung des Spurwechselzeitpunktes eignen. Bei der linearen Quantil-Regression wird jedes zu schätzende Quantil durch eine Linearkombination der Regressorvariablen modelliert

$$\Omega_{\eta_i}(\mathcal{X}_i, \beta_{\eta_i}) = \beta_{\eta_i}^T \mathcal{X}_i \quad (6.2.4)$$

mit dem unbekanntem Parametervektor β_{η_i} . Die Parameter können durch die Lösung von Gleichung (6.2.2) bestimmt werden. Als alternatives nichtlineares Schätzverfahren werden *Quantile Regression Forests* angewendet, um die Quantile der Verteilung zu bestimmen. Der Vergleich zeigt, dass das nichtlineare Verfahren die verbleibende Zeit bis zum Spurwechsel deutlich genauer schätzen kann und gleichzeitig eine geringere Unsicherheit aufweist. Zusätzlich ist zu jeder Zeit die Konsistenz der einzelnen Quantile gegeben, sodass gilt $\eta_i > \eta_j$ für $i > j$. Bei der linearen Quantil-Regression ist dies durch die unabhängige Schätzung der einzelnen Quantile nicht garantiert. Für die Anwendung wird daher das Verfahren der *Quantile Regression Forests* verwendet, welches im Folgenden detailliert erläutert wird.

6.3. Quantile Regression Forest

Die Methode der *Quantile Regression Forests* (QRF) ist eine Erweiterung des *Random Forest* Algorithmus, der von Breiman [Bre01] eingeführt wurde. Das Verfahren erweitert das Konzept der Ensemble-Algorithmen für die probabilistische Prädiktion. Dazu werden anstatt des bedingten Mittelwertes einer Verteilung beliebige bedingte Quantile dieser vorhergesagt.

Im klassischen *Random Forest* Verfahren wird während des Trainings ein Ensemble von Entscheidungsbäumen erstellt. Um dabei die Varianz des Modells zu minimieren, wird ein *Bagging* Verfahren angewandt. Dabei wird jeder einzelne Entscheidungsbaum mit einer Teilmenge der Trainingsdaten erstellt. Diese wird zufällig mit zurücklegen aus der Gesamtmenge gezogen. Zusätzlich wird während der Erstellung eines Entscheidungsbaums für die Teilung in jedem Knoten eine zufällige Untermenge $\mathcal{B} \subseteq \mathbb{R}^{n_{\mathcal{X}}}$ aller Merkmale betrachtet. Die Anzahl der dabei berücksichtigten Merkmale $n_{\mathcal{F}}^{\text{QRF}} \leq n_{\mathcal{X}}$ ist ein Hyperparameter des Verfahrens. Beide Techniken reduzieren die Korrelation zwischen den einzelnen Bäumen im *Random Forest* sowie die Varianz des gesamten Modells. In jedem Blatt des resultierenden Baums wird der Mittelwert aller zugehörigen Trainingsbeispiele bestimmt. Insgesamt werden so $n_{\text{tree}}^{\text{QRF}}$ Entscheidungsbäume generiert. Für die Vorhersage eines neuen Beispiels wird über die Ausgabe aller Bäume im *Random Forest* gemittelt. Um das Ergebnis eines einzelnen Baums zu erhalten, wird am Wurzelknoten gestartet und die Knoten entlang des Baums für das Eingangsbeispiel ausgewertet. Die Prädiktion ist der Mittelwert des Blattes, in dem das Eingangsbeispiel endet.

Die Erweiterung zu *Quantile Regression Forests* wurde von Meinshausen [Mei06] eingeführt. Der QRF wird grundsätzlich auf die gleiche Art erstellt wie ein klassischer *Random Forest*. Anstatt für die Vorhersage den Mittelwert aller Trainingsbeispiele in den Blättern zu berechnen, werden die zu bestimmenden Quantile aus der Verteilung der Trainingsbeispiele berechnet. Damit ergibt sich für jeden einzelnen Baum eine Vorhersage für das bedingte Quantil. Die finale Prädiktion kann dann aus dem Mittelwert aller Quantile der einzelnen Bäume gebildet werden. Um auf Basis der Trainingsbeispiele in den Blättern der Bäume die Quantile berechnen zu können, muss eine ausreichend große Menge von Beispielen vorhanden sein, die eine gute Repräsentation der bedingten Verteilung abbilden. Daher wird ein zusätzlicher Parameter n_N^{QRF} eingeführt, der während des Trainings die minimale Anzahl an Beispielen pro Blatt definiert. Würde durch eine weitere Teilung die Anzahl der Beispiele in diesem Blatt unter n_N^{QRF} fallen, wird von der Teilung abgesehen. Es ergibt sich intuitiv der Nachteil, dass für jeden Baum im QRF die Beispiele in jedem Blatt vorgehalten werden müssen. Dadurch ergibt sich je nach Umfang der Trainingsdaten ein erheblicher Speicherbedarf.

6.4. Auswertung des geschätzten Spurwechselzeitpunktes

Das vorgestellte Verfahren zur Schätzung der verbleibenden Zeit bis zum Spurwechsel wird im Folgenden evaluiert. Dabei wird zum einen die Genauigkeit des prädizierten Zeitpunktes für den Spurwechsel sowie die assoziierte Unsicherheit und zum anderen die Häufigkeit von korrekten Vorhersagen bewertet. Die Geschwindigkeit der beobachteten Fahrzeuge im Datensatz entspricht typischen Autobahngeschwindigkeiten von 80 km/h bis zu 180 km/h². Aus dem Testdatensatz kann die tatsächlich verbleibende Zeit bis zum Spurwechsel t_{LC}^{f} direkt extrahiert und mit der Prädiktion verglichen

²Da das Verfahren die zeitliche Dynamik schätzt, kann das Vorgehen auf beliebige Geschwindigkeitsbereiche angewandt werden.

werden. Zunächst wird die mittlere absolute Abweichung (MAE^{tlc}) des prädizierten Medians $\hat{t}_{LC|\eta=0,5}$ von der Referenzzeit für Spurwechsel nach rechts und links bestimmt. Zusätzlich werden die geschätzten Intervalle analysiert. Hier wird zum einen das Intervall zwischen dem ersten und dritten Quartil (25 % und 75 % Quantile), die so genannte *Inter Quartil Range* (IQR), betrachtet, in dem 50 % aller Beispiele liegen. Zum anderen wird die Breite des Intervalls zwischen dem 10 % und dem 90 % Quantil ausgewertet. Mathematisch lassen sich die Intervalle mit

$$IQR = \hat{t}_{LC|\eta=0,75} - \hat{t}_{LC|\eta=0,25} \quad (6.4.1)$$

$$I_{80} = \hat{t}_{LC|\eta=0,9} - \hat{t}_{LC|\eta=0,1} \quad (6.4.2)$$

beschreiben. Für beide gilt dabei, dass kleinere Intervalle eine Vorhersage mit geringerer Unsicherheit repräsentieren.

Zusätzlich zu der Genauigkeit wird untersucht, ob die tatsächliche Zeit bis zum Spurwechsel innerhalb des prädizierten I_{80} Intervalls liegt. Dabei sind besonders die Bereiche von Interesse, in denen \hat{t}_{LC} unterhalb einer kritischen Zeit $t_{LC, \text{crit}}$ vor der Überquerung der Spurmarkierung liegt und die damit einen bevorstehenden Spurwechsel implizieren. Als Metrik wird das Verhältnis aller korrekt vorhergesagten Beispiele zu der Gesamtanzahl innerhalb der kritischen Bereiche verwendet. Wenn $n_{LC, \text{crit}}$ die Anzahl aller Beispiele im Datensatz ist, für die $\hat{t}_{LC} < t_{LC, \text{crit}}$ gilt, dann wird die Rate der korrekt prädizierten Beispiele definiert als

$$\text{tpr}^{tlc} = \frac{1}{n_{LC, \text{crit}}} \sum_{n_{LC, \text{crit}}} \mathbb{I}_{\{\hat{t}_{LC|\eta=0,1} \leq \hat{t}_{LC} \leq \hat{t}_{LC|\eta=0,9}\}}. \quad (6.4.3)$$

Dabei ist \mathbb{I} die Indikatorfunktion, die im Anhang A.3.2 definiert ist. Als kritische Zeit wird $t_{LC, \text{crit}} = 3 \text{ s}$ gewählt. Da der Ansatz mit der in Kapitel 4 vorgestellten Manöverklassifikation kombiniert wird, werden Beispiele außerhalb dieser Bereiche nicht betrachtet. Mit einem idealen Klassifikator wird zu jedem anderen Zeitpunkt die Klasse Spurhalten vorhergesagt, sodass die Zeit bis zum Spurwechsel nicht von Interesse ist.

In Abbildung 6.3 ist der Verlauf des prädizierten Medians für einen Spurwechsel im Testdatensatz als schwarze durchgezogene Linie dargestellt. Als Vergleich ist die tatsächliche Zeit bis zum Spurwechsel als gepunktete Linie abgebildet. Es ist zu erkennen, dass die Schätzung für das gezeigte Beispiel sehr genau ist und ab 2,4 Sekunden nur minimal von der Referenz abweicht. Zusätzlich ist die IQR und das I_{80} Intervall dargestellt. Beide Intervalle werden mit abnehmender Zeit bis zum Spurwechsel kleiner, womit sich eine steigende Konfidenz der Schätzung zeigt. Im Bereich von drei bis 2,4 s vor dem Spurwechsel ist außerdem die unsymmetrische geschätzte Verteilung zu erkennen. Das 90 % Quantil (obere Linie) verfügt über einen größeren Abstand zum geschätzten Median als das untere 10 % Quantil. Die Verteilung fällt in Richtung der späteren Zeitpunkte für einen Spurwechsel flacher ab. Außerdem zeigt sich, dass sich die Referenz während der kompletten dargestellten Dauer innerhalb beider geschätzter Intervalle befindet, sodass hier alle Beispiele als korrekt prädiziert angenommen werden können.

Wird der absolute Fehler aller im Datensatz vorkommenden Spurwechsel gemittelt und über die Zeit bis zum Spurwechsel aufgetragen, ergibt sich der Verlauf im oberen

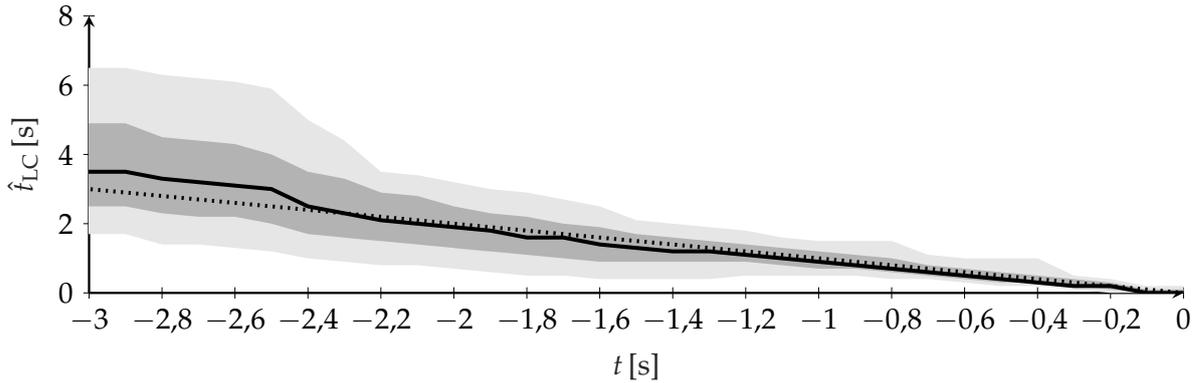


Abbildung 6.3.: Beispielverlauf des geschätzten Medians (schwarze Linie) und des IQR (dunkelgraue Fläche) sowie des I_{80} (hellgraue Fläche) für einen Spurwechsel nach links eines beobachteten Fahrzeugs. Die Referenzzeit ist als gepunktete schwarze Linie dargestellt.

Teil von Abbildung 6.4. Hier visualisiert der schwarze Verlauf die mittlere Abweichung der Medianschätzung von der Referenz für Spurwechselmanöver nach links und die graue Linie rechts. Es ist zu erkennen, dass für beide Manöverarten der Fehler kleiner wird, je näher der tatsächliche Zeitpunkt des Spurwechsels kommt. Dies lässt sich durch die laterale Bewegung des jeweiligen beobachteten Fahrzeugs erklären, das sich kurz vor dem Spurwechsel bereits teilweise auf der Zielspur befindet. Dadurch ist die Evidenz eines in kurzer Zeit stattfindenden Spurwechsels sehr hoch, was sich in einer guten Schätzung und einem kleinen Konfidenzintervall widerspiegelt. Für Spurwechsel nach links ist ein Fehler von mehr als einer Sekunde im Mittel für $t_{LC} > 2$ s zu erkennen. Bei Manövern nach rechts ist der Fehler im gleichen Zeitraum hingegen geringer. Spurwechsel nach rechts können daher bereits früher mit einer größeren Genauigkeit zeitlich gut eingeschätzt werden, da diese generell langsamer ausgeführt werden. Kurz vor dem Abschluss des Manövers ist der Fehler für Spurwechsel nach links minimal kleiner als der für Spurwechsel nach rechts. Der Verlauf der Intervallgröße bestätigt die bessere Vorhersage für LCR, da sowohl das IQR als auch das I_{80} Intervall kleiner als das jeweilige Intervall für LCL sind. Die Vorhersage der verbleibenden Zeit bis zum Spurwechsel nach rechts hat somit eine höhere Konfidenz. Es zeigt sich auch hier, dass alle betrachteten Intervalle für $t_{LC} \rightarrow 0$ klein werden und damit eine genaue Schätzung repräsentieren.

Bei der Betrachtung der korrekt geschätzten Zeiten ergibt sich eine $\text{tpr}_{LCL}^{\text{tlc}} = 0,81$ für Spurwechsel nach links und eine $\text{tpr}_{LCR}^{\text{tlc}} = 0,84$ für Spurwechsel nach rechts. Auch hier zeigt sich eine leicht bessere Schätzung der Manöverdynamik für Spurwechsel nach rechts als nach links. Insgesamt enthält das Intervall zwischen dem geschätzten $\hat{t}_{LC|\eta=0,1}$ und $\hat{t}_{LC|\eta=0,9}$ Quantil mehr als 80 % aller Beispiele für Spurwechselmanöver in beide Richtungen. Die Vorhersage erlaubt somit eine gute Abschätzung der Verteilung. Anhand der Relationen zwischen dem Median und den Intervallgrenzen kann außerdem auf die Form der Verteilung geschlossen werden. Sollte für eine Anwendung eine größere Abdeckung der Spurwechseldynamik erforderlich sein, lässt sich diese durch die Wahl eines größeren Intervalls und der entsprechenden Quantile realisieren. Dann ist ebenfalls eine höhere tpr^{tlc} zu erwarten. Wird dieses Intervall allerdings bei der

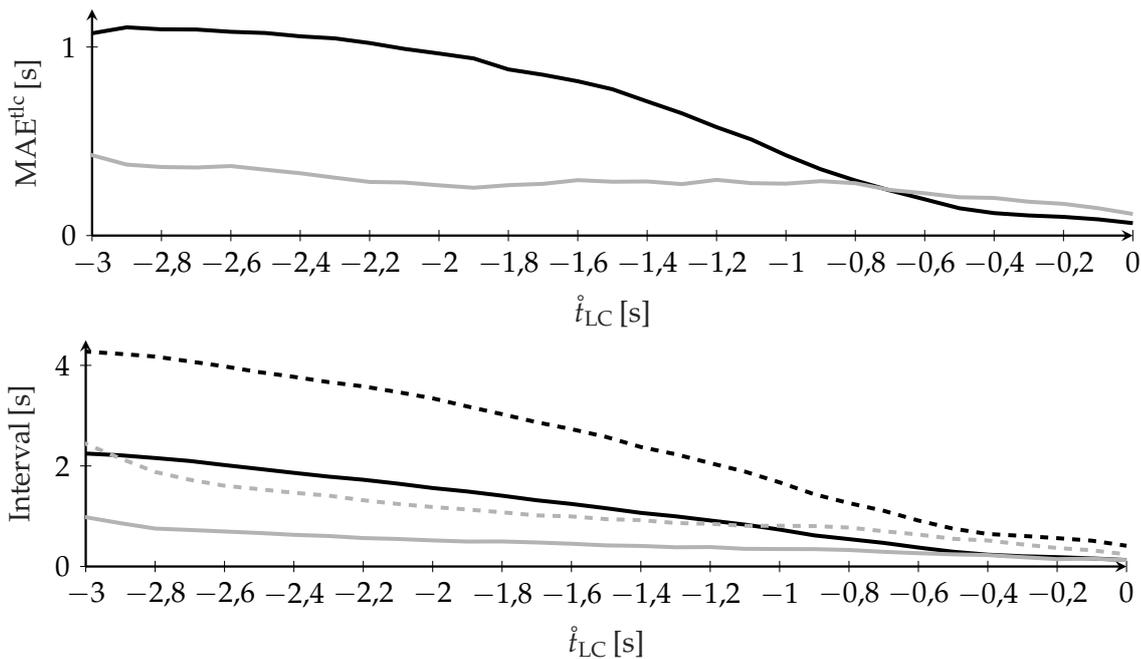


Abbildung 6.4.: In der oberen Abbildung ist der mittlere Fehler des prädizierten Medians der geschätzten Zeit bis zur Überquerung der Spurmarkierung für Spurwechsel nach links (schwarz) sowie nach rechts (grau) dargestellt. Unten sind die mittlere Intervallgröße des IQR (durchgezogene Linie) und des I_{80} (gestrichelte Linie) für jeweils Spurwechsel nach links und rechts zu sehen. Beide Abbildungen wurden auf Basis von Simulationsdaten erstellt.

Planung eines Ego-Manövers berücksichtigt, resultiert dies in einer sehr konservativen Fahrweise, da zu jeder Zeit mit sehr dynamischen Spurwechselmanövern gerechnet werden muss.

Insgesamt zeigt die Schätzung der Manövereigenschaften von Spurwechseln gute Ergebnisse für die Daten, die mit der Simulationsumgebung erzeugt werden. Der geschätzte Mittelwert mit den entsprechenden Intervallen beschreibt die tatsächliche Manöverdynamik inklusive der bedingten Unsicherheit und ergänzt damit die in Kapitel 4 vorgestellte Manöverklassifikation. Bereits einige Sekunden vor dem eigentlichen Spurwechsel ist der Fehler ausreichend klein, um die Dynamik des Spurwechsels einzuschätzen. Zusätzlich kann die Konfidenz der Vorhersage anhand des geschätzten Intervalls bewertet und eine Aussage über die Ausprägung eines dynamischen Spurwechsels getroffen werden.

7

Sicherheitskritische Trajektorienprädiktion

Die Auswertung in Kapitel 5 hat gezeigt, dass sich mit einem manöverbasierten Ansatz zur Trajektorienprädiktion eine gute Vorhersage der Bewegung beobachteter Fahrzeuge in einem begrenzten Zeithorizont durchführen lässt. Gerade für Spurfolgemanöver erlaubt die Transformation in das kurvilineare Koordinatensystem eine gute Vorhersage mit einem einfachen Prototypenmodell als Trajektorienrepräsentation. Ein Nachteil der in Kapitel 5 vorgestellten Methode stellt die Betrachtung der Unsicherheit als linear anwachsende Normalverteilung dar. Insbesondere für Spurwechselmanövern ist die Annahme einer symmetrischen Verteilung der Trajektorien in vielen Fällen nicht zutreffend. Dies wird bereits aus den Untersuchungen in Kapitel 6 ersichtlich, da die gefahrene Trajektorie direkt mit der Zeit bis zum Überqueren der Spurmarkierung zusammenhängt und diese ebenfalls keine symmetrische Verteilung ausweist. Zusätzlich stellen Spurwechselmanöver, die schneller ausgeführt werden als vorhergesagt, ein erhebliches Sicherheitsrisiko für das automatisierte Fahrzeug dar. Je nach Abstand und Relativgeschwindigkeit ist im Falle einer falschen Prädiktion eine starke und unkomfortable Verzögerung notwendig, um eine Kollision zu verhindern. Um zum einen eine genauere Repräsentation der Unsicherheit der prädizierten Trajektorien zu erhalten und zum anderen auch sicherheitskritische Manöverausführungen zu betrachten, wird in diesem Kapitel ein Ansatz vorgestellt, der die berechnete Zeit bis zur Überquerung der Spurmarkierung in die Prädiktion einschließt.

7.1. Kritische Trajektorien auf Autobahnen

Wie bereits Clarke u. a. [Cla+98] aufgezeigt haben, sind Spurwechsel und Überholvorgänge die Fahrmanöver mit dem größten Risiko während der Autobahnfahrt verbunden. Nicht nur für das ausführende sondern auch für die umgebenden Fahrzeuge entstehen bei unbedachten Spurwechselmanövern die Gefahr einer Kollision. Besonders Einfädelvorgänge können im Falle einer falschen Einschätzung des Folgefahrzeugs auf der Zielspur starke Verzögerung oder sogar eine Gefahrenbremsung erfordern. In der in Abbildung 7.1 dargestellten Verkehrsszene muss das Ego-Fahrzeug auf einen Spurwechsel des Fahrzeugs N_1 vorbereitet sein. In der Mitte der Verteilung ist die wahrscheinlichste und damit zu erwartende Ausführung des Manövers zu erkennen, die von dem Ansatz aus Kapitel 5 prädiziert werden kann. Um eine sichere Fahr-

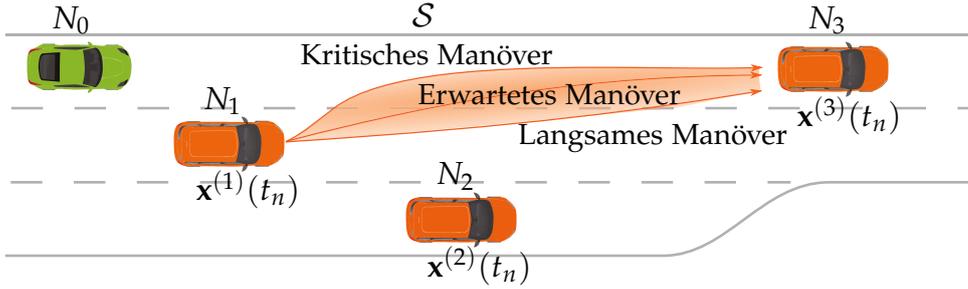


Abbildung 7.1.: Darstellung der Prädiktion von sicherheitskritischen Trajektorien für Spurwechselmanöver.

weise zu ermöglichen, müssen allerdings auch andere Ausführungen berücksichtigt werden. Hierbei ist insbesondere ein schnelleres und damit kritischeres Manöver von Bedeutung. Eine Möglichkeit, kritische Manöver zu betrachten, ist eine *worst-case* Abschätzung, bei der der fahrdynamisch schnellstmögliche Spurwechsel angenommen wird. Der Nachteil dieser Abschätzung ist die daraus resultierende sehr konservative Fahrweise, obwohl das Manöver nur selten in dieser Form durchgeführt wird. Außerdem lässt das Vorgehen keinerlei Aussage zu, wie hoch die Wahrscheinlichkeit für ein Manöver im Grenzbereich ist.

Der hier vorgestellte Ansatz zur Prädiktion von kritischen Trajektorien nutzt die mit Hilfe der Methode aus Kapitel 6 geschätzten Quantile der Verteilung der Zeit bis zur Überquerung der Spurmarkierung, um die wahrscheinlichste sowie kritische Spurwechseltrajektorien zu bestimmen, und folgt dabei dem Vorgehen in [Wis+18b]. Die Verteilung aus Gleichung (2.2.2) wird analog zu dem Vorgehen in Abschnitt 5.1 für Spurwechselmanöver approximiert durch das Produkt aus der Manöververteilung und der Repräsentation der Trajektorie

$$\hat{\mathbf{x}}^{(k)}(\tau) \sim p\left(\hat{\mathbf{x}}^{(k)}(\tau) \mid \mathbf{x}^{(k)}(t_n), \mathcal{S}, m^{(k)}(t_n), \hat{t}_{\text{LC}}\right) p\left(m^{(k)}(t_n) \mid \mathcal{X}^{(k)}(t_n)\right). \quad (7.1.1)$$

Zusätzlich wird mit Hilfe der probabilistischen Schätzung der Manöverdynamik die explizite Darstellung von kritischen Spurwechseln in der modellierten Verteilung ermöglicht. Das Verfahren wird im Folgenden auch mit SKTP abgekürzt. Um die Verteilung der Spurwechseltrajektorie so effizient wie möglich zu modellieren, ohne dabei die Information über die geschätzte Verteilung des Spurwechselzeitpunktes zu verlieren, wird diese durch einzelne Realisierungen von

$$\hat{\mathbf{x}}_{\eta=\eta_i}^{(k)}(\tau) = \mathbf{f}\left(\mathbf{x}^{(k)}(t_n), \hat{t}_{\text{LC}|\eta=\eta_i}\right) \quad (7.1.2)$$

dargestellt. Hierzu wird analog zu Abschnitt 5.1 ein kubischer Spline verwendet, mit dem die Quantile $\eta_i \in \Lambda = \{0,10,0,25,0,50,0,75,0,90\}$ modelliert werden. Um mit Hilfe der Prädiktion von kritischen Trajektorien die Sicherheit eines automatisierten Fahrzeugs zu erhöhen, kann im Falle eines Einschermanövers die Trajektorie $\hat{\mathbf{x}}_{\eta=0,1}^{(k)}$ für die Regelung berücksichtigt werden. Dadurch wird eine konservativere Fahrweise erreicht, ohne eine *worst-case* Abschätzung durchführen zu müssen.

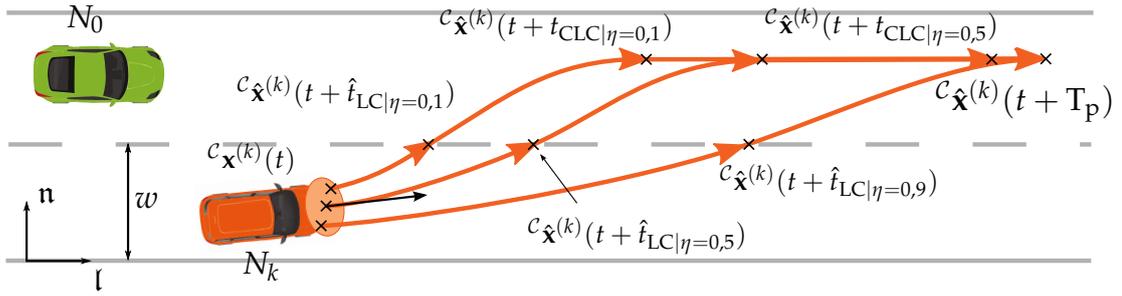


Abbildung 7.2.: Spline basierte Repräsentation der Spurwechseltrajektorie unter Berücksichtigung des geschätzten Spurwechselzeitpunktes sowie der Quantile der geschätzten Zustandsverteilung und Verteilung der Spurwechseldauer.

7.2. Trajektorienprädiktion mit zeitlichen Manövereigenschaften

Die grundsätzliche Darstellung der Trajektorien wird aus dem manöverbasierten Ansatz in Kapitel 5 übernommen. Das gilt insbesondere für prädizierte Spurhaltetrajektorien, da hier keine zeitliche Komponente in die Prädiktion einfließt. Somit können die Randbedingungen für diesen Fall direkt aus den Gleichungen (5.2.3) bis (5.2.6) übernommen werden.

Für Spurwechselmanöver wird im Vergleich zum Vorgehen in Abschnitt 5.1 ein zusätzlicher Kontrollpunkt ($\kappa = 4$) auf der Spurmarkierung zum Zeitpunkt $\hat{t}_{LC|\eta=\eta_i}$ platziert (siehe Abbildung 7.2). Die wahrscheinlichste Trajektorie $\hat{\mathbf{x}}_{\eta=0,5}^{(k)}(\tau)$ verläuft dabei durch den Median der geschätzten Verteilung des Spurwechselzeitpunktes. Abhängig von dem Quantil sind zwei zusätzliche Randbedingungen für $t_1 = \hat{t}_{LC|\eta=\eta_i}$ gegeben durch

$$\begin{aligned} \hat{l}(t_1) &= l(t_n) + v_l(t_n)(t_1 - t_n) \text{ und} \\ \hat{n}(t_1) &= w. \end{aligned} \quad (7.2.1)$$

Um die Parameter eindeutig bestimmen zu können, wird zusätzlich die Stetigkeit der ersten und zweiten Ableitung am Kontrollpunkt 1 ($\dot{z}_0(t_1) \stackrel{!}{=} \dot{z}_1(t_1)$ und $\ddot{z}_0(t_1) \stackrel{!}{=} \ddot{z}_1(t_1)$) gefordert.

Zusätzlich zu der betrachteten Dynamik des Manövers muss für eine sicherheitskritische Trajektorienprädiktion die ungenaue Schätzung des aktuellen Zustandes im Umgebungsmodell berücksichtigt werden. Daher wird für einen Spurwechsel nach rechts als Startzustand der Trajektorie $\hat{\mathbf{x}}_{\eta=\eta_i}^{(k)}(\tau)$ das entsprechende Quantil der Zustandsverteilung gewählt

$$P(\mathcal{C}_{\mathbf{x}}(t_n)) \geq \eta_i. \quad (7.2.2)$$

$P(\mathcal{C}_{\mathbf{x}}(t_n))$ beschreibt die kumulative Verteilung der Zustandsnormalverteilung im Umgebungsmodell. Für einen Spurwechsel nach links muss im Sinne der sicherheitskritischen Betrachtung die andere Seite der Verteilung betrachtet werden, sodass hier für den ersten Zustand

$$P(\mathcal{C}_{\mathbf{x}}(t_n)) \geq 1 - \eta_i \quad (7.2.3)$$

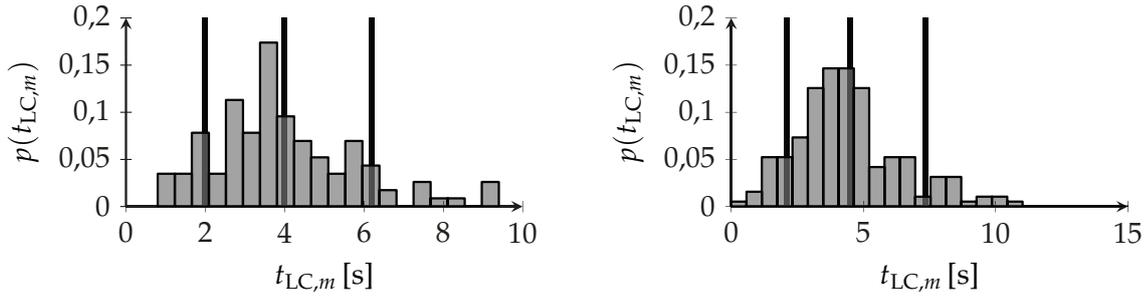


Abbildung 7.3.: Verteilung der Spurwechseldauer für Spurwechselmanöver nach links und rechts im Datensatz, der mit dem Testfahrzeug aufgenommen wurde. Die senkrechten Balken repräsentieren von links nach rechts jeweils das 25 %, das 50 % und das 75 % Quantil.

gilt. Auf diese Weise werden von der geschätzten Verteilung die in der jeweiligen Situation kritischen Zustände in der Prädiktion berücksichtigt.

Für die Bestimmung des Zeitpunkt t_{CLC} , an dem der Spurwechsel abgeschlossen ist, wird wie schon in Abschnitt 5.1 eine konstante Spurwechseldauer angenommen. Um allerdings die unterschiedlichen Ausführungen eines Spurwechsels auf der Zielspur ebenfalls zu beachten, wird nicht nur der Mittelwert der Spurwechseldauer in den aufgenommenen Daten betrachtet. Für die Verteilung der gesamt Spurwechseldauer $p(\tilde{t}_{LC,m})$ wird das Quantil $\tilde{t}_{LC,m|\eta=\eta_i}$ entsprechend der betrachteten Trajektorie bestimmt. Mit diesem ergibt sich dann

$$t_{CLC|\eta=\eta_i} = \hat{t}_{LC|\eta=\eta_i} + \frac{\tilde{t}_{LC,m|\eta=\eta_i}}{2} \quad (7.2.4)$$

für den Endzeitpunkt des Spurwechsels. Da die Verteilung $p(\tilde{t}_{LC,m})$ aus aufgenommenen Daten extrahiert wird, können die benötigten Quantile vorab berechnet und abgelegt werden, sodass keine zusätzliche Berechnung zur Laufzeit notwendig ist. Die Verteilungen der Spurwechseldauer in den mit dem Testfahrzeug aufgenommenen Daten sind in Abbildung 7.3 dargestellt. Der Mittelwert für Spurwechsel nach links beträgt $\tilde{t}_{LC,m=LCL} = 4\text{ s}$ und nach rechts $\tilde{t}_{LC,m=LCR} = 4,5\text{ s}$. Zusätzlich sind die 25%, 50% und 75% Quantile als senkrechte Linien abgebildet.

Die Spline Parameter werden für alle Quantile aus Λ bestimmt und damit die Zustände der zu prädizierenden Trajektorien berechnet. Für alle Trajektorien mit $t_{CLC|\eta=\eta_i} < T_p$ wird außerdem ein zusätzlicher Kontrollpunkt auf der Zielspur für $t_3 = T_p$ platziert. Die notwendigen Randbedingungen ergeben sich analog zu Gleichung (5.2.5) und (5.2.7).

7.3. Evaluation der sicherheitskritischen Trajektorienprädiktion

Für die Auswertung der SKTP können zunächst die gleichen Kriterien herangezogen werden, wie sie bei der manöverbasierten Prädiktion in Abschnitt 5.3 verwendet wurden. Entsprechend wird der laterale und longitudinale Fehler der wahrscheinlichsten

prädizierten Trajektorie $\hat{x}_{\eta=0.5}(\tau)$ ausgewertet und mit dem Ergebnis des manöverbasierten Ansatzes verglichen. Allerdings stehen zusätzliche Informationen über die prädizierte Verteilung der Trajektorien zur Verfügung. Durch die Betrachtung der prädizierten Quantile innerhalb der Planung des Ego-Manövers kann eine konservative und damit sichere sowie komfortable Fahrweise umgesetzt werden, indem im Falle eines Spurwechsels nicht nur das wahrscheinlichste, sondern auch ein schnell ausgeführtes Manöver berücksichtigt wird. So können notwendige Bremsingriffe aufgrund von falsch prädizierten Trajektorien auf ein Minimum beschränkt werden. Für die Auswertung ist daher relevant, wie häufig die Referenz außerhalb des durch zwei Quantile begrenzten Bereiches liegen. Die Bereiche werden analog zu der Auswertung der Schätzung der verbleibenden Zeit bis zum Spurwechsel in Abschnitt 6.4 über die Intervalle zwischen dem 10% und 90% Quantil sowie zwischen dem 25% und 75% Quantil definiert. Als Metrik dient der Prozentsatz aller Spurwechseltrajektorien, die innerhalb des durch die entsprechenden Trajektorien $\hat{x}_{\eta=\eta_i}(\tau)$ und $\hat{x}_{\eta=\eta_j}(\tau)$ beschriebenen Bereiches liegen

$$\text{acc}_{i|j}^{\text{SKTP}}(\tau) = \frac{1}{n_{\text{LC, crit}}} \sum_{n_{\text{LC, crit}}} \mathbb{I}_{\{\hat{x}_{\eta=\eta_i}(\tau) \leq \hat{x}(\tau) \leq \hat{x}_{\eta=\eta_j}(\tau)\}} \cdot 100\%. \quad (7.3.1)$$

Wenn alle Trajektorien im Datensatz innerhalb des entsprechenden Bereichs liegen, ergibt die Metrik den optimalen Wert von 100%.

Exemplarisches Szenario

Zunächst wird in Abbildung 7.4 ein beispielhaftes Szenario betrachtet, in dem sich das Ego-Fahrzeug und fünf weitere Fahrzeuge auf einer zweispurigen Autobahn befinden. In dieser Situation steht das Fahrzeug N_4 im Fokus, da es einen Spurwechsel auf die Fahrspur des Ego-Fahrzeugs durchführt und damit in der Planung des Ego-Manövers direkt berücksichtigt werden muss. Die Punkte bei den Fahrzeugen N_1 , N_4 und N_5 zeigen, dass das jeweilige Fahrzeug von dem Sensorsetup des Ego-Fahrzeugs wahrgenommen wird und stellen die aktuelle geschätzte Position des Objektes dar. Dem entsprechend ist zu erkennen, dass die Fahrzeuge N_2 und N_3 aufgrund der Verdeckung durch andere Objekte nicht wahrgenommen werden. Zum Zeitpunkt $t = 0$ s wird der Spurwechsel von der Manöverklassifikation aus Kapitel 4 erkannt und die Quantile der Verteilung der verbleibenden Zeit bis zur Überquerung der Spurmarkierung werden mit dem Verfahren in Kapitel 6 geschätzt. Der Median der Verteilung wird durch die gestrichelte Linie ausgehend von Fahrzeug N_4 dargestellt. Dieser ist von dem Intervall zwischen den Trajektorien $\hat{x}_{\eta=0,25}^{(4)}(\tau)$ und $\hat{x}_{\eta=0,75}^{(4)}(\tau)$ eingeschlossen und dieses wiederum von dem Intervall zwischen $\hat{x}_{\eta=0,1}^{(4)}(\tau)$ und $\hat{x}_{\eta=0,9}^{(4)}(\tau)$. Beide Intervalle sind jeweils als Fläche um den Median dargestellt. Zusätzlich ist die Referenztrajektorie als schwarze Linie mit Kreuzen in 0,5 s Abständen zu erkennen. In der oberen Abbildung zum Zeitpunkt $t = 0$ s ist keine genaue Aussage über die Manöverdynamik möglich, was durch eine breite Verteilung entlang der Spurmarkierung repräsentiert wird. Gleichzeitig ist zu erkennen, dass der geschätzte Median einen deutlichen Fehler gegenüber der Referenztrajektorie aufweist und einen späteren Spurwechsel impliziert. Allerdings liegt die tatsächlich gefahrene Trajektorie während des ersten Teils

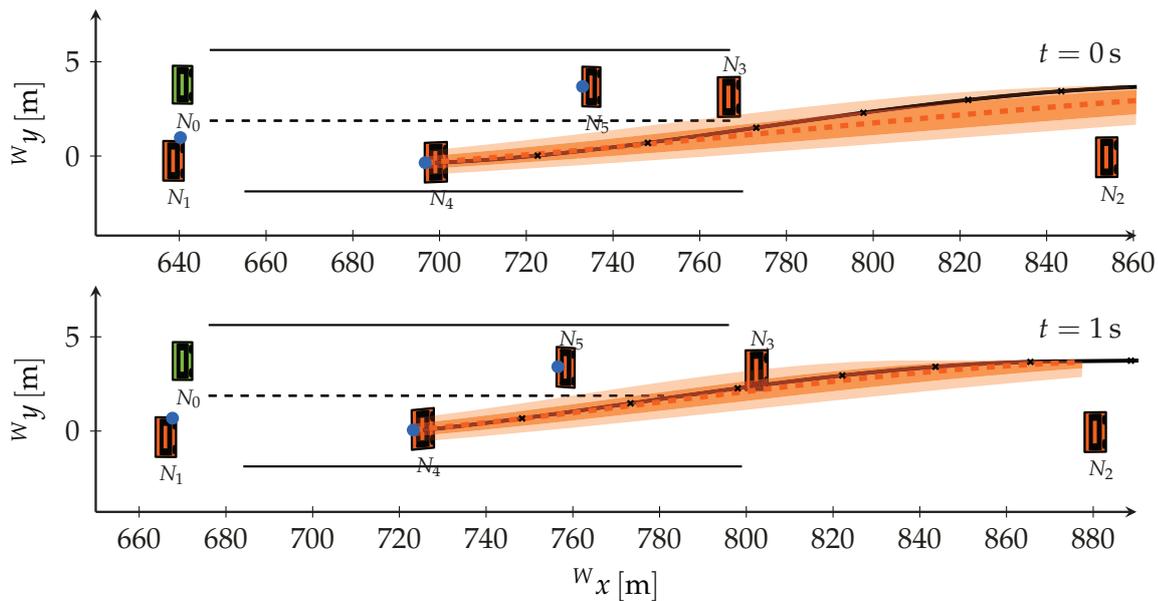


Abbildung 7.4.: Beispiel Szenario mit einem Spurwechsel von Fahrzeug N_4 nach links auf die Ego-Spur.

des Manövers innerhalb des inneren Intervalls und zu jedem Zeitpunkt in dem Bereich zwischen $\hat{\mathbf{x}}_{\eta=0,1}^{(4)}(\tau)$ und $\hat{\mathbf{x}}_{\eta=0,9}^{(4)}(\tau)$. Wird innerhalb der Planung des Ego-Manövers also der entsprechende Bereich berücksichtigt, kann eine starke Verzögerung aufgrund eines unerwartet schnellen Spurwechsels vermieden werden. In der unteren Abbildung ist die weitere Entwicklung der Situation zu erkennen. Nach $t = 1$ s ist die Abweichung des prädizierten Medians und der Referenztrajektorie sehr klein und impliziert so einen kleinen Prädiktionsfehler. Außerdem wird das geschätzte Intervall und damit die Unsicherheit kleiner. Anhand der gezeigten Situation werden die Vorteile der Betrachtung von Quantilen der verbleibenden Zeit bis zum Spurwechsel deutlich. Auch wenn die prädizierte wahrscheinlichste Trajektorie einen Fehler gegenüber der Referenz aufweist, liegt diese innerhalb der prädizierten Intervalle und kann somit bei der Planung berücksichtigt werden.

Statistische Evaluation

Im Folgenden wird die statistische Genauigkeit der SKTP auf Basis der in der Simulationsumgebung erzeugten Daten ausgewertet. In Abbildung 7.5 ist der longitudinale und laterale absolute Fehler der sicherheitskritischen Trajektorienprädiktion über die Prädiktionszeit (grau) als Boxplot dargestellt. Als Vergleich ist der Fehler des manöverbasierten Ansatzes aus Kapitel 5 (schwarz) abgebildet. Da die Modellierung der Trajektorien für Spurhaltenmanöver in beiden Verfahren identisch ist, werden an dieser Stelle lediglich Spurwechselbeispiele ausgewertet. Für den absoluten longitudinalen Fehler (links) sind keine großen Unterschiede zwischen den Verfahren zu erkennen. Der Fehlermedian liegt für die SKTP bei einer Prädiktionszeit von $\tau = 5$ s bei $MAE_y(5s) = 2,41$ m und ist damit minimal größer als der der MBTP. Auch in lateraler Richtung machen beide Verfahren einen ähnlichen absoluten Fehler. Durch die

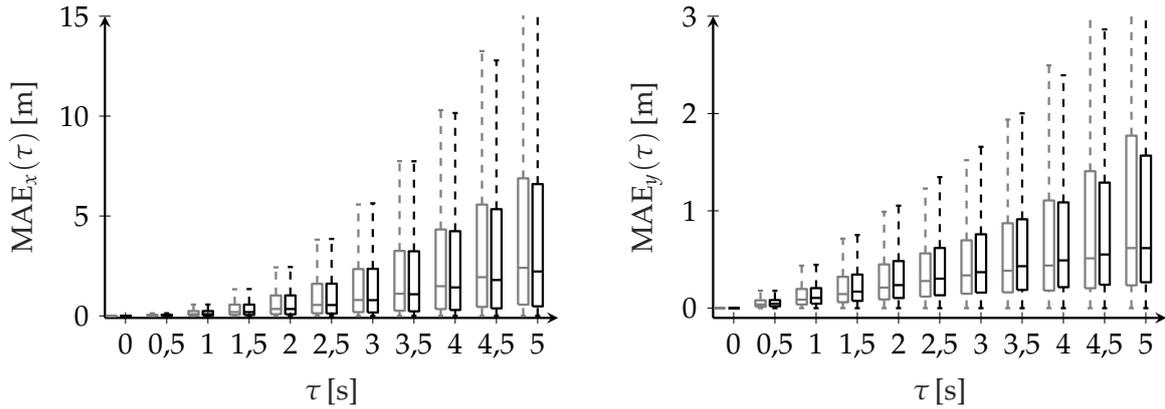


Abbildung 7.5.: Vergleich des longitudinalen (links) und lateralen Fehlers (rechts) der SKTP (grau) und der MBTP (schwarz) für Spurwechselbeispiele.

Verwendung der nichtlinearen Schätzung bis zum Überqueren der Spurmarkierung ist der Fehlermedian der SKTP etwas geringer als bei der alleinigen Betrachtung des Manövers. Gleichzeitig ist der Bereich des Fehlers etwas größer. Generell zeigt sich, dass die Verwendung des Verfahrens aus Kapitel 6 keinen großen Einfluss auf die Genauigkeit der Trajektorienprädiktion hat. Die resultierenden Fehler sind vergleichbar mit denen der manöverbasierten Trajektorienprädiktion.

Zusätzlich zu der Genauigkeit der Prädiktion wird der prozentuale Anteil der korrekt prädizierten Situationen untersucht. Dazu wird die $\text{acc}_{0,25|0,75}^{\text{SKTP}}(\tau)$ (schwarz) und die $\text{acc}_{0,1|0,9}^{\text{SKTP}}(\tau)$ (grau) im linken Teil von Abbildung 7.6 ausgewertet. Zu Beginn der jeweiligen Prädiktion liegen 100% aller Beispiele innerhalb der beiden betrachteten Intervalle und mit steigender Prädiktionszeit sinkt die Genauigkeit auf $\text{acc}_{0,25|0,75}^{\text{SKTP}}(5\text{ s}) = 49,4\%$ und $\text{acc}_{0,1|0,9}^{\text{SKTP}}(5\text{ s}) = 77,2\%$. Aufgrund der Wahl der Quantile ist für das Intervall zwischen $\eta = 0,25$ und $\eta = 0,75$ eine Genauigkeit von 50% und für das Intervall zwischen $\eta = 0,1$ und $\eta = 0,9$ eine Genauigkeit von 80% zu erwarten. Dies wird für einen Großteil der Prädiktionszeit erfüllt, lediglich für $\tau > 4,3\text{ s}$ ist die Genauigkeit etwas niedriger.

Zusätzlich zu der Überprüfung, ob die Referenz innerhalb der prädizierten Intervalle liegt, wird der für die Planung kritische Fall betrachtet, dass ein beobachtetes Fahrzeug schneller die Ego-Spur erreicht, als es prädiziert wird

$$\text{acc}_i^{\text{SKTP}}(\tau) = \text{acc}_{i|1}^{\text{SKTP}}(\tau). \quad (7.3.2)$$

Dazu werden lediglich die Trajektorien $\hat{\mathbf{x}}_{\eta=0,1}(\tau)$ und $\hat{\mathbf{x}}_{\eta=0,25}(\tau)$ ausgewertet, da diese einen Spurwechsel repräsentieren, der schneller als erwartet ausgeführt wird. Die Ergebnisse sind im rechten Teil von Abbildung 7.6 dargestellt. Für das $\eta = 0,25$ Quantil ist eine Genauigkeit von 75% zu erwarten. Diese wird für die gesamte Prädiktionszeit übertroffen wird. Im Fall von $\hat{\mathbf{x}}_{\eta=0,1}(\tau)$ fällt die Genauigkeit am Ende der Prädiktionszeit unterhalb des zu erwartenden Werts von 90%. Die geschätzten Trajektorien bilden die kritischen Spurwechselmanöver sehr gut ab, sodass bei einer Planung mit der $\hat{\mathbf{x}}_{\eta=0,1}(\tau)$ Trajektorie in 90% aller Fälle eine starke unkomfortable Verzögerung vermieden werden kann.

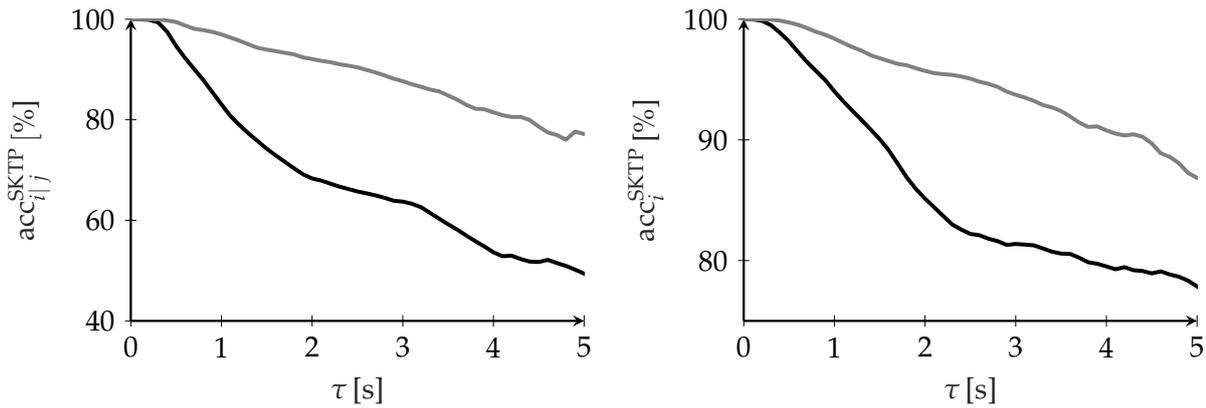


Abbildung 7.6.: Links: Der prozentuale Anteil von Trajektorien, die innerhalb des prädizierten Intervalls liegen ($acc_{0,1|0,9}^{SKTP}$ grau und $acc_{0,25|0,75}^{SKTP}$ schwarz). Rechts: Anteil von Trajektorien, die die Zielspur nach der geschätzten kritischen Trajektorie erreichen ($acc_{0,9}^{SKTP}$ grau, $acc_{0,75}^{SKTP}$ schwarz).

Die Auswertung der SKTP zeigt, dass die nichtlineare Schätzung der verbleibenden Zeit bis zum Überqueren der Spurmarkierung keine signifikante Verringerung der Abweichung zwischen der prädizierten und der Referenztrajektorie bewirkt. Die lateralen und longitudinalen Fehler sind mit denen des manöverbasierten Ansatzes zu vergleichen, da sich das Modell zur Repräsentation der wahrscheinlichsten Trajektorie nur wenig unterscheidet. Allerdings erlaubt die sicherheitskritische Betrachtung von Spurwechseltrajektorien zusätzlich eine Abschätzung der Dynamik im Falle eines schnelleren Manövers. Die statistische Überprüfung zeigt, dass der Ansatz abhängig von den gewählten Quantilen auch dynamische Spurwechsel mit der erwarteten Genauigkeit repräsentiert. Durch die Betrachtung der Prädiktion innerhalb der Planung des Ego-Manövers können somit kritische Manöver berücksichtigt und eine sichere und komfortable Fahrweise umgesetzt werden.

8

Interaktionsbasierte Trajektorienprädiktion

Die bisher vorgestellten Verfahren zur Prädiktion von Trajektorien betrachten jedes Fahrzeug in der Umgebung des Ego-Fahrzeugs individuell. Jede Interaktion mit anderen Verkehrsteilnehmern wird während der Berechnung der zukünftigen Zustände vernachlässigt oder lediglich implizit in der Manöverklassifikation betrachtet. Gerade für eine Prädiktion mit einem langen Prädiktionshorizont haben Interaktionen allerdings einen bedeutenden Einfluss auf die Manöver und damit die Trajektorie der beobachteten Fahrzeuge. In diesem Kapitel wird daher ein interaktionsbasierter Ansatz für die Trajektorienprädiktion vorgestellt. Die Wechselwirkung zwischen den Manövern einzelner Fahrzeuge wird explizit in der Prädiktion berücksichtigt. Zusätzlich können Informationen über die Straßentopologie und Einflüsse von Verkehrsregeln direkt im Ansatz modelliert werden, sodass eine realistische Prädiktion für einen langen Zeithorizont ermöglicht wird. Dazu wird in einem ersten Schritt der Einfluss der Interaktion auf die Prädiktion verdeutlicht. Anschließend wird der auf einer *Monte Carlo* Simulation basierende Ansatz zur interaktionsbasierten Trajektorienprädiktion beschrieben. Für die Berücksichtigung von Wechselwirkungen zwischen einzelnen Fahrzeugen ist ein vollständiges Umgebungsmodell erforderlich. Da dieses nicht immer garantiert werden kann, wird der Ansatz um eine initiale Manöverklassifikation erweitert. Abschließend werden Ergebnisse für eine lange Prädiktionszeit ($T_p > 5$ s) auf Basis von simulierten Daten vorgestellt.

8.1. Interaktionen zwischen Verkehrsteilnehmern

Für die Prädiktion von Trajektorien werden zwei Arten von Interaktionen betrachtet: Zum einen wird die Interaktion zwischen zwei oder mehr Fahrzeugen innerhalb der aktuellen Verkehrssituation betrachtet; also die Auswirkungen, die ein Manöver von Fahrzeug N_i auf das Verhalten von Fahrzeug N_j hat. Zum anderen wird die Interaktion eines Fahrzeugs N_i mit der Straßentopologie S und den Verkehrsregeln berücksichtigt. Dabei sind vor allem endende Spuren, wie zum Beispiel das Ende der Beschleunigungsspur einer Autobahnauffahrt, und Geschwindigkeitsbeschränkungen von Bedeutung. Im Kontext der interaktionsbasierten Prädiktion werden Fahrzeuge auch als Agenten bezeichnet, die das Verhalten des jeweils anderen beeinflussen können. Beide Arten der Interaktion können anhand der bereits in den vorigen Kapiteln

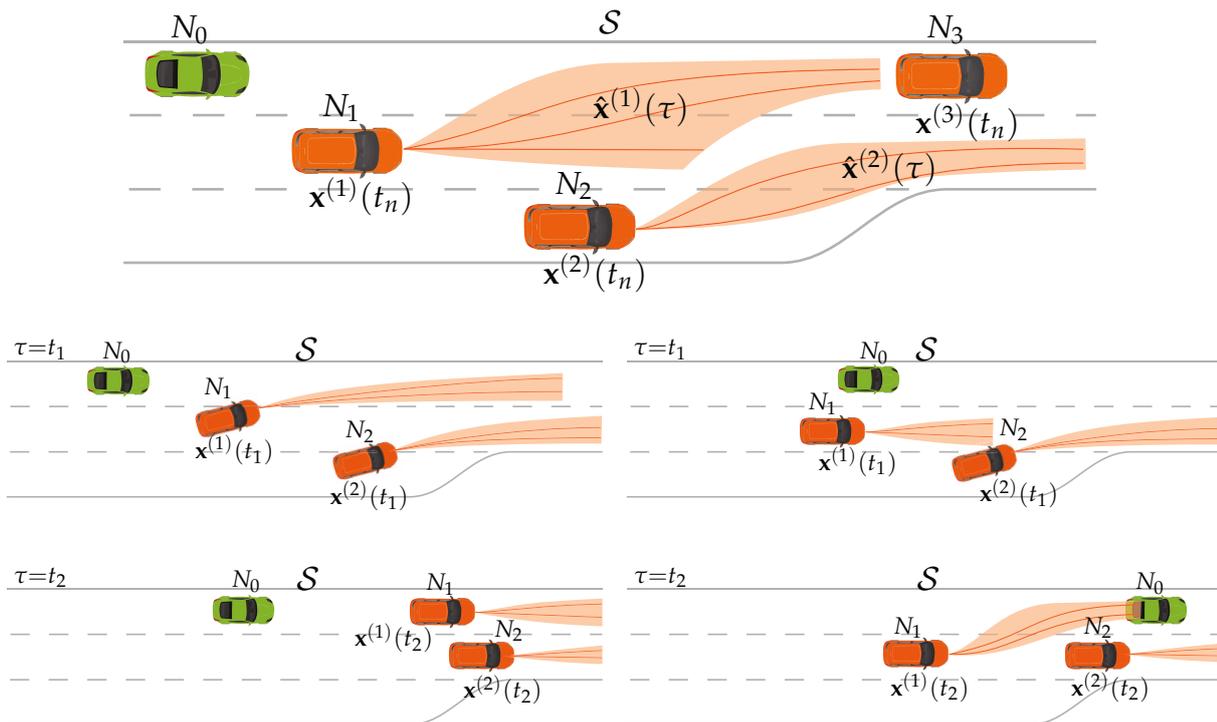


Abbildung 8.1.: Einfluss der Interaktion zwischen den einzelnen Agenten auf die Trajektorienprädiktion. Unter der Darstellung der Ausgangssituation sind zwei mögliche Entwicklungen der Situation innerhalb der Prädiktionszeit τ dargestellt.

betrachteten Verkehrssituation in Abbildung 8.1 genauer erläutert werden. Im oberen Bild ist die Ausgangssituation dargestellt. Es zeigt die Interaktion eines Agenten mit der Straßentopologie, da das Fahrzeug auf der rechten Spur N_2 aufgrund der endenden Spur einen Spurwechsel nach links durchführen muss. Dieser beeinflusst direkt das Manöver von N_1 , da es nicht mehr möglich ist, der Spur mit konstanter Geschwindigkeit zu folgen. Agent N_1 hat die Möglichkeit die Geschwindigkeit zu verringern oder ebenfalls einen Spurwechsel nach links durchzuführen. Hier zeigt sich die Interaktion zwischen den beiden Fahrzeugen, da das Manöver von N_1 direkt das Manöver von N_2 beeinflusst. Es ergeben sich verschiedene Möglichkeiten der weiteren Entwicklung der Situation. Zwei Mögliche sind ebenfalls in Abbildung 8.1 dargestellt. Auf der linken Seite führt Agent N_1 einen Spurwechsel nach links durch, um die aktuelle Geschwindigkeit zu halten, wodurch sich ein direkter Einfluss auf die Aktionen des Ego-Fahrzeugs ergeben. Im Falle einer hohen Differenzgeschwindigkeit muss das Ego-Fahrzeug verzögern, um ausreichend Platz für den Spurwechsel bereit zu stellen. Eine andere Möglichkeit ist auf der rechten Seite abgebildet. Hier verzögert N_1 , um den Sicherheitsabstand zu N_2 nach dem Spurwechsel herzustellen. Somit findet keine Interaktion zwischen N_1 und dem Ego-Fahrzeug N_0 statt und es ist keine Anpassung der Geschwindigkeit seitens des Ego-Fahrzeugs notwendig. Prinzipiell ist noch eine Vielzahl von anderen Entwicklungen der Situation möglich, die hier nicht abgebildet sind. Es wird jedoch deutlich, dass die Interaktion zwischen einzelnen Agenten einen

entscheidenden Einfluss auf die Entwicklung der Situation haben und damit im Falle einer Trajektorienprädiktion mit langer Prädiktionszeit $T_p > 5$ s nicht vernachlässigt werden können. Vielmehr spielt nicht nur die Interaktion zwischen den einzelnen beobachteten Fahrzeugen N_k mit $k \in \{1, 2, \dots, K\}$ eine Rolle, sondern zusätzlich die Interaktion mit dem Ego-Fahrzeug. In der gezeigten Situation muss dieses je nach Verhalten der anderen Agenten bremsen, beschleunigen oder kann ohne Anpassung der Geschwindigkeit weiterfahren.

Außerdem zeigt die Situation, dass die Manöver des automatisierten Ego-Fahrzeugs immer einen Einfluss auf den umgebenden Verkehr haben. Dies muss bei der Planung des Ego-Manövers berücksichtigt werden, um ein akzeptables Verhalten des Fahrzeugs zu erreichen. Dabei kann die Auswirkung nur auf Basis der prädizierten Manöver anderer Verkehrsteilnehmer bewertet werden, sodass sich hier eine Kopplung der interaktionsbasierten Trajektorienprädiktion mit der Manöverplanung eines automatisierten Fahrzeugs ergibt. Die Beschreibung und Untersuchung dieser Kopplung ist allerdings nicht Teil der vorliegenden Arbeit, sodass an dieser Stelle auf die Arbeiten von Schmidt u. a. [Sch+19a] und Lienke u. a. [Lie+19b] verwiesen wird.

8.2. Modellierung von Interaktionen

Um das in Abschnitt 2.2 definierte Problem der Trajektorienprädiktion unter Berücksichtigung der im vorherigen Abschnitt beschriebenen Interaktionen zu lösen, wird die aktuelle Verkehrssituation mit Hilfe von parametrisierten Fahrermodellen mehrfach vorwärts simuliert und damit die Verteilung aus Gleichung (2.2.2) approximiert. Dabei wird angenommen, dass sich jeder Agent k innerhalb des Szenarios mit einer longitudinalen Beschleunigung $a_l^{(k)}(\tau) \in [a_{\min}, a_{\max}]$ mit $a_{\min} < 0$ sowie $a_{\max} > 0$ bewegt und dabei zu jedem Zeitpunkt τ genau ein laterales Manöver $m^{(k)}(\tau) \in \mathcal{M}$ ausführt. Auf Basis des lateralen Manövers wird ein Ausführungspfad, anhand dessen sich das Fahrzeug durch die Verkehrssituation bewegt, bestimmt und anschließend in eine laterale Beschleunigung $a_n^{(k)}$ überführt. Mit der gegebenen longitudinalen und lateralen Beschleunigung kann der Übergang von Zustand $c_{\mathbf{x}^{(k)}}(\tau)$ in $c_{\mathbf{x}^{(k)}}(\tau + \Delta T)$ mit Hilfe eines Bewegungsmodells $\mathbf{f} : \mathbb{R}^4 \times \mathbb{R}^2 \rightarrow \mathbb{R}^4$

$$c_{\hat{\mathbf{x}}^{(k)}}(\tau + \Delta T) = \mathbf{f} \left(c_{\hat{\mathbf{x}}^{(k)}}(\tau), \mathbf{a}^{(k)} \right) \quad (8.2.1)$$

mit $\mathbf{a}^{(k)} = [a_l^{(k)}, a_n^{(k)}]^T$ beschrieben werden. Dabei ist sowohl die Wahl der longitudinalen Beschleunigung als auch des lateralen Manövers in der jeweiligen Situation stark abhängig vom individuellen Fahrer des beobachteten Fahrzeugs. Da die Präferenzen des Fahrers allerdings nicht beobachtbar sind, muss für beide Größen auch die Unsicherheit modelliert werden. Daher werden die longitudinale Beschleunigung und das laterale Manöver jeweils durch die Verteilung

$$a_l^{(k)}(\tau) \sim p \left(a_l^{(k)}(\tau) | c_{\hat{\mathbf{x}}^{(k)}}(\tau), \mathcal{Z}_k, \mathcal{S} \right) \quad \text{und} \quad (8.2.2)$$

$$m^{(k)}(\tau) \sim p \left(m^{(k)}(\tau) | c_{\hat{\mathbf{x}}^{(k)}}(\tau), \mathcal{Z}_k, \mathcal{S}, m^{(k)}(\tau - \Delta T) \right) \quad (8.2.3)$$

abgebildet.

Die Verteilung über die Trajektorien aller Agenten in der Szene wird dann durch wiederholte Vorwärtssimulation der Verkehrssituation mit Hilfe von probabilistischen Fahrermodellen approximiert. Dazu werden in einer *Monte Carlo* Simulation die Parameter der Fahrermodelle variiert, um verschiedene Fahrertypen abzubilden. Zu jedem Zeitpunkt $\tau \in [t_n, t_n + T_p]$ wird eine longitudinale Beschleunigung und ein laterales Manöver berechnet, sodass anhand des Bewegungsmodells die Zustandstrajektorie für den Prädiktionshorizont T_p bestimmt werden kann. Um dabei die Interaktion zu berücksichtigen, wird für jeden Agent jeweils ein Simulationsschritt durchgeführt und anschließend auf Basis der Situation eine erneute Bewertung durch die Fahrermodelle vorgenommen. Die Vorwärtssimulation wird insgesamt $n_{MC} \in \mathbb{N}_+$ Mal wiederholt, um die Verteilung in Gleichung (2.2.2) zu approximieren. Die resultierenden prädizierten Trajektorien aus den Simulationszyklen werden für jeden Agenten in einer kompakten Repräsentation zusammengefasst, indem ähnliche Manöver gruppiert werden (Vergleiche Anhang A.6).

Das Vorgehen ist im Anhang in Algorithmus A.1 dargestellt. Das Verfahren zur interaktionsbasierten Trajektorienprädiktion wird mit IBTP abgekürzt und im Folgenden in den einzelnen Teilschritten erläutert.

Bewegungsmodell

Der aktuelle Zustand eines Agenten N_k während der Simulation ist gegeben durch die Position und die Geschwindigkeit in longitudinaler und lateraler Richtung. Um die Unsicherheit der Zustandsschätzung aus dem Umgebungsmodell zu berücksichtigen, wird der Startzustand für die Simulation in jeder *Monte Carlo* Iteration neu aus der Verteilung $\mathbf{x}^{(k)}(t_n) = \mathcal{N}(\boldsymbol{\mu}^{(k)}(t_n), \boldsymbol{\Sigma}^{(k)}(t_n))$ gezogen. Für die Berechnung des Folgezustandes wird ein Bewegungsmodell benötigt, das die Bewegung des Fahrzeugs mit ausreichender Genauigkeit beschreibt. Gleichzeitig muss der Berechnungsaufwand des Modells möglichst gering sein, um die Gesamtrechenzeit so gering wie möglich zu halten. Da außerdem der Lenkradwinkel anderer Verkehrsteilnehmer ohne Fahrzeug-zu-Fahrzeug-Kommunikation nicht gemessen werden kann, wird das Punktmassmodell aus Abschnitt 3.3 verwendet. Dieses bietet eine ausreichende Genauigkeit mit gleichzeitig geringem Rechenaufwand. Der Zustandsübergang wird dabei durch Gleichung (3.3.1) beschrieben.

Longitudinales Fahrermodell

Um eine realistische longitudinale Beschleunigung für jeden Agenten zu bestimmen, muss die Interaktion zwischen Fahrzeugen auf der gleichen Spur sowie Fahrzeugen, die auf eben diese wechseln, berücksichtigt werden. Dabei gilt die Annahme, dass ein Fahrer eine Verzögerung in Kauf nimmt, um eine Kollision zu verhindern. Ein solches Verhalten wird von Fahrzeugfolgemodellen in mikroskopischen Verkehrssimulationen umgesetzt. Für die Anwendung innerhalb der *Monte Carlo* Simulation steht auch hier ein geringer Berechnungsaufwand im Vordergrund. Zusätzlich muss durch die Variation der Modellparameter ein unterschiedliches Verhalten der Agenten erzeug-

bar sein. Dabei ist es von Vorteil, wenn das Verhalten nur durch eine kleine Anzahl von Parametern entscheidend beeinflusst wird, sodass die geeignete Variation dieser Parameter die Verteilung in Gleichung (8.2.2) gut approximiert.

In der vorliegenden Arbeit wird als longitudinales Fahrermodell das *Intelligent Driver Model* eingesetzt, das bereits in der in Kapitel 3 vorgestellten Simulationsumgebung verwendet wird. Die Beschleunigung zum Zeitpunkt τ ist gegeben durch Gleichung (3.3.2). Alle Parameter des Modells für Agent N_k werden im Parametervektor $\theta_{\text{Long}}^{(k)} = [v_{\text{des}}^{(k)}, a_{l,\text{max}}^{(k)}, b^{(k)}, \delta, s_0^{(k)}, T_H^{(k)}]^T$ zusammengefasst und sind nicht messbar. Daher werden die Parameter aus Tabelle 3.1 verwendet. Wie in Abschnitt 3.3 beschrieben, kann das Modell in zwei Teile unterteilt werden. Der erste beschreibt das Verhalten auf freier Strecke, sodass hier die Wunschgeschwindigkeit den entscheidenden Parameter für das Verhalten des Fahrzeugs darstellt. Um alle möglichen Manöverausprägungen und Kombinationen in der Prädiktion abzudecken, wird die Wunschgeschwindigkeit mit einer Gleichverteilung um die aktuell gemessene Geschwindigkeit modelliert

$$p\left(v_{\text{des}}^{(k)}\right) = \mathcal{U}\left(v_l^{(k)} - \sigma_{\text{des}}v_l^{(k)}, v_l^{(k)} + \sigma_{\text{des}}v_l^{(k)}\right). \quad (8.2.4)$$

Alternativ kann die Wunschgeschwindigkeit als Verteilung um die bis zu diesem Zeitpunkt höchste gemessene Geschwindigkeit modelliert werden. Der Parameter σ_{des} beeinflusst die Breite der Gleichverteilung und wird in dieser Arbeit empirisch als $\sigma_{\text{des}} = 0,2$ gewählt. In dichtem Verkehr wirkt sich die Wunschgeschwindigkeit nur wenig auf die Beschleunigung aus, sodass hier der minimale zeitliche Abstand $T_H^{(k)}$ mit einer Gleichverteilung um den Wert aus Tabelle 3.1 abgebildet wird. Alle anderen Parameter werden für die einzelnen *Monte Carlo* Iterationen nicht verändert und bleiben somit konstant. Aktuell werden Fahrzeugtypen für die Prädiktion nicht unterschieden. Um allerdings beispielsweise Lastkraftwagen gesondert zu betrachten, können die Parameter der Fahrermodelle entsprechend angepasst werden, wenn die Fahrzeugklasse als Information im Umgebungsmodell bereitsteht.

Laterales Fahrermodell

Zusätzlich zur longitudinalen Beschleunigung werden laterale Bewegungen der beobachteten Agenten für die Prädiktion betrachtet. Dazu wird erneut die Annahme aus Kapitel 4 herangezogen, dass sich alle Manöver auf Autobahnen durch die drei Basismanöver Spurwechsel nach links, Spurhalten sowie Spurwechsel nach rechts darstellen lassen ($\mathcal{M} = \{\text{LCL}, \text{LK}, \text{LCR}\}$). Alle komplexeren Manöver können in eine Abfolge der Basismanöver zerlegt werden. Entsprechend muss das laterale Fahrermodell für jeden Agenten in der jeweiligen Verkehrssituation das wahrscheinlichste Manöver aus \mathcal{M} basierend auf dem Zustand der Simulationssiteration bestimmen. Während einer *Monte Carlo* Iteration wird das Fahrermodell in jedem Prädiktionsschritt ausgeführt, sodass eine Sequenz von Manövern umgesetzt wird. Hiermit lassen sich beispielsweise vollständige Überholmanöver darstellen. Für die Auswahl des aktuellen Manövers müssen Interaktionen mit anderen Agenten sowie die Straßentopologie berücksichtigt werden. Außerdem ist eine geringe Anzahl von Modellparametern wünschenswert, da andernfalls viele *Monte Carlo* Iterationen notwendig sind, um die Verteilung in

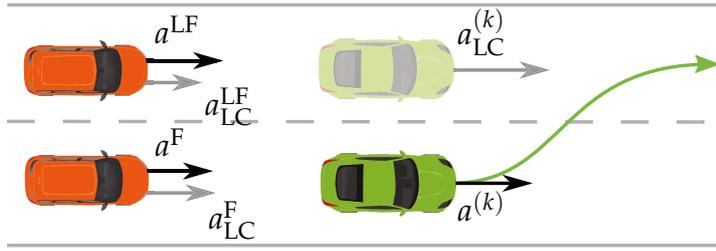


Abbildung 8.2.: Darstellung der Beschleunigungen des Folgefahrzeugs auf der aktuellen Fahrspur und der Zielspur für den Fall des Spurhaltens ($a^{F/LF}$) und einen Spurwechseln von Agent N_k ($a_{LC}^{F/LF}$).

Gleichung (8.2.3) zu approximieren. Als weiteres Kriterium ist die Umsetzung der Straßenverkehrsordnung der Bundesrepublik Deutschland zu beachten. Da auf deutschen Autobahnen überholen nur auf der linken Seite erlaubt ist und damit die linke Spur eine höhere Durchschnittsgeschwindigkeit ausweist, sind Modelle, die lediglich einen symmetrischen Verkehrsfluss modellieren, nicht geeignet. Außerdem muss das Modell effizient zu berechnen sein.

Um alle Anforderungen bestmöglich abzudecken, wird das Spurwechselmodell MOBIL (*Minimal Overall Braking Induced by Lane change*) von Kesting u. a. [Kes+07] ausgewählt. Das Modell minimiert abhängig von den Parametern die durch einen Spurwechsel induzierte Verzögerung aller Fahrzeuge in der aktuellen Verkehrssituation. Es verfügt über insgesamt vier Parameter und basiert hauptsächlich auf Beschleunigungen, die mit Hilfe des longitudinalen Fahrermodells berechnet werden. Zusätzlich kann es sowohl für den symmetrischen sowie asymmetrischen Verkehrsfluss eingesetzt werden. Um nur sichere Spurwechsel zuzulassen, wird ein Sicherheitskriterium definiert

$$a_{LC}^{LF} \geq -b_{\text{safe,mobil}}. \quad (8.2.5)$$

Dabei ist a_{LC}^{LF} die Verzögerung des Folgefahrzeugs auf der Zielspur, die durch einen potentiellen Spurwechsel von Agent N_k bewirkt wird, und $b_{\text{safe,mobil}}$ ein Modellparameter. Gleichung (8.2.5) beschreibt die maximale Verzögerung, die für die Durchführung eines Spurwechsels akzeptiert wird. Analog zu dem Sicherheitskriterium wird die Entscheidung für einen Spurwechsel auf Basis der gewonnenen Beschleunigung des jeweiligen Agenten und der Auswirkungen auf andere Agenten getroffen (siehe Abbildung 8.2). Das Kriterium anhand dessen die Entscheidung für einen Spurwechsel nach links getroffen wird, ist definiert durch

$$a_{LC}^{(k)} - a^{(k)} + \varrho^{(k)}(a_{LC}^{LF} - a^{LF}) > \Delta a_{\text{th,mobil}} + \Delta a_{\text{bias,mobil}}. \quad (8.2.6)$$

Analog ist das Kriterium für einen Spurwechsel nach rechts

$$a_{LC}^{(k)} - a^{(k)} + \varrho^{(k)}(a_{LC}^F - a^F) > \Delta a_{\text{th,mobil}} - \Delta a_{\text{bias,mobil}}. \quad (8.2.7)$$

Dabei ist

- $a^{(k)}$ die Beschleunigung von Agent N_k auf der aktuellen Spur,

- $a_{LC}^{(k)}$ die Beschleunigung von Agent N_k im Falle eines Spurwechsels,
- a_{LC}^{LF} und a_{LC}^{LF} die Beschleunigung des linken Folgefahrzeugs ohne und mit einem Spurwechsel von Agent N_k ,
- a^F und a_{LC}^F die Beschleunigung des aktuellen Folgefahrzeugs ohne und mit einem Spurwechsel von Agent N_k .

Alle Beschleunigungen werden mit dem longitudinalen Fahrermodell berechnet. Der Parameter $\Delta a_{th,mobil}$ stellt einen Schwellwert für eine Spurwechselentscheidung dar und $\Delta a_{bias,mobil}$ erzeugt ein Bias in Richtung der rechten Spur. So wird ein wiederholtes Wechseln aufgrund von leichten Beschleunigungsunterschieden vermieden und ein bevorzugter Wechsel auf die rechte Spur umgesetzt. Als letzter Parameter ist der Höflichkeitsfaktor $\varrho^{(k)} \in [0, 1]$ zu nennen. Für einen Spurwechsel nach links wird der Beschleunigungsgewinn durch das Manöver des jeweiligen Agenten N_k gegenüber dem potentiellen Verlust des Folgefahrzeugs auf der Zielspur abgewogen. Letzteres wird mit dem Höflichkeitsfaktor gewichtet. Ist der Schwellwert überschritten, wird der Spurwechsel ausgeführt. Im Falle eines Spurwechsels nach rechts wird der potentielle Gewinn des folgenden Fahrzeugs gegenüber dem Verlust des Agenten N_k abgewogen. Der Höflichkeitsfaktor bestimmt dabei, wie stark der Gewinn des Folgefahrzeugs die Entscheidung beeinflusst. Für $\varrho^{(k)} = 0$ wird eine rein egoistische Fahrweise umgesetzt. Im Falle von $\varrho^{(k)} = 1$ reagiert der Agent eher altruistisch und setzt den Gewinn eines anderen Fahrzeugs gleich mit dem eigenen. Das Modell hat insgesamt vier Parameter für jeden Agenten N_k , die in $\theta_{Lat}^{(k)} = [b_{safe,mobil}, \Delta a_{th,mobil}, \Delta a_{bias,mobil}, \varrho^{(k)}]^T$ aggregiert werden. Wie bei dem longitudinalen Fahrermodell werden nur die Parameter mit dem größten Einfluss auf das Fahrverhalten innerhalb der *Monte Carlo* Iterationen variiert, während die anderen konstant bleiben. Im Fall des lateralen Fahrermodells wird lediglich der Höflichkeitsfaktor mit einer Verteilung modelliert, die sowohl egoistische als altruistische Fahrer abbildet

$$\varrho^{(k)} = \mathcal{U}(0, 1). \quad (8.2.8)$$

Um die Straßentopologie in der Spurwechselentscheidung zu berücksichtigen, wird ein fiktives stehendes Hindernis am Ende einer endenden Spur platziert. Dieses verursacht eine Verzögerung eines Agenten auf der Spur und induziert somit einen Spurwechsel. Basierend auf der Straßentopologie, den anderen Agenten und den Parametern bestimmt das laterale Fahrermodell in jedem Prädiktionsschritt ein Manöver aus \mathcal{M} .

Probabilistische Modellierung der Manöverausführung

Neben der Unsicherheit der Manöverauswahl, die durch die probabilistische Formulierung der Fahrermodelle modelliert wird, muss für die anschließende Ausführung ebenfalls der nicht beobachtbare Fahrer berücksichtigt werden. Dazu wird für den Agenten N_k basierend auf dem aktuellen Manöver ein Pfad $\check{p}_m^{(k)}$ generiert, dem der Agent für die aktuelle *Monte Carlo* Iteration durch die Verkehrssituation folgt. Dabei wird der Pfad konstant gehalten, solange sich das Manöver nicht ändert ($m^{(k)}(\tau) :=$

$m^{(k)}(\tau - \Delta T)$). Um Abweichungen von der Standardausführung eines Manövers zu modellieren, wird ein Pfad aus einem Basispfad und einer Stichprobe aus einem Zufallsprozess zusammengesetzt. Das Vorgehen ist dabei analog zu dem in Abschnitt 3.3, sodass sich der Pfad aus Gleichung (3.3.7) ergibt. Die Unsicherheit der Manöverausführung wird durch die unterschiedliche Ausführung der Manöver in jeder *Monte Carlo* Iteration modelliert.

Um dem erstellten Pfad zu folgen, wird eine Pfadfolgeregelung umgesetzt, die den Fehler zwischen einem Vorausschaupunkt und dem Pfad minimiert. Dazu wird zunächst die laterale Position zur Vorausschauzeit t_V mit der gesuchten Beschleunigung a_n bestimmt

$$n(\tau + t_V) = n(\tau) + v_n(\tau)t_V + \frac{1}{2}a_n t_V^2. \quad (8.2.9)$$

Wird der Fehler zwischen diesem Punkt und dem Pfad n_p zu Null gesetzt

$$0 \stackrel{!}{=} n(\tau + t_V) - n_p \quad (8.2.10)$$

und anschließend nach der Beschleunigung aufgelöst, ergibt sich

$$a_n = 2 \frac{n_p - (n(\tau) + v_n(\tau)t_V)}{t_V^2}. \quad (8.2.11)$$

Mit dem vorgestellten Vorgehen können die Trajektorien aller Agenten in der aktuellen Verkehrssituation unter Berücksichtigung der Interaktionen zwischen diesen präzisiert werden. Da allerdings auch die Manöver des Ego-Fahrzeugs einen Einfluss auf die beobachteten Agenten haben, muss dieses ebenfalls in die Prädiktion einbezogen werden. Im Falle einer Kopplung mit der Entscheidungsfindung ist die Trajektorie des Ego-Fahrzeugs durch das ausgewählte Manöver gegeben. Alternativ kann die geplante Trajektorie aus der letzten Iteration genutzt werden. Da hier allerdings die Prädiktion als eigenständige Funktion dargestellt werden soll, wird das Ego-Fahrzeug als weiterer Agent behandelt, der mit Hilfe der Fahrermodelle in der Situation präzisiert wird. Der vorgestellte Ansatz betrachtet dabei die drei Arten von Unsicherheiten, die bereits in Abschnitt 2.2 vorgestellt wurden:

1. Die Unsicherheit des aktuellen Zustands kann durch Darstellung des Startzustandes als eine Stichprobe aus der geschätzten Verteilung in jeder *Monte Carlo* Simulation berücksichtigt werden.
2. Die Unsicherheit des ausgeführten Fahrmanövers abhängig von der aktuellen Verkehrssituation wird durch die Variation der Fahrermodellparameter erreicht. Es werden verschiedene Fahrertypen betrachtet und so unterschiedliche Entwicklungen der Verkehrssituation präziziert.
3. Die Unsicherheit der fahrerindividuellen Ausführung einzelner Manöver wird durch die Überlagerung des Manöverpfades mit dem Gauß Prozess modelliert. Da die Parameter des Gauß Prozesses mit Hilfe von aufgenommenen Daten der beobachteten Fahrzeuge bestimmt werden, bilden diese unterschiedliche Fahrstile ab.

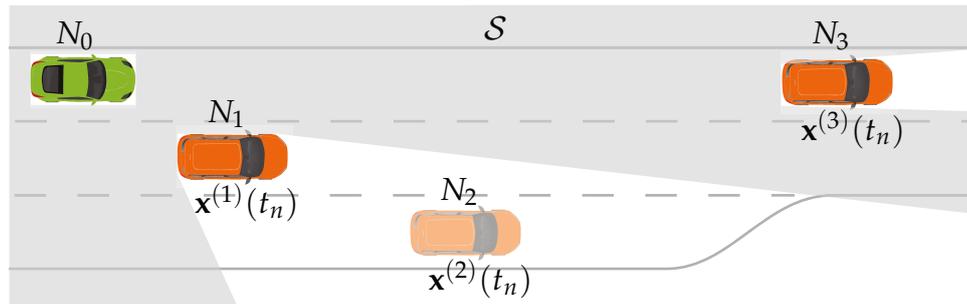


Abbildung 8.3.: Darstellung des Sensorsichtbereiches des Ego-Fahrzeugs und der damit verbundenen Unvollständigkeit des Umgebungsmodells.

8.3. Verbesserung bei einem unvollständigen Umgebungsmodell

Der bisher beschriebene Ansatz zur interaktionsbasierten Prädiktion von Trajektorien kann grundsätzlich mit jeder Art von Sensorconfiguration genutzt werden. Allerdings ist die Vollständigkeit des Umfeldmodells ein wichtiges Kriterium, um Interaktionen zu modellieren. In Abbildung 8.3 ist der Sichtbereich einer Sensorconfiguration, die nur auf im Ego-Fahrzeug verbauten Sensoren beruht, dargestellt. In dem dargestellten Beispiel werden keine hoch genauen Karten verwendet, aus denen die Straßentopologie abgeleitet werden kann. Außerdem kann nicht auf eine Fahrzeug zu Fahrzeug Kommunikation zurückgegriffen werden, da die Verbreitung in aktuellen Fahrzeugen nicht gegeben ist. Aufgrund der Verdeckung durch Agent N_1 wird N_2 von den Sensoren nicht wahrgenommen. Zusätzlich ist die endende rechte Spur aus Sicht des Ego-Fahrzeugs nicht zu erkennen. Das Umgebungsmodell, auf Basis dessen die Prädiktion stattfindet, ist in diesem Moment nicht vollständig.

Das unvollständige Umgebungsmodell führt zu der Vernachlässigung von Interaktionen zwischen Verkehrsteilnehmern. In dem Beispiel wird zum einen die Interaktion zwischen N_1 und N_2 nicht berücksichtigt, sodass für N_2 kein Spurwechsel nach links vorhergesagt wird. Vielmehr prädiziert ein interaktionsbasierter Ansatz für N_1 entsprechend des Rechtsfahrgebotes und Gleichung (8.2.7) einen Spurwechsel nach rechts, da das Ende der rechten Spur nicht erkannt und somit eine freie Spur angenommen wird. Durch die fehlende Interaktion erfolgt auch im Falle eines bereits begonnenen Spurwechsels keine Prädiktion auf die Zielspur, sodass hier ein großer Prädiktionsfehler entsteht.

Um den Einfluss des unvollständigen Umgebungsmodells zu reduzieren, wird die in Kapitel 4 vorgestellte probabilistische Manöverklassifikation genutzt. Damit wird für jeden Agenten N_k im Umgebungsmodell die Verteilung über das aktuelle Fahrmanöver $p(m^{(k)}(t_n))$ zum Zeitpunkt t_n geschätzt. Aus dieser Wahrscheinlichkeitsverteilung wird für jede Monte Carlo Iteration des initiale Manöver gezogen und ein entsprechender Pfad generiert. Diese Vorgehensweise vereint den Vorteil der manöverbasierten Trajektorienprädiktion in Form einer hohen Genauigkeit für einen kurzen zeitlichen Horizont mit den Vorteilen der interaktionsbasierten Prädiktion.

8.4. Evaluation der interaktionsbasierten Trajektorienprädiktion

Die Berücksichtigung der Interaktionen zwischen den Agenten innerhalb einer Verkehrssituation erlaubt eine Prädiktion über die Umsetzung einzelner Manöver hinaus. Im Vergleich zu dem in Kapitel 5 vorgestellten manöverbasierten Ansatz zur Trajektorienprädiktion ist daher ein kleinerer Fehler für große Prädiktionszeiten $\tau > 5$ s zu erwarten. Für die Auswertung wird der absolute longitudinale und laterale Fehler der prädizierten Trajektorien für eine Prädiktionsdauer von $T_p = 10$ s des interaktionsbasierten mit dem manöverbasierten Ansatz verglichen. Um die modellierte Interaktion zwischen den Agenten auszuwerten, wird zusätzlich die Anzahl der prädizierten Kollisionen in beiden Ansätzen ausgewertet. Im normalen Verkehrsfluss versucht jeder Fahrer eine Kollision mit einem anderen Fahrzeug bestmöglich zu vermeiden. Entsprechend ist die Güte einer geschätzten Verteilung, die keine Kollisionen innerhalb des Prädiktionshorizontes enthält, gegenüber prädizierten Trajektorien mit Kollisionen zu bevorzugen. Hier ist für die manöverbasierte Trajektorienprädiktion ein schlechteres Ergebnis gegenüber dem interaktionsbasierten Ansatz zu erwarten, da die Trajektorie für jeden Agenten individuell ohne Einflüsse der anderen Agenten bestimmt wird. Zwei Trajektorien werden dabei als kollidierend gewertet, wenn in den prädizierten Trajektorien von Agent i und Agent j zwei Zustände zum gleichen Zeitpunkt einen longitudinalen Abstand kleiner $d_{\text{long}}^c = 2$ m und einen lateralen Abstand kleiner $d_{\text{lat}}^c = 1$ m aufweisen. Als Metrik dient die gesamte Anzahl der Kollisionen innerhalb der Menge von prädizierten Situationen \mathcal{T}

$$n^c = \sum_{\mathcal{T}} \sum_{i,j \in \mathcal{Z}, i \neq j} \Psi \left(\hat{\mathbf{x}}^{(i)}(\tau), \hat{\mathbf{x}}^{(j)}(\tau) \right). \quad (8.4.1)$$

Dabei ist die Kollisionsfunktion Ψ definiert als

$$\Psi \left(\hat{\mathbf{x}}^{(i)}(\tau), \hat{\mathbf{x}}^{(j)}(\tau) \right) = \begin{cases} 1 & \text{wenn } \exists \tau \in [0, T_p] : |\hat{\mathbf{x}}^{(i)}(\tau) - \hat{\mathbf{x}}^{(j)}(\tau)| < d_{\text{long}}^c \wedge |\hat{\mathbf{y}}^{(i)}(\tau) - \hat{\mathbf{y}}^{(j)}(\tau)| < d_{\text{lat}}^c \\ 0 & \text{sonst} \end{cases}. \quad (8.4.2)$$

Qualitative Auswertung in ausgewählten Szenarien

Zunächst wird die Auswirkung der Modellierung von Interaktionen zwischen Agenten innerhalb der Verkehrssituation auf die geschätzte Verteilung der zukünftigen Trajektorien anhand von zwei exemplarischen Szenarien verdeutlicht. Das erste Beispiel ähnelt der Situation in Abbildung 8.1. Das Ego-Fahrzeug befindet sich auf einer dreispurigen Autobahn, dessen rechte Spur in etwa in 250 m endet. Zusätzlich fahren drei Agenten N_1 , N_2 und N_3 vor dem Ego-Fahrzeug, wobei sich N_2 auf der endenden rechten Spur befindet und somit einen Spurwechsel nach links durchführen muss. Das Szenario entspricht somit einer Autobahnauffahrt, bei der sich N_2 auf der Autobahn einordnen muss. Es wird angenommen, dass die Entfernung bis zum Ende der rechten Spur für die Prädiktion bekannt ist, sodass der Spurwechsel von N_2 aufgrund der

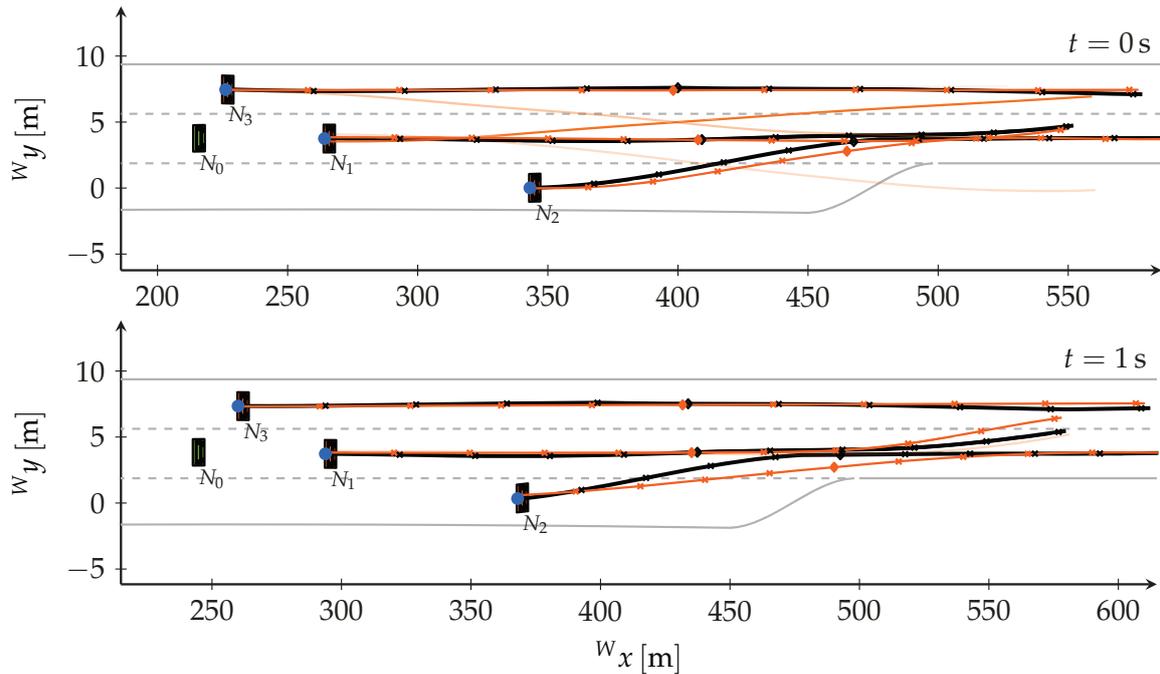


Abbildung 8.4.: Beispiel Szenario mit einer endenden rechten Spur. Das Fahrzeug auf der rechten Spur muss einen Spurwechsel nach links durchführen und beeinflusst damit die Manöver der restlichen Fahrzeuge.

Interaktion mit der statischen Umgebung modelliert werden kann. Auch wenn diese Information im Idealfall aus einer digitalen Karte entnommen werden kann, muss diese nicht notwendiger Weise vorhanden sein. Die Informationen über die endende Spur kann auch durch entsprechende Schilder oder Kontextwissen, zum Beispiel über die Topologie einer Auffahrt, erlangt werden. Für jeden Agenten ist zum einen die Referenztrajektorie (schwarz) und zum anderen die prädizierten Trajektorien für die möglichen Entwicklungen der Situation dargestellt. Dabei wird die Wahrscheinlichkeit einer Trajektorie über die Transparenz ausgedrückt. Für die wahrscheinlichste Vorhersage jedes Agenten sowie die Referenztrajektorie sind zusätzlich für jede Sekunde Kreuzmarkierungen und nach $\tau = 5$ s eine Raute aufgetragen, um eine zeitliche Zuordnung zu ermöglichen. Die Anfangszustände aller Agenten in dem Szenario sind in Tabelle 8.1 zusammengefasst.

Im oberen Teil von Abbildung 8.4 ist die Ausgangssituation und die Ergebnisse der Prädiktion zu diesem Zeitpunkt dargestellt. Entsprechend der Straßentopologie wird für N_2 ein unmittelbarer Spurwechsel nach links prädiziert, sodass das Fahrzeug der mittleren Spur weiter folgt. Aufgrund des Manövers von N_2 ergibt sich für Agent N_1 die Möglichkeit in der aktuellen Spur zu bleiben und die Geschwindigkeit zu verringern oder ebenfalls einen Spurwechsel nach links durchzuführen und damit Agent N_3 zu einer Verringerung der Geschwindigkeit zu zwingen. Zum Zeitpunkt $t = 0$ s werden beide Möglichkeiten mit etwa gleicher Wahrscheinlichkeit prädiziert. Die Verzögerung auf der mittleren Spur ist anhand der kürzeren Trajektorie im Vergleich zum Spurwechsel zu erkennen. Für Agent N_3 wird aufgrund der hohen Geschwindigkeit ein Spurhalteманöver prädiziert. Allerdings beeinflusst der mögliche Spurwechsel von

Tabelle 8.1.: Anfangszustände der Agenten in den gezeigten Verkehrssituationen.

| Agent | $^W x(t = 0)$ | $^W y(t = 0)$ | $v_x(t = 0)$ | $v_y(t = 0)$ |
|---------------------------------|---------------|---------------|--------------|--------------|
| Endende Spur | | | | |
| N_0 | 216 m | 3,75 m | 29,60 m/s | 0 m/s |
| N_1 | 266 m | 3,75 m | 29,96 m/s | 0 m/s |
| N_2 | 345 m | 0,00 m | 24,84 m/s | 0 m/s |
| N_3 | 227 m | 7,50 m | 35,00 m/s | 0 m/s |
| Unvollständiges Umgebungsmodell | | | | |
| N_0 | 105 m | 0,00 m | 29,23 m/s | 0 m/s |
| N_1 | 155 m | 0,00 m | 27,03 m/s | 0 m/s |
| N_2 | 205 m | 0,00 m | 21,96 m/s | 0 m/s |
| N_3 | 82 m | 3,75 m | 35,69 m/s | 0 m/s |

N_1 die Prädiktion, sodass zusätzlich zu der Möglichkeit die aktuelle Geschwindigkeit beizubehalten die Möglichkeit einer Verzögerung als Reaktion auf das langsamere Fahrzeug prädiziert wird. Die Trajektorie, die die Verzögerung abbildet, ist in der Abbildung nicht zu erkennen, da sie hinter der Trajektorie mit konstanter Geschwindigkeit liegt. Eine Sekunde später hat sich die Geschwindigkeit von Agent N_3 nicht verringert, während Agent N_1 langsamer geworden ist. Daher ist die Möglichkeit eines Spurwechsels von N_1 auf die linke Spur deutlich unwahrscheinlicher geworden, sodass eine Verzögerung prädiziert wird. Gleichzeitig ist für die Prädiktion von N_3 keine Verzögerung notwendig. Außerdem ist am Ende der prädizierten Trajektorie von N_1 der Start eines Spurwechsels nach links zu erkennen. Nachdem N_1 von N_3 überholt wurde, ist die linke Spur frei und wird von N_1 für den Überholvorgang des langsameren Agenten N_2 genutzt. Hier zeigt sich deutlich der Vorteil der betrachteten Interaktion für die Prädiktion über einen langen Zeitraum. Durch die alleinige Betrachtung des aktuellen Fahrmanövers ist die Prädiktion des späten Überholvorganges nicht möglich.

Wie bereits in Abschnitt 8.3 dargelegt, ist die Vollständigkeit des Umgebungsmodells eine wichtige Voraussetzung für die korrekte Modellierung von Interaktionen zwischen einzelnen Agenten. In Abbildung 8.5 ist eine Verkehrssituation dargestellt, in der durch Verwendung des klassifizierten Fahrmanövers das fehlerhafte Umgebungsmodell teilweise kompensiert werden kann. Das Ego-Fahrzeug befindet sich mit drei weiteren Fahrzeugen auf einer dreispurigen Autobahn. Dabei wird Agent N_2 aufgrund der Verdeckung durch Agent N_1 von den Sensoren des Ego-Fahrzeugs nicht wahrgenommen. Der schnellere Agent N_1 führt einen Spurwechsel nach links durch und beeinflusst damit N_3 ebenfalls zu einem Spurwechsel. Aufgrund der fehlenden Interaktion zwischen N_2 und N_1 wird allerdings zum Zeitpunkt $t = 0$ s kein Spurwechsel prädiziert. Eine Sekunde später beginnt das Manöver von N_2 , sodass die Spurwechselwahrscheinlichkeit ansteigt und sich somit eine zweite mögliche Entwicklung der Situation ergibt. Da N_3 eine größere longitudinale Geschwindigkeit aufweist, führt der prädizierte Spurwechsel von N_2 zu einer Interaktion und damit ebenfalls zu einem möglichen Spurwechsel nach links. Zum Zeitpunkt $t = 2$ s ist die Wahrscheinlichkeit für einen Spurwechsel größer als für ein Spurhalte-Manöver, sodass die entsprechende

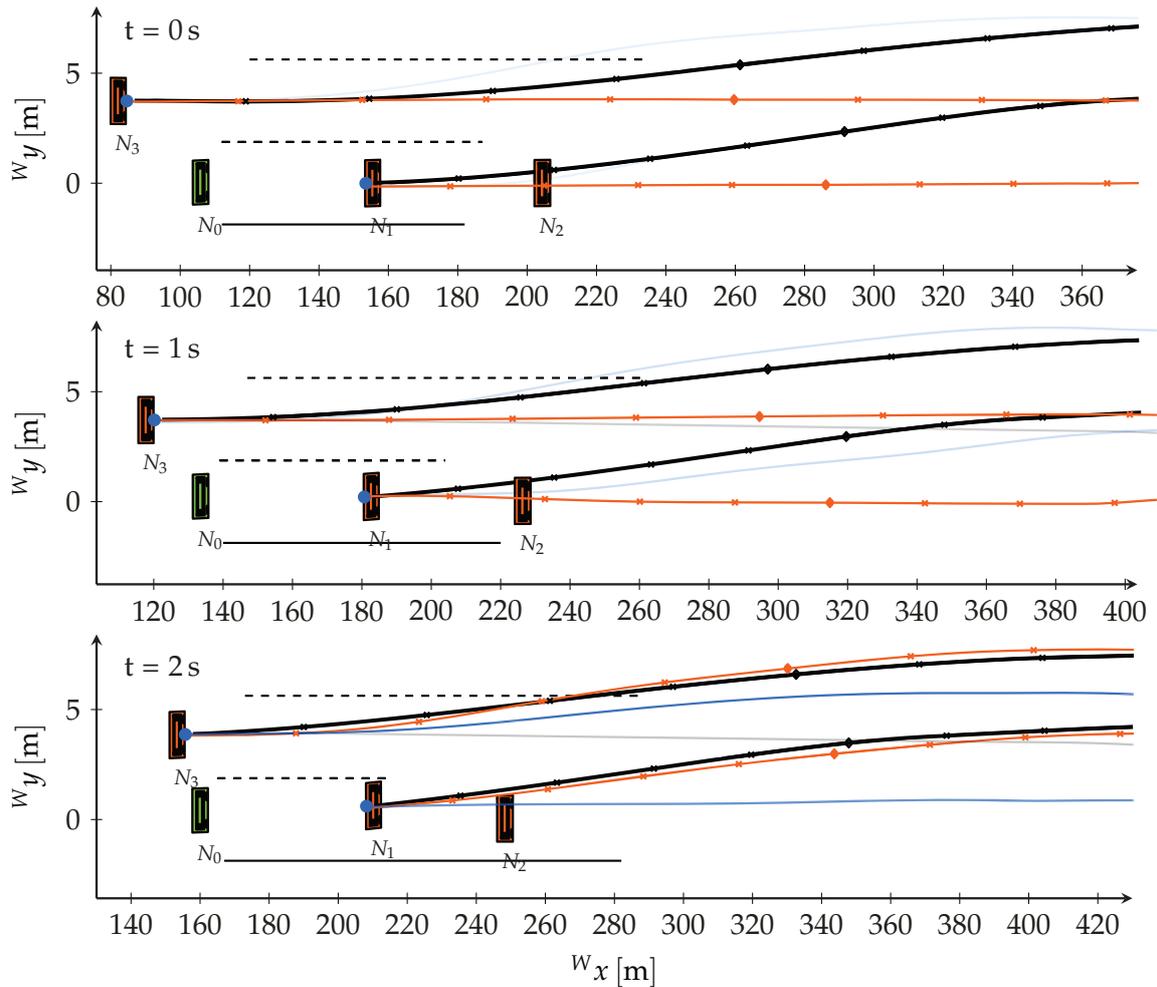


Abbildung 8.5.: Beispiel Szenario mit drei Spuren, in dem das Vorderfahrzeug von N_1 nicht von den Sensoren des Ego-Fahrzeugs erfasst und somit keine Interaktion modelliert werden kann.

Trajektorie am wahrscheinlichsten wird. Das Beispiel zeigt die Möglichkeiten, ein unvollständiges Umgebungsmodell mit Hilfe der probabilistischen Manöverklassifikation zu kompensieren. Allerdings wird auch deutlich, dass die Kompensation ausschließlich für aktuelle Manöver wirksam ist. Der Vorteil einer gültigen Prädiktion für einen langen Prädiktionshorizont kann mit einem unvollständigen Umgebungsmodell nicht ausgenutzt werden.

Quantitative Auswertung der Prädiktionsgüte

Die Ergebnisse der interaktionsbasierten Trajektorienprädiktion in einzelnen Szenarien zeigen das Potential des Ansatzes, wenn ein vollständiges Umgebungsmodell zur Verfügung steht. Allerdings wird auch deutlich, dass eine fehlerhafte Repräsentation der Umgebung zu deutlichen Fehlern der Prädiktion führen kann. Im Folgenden wird der statistische Fehler auf Basis der in der Simulation erzeugten Daten bestimmt und mit dem des manöverbasierten Ansatzes verglichen. Dazu ist in Abbildung 8.6 der longitudinale und laterale Fehler für die Prädiktionszeit $\tau \in [0, T_p = 10\text{ s}]$ beider An-

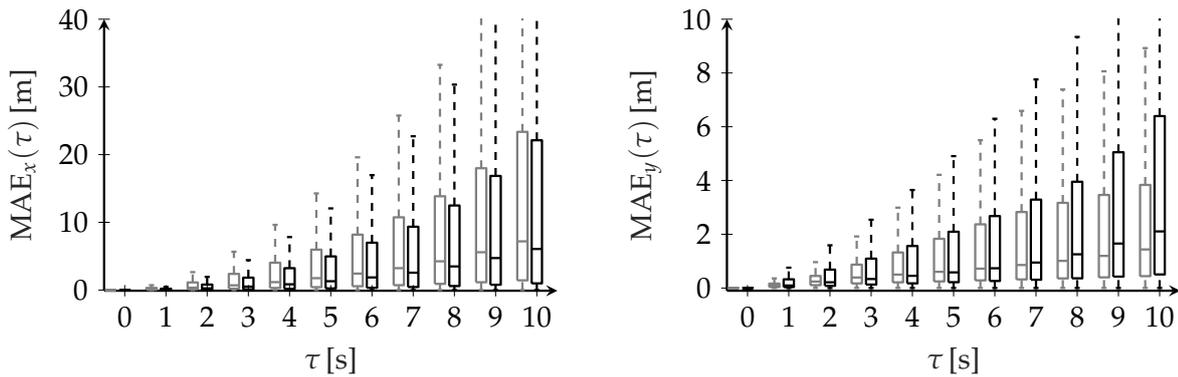


Abbildung 8.6.: Vergleich des absoluten longitudinalen (links) und lateralen (rechts) Fehlers für den manöverbasierten (schwarz) und den interaktionsbasierten Ansatz (grau).

sätze dargestellt. Da die Interaktion mit Agenten, die sich hinter dem Ego-Fahrzeug befinden, ebenfalls modelliert wird, werden diese Fahrzeuge anders als in den Kapiteln 5 und 7 in der Auswertung zusätzlich berücksichtigt. Dazu werden die erkannten Spuren nach hinten extrapoliert, um die Zuordnung einzelner Fahrzeuge durchzuführen. Eine zuverlässige Berechnung der Merkmale für die Manöverklassifikation ist auf dieser Basis nicht möglich, sodass für alle Fahrzeuge ein Spurhaltenmanöver angenommen wird.

Es ist zu erkennen, dass der longitudinale Fehler des interaktionsbasierten Ansatzes etwas größer ist als der des manöverbasierten Ansatzes. Dies resultiert zum einen aus dem unvollständigen Umgebungsmodell, durch das Interaktionen innerhalb der Prädiktion falsch oder gar nicht betrachtet werden können. Zum größeren Teil wird der Fehler allerdings durch die Approximation der Verteilung durch die *Monte Carlo* Simulation verursacht. Die Variation der Wunschgeschwindigkeit und die begrenzte Anzahl von Iterationen führen zu einer mittleren Wunschgeschwindigkeit, die von der aktuellen Geschwindigkeit abweicht. Im Falle eines unvollständigen Umfeldmodells ist die Annahme einer konstanten Geschwindigkeit allerdings besser als eine zufällige Variation. Der entsprechende Fehler ist in der linken Abbildung in 8.6 zu erkennen. Im Gegensatz dazu ist für den lateralen Fehler eine Verbesserung im Vergleich zu dem manöverbasierten Ansatz zu sehen. Gerade für große Prädiktionszeiten $\tau > 5$ s sind sowohl der Median als auch die dargestellten Intervalle des lateralen Fehlers für den interaktionsbasierten Ansatz kleiner als der entsprechende Fehler der MBTP aus Kapitel 5. Im Vergleich zu den Fehlern in Abbildung 5.4 ist insgesamt ein Anstieg zu erkennen, der auf die Prädiktion für Agenten, die sich hinter dem Ego-Fahrzeug befinden, zurückzuführen ist.

Um die Güte der approximierten Verteilung zu bewerten, ist in Abbildung 8.7 die Likelihood der Referenztrajektorie für die prädizierte Zustandsverteilung für die interaktionsbasierte Trajektorienprädiktion sowie für den manöverbasierten Ansatz als Vergleich dargestellt. Hier zeigt sich der Vorteil der genaueren Modellierung der Unsicherheit im interaktionsbasierten Ansatz. Die Variation in der simulierten Manöverausführung, die durch den mit Hilfe von aufgenommenen Daten parametrisierten Gauß Prozess erreicht wird, bildet die tatsächliche Unsicherheit deutlich genauer ab als die

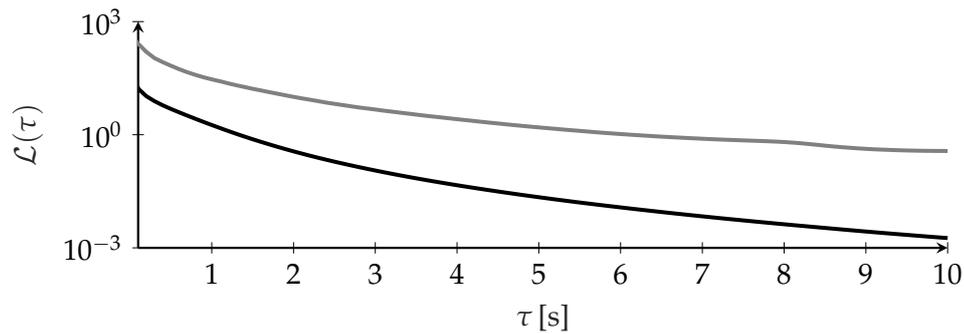


Abbildung 8.7.: Vergleich der Likelihood des manöverbasierten (schwarz) und des interaktionsbasierten Ansatzes (grau).

Unsicherheitsfortpflanzung aus Abschnitt 5.2. Somit ergibt sich eine höhere Likelihood für den interaktionsbasierten Ansatz über den gesamten Prädiktionshorizont.

Abschließend werden die prädizierten Kollisionen beider Verfahren ausgewertet. Für den interaktionsbasierten Ansatz ergeben sich für alle ausgewerteten Situationen im Simulationsdatensatz insgesamt $n^c = 939$ Kollisionen. Als Vergleich wird erneut die manöverbasierte Trajektorienprädiktion herangezogen, in der insgesamt $n^c = 1839$ Kollisionen auftreten. Durch die Berücksichtigung von Interaktionen kann die Anzahl der prädizierten Kollisionen in etwa halbiert werden, was für eine insgesamt bessere Prädiktion spricht. Die Ursache für Kollisionen im interaktionsbasierten Ansatz liegen hauptsächlich in der Umsetzung der Spurwechselentscheidungen während der Vorwärtssimulation. Sobald die Entscheidung getroffen und das Manöver gestartet ist, wird der Agent der Zielspur zugeordnet. Schnellere Agenten auf der aktuellen Spur können also bereits zu diesem Zeitpunkt ein Überholmanöver durchführen. Im Zuge dessen kommt es besonders im dichten Verkehr zu Situationen, in denen der Mindestabstand für eine Kollision unterschritten wird.

Insgesamt zeigt die Auswertung die Einschränkungen der interaktionsbasierten Trajektorienprädiktion für den Fall eines unvollständigen Umfeldmodells auf. Für die Modellierung von Interaktionen ist entscheidend, dass möglichst alle Verkehrsteilnehmer, die einen Einfluss auf das zu prädizierende Fahrzeug haben können, im Umgebungsmodell enthalten sind. Diese Einschränkung kann durch die Betrachtung von initialen Fahrmanövern auf Basis der geschätzten Manöververteilung zum Teil aufgehoben werden. Nicht unmittelbar stattfindende Spurwechsel können allerdings weiterhin nicht prädiziert werden. Zusätzlich profitiert das Verfahren von Informationen über die Straßentopologie, die entweder aus einer digitalen Karte oder aus Verkehrsschildern und Kontextwissen gewonnen werden können. Die Auswertung zeigt allerdings auch, dass für eine zuverlässige Prädiktion über einen langen Zeithorizont die Interaktionen zwischen einzelnen Verkehrsteilnehmern nicht vernachlässigt werden können. Das vorgestellte Verfahren ermöglicht im Falle eines genauen und vollständigen Umgebungsmodells die Prädiktion von beliebigen Autobahnscenarien für einen langen Prädiktionshorizont, wobei auch topologische Begebenheiten direkt berücksichtigt werden können.

9

Zusammenfassung und Ausblick

Die Umsetzung einer voll automatisierten Autobahnfahrt, in der der Fahrer keine Brems- oder Lenkeingriffe mehr durchführen muss und sich fahrfremden Tätigkeiten widmen kann, erfordert großen Entwicklungsaufwand in den verschiedenen Bereichen der funktionalen Architektur eines automatisierten Fahrzeugs. Neben der Sensorwahrnehmung und Fusion ist die Situationsanalyse eine der notwendigen Voraussetzungen für eine sichere sowie komfortable Planung und Umsetzung des Fahrmanövers. Innerhalb der Situationsanalyse wird auf Basis des Umgebungsmodells, welches die aktuelle Verkehrsszene abbildet, die mögliche Entwicklung der Situation prädiziert. Dabei müssen aufgrund der nicht messbaren Größen wie beispielsweise der Fahrerintention verschiedene Arten von Unsicherheiten berücksichtigt werden, sodass als Ergebnis eine Verteilung über die zukünftigen Zustände der beobachteten Fahrzeuge zur Verfügung steht. Die Manöverplanung kann anschließend unter Berücksichtigung aller Unsicherheiten das bestmögliche Manöver für das Ego-Fahrzeug bestimmen.

Die vorliegende Arbeit stellt drei verschiedene Verfahren zur Trajektorienprädiktion für automatisierte Fahrzeuge in Autobahnscenarien vor. Dabei wird die Entwicklung der Verfahren mit Hilfe einer Simulationsumgebung vorgenommen, die auf die speziellen Anforderungen der Trajektorienprädiktion zugeschnitten ist. Diese Anforderungen werden zunächst identifiziert und eine Analyse von vorhandenen kommerziellen sowie wissenschaftlichen Simulationsumgebungen durchgeführt. Da keine der untersuchten Umgebungen alle Anforderungen zufriedenstellend erfüllt, wird im nächsten Schritt die selbst entwickelte Simulationsumgebung DESIM vorgestellt. Die Situationsanalyse verwendet das Umgebungsmodell als Ausgangspunkt, welches auf vollständig fusionierten Sensormessungen basiert. Eine detaillierte Modellierung einzelner Sensoren in der Simulation ist daher nicht nötig. Vielmehr muss die vollständige Verarbeitungskette der Wahrnehmung bestehend aus Sensordetektion, Fusion und Tracking über mehrere Zeitschritte mit den für die Situationsanalyse relevanten Effekten in der Simulation abgebildet werden. Hierzu wird ein rekursives Modell für die Schätzung der Unsicherheit eines detektierten Fahrzeugs in Kombination mit der Modellierung einiger sensorspezifischer Effekte vorgestellt. Ein weiterer Schwerpunkt der Simulation liegt in der Abbildung des Umgebungsverkehrs, der sich automatisiert in dem betrachteten Szenario bewegen muss. Dabei ist ein menschliches, stochastisches Verhalten der Verkehrsteilnehmer erforderlich. Der Einsatz von Fahrzeugfolge- und Spurwechselmodellen aus der mikroskopischen Verkehrssimulation ermöglicht durch

zufällige Parametrierung eine große Variabilität in den simulierten Szenarien. DESIM erfüllt damit alle Anforderungen für die Entwicklung einer Trajektorienprädiktion für Autobahnszenarien.

Die vorgestellte manöverbasierte Trajektorienprädiktion und die sicherheitskritische Trajektorienprädiktion gehören zur Kategorie der manöverbasierten Verfahren. Zunächst wird für jedes Fahrzeug eine probabilistische Klassifikation zwischen den Manövern Spurwechsel nach links oder rechts sowie Spurhalten vorgenommen, wobei als Klassifikator die Support Vektor Maschine gewählt wird. Auf Basis von Merkmalen, die sowohl die Bewegung des Fahrzeugs als auch die aktuelle Verkehrssituation beschreiben, wird für jedes Fahrzeug die Verteilung über die Manöverwahrscheinlichkeiten bestimmt. Die Klassifikation wurde zum einen mit Daten aus der Simulation und zum anderen mit Daten aus einem Testfahrzeug validiert. Für die manöverbasierte Trajektorienprädiktion wird jede Manöverklasse mit einer Prototypentrajektorie abgebildet und mit der geschätzten Wahrscheinlichkeitsverteilung kombiniert. Um auch in kurvigen Szenarien die Verwendung einer einfacher Beschreibungsform zu ermöglichen, werden die beobachteten Fahrzeuge in ein kurvilineares Koordinatensystem transformiert, sodass die Prädiktion immer für einen geraden Straßenverlauf durchgeführt werden kann. Zur Beschreibung der einzelnen Trajektorien wird ein kubischer Spline mit einer linearen Unsicherheitsfortpflanzung verwendet. Die Auswertung auf Basis der in der Simulation erzeugten Daten zeigt die Vorteile der MBTP gegenüber physikalischen Verfahren wie CV und CVCL in kurvigen Szenarien und für Spurwechselmanöver. Insbesondere ermöglicht die MBTP eine detailliertere Abbildung der Wahrscheinlichkeitsverteilung über die prädizierten Zustände. Bei der Auswertung der Daten aus dem Testfahrzeug zeigt sich, dass eine Prädiktion mit der Annahme konstanter Geschwindigkeit und Orientierung allen weiteren betrachteten Verfahren überlegen ist. Die Ursache liegt in der Repräsentation des Straßenverlaufes im Umgebungsmodell. Da die betrachteten Verfahren die Transformation in das kurvilineare Koordinatensystem nutzen, entsteht durch einen falsch gemessenen Straßenverlauf ein großer Fehler, der den Fehler der Orientierungsschätzung übertrifft. Zusätzlich sind in den mit dem Testfahrzeug aufgenommenen Daten nur minimal gekrümmte Straßenverläufe enthalten, sodass die Prädiktion einer Fahrt geradeaus häufig gute Ergebnisse erzeugt.

In einem nächsten Schritt wird die MBTP um die Betrachtung der Dynamik eines beobachteten Spurwechsels erweitert. Dazu wird die Zeit geschätzt, die ein Fahrzeug bis zum Überqueren der Spurmarkierung benötigt. Da die Ausführung eines Manövers je nach Fahrer und Situation einer Variation unterliegt, wird eine probabilistische Betrachtung vorgenommen. Um Einschränkungen durch eine parametrische Darstellung der Verteilung zu vermeiden, wird die Schätzung einzelner bedingter Quantile als Regressionsproblem formuliert, welches mit Hilfe von *Quantile Regression Forests* gelöst wird. Die resultierenden geschätzten Quantile und der Median werden innerhalb der SKTP verwendet, um durch die Berücksichtigung von unerwartet dynamischen Spurwechselmanövern eine komfortable und sichere Planung des Ego-Fahrmanövers umzusetzen. Dazu werden Trajektorien unter Berücksichtigung der geschätzten Quantile als kubische Splines repräsentiert und stellen somit je nach gewähltem Quantil einen mehr oder weniger dynamischen Spurwechsel dar. In der Auswertung zeigt die

SKTP bei der Betrachtung des Medians eine ähnliche Genauigkeit wie die MBTP. Die durch weitere Quantile begrenzten Bereiche erlauben zusätzlich die Berücksichtigung von einem Großteil aller Spurwechseltrajektorien in dem Simulationsdatensatz.

Als drittes Verfahren wird eine interaktionsbasierte Trajektorienprädiktion (IBTP) vorgestellt, die die Vorhersage verschiedener Entwicklungen der aktuellen Verkehrssituation ermöglicht und die entsprechende Wahrscheinlichkeit bestimmt. Dabei wird eine *Monte-Carlo* Simulation in Verbindung mit probabilistischen Fahrermodellen verwendet, um die Interaktion zwischen einzelnen Verkehrsteilnehmern zu modellieren. In jedem Simulationszyklus werden die Parameter der Fahrermodelle variiert, sodass unterschiedliche Fahrertypen abgebildet werden. Zur Kompensation eines unvollständigen Umgebungsmodells, wird zusätzlich die Verteilung der Manöverwahrscheinlichkeiten für die Bestimmung des initialen Fahrmanövers in den einzelnen Simulationsdurchläufen verwendet. Die Auswertung in beispielhaften Szenarien zeigt das Potential für ein vollständiges und die Folgen eines unvollständigen Umgebungsmodells der IBTP. Die Betrachtung der geschätzten Manöververteilung eignet sich zu einer teilweisen Kompensation eines fehlerhaften Umgebungsmodells, sodass der statistische Fehler für lange Prädiktionszeiten kleiner ist als für die MBTP. Außerdem zeigt sich, dass die Modellierung der Unsicherheit der IBTP die tatsächliche Verteilung der Trajektorien besser abbildet als die einfachen Unsicherheitsfortpflanzung in der MBTP. Die Verwendung der Simulationsumgebung für die Entwicklung der Verfahren zur Trajektorienprädiktion und die anschließende Auswertung mit Daten aus dem Testfahrzeug zeigt, dass generell keine detaillierte Modellierung einzelner Sensoren innerhalb der Simulation notwendig ist. Allerdings ist die Abbildung von bestimmten Effekten, die die Qualität des Umgebungsmodells beeinflussen, entscheidend, um eine Anwendung des mit der Simulation entwickelten Verfahrens im Testfahrzeug zu ermöglichen. In diesem konkreten Fall ist die Genauigkeit der Spurbeschreibung durch die von der Kamera detektierten Spurmarkierungen in der Simulation zu hoch, sodass die Berücksichtigung des Straßenverlaufes für die Prädiktion im Testfahrzeug zu einer Verschlechterung der Güte geführt hat. Die Transformation in ein kurvilineares Koordinatensystem erlaubt die Anwendung einer Prädiktion für gerade Straßen auch in kurvigen Szenarien. Die Voraussetzung hierfür ist eine gute Schätzung des tatsächlichen Spurverlaufes, die mit den aktuellen Daten im Testfahrzeug nicht gegeben ist. Daher bietet ein komplexeres Prädiktionsverfahren ohne eine Verbesserung des Umgebungsmodells keine Vorteile gegenüber der Annahme einer konstanten Geschwindigkeit und Orientierung. Gleichzeitig zeigt die Entwicklung in der Simulation die zu erreichende Genauigkeit für den Fall einer besseren Beschreibung des Straßenverlaufes. Dabei wird kein exaktes Umgebungsmodell angenommen, da die Verdeckung durch andere Fahrzeuge, ungenaue Messungen und nur begrenzt sichtbare Spurmarkierungen berücksichtigt werden. Eine vergleichbare Qualität der Schätzung des Spurverlaufes ist auch mit fahrzeuginterner Sensorik oder dem Einsatz einer digitalen Karte zu erreichen. Für das entsprechende Umgebungsmodell zeigen die vorgestellten Verfahren, dass eine Steigerung der Güte durch die Berücksichtigung von distinkten Fahrmanövern innerhalb der Prädiktion möglich ist. Das bestmögliche Prädiktionsergebnis kann durch die zusätzliche Berücksichtigung von Interaktionen zwischen Verkehrsteilnehmern erreicht werden.

Als Ausblick für weitere Arbeiten ist zunächst die Verbesserung des Umgebungsmodells und insbesondere der Schätzung des Straßenverlaufes zu nennen. Anschließend ist eine erneute Evaluierung der vorgestellten Ansätze durchzuführen, um die Steigerung der Güte gegenüber der Annahme einer konstanten Geschwindigkeit und Orientierung für Daten aus dem Testfahrzeug zu validieren. Im Rahmen von weiteren Untersuchungen sollte außerdem die Schätzung der Geschwindigkeit für die manöverbasierte Trajektorienprädiktion verbessert werden. Die Annahme einer konstanten Geschwindigkeit ist lediglich in der Abwesenheit weiterer Verkehrsteilnehmer sinnvoll, da andernfalls eine Reaktion auf eventuelle langsamere Fahrzeuge zu erwarten ist. Um dies innerhalb der Prädiktion zu berücksichtigen, könnte ein Fahrzeugfolgemodell zur Bestimmung der wahrscheinlichsten Geschwindigkeit in dichtem Verkehr angewandt und mit einem geeigneten Modell der Unsicherheit ergänzt werden. Damit wird die Interaktion zweier aufeinander folgender Fahrzeuge berücksichtigt ohne die Notwendigkeit einer zeitaufwändigen *Monte Carlo* Simulation. Dieser ist einer der hauptsächlichen Nachteile der vorgestellten IBTP. Allerdings bietet sich eine Parallelisierung der Simulationsiterationen an, da einzelne *Monte Carlo* Iterationen unabhängig voneinander sind. Ein weiteres in dieser Arbeit nicht berücksichtigtes Feld ist die Trajektorienprädiktion in urbanem Verkehr. Durch komplexere Straßentopologien und eine deutlich größere Vielfalt der Verkehrsteilnehmer ergibt sich Spielraum für die Erweiterung der vorgestellten Ansätze.

Literatur

- [Ahr16] **D. Ahrens:** „Vorgehensmodell zur Modellierung, Strukturierung und objektiven Bewertung von Software-Architekturen in der Fahrerassistenz“. Dissertation. Technische Universität Dortmund, 2016.
- [AM11] **M. Althoff und A. Mergel:** „Comparison of Markov Chain Abstraction and Monte Carlo Simulation for the Safety Assessment of Autonomous Cars“. In: *IEEE Transactions on Intelligent Transportation Systems* 12.4 (2011), S. 1237–1247.
- [AN09] **S. Ammoun und F. Nashashibi:** „Real time trajectory prediction for collision risk estimation between vehicles“. In: *IEEE International Conference on Intelligent Computer Communication and Processing*. 2009, S. 417–422.
- [Aou+10] **G. S. Aoude, B. D. Luders, K. K. H. Lee, D. S. Levine und J. P. How:** „Threat assessment design for driver assistance system at intersections“. In: *IEEE International Conference on Intelligent Transportation Systems*. 2010, S. 1855–1862.
- [Aou+11a] **G. S. Aoude, V. R. Desaraju, L. H. Stephens und J. P. How:** „Behavior classification algorithms at intersections and validation using naturalistic data“. In: *IEEE Intelligent Vehicles Symposium*. 2011, S. 601–606.
- [Aou+11b] **G. S. Aoude, J. Joseph, N. Roy und J. How:** „Mobile agent trajectory prediction using Bayesian nonparametric reachability trees“. In: *Infotech@Aerospace* (2011), S. 1512.
- [Aug+18] **D. Augustin, M. Hofmann und U. Konigorski:** „Motion Pattern Recognition for Maneuver Detection and Trajectory Prediction on Highways“. In: *IEEE International Conference on Vehicular Electronics and Safety*. 2018, S. 1–8.
- [Aug+19a] **D. Augustin, M. Hofmann und U. Konigorski:** „Prediction of Highway Lane Changes Based on Prototype Trajectories“. In: *Forschung im Ingenieurwesen* 83 (2019), S. 149–161.
- [Aug+19b] **D. Augustin, J. Schucker, J. Tschirner, M. Hofmann und U. Konigorski:** „A Simulation-Based Reinforcement Learning Approach for Long-Term Maneuver Planning in Highway Traffic Scenarios“. In: *VDI/VDE-Fachtagung AUTOREG 2019*. Mannheim, Germany, 2019, S. 47–60.
- [AV 18] **AV Simulation:** *SCANer Studio Simulation Mode, Version 1.7*. 2018.
- [Bah+16a] **M. Bahram, C. Hubmann, A. Lawitzky, M. Aeberhard und D. Wollherr:** „A Combined Model- and Learning-Based Framework for Interaction-A-

- ware Maneuver Prediction“. In: *IEEE Transactions on Intelligent Transportation Systems* 17.6 (2016), S. 1538–1550.
- [Bah+16b] **M. Bahram, A. Lawitzky, J. Friedrichs, M. Aeberhard und D. Wollherr:** „A Game-Theoretic Approach to Replanning-Aware Interactive Scene Prediction and Planning“. In: *IEEE Transactions on Vehicular Technology* 65.6 (2016), S. 3981–3992.
- [BAS14] **BASt:** *Anweisung StraßeninformationsBank - Segment: Querschnitt und Aufbau*. Regelwerk. Bundesministerium für Verkehr und Digitale Infrastruktur, Feb. 2014.
- [Ben+14] **P. Bender, J. Ziegler und C. Stiller:** „Lanelets: Efficient map representation for autonomous driving“. In: *IEEE Intelligent Vehicles Symposium*. 2014, S. 420–425.
- [Ber+08] **H. Berndt, J. Emmert und K. Dietmayer:** „Continuous Driver Intention Recognition with Hidden Markov Models“. In: *IEEE International Conference on Intelligent Transportation Systems*. 2008, S. 1189–1194.
- [Ber+15] **S. Bernsteiner, Z. Magosi, D. Lindvai-Soos und A. Eichberger:** „Radarsensormodell für den virtuellen Entwicklungsprozess“. In: *ATZelektronik* 10.2 (2015), S. 72–79.
- [BF08] **A. Barth und U. Franke:** „Where will the oncoming vehicle be the next second?“ In: *IEEE Intelligent Vehicles Symposium*. 2008, S. 1068–1073.
- [Bra+10] **M. Brannstrom, E. Coelingh und J. Sjoberg:** „Model-Based Threat Assessment for Avoiding Arbitrary Vehicle Collisions“. In: *IEEE Transactions on Intelligent Transportation Systems* 11.3 (2010), S. 658–669.
- [Bre01] **L. Breiman:** „Random forests“. In: *Machine learning* 45.1 (2001), S. 5–32.
- [BY00] **S. A. Boxill und L. Yu:** „An evaluation of traffic simulation models for supporting its“. In: *Houston, TX: Development Centre for Transportation Training and Research, Texas Southern University* (2000).
- [Cla+98] **D. D. Clarke, P. J. Ward und J. Jones:** „Overtaking road-accidents: Differences in manoeuvre as a function of driver age“. In: *Accident Analysis & Prevention* 30.4 (1998), S. 455–467.
- [Dyc+11] **H. Dyckmanns, R. Matthaei, M. Maurer, B. Lichte, J. Effertz und D. Stüker:** „Object tracking in urban intersections based on active use of a priori knowledge: Active interacting multi model filter“. In: *IEEE Intelligent Vehicles Symposium*. 2011, S. 625–630.
- [Est+96] **M. Ester, H.-P. Kriegel, J. Sander, X. Xu u. a.:** „A density-based algorithm for discovering clusters in large spatial databases with noise.“ In: *International Conference on Knowledge Discovery and Data Mining*. Bd. 96. 34. 1996, S. 226–231.

- [Fat+14] **M. Fatemi, L. Hammarstrand, L. Svensson und A. Garcia-Fernandez:** „Road geometry estimation using a precise clothoid road model and observations of moving vehicles“. In: *IEEE International Conference on Intelligent Transportation Systems*. 2014, S. 238–244.
- [Gal+17] **E. Galceran, A. G. Cunningham, R. M. Eustice und E. Olson:** „Multi-policy decision-making for autonomous driving via changepoint-based behavior prediction: Theory and experiment“. In: *Autonomous Robots* 41.6 (2017), S. 1367–1382.
- [Gar+11] **M. Garcia Ortiz, J. Fritsch, F. Kummert und A. Gepperth:** „Behavior prediction at multiple time-scales in inner-city scenarios“. In: *IEEE Intelligent Vehicles Symposium*. 2011, S. 1068–1073.
- [Gip81] **P. Gipps:** „A behavioural car-following model for computer simulation“. In: *Transportation Research Part B: Methodological* 15.2 (1981), S. 105–111.
- [Gip86] **P. G. Gipps:** „A model for the structure of lane-changing decisions“. In: *Transportation Research Part B: Methodological* 20.5 (1986), S. 403–414.
- [Gmb12] **dSPACE GmbH:** *Automotive Simulation Models*. 2012.
- [Gmb17] **dSPACE GmbH:** *ASM Traffic*. 2017.
- [Gon+17] **D. S. González, V. Romero-Cano, J. S. Dibangoye und C. Laugier:** „Interaction-aware driver maneuver inference in highways using realistic driver models“. In: *IEEE International Conference on Intelligent Transportation Systems*. 2017, S. 1–8.
- [Göt+17] **C. Götte, C. Wissing, M. Keller, T. Nattermann, C. Haß, K.-H. Glander und T. Bertram:** „Simulationsbasierte Entwicklung eines Trajektorienplanungsverfahrens für automatisiertes Fahren“. In: *AUTOREG 2017 - VDI-Berichte 2292*. 2017, S. 247–259.
- [Gsc+11] **M. Gschwandtner, R. Kwitt, A. Uhl und W. Pree:** „BlenSor: Blender Sensor Simulation Toolbox“. In: *Advances in Visual Computing*. 2011, S. 199–208.
- [Gub+13] **D. Gubelli, O. A. Krasnov und O. Yarovy:** „Ray-tracing simulator for radar signals propagation in radar networks“. In: *European Radar Conference*. 2013, S. 73–76.
- [Ham+16] **L. Hammarstrand, M. Fatemi, Á. F. García-Fernández und L. Svensson:** „Long-Range Road Geometry Estimation Using Moving Vehicles and Roadside Observations“. In: *IEEE Transactions on Intelligent Transportation Systems* 17.8 (2016), S. 2144–2158.
- [Her+09] **C. Hermes, C. Wohler, K. Schenk und F. Kummert:** „Long-term vehicle motion prediction“. In: *IEEE Intelligent Vehicles Symposium*. 2009, S. 652–657.

- [Hil+06] **J. Hillenbrand, A. M. Spieker und K. Kroschel:** „A Multilevel Collision Mitigation Approach - Its Situation Assessment, Decision Making, and Performance Tradeoffs“. In: *IEEE Transactions on Intelligent Transportation Systems* 7.4 (2006), S. 528–540.
- [HL94] **J. Hunt und G. Lyons:** „Modelling dual carriageway lane changing using neural networks“. In: *Transportation Research Part C: Emerging Technologies* 2.4 (1994), S. 231–245.
- [Hsu+03] **C.-W. Hsu, C.-C. Chang und C.-J. Lin:** *A practical guide to support vector classification*. 2003.
- [Hub+18] **C. Hubmann, J. Schulz, M. Becker, D. Althoff und C. Stiller:** „Automated Driving in Uncertain Environments: Planning With Interaction and Uncertain Maneuver Prediction“. In: *IEEE Transactions on Intelligent Vehicles* 3.1 (2018), S. 5–17.
- [Jos+11] **J. Joseph, F. Doshi-Velez, A. S. Huang und N. Roy:** „A Bayesian nonparametric approach to modeling motion patterns“. In: *Autonomous Robots* 31.4 (2011), S. 383.
- [KA17a] **M. Koschi und M. Althoff:** „Interaction-aware occupancy prediction of road vehicles“. In: *IEEE International Conference on Intelligent Transportation Systems*. 2017, S. 1–8.
- [KA17b] **M. Koschi und M. Althoff:** „SPOT: A tool for set-based prediction of traffic participants“. In: *IEEE Intelligent Vehicles Symposium*. 2017, S. 1686–1693.
- [Kae+04] **N. Kaempchen, K. Weiss, M. Schaefer und K. Dietmayer:** „IMM object tracking for high dynamic driving maneuvers“. In: *IEEE Intelligent Vehicles Symposium*. 2004, S. 825–830.
- [Kae+09] **N. Kaempchen, B. Schiele und K. Dietmayer:** „Situation Assessment of an Autonomous Emergency Brake for Arbitrary Vehicle-to-Vehicle Collision Scenarios“. In: *IEEE Transactions on Intelligent Transportation Systems* 10.4 (2009), S. 678–687.
- [Kal60] **R. E. Kalman:** „A new approach to linear filtering and prediction problems“. In: *Journal of basic Engineering* 82.1 (1960), S. 35–45.
- [Kas+12] **D. Kasper, G. Weidl, T. Dang, G. Breuel, A. Tamke, A. Wedel und W. Rosenstiel:** „Object-Oriented Bayesian Networks for Detection of Lane Change Maneuvers“. In: *IEEE Intelligent Transportation Systems Magazine* 4.3 (2012), S. 19–31.
- [KB78] **R. Koenker und G. Bassett:** „Regression Quantiles“. In: *Econometrica* 46.1 (1978), S. 33–50.

- [Kes+07] **A. Kesting, M. Treiber und D. Helbing:** „General lane-changing model MOBIL for car-following models“. In: *Transportation Research Record* 1999.1 (2007), S. 86–94.
- [Kes+10] **A. Kesting, M. Treiber und D. Helbing:** „Enhanced intelligent driver model to access the impact of driving strategies on traffic capacity“. In: *Philosophical Transactions of the Royal Society A: Mathematical, Physical and Engineering Sciences* 368.1928 (2010), S. 4585–4605.
- [KH01] **R. Koenker und K. F. Hallock:** „Quantile Regression“. In: *Journal of Economic Perspectives* 15.4 (2001), S. 143–156.
- [Kim+17] **B. Kim, C. M. Kang, J. Kim, S. H. Lee, C. C. Chung und J. W. Choi:** „Probabilistic vehicle trajectory prediction over occupancy grid map via recurrent neural network“. In: *IEEE International Conference on Intelligent Transportation Systems*. 2017, S. 399–404.
- [Kli+14] **S. Klingelschmitt, M. Platho, H. Groß, V. Willert und J. Eggert:** „Combining behavior and situation information for reliably estimating multiple intentions“. In: *IEEE Intelligent Vehicles Symposium*. 2014, S. 388–393.
- [Kra+96] **S. Krauss, P. Wagner und C. Gawron:** „Continuous limit of the Nagel-Schreckenberg model“. In: *Physical Review E* 54 (4 1996), S. 3707–3712.
- [Kru+16] **M. Krueger, S. Meuresch, A. Stockem Novo, T. Nattermann, K.-H. Glander und T. Bertram:** „Structural analysis of a neural network for lane change prediction for automated driving“. In: *Workshop Computational Intelligence*. 2016.
- [Kum+13] **P. Kumar, M. Perrollaz, S. Lefèvre und C. Laugier:** „Learning-based approach for online lane change intention prediction“. In: *IEEE Intelligent Vehicles Symposium*. 2013, S. 797–802.
- [Lac+08] **B. Lacroix, P. Mathieu und A. Kemeny:** „A Normative Model for Behavioral Differentiation“. In: *IEEE/WIC/ACM International Conference on Web Intelligence and Intelligent Agent Technology*. 2008, S. 96–99.
- [Lau+11] **C. Laugier, I. E. Paromtchik, M. Perrollaz, M. Yong, J. Yoder, C. Tay, K. Mekhnacha und A. Nègre:** „Probabilistic Analysis of Dynamic Scenes and Collision Risks Assessment to Improve Driving Safety“. In: *IEEE Intelligent Transportation Systems Magazine* 3.4 (2011), S. 4–19.
- [LC14] **S. Lefèvre und D. V. and Christian Laugier:** „A survey on motion prediction and risk assessment for intelligent vehicles“. In: *ROBOMECH Journal* 1.1 (2014), S. 1.
- [Lef+12] **S. Lefèvre, C. Laugier und J. Ibañez-Guzmán:** „Risk assessment at road intersections: Comparing intention and expectation“. In: *IEEE Intelligent Vehicles Symposium*. 2012, S. 165–171.

- [Len+17] **D. Lenz, F. Diehl, M. T. Le und A. Knoll:** „Deep neural networks for Markovian interactive scene prediction in highway scenarios“. In: *IEEE Intelligent Vehicles Symposium*. 2017, S. 685–692.
- [Lie+19a] **C. Lienke, C. Wissing, M. Keller, T. Nattermann und T. Bertram:** „Predictive Driving: Fusing Prediction and Planning for Automated Highway Driving“. In: *IEEE Transactions on Intelligent Vehicles* 4.3 (2019), S. 456–467.
- [Lie+19b] **C. Lienke, M. Schmidt, C. Wissing, M. Keller, C. Manna, T. Nattermann und T. Bertram:** „Core Components of Automated Driving – Algorithms for Situation Analysis, Decision Making and Trajectory Planning“. In: *Automatisiertes Fahren 2019*. Springer Fachmedien Wiesbaden, 2019, S. 195–215.
- [Lin+00] **C.-F. Lin, A. G. Ulsoy und D. J. LeBlanc:** „Vehicle dynamics and external disturbance estimation for vehicle path prediction“. In: *IEEE Transactions on Control Systems Technology* 8.3 (2000), S. 508–518.
- [LM12] **B. Lacroix und P. Mathieu:** „Automated Generation of Various and Consistent Populations in Multi-Agent Simulations“. In: *Advances on Practical Applications of Agents and Multi-Agent Systems*. 2012, S. 127–137.
- [Lop+18] **P. A. Lopez, M. Behrisch, L. Bieker-Walz, J. Erdmann, Y. Flötteröd, R. Hilbrich, L. Lücken, J. Rummel, P. Wagner und E. Wießner:** „Microscopic Traffic Simulation using SUMO“. In: *IEEE International Conference on Intelligent Transportation Systems*. 2018, S. 2575–2582.
- [Mac03] **D. J. C. MacKay:** *Information theory, inference and learning algorithms*. Cambridge University Press, 2003.
- [Mei06] **N. Meinshausen:** „Quantile regression forests“. In: *Journal of Machine Learning Research* 7.Jun (2006), S. 983–999.
- [Mey+09a] **D. Meyer-Delius, C. Plagemann und W. Burgard:** „Probabilistic situation recognition for vehicular traffic scenarios“. In: *IEEE International Conference on Robotics and Automation*. 2009, S. 459–464.
- [Mey+09b] **D. Meyer-Delius, J. Sturm und W. Burgard:** „Regression-based online situation recognition for vehicular traffic scenarios“. In: *IEEE/RSJ International Conference on Intelligent Robots and Systems*. 2009, S. 1711–1716.
- [Mor+11] **B. Morris, A. Doshi und M. Trivedi:** „Lane change intent prediction for driver assistance: On-road design and evaluation“. In: *IEEE Intelligent Vehicles Symposium*. 2011, S. 895–901.
- [NS92] **K. Nagel und M. Schreckenberg:** „A cellular automaton model for freeway traffic“. In: *Journal de Physique I* 2.12 (1992), S. 2221–2229.
- [Pas+11] **L. S. Passos, R. J. F. Rossetti und Z. Kokkinoginis:** „Towards the next-generation traffic simulation tools: a first appraisal“. In: *IEEE Iberian Conference on Information Systems and Technologies*. 2011, S. 1–6.

- [Pla+12] **M. Platho, H. Groß und J. Eggert:** „Traffic situation assessment by recognizing interrelated road users“. In: *IEEE International Conference on Intelligent Transportation Systems*. 2012, S. 1339–1344.
- [Pla99] **J. C. Platt:** „Probabilistic Outputs for Support Vector Machines and Comparisons to Regularized Likelihood Methods“. In: *Advances In Large Margin Classifiers*. 1999, S. 61–74.
- [RW05] **C. E. Rasmussen und C. K. I. Williams:** *Gaussian Processes for Machine Learning (Adaptive Computation and Machine Learning)*. Cambridge: The MIT Press, 2005.
- [SAE18] **SAE:** *Taxonomy and Definitions for Terms Related to Driving Automation Systems for On-Road Motor Vehicles*. Standard. SAE International, Juni 2018.
- [Sch+08a] **R. Schubert, E. Richter und G. Wanielik:** „Comparison and evaluation of advanced motion models for vehicle tracking“. In: *IEEE International Conference on Information Fusion*. 2008, S. 1–6.
- [Sch+08b] **K. Schuler, D. Becker und W. Wiesbeck:** „Extraction of Virtual Scattering Centers of Vehicles by Ray-Tracing Simulations“. In: *IEEE Transactions on Antennas and Propagation* 56.11 (2008), S. 3543–3551.
- [Sch+12] **W. Schakel, V. Knoop und B. van Arem:** „Integrated Lane Change Model with Relaxation and Synchronization“. In: *Transportation Research Record* 2316.1 (2012), S. 47–57.
- [Sch+13] **M. Schreiber, C. Knöppel und U. Franke:** „LaneLoc: Lane marking based localization using highly accurate maps“. In: *IEEE Intelligent Vehicles Symposium*. 2013, S. 449–454.
- [Sch+15] **J. Schlechtriemen, F. Wirthmueller, A. Wedel, G. Breuel und K. Kuhnert:** „When will it change the lane? A probabilistic regression approach for rarely occurring events“. In: *IEEE Intelligent Vehicles Symposium*. 2015, S. 1373–1379.
- [Sch+16] **M. Schreier, V. Willert und J. Adamy:** „An Integrated Approach to Maneuver-Based Trajectory Prediction and Criticality Assessment in Arbitrary Road Environments“. In: *IEEE Transactions on Intelligent Transportation Systems* 17.10 (2016), S. 2751–2766.
- [Sch+18b] **J. Schulz, C. Hubmann, J. Löchner und D. Burschka:** „Interaction-Aware Probabilistic Behavior Prediction in Urban Environments“. In: *IEEE/RSJ International Conference on Intelligent Robots and Systems*. 2018, S. 3999–4006.
- [Sch+19a] **M. Schmidt, C. Manna, J. H. Braun, C. Wissing, M. Mohamed und T. Bertram:** „An Interaction-Aware Lane Change Behavior Planner for Automated Vehicles on Highways Based on Polygon Clipping“. In: *IEEE Robotics and Automation Letters* 4.2 (2019), S. 1876–1883.

- [Sch+19b] **M. Schmidt, C. Wissing, J. H. Braun, T. Nattermann und T. Bertram:** „Maneuver Identification for Interaction-Aware Highway Lane Change Behavior Planning based on Polygon Clipping and Convex Optimization“. In: *IEEE International Conference on Intelligent Transportation Systems*. 2019, S. 3948–3953.
- [SH14] **T. Streubel und K. H. Hoffmann:** „Prediction of driver intended path at intersections“. In: *IEEE Intelligent Vehicles Symposium*. 2014, S. 134–139.
- [Sta+19] **N. Stannartz, C. Wissing, M. Krueger, A. Tolmidis, S. I. Ali, T. Nattermann und T. Bertram:** „Ego-Motion Correction based on Static Objects detected by an Automotive Lidar Sensor System“. In: *AmE 2019 - Automotive meets Electronics*. 2019, S. 1–6.
- [Taş+16] **Ö. Ş. Taş, F. Kuhnt, J. M. Zöllner und C. Stiller:** „Functional system architectures towards fully automated driving“. In: *IEEE Intelligent Vehicles Symposium*. 2016, S. 304–309.
- [Tay09] **C. Tay:** „Analysis of Dynamic Scenes: Application to Driving Assistance“. Dissertation. Institut National Polytechnique de Grenoble - INPG, 2009.
- [TF14] **Q. Tran und J. Firl:** „Online maneuver recognition and multimodal trajectory prediction for intersection assistance using non-parametric regression“. In: *IEEE Intelligent Vehicles Symposium*. 2014, S. 918–923.
- [Tre+00] **M. Treiber, A. Hennecke und D. Helbing:** „Congested traffic states in empirical observations and microscopic simulations“. In: *Physical Review E* 62 (2 2000), S. 1805–1824.
- [Tso+04] **I. Tsochantaridis, T. Hofmann, T. Joachims und Y. Altun:** „Support Vector Machine Learning for Interdependent and Structured Output Spaces“. In: *International Conference on Machine Learning*. 2004, S. 104.
- [Uhl95] **J. K. Uhlmann:** „Dynamic map building and localization: New theoretical foundations“. Dissertation. University of Oxford, 1995.
- [VF04] **D. Vasquez und T. Fraichard:** „Motion prediction for moving objects: a statistical approach“. In: *IEEE International Conference on Robotics and Automation*. 2004, S. 3931–3936.
- [Whe+17] **T. A. Wheeler, M. Holder, H. Winner und M. J. Kochenderfer:** „Deep stochastic radar models“. In: *IEEE Intelligent Vehicles Symposium*. 2017, S. 47–53.
- [Wie+13] **J. Wiest, F. Kunz, U. Kreßel und K. Dietmayer:** „Incorporating Categorical Information for Enhanced Probabilistic Trajectory Prediction“. In: *IEEE International Conference on Machine Learning and Applications*. 2013, S. 402–407.
- [Wie74] **R. Wiedemann:** „Simulation des Straßenverkehrsflusses“. In: *Schriftenreihe des Instituts für Verkehrswesen der Universität Karlsruhe* 8 (1974).

- [Wis+15] **C. Wissing, J. H. Braun, C. Rösmann und T. Bertram:** „Entwicklung eines Regelungskonzeptes für einen Knick-Arm-Roboter für das automatisierte Laden“. In: *Fachtagung Mechatronik*. 2015, S. 31–36.
- [Wis+16] **C. Wissing, T. Nattermann, K.-H. Glander, A. Seewald und T. Bertram:** „Environment Simulation for the Development, Evaluation and Verification of Underlying Algorithms for Automated Driving“. In: *AmE 2016 – Automotive meets Electronics*. 2016, S. 1–6.
- [Wis+17a] **C. Wissing, K.-H. Glander, C. Haß, T. Nattermann und T. Bertram:** „Development and test of a lane change prediction algorithm for automated driving“. In: *Fahrerassistenzsysteme 2017*. Springer Fachmedien Wiesbaden, 2017, S. 385–402.
- [Wis+17b] **C. Wissing, T. Nattermann, K.-H. Glander und T. Bertram:** „Lane Change Prediction by Combining Movement and Situation based Probabilities“. In: *20th IFAC World Congress*. 2017, S. 3554–3559.
- [Wis+17c] **C. Wissing, T. Nattermann, K.-H. Glander und T. Bertram:** „Probabilistic time-to-lane-change prediction on highways“. In: *IEEE Intelligent Vehicles Symposium*. 2017, S. 1452–1457.
- [Wis+18a] **C. Wissing, T. Nattermann, K.-H. Glander und T. Bertram:** „Interaction-Aware Long-term Driving Situation Prediction“. In: *IEEE International Conference on Intelligent Transportation Systems*. 2018, S. 137–143.
- [Wis+18b] **C. Wissing, T. Nattermann, K.-H. Glander und T. Bertram:** „Trajectory Prediction for Safety Critical Maneuvers in Automated Highway Driving“. In: *IEEE International Conference on Intelligent Transportation Systems*. 2018, S. 131–136.
- [WM41] **E. E. Wilson und R. Moyer:** „Deceleration distances for high speed vehicles“. In: *Highway Research Board Proceedings*. 1941, S. 393–398.
- [Wu+04] **T.-F. Wu, C.-J. Lin und R. C. Weng:** „Probability Estimates for Multi-class Classification by Pairwise Coupling“. In: *Journal of Machine Learning Research* 5 (2004), S. 975–1005.
- [Zyn+17] **A. Zyner, S. Worrall, J. Ward und E. Nebot:** „Long short term memory for driver intent prediction“. In: *IEEE Intelligent Vehicles Symposium*. 2017, S. 1484–1489.

Eigene wissenschaftliche Publikationen

- C. Lienke, C. Wissing, M. Keller, T. Nattermann und T. Bertram:** „Predictive Driving: Fusing Prediction and Planning for Automated Highway Driving“. In: *IEEE Transactions on Intelligent Vehicles* 4.3 (2019), S. 456–467.
- C. Lienke, M. Schmidt, C. Wissing, M. Keller, C. Manna, T. Nattermann und T. Bertram:** „Core Components of Automated Driving – Algorithms for Situation Analysis, Decision Making and Trajectory Planning“. In: *Automatisiertes Fahren 2019*. Springer Fachmedien Wiesbaden, 2019, S. 195–215.
- M. Schmidt, C. Manna, J. H. Braun, C. Wissing, M. Mohamed und T. Bertram:** „An Interaction-Aware Lane Change Behavior Planner for Automated Vehicles on Highways Based on Polygon Clipping“. In: *IEEE Robotics and Automation Letters* 4.2 (2019), S. 1876–1883.
- M. Schmidt, C. Wissing, J. H. Braun, T. Nattermann und T. Bertram:** „Maneuver Identification for Interaction-Aware Highway Lane Change Behavior Planning based on Polygon Clipping and Convex Optimization“. In: *IEEE International Conference on Intelligent Transportation Systems*. 2019, S. 3948–3953.
- N. Stannartz, C. Wissing, M. Krueger, A. Tolmidis, S. I. Ali, T. Nattermann und T. Bertram:** „Ego-Motion Correction based on Static Objects detected by an Automotive Lidar Sensor System“. In: *AmE 2019 - Automotive meets Electronics*. 2019, S. 1–6.
- C. Wissing, T. Nattermann, K.-H. Glander und T. Bertram:** „Interaction-Aware Long-term Driving Situation Prediction“. In: *IEEE International Conference on Intelligent Transportation Systems*. 2018, S. 137–143.
- C. Wissing, T. Nattermann, K.-H. Glander und T. Bertram:** „Trajectory Prediction for Safety Critical Maneuvers in Automated Highway Driving“. In: *IEEE International Conference on Intelligent Transportation Systems*. 2018, S. 131–136.
- C. Götte, C. Wissing, M. Keller, T. Nattermann, C. Haß, K.-H. Glander und T. Bertram:** „Simulationsbasierte Entwicklung eines Trajektorienplanungsverfahrens für automatisiertes Fahren“. In: *AUTOREG 2017 - VDI-Berichte 2292*. 2017, S. 247–259.
- C. Wissing, K.-H. Glander, C. Haß, T. Nattermann und T. Bertram:** „Development and test of a lane change prediction algorithm for automated driving“. In: *Fahrerassistenzsysteme 2017*. Springer Fachmedien Wiesbaden, 2017, S. 385–402.
- C. Wissing, T. Nattermann, K.-H. Glander und T. Bertram:** „Lane Change Prediction by Combining Movement and Situation based Probabilities“. In: *20th IFAC World Congress*. 2017, S. 3554–3559.
- C. Wissing, T. Nattermann, K.-H. Glander und T. Bertram:** „Probabilistic time-to-lane-change prediction on highways“. In: *IEEE Intelligent Vehicles Symposium*. 2017, S. 1452–1457.
- C. Wissing, T. Nattermann, K.-H. Glander, A. Seewald und T. Bertram:** „Environment Simulation for the Development, Evaluation and Verification of Underlying

Algorithms for Automated Driving“. In: *AmE 2016 – Automotive meets Electronics*. 2016, S. 1–6.

C. Wissing, J. H. Braun, C. Rösmann und T. Bertram: „Entwicklung eines Regelungskonzeptes für einen Knick-Arm-Roboter für das automatisierte Laden“. In: *Fachtagung Mechatronik*. 2015, S. 31–36.

Betreute Abschlussarbeiten

M. Hamza: „Causal-Dependency-Aware Lane Change Prediction using Bayesian Networks“. Masterarbeit. Technische Universität Dortmund, 2018.

N. Stannartz: „LIDAR-based Ego-Localization in high-precision Maps“. Masterarbeit. Technische Universität Dortmund, 2018.

F. Friedrich: „Entwicklung einer Trajektorienprädiktion auf Basis einer Spurwechselwahrscheinlichkeit für Fremdfahrzeuge in Autobahnszenarien“. Bachelorarbeit. Technische Universität Dortmund, 2017.

H. Gerdes: „Erweiterung eines Sensormodells zur Generierung von realistischen Umgebungsdaten als Datenbasis einer Spurwechselvorhersage“. Bachelorarbeit. Technische Universität Dortmund, 2017.

J. Schmitz: „Entwicklung einer interaktiven Trajektorienprädiktion auf Basis eines Potentialfeldansatzes für Fremdfahrzeuge in Autobahnszenarien“. Bachelorarbeit. Technische Universität Dortmund, 2017.

J. Exner: „Untersuchung von Gaußprozessen zur Fahrmanöverdetektion auf Autobahnen“. Masterarbeit. Technische Universität Dortmund, 2015.

N. Stannartz: „Datenbasierte Abbildung der Sensorunsicherheit mit Hilfe von Neuronalen Netzen in einer Umgebungssimulation für automatisiertes Fahren“. Bachelorarbeit. Technische Universität Dortmund, 2015.

Betreute Projektgruppen

J. Schmitz, M. König, F. Geiger, J. Stockermann, A. Ulla, W. Qingyang, R. Sicking, N. Jannasch, H. L. Nguyen, Q. Huang, R. Nocon und P. Dorpmüller: *360° Surroundview Assistant*. Technische Universität Dortmund, 2018.

K. Bartsch, Q. T. Bui, C. Diehl, A. Dikarew, A. Hugenroth, T. Kiratli und Y. Sun: *Entwicklung automatisierter Fahrerassistenzsysteme*. Technische Universität Dortmund, 2017.

A. S. Overmann, B. Möllenbeck, E. Mares, F. Albers, J. Bruchhaus, M. A. Ali, M. Hamza, M. S. Irshad und W. Schulz: *Development of a multistep test environment for advanced driver assistance systems*. Technische Universität Dortmund, 2016.

A

Anhang

Der Anhang enthält einige weiterführende Informationen zu verschiedenen Abschnitten der vorliegenden Arbeit. Zunächst wird die Entwicklung eines Ansatzes zur Trajektorienprädiktion in einer virtuellen Umgebung detailliert beleuchtet. Anschließend werden zusätzliche Informationen zu der verwendeten Umgebungssimulation bereitgestellt. Außerdem enthält der Anhang die Definition verschiedener Funktionen und Verfahren, die innerhalb der Arbeit genutzt werden, sowie eine Beschreibung der verwendeten Datensätze. Abschließend sind zusätzliche Informationen zu den in der Arbeit vorgestellten Verfahren dargestellt.

A.1. Entwicklung in virtueller Umgebung

Für die Entwicklung eines Ansatzes zur Trajektorienprädiktion werden in diesem Abschnitt zunächst die Anforderungen an die genutzte Simulationsumgebung definiert. Anschließend werden verfügbare Simulationsumgebungen und der aktuelle Stand der Technik auf die Erfüllung dieser Anforderungen überprüft.

A.1.1. Anforderungen an Simulationsumgebungen

Für die Entwicklung einer Trajektorienprädiktion mit Hilfe einer Simulationsumgebung müssen eine Reihe von Anforderungen erfüllt werden, um eine Anwendung im Testfahrzeug zu gewährleisten.

1. Darstellung von variablen Autobahnszenarien:
Die Prädiktion von Trajektorien muss in unterschiedlichen Szenarien auf Autobahnen validiert werden. Dabei müssen die Krümmungsradien variabel sein und die Anzahl der Spuren anpassbar sein. Eine höhere Anzahl von Fahrstreifen ermöglicht mehr Manöver der beobachteten Verkehrsteilnehmer und stellt somit größere Anforderungen an die zu entwickelnde Trajektorienprädiktion.
2. Simulation der Umgebungsfahrzeuge:
Innerhalb der Szenarien müssen andere Verkehrsteilnehmer platzierbar sein, die

sich im Umfeld des Ego-Fahrzeugs bewegen und von der simulierten Sensorkonfiguration wahrgenommen werden können. In der Entwicklungsphase werden für diese Fahrzeuge die Trajektorien prädiziert und ausgewertet.

3. Menschliches Fahrverhalten der Umgebungsfahrzeuge:
Die in der Simulation platzierten Fahrzeuge sollten sich eigenständig durch das Szenario bewegen und dabei ein näherungsweise menschliches Verhalten zeigen. Abhängig von der Wunschgeschwindigkeit sollten die Fahrzeuge selbstständig Entscheidungen bezüglich anstehender Überholmanöver treffen und die Manöver anschließend ausführen. Zusätzlich sollte das Verhalten und die Manöverausführung einer stochastischen Variation unterliegen, sodass unterschiedliche Fahrertypen abgebildet und eine große Variabilität von Verkehrssituationen dargestellt werden können.
4. Variable Verkehrsdichte:
In einem Szenario mit fester Straßentopologie sollten durch einfache Parametrierung unterschiedliche Verkehrsdichten im Bereich des Ego-Fahrzeugs generierbar sein.
5. Generierung des Umgebungsmodells:
Die Simulationsumgebung muss ein Umgebungsmodell bereit stellen, das formal und qualitativ dem des Testfahrzeugs entspricht. Dies beinhaltet einerseits die Repräsentation der wahrgenommenen Objekte sowie der Straßentopologie und andererseits die Genauigkeit sowie sensorspezifische Effekte, die die Qualität des Umgebungsmodells beeinflussen.
6. Flexibilität:
Die Simulationsumgebung muss leicht zu erweitern und einfach zu konfigurieren sein. Die Einbindung neuer und die Anpassung vorhandener Module muss mit wenig Aufwand durchführbar sein.

Auf Basis der dargestellten Anforderungen wird eine Simulationsumgebung ausgewählt, die sich zur Entwicklung der Trajektorienprädiktion eignet. Dafür werden zunächst aktuell verfügbare Umgebungen auf die Erfüllung der Anforderungen untersucht. Anschließend wird der Stand der Technik in Bezug auf verfügbare Sensormodelle und die Modellierung des Umgebungsverkehrs analysiert. Die Anforderungen in beiden Bereichen sind entscheidend für die Entwicklung einer Trajektorienprädiktion und müssen von der Simulationsumgebung erfüllt werden.

A.1.2. Stand der Technik

Für die Analyse der verfügbaren Simulationsumgebungen werden drei Arten der Simulation unterschieden:

- Makroskopische Verkehrssimulationen,
- Mikroskopische Verkehrssimulationen und

- Fahrdynamiksimulationen.

Eine makroskopische Verkehrssimulation fokussiert die Simulation des gesamten Verkehrsflusses innerhalb eines Straßennetzwerkes. Dabei werden Größen wie Geschwindigkeit, Verkehrsfluss und -dichte in Abhängigkeit der Straßentopologie, Kreuzungsaufbau und Verkehrsregelanlagen untersucht. Fahrzeuge werden innerhalb der Simulation als Gruppen modelliert, deren Bewegung mathematisch mit Modellen der Strömungsmechanik beschrieben wird (siehe Passos u. a. [Pas+11]), um eine effiziente Berechnung des Szenarios zu erreichen. Einzelne Szenarien in makroskopischen Simulationen können dabei gesamte Städte oder große Autobahnnetze umfassen.

Im Gegensatz dazu wird in mikroskopischen Verkehrssimulationen jedes Fahrzeug und dessen Fahrer individuell betrachtet [BY00]. Die Bewegung wird dabei mindestens spurdiskret oder quasi kontinuierlich modelliert, wobei die Fahrzeuge zwischen einzelnen Spuren wechseln können. Um das menschliche Fahrverhalten abzubilden, werden auch Interaktionen zwischen einzelnen Fahrzeugen berücksichtigt. Hierzu kommen Fahrermodelle, die verschiedene Verhaltensweisen umsetzen, zum Einsatz. Im Vergleich zu makroskopischen Simulationen sind die betrachteten Szenarien kleiner.

Als letzte Simulationsart werden Fahrdynamiksimulationen betrachtet. Hierbei liegt der Fokus auf der detaillierten Modellierung der einzelnen Teilkomponenten des Ego-Fahrzeugs, um auch im fahrdynamischen Grenzbereich eine gute Abschätzung des Fahrverhaltens zu erhalten. Die Simulation kann häufig durch einen menschlichen Fahrer in einem Fahrsimulator Aufbau, der unterschiedlich detaillierte Nachbildungen eines Fahrzeugcockpits enthalten kann, bedient werden, sodass auch die Fahrzeug-Mensch-Interaktion untersucht werden kann. Um dem Fahrer eine Einschätzung der Verkehrssituation zu ermöglichen, wird eine möglichst realistische dreidimensionale Visualisierung der Umgebung erzeugt und dem Fahrer zur Verfügung gestellt. Der Umgebungsverkehr dient hierbei lediglich der Nachbildung einer realistischen Verkehrsszene und muss daher nur rudimentär menschliches Fahrverhalten aufweisen. Grundsätzlich sind vorhandene Simulationsumgebungen nicht exklusiv einer Kategorie zuzuordnen, sondern bilden eine Kombination der vorgestellten Klassen. In mikroskopischen Verkehrssimulationen sind zusätzlich makroskopische Aspekte enthalten und Fahrdynamiksimulationen beinhalten zumindest eine grundsätzliche Umsetzung eines automatisierten Verkehrs.

Verfügbare Simulationsumgebungen

Nach der Einführung der einzelnen Kategorien werden nun exemplarische Simulationsumgebungen vorgestellt und auf die Erfüllung der Anforderungen aus Abschnitt A.1.1 überprüft. In diesem Zusammenhang wird sowohl kommerzielle als auch frei verfügbare Software untersucht. Eine Übersicht ist in Tabelle A.1 dargestellt.

SCANeR Die kommerzielle Software SCANeR ist ein Produkt von AV Simulation, einem Zusammenschluss von OKTAL SYDAC und Renault, und stellt eine Fahrdynamiksimulation mit einer dreidimensionalen Visualisierung dar. Durch die Beteiligung

eines Fahrzeugherstellers ist der Fokus vollständig auf die Entwicklung und Validierung von automatisierten Fahrfunktionen ausgerichtet, welche durch einen Fahr Simulator Aufbau unterstützt werden kann. Die Software stellt eine große Anzahl an Sensormodellen für die Abbildung unterschiedlicher Sensortechnologien in der Simulation bereit. Damit ist eine grundsätzliche Abbildung von Sensorungenauigkeiten möglich. Für eine genaue Modellierung des Umgebungsmodells müssen Effekte der Datenfusion und des Trackings hinzugefügt werden, um die Anforderung fünf vollständig zu erfüllen. Ein Vorteil von SCANer ist die detaillierte Nachbildung menschlichen Fahrverhaltens in der Simulation (siehe Lacroix und Mathieu [LM12] und Lacroix u. a. [Lac+08]). Damit lassen sich unterschiedliche Verkehrsdichten simulieren und zusätzlich wird ein stochastisches Verhalten der Verkehrsteilnehmer erreicht, bei dem jedes Fahrzeug ein individuelles Fahrerverhalten aufweist. Die Simulationsumgebung erfüllt damit nahezu alle Anforderungen. Lediglich die Flexibilität ist aufgrund des geschlossenen Quellcodes und der begrenzten Schnittstellen eingeschränkt.

dSPACE ASM dSPACE ASM (Automotive Simulation Models) ist eine Tool Suite für die Simulation verschiedener Komponenten des Fahrzeugs sowie der Umgebung und kann innerhalb der Programmierumgebung MATLAB von Mathworks zur modellbasierten Funktionsentwicklung eingesetzt werden [Gmb12]. Der Fokus liegt hierbei auf Rapid Prototyping Technologien für einzelne Komponenten des Fahrzeugs und dem Einsatz in Hardware-in-the-Loop Simulatoren. dSPACE ASM ermöglicht eine dreidimensionale Visualisierung der Verkehrsszene und beinhaltet einfache Sensormodelle. Allerdings muss die Bewegung des Umgebungsverkehrs manuell definiert werden (siehe GmbH [Gmb17]), sodass kein stochastischer Umgebungsverkehr möglich ist.

SUMO SUMO (Simulation of Urban Mobility) wird vom Deutschen Zentrum für Luft- und Raumfahrt entwickelt [Lop+18] und ist eine Kombination einer makro- und mikroskopischen Verkehrssimulation. Der Fokus liegt auf der Simulation des Verkehrsflusses in großen Straßennetzwerken, sodass unterschiedliche Verkehrsdichten sehr effizient umgesetzt werden können. Dabei wird jedes Fahrzeug individuell modelliert und die Interaktion zwischen einzelnen Fahrzeugen betrachtet. Die laterale Bewegung wird spurdiskret oder mit diskretisierten Abweichungen von der Mitte der jeweiligen Spur umgesetzt, sodass keine kontinuierliche Bewegung des Umgebungsverkehrs möglich ist. SUMO implementiert keine Sensormodelle, die eine Generierung des Umfeldmodells erlauben. Allerdings ist die Implementierung von SUMO quelloffen, sodass die Simulation um entsprechende Funktionalitäten erweitert werden kann.

Da die vorgestellten Simulationsumgebungen die Anforderungen nicht vollständig erfüllen und insbesondere die kommerziellen Produkte nicht flexibel einsetzbar sind, wird im folgenden der Stand der Technik in Bezug auf Verfahren zur Modellierung von Sensoren und zur Integration von menschlichem Fahrverhalten untersucht.

Tabelle A.1.: Vergleich der Simulationsumgebungen auf Basis der Anforderungen für die Entwicklung einer Trajektorienprädiktion (+: Vollständig erfüllt, o: Mit geringem Aufwand erweiterbar, -: Nicht erfüllt).

| | 1. Szenarien | 2. Umgebungs-fahrzeuge | 3. Fahrverhalten | 4. Verkehrs-dichte | 5. Umgebungs-modell | 6. Flexi-bilität |
|------------|--------------|------------------------|------------------|--------------------|---------------------|------------------|
| SCANeR | + | + | + | + | o | o |
| dSpace ASM | + | + | - | o | o | o |
| SUMO | + | + | o | + | - | + |

Sensormodelle in Simulationsumgebungen

Die Modellierung der Sensorwahrnehmung hängt stark von der Art des zu simulierenden Sensors ab. Lidar-Sensoren (Light Detection and Ranging) werden in Simulationsumgebungen häufig mittels *Raytracing* Algorithmen umgesetzt [Gsc+11], sodass für jeden vom Sensor versendeten Lichtimpuls der Auftreffpunkt sowie Reflexionswinkel berechnet und über die gesamte Weglänge der resultierende Sensormesswert bestimmt werden kann.

Eine ähnliche Technik kann für die Simulation von Radar Messungen genutzt werden [Gub+13]. Dabei können Effekte wie Mehrwegeausbreitung oder der Dopplereffekt berücksichtigt werden, um eine realistische Messung zu generieren. Andere Ansätze versuchen auf Basis von *Raytracing* virtuelle Streuzentren zu bestimmen, die eine charakteristische Radarmessung ergeben (siehe Schuler u. a. [Sch+08b]). Das grundlegende Problem aller Ansätze auf Basis von *Raytracing* ist die erforderliche Rechenleistung, die während der Simulation benötigt wird. Für komplexe Szenen sind diese Anforderungen in Echtzeit nur schwer zu erfüllen. Eine andere Herangehensweise ist die so genannte *Black Box* Modellierung, in der versucht wird, eine generelle Abbildung der einzelnen physikalischen Effekte und der Ungenauigkeiten mit Hilfe von parametrischen Modellen zu erreichen. In Bernsteiner u. a. [Ber+15] wird ein Radarsensor mit Hilfe der geometrischen Eigenschaften der Szene sowie einem phänomenologischen Sensormodell abgebildet. Dabei werden Effekte wie die Verdeckung eines Objektes oder eine fehlerhafte Messung aufgrund von Sensorungenauigkeiten berücksichtigt. Im Vergleich mit Messungen eines realen Sensors zeigt das Modell qualitativ gute Ergebnisse, allerdings werden weitere Effekte wie beispielsweise der Dopplereffekt vernachlässigt. In Wheeler u. a. [Whe+17] wird ein datenbasiertes Modell vorgestellt. Hierbei wird eine *Variational Autoencoder* Netzarchitektur gewählt und anhand von aufgenommenen Daten trainiert. Im Vergleich mit anderen datenbasierten Modellen hat das Verfahren für den genutzten Datensatz Vorteile. Allerdings besteht dieser lediglich aus einer statischen Situation auf einem Testgelände. Es ist somit unklar, inwiefern der Ansatz für beliebige dynamische Szenen generalisiert.

Für die Simulation von Kamerasensoren wird in Simulationsumgebungen mit dreidimensionaler Visualisierung die Grafik Engine genutzt, um Bilder der virtuellen Welt abhängig von der Einbauposition des Sensors am simulierten Ego-Fahrzeug zu erstellen.

len. Dabei können Effekte wie die Linsenverzerrung der Kamera berücksichtigt werden (siehe AV Simulation [AV 18]). Die Qualität des erzeugten Bildes hängt zum großen Teil von der Darstellungsqualität innerhalb der Simulation ab. Da für die Entwicklung einer Trajektorienprädiktion keine einzelnen Kamerabilder sondern das vollständige Umgebungsmodell benötigt wird, ist die Verwendung eines solchen Modells in diesem Anwendungsfall nicht sinnvoll.

Alle vorgestellten Sensormodelle beschränken sich auf die Modellierung eines einzelnen Sensors oder einer einzigen Sensortechnologie. Um das vollständige Umgebungsmodell zu erstellen, müssen allerdings alle Sensoren des Fahrzeugs inklusive der anschließenden Verarbeitung gemeinsam modelliert werden. Dieser Anwendungsfall wird von den Verfahren nicht vorgesehen.

Simulation intelligenter Fahrzeuge

Zusätzlich zu der Betrachtung von Sensormodellen ist die Abbildung des menschlichen Fahrverhaltens entscheidend, da dieses die gefahrene Trajektorie durch Manöverentscheidungen in einzelnen Verkehrssituationen maßgeblich beeinflusst. Für die Entwicklung der Trajektorienprädiktion stehen Autobahnszenarien im Vordergrund, sodass Fahrermodelle betrachtet werden, die ein Fahrzeugfolge- oder Spurwechselverhalten umsetzen.

Fahrzeugfolgemodelle bestimmen die Beschleunigung eines Fahrzeugs, um dem vorausfahrenden Fahrzeug in einem sicheren Abstand zu folgen. Eines der am stärksten verbreiteten Modelle ist das *Intelligent Driver Model* (IDM) von Treiber u. a. [Tre+00]. Das Modell bestimmt die aktuelle Beschleunigung basierend auf dem Abstand und der Relativgeschwindigkeit des Führungsfahrzeugs. Sollte kein Führungsfahrzeug existieren oder dieses einen ausreichend großen Abstand haben, wird auf eine vorab definierte Wunschgeschwindigkeit beschleunigt. Das Modell ist kollisionsfrei, da die berechnete Verzögerung nicht begrenzt ist. Dies führt gleichzeitig dazu, dass ein Einfädelmanöver vor dem Fahrzeug eine abrupte Verzögerung zur Folge hat. Kesting u. a. [Kes+10] erweiterten das Modell um eine gesonderte Behandlung von Einfädelvorgängen, um die sprunghaften Änderungen zu verhindern. P. Gipps [Gip81] schlägt ein Fahrzeugfolgmodell vor, das die Beschleunigung auf Basis eines bevorzugten Abstands zum Führungsfahrzeug bestimmt. Der gewählte Abstand stellt eine kollisionsfreie Verzögerung im Falle einer Gefahrenbremsung des Führungsfahrzeuges sicher. Eine verbreitete Methode für makroskopische Verkehrssimulationen sind Zelluläre Automaten. Dazu wird die Straße in einzelne Teilstücke diskretisiert, in denen sich die Fahrzeuge bewegen. Für die Bestimmung der Geschwindigkeit schlagen Nagel und Schreckenberg [NS92] vier einfache Regeln vor, mit denen die Anzahl der Zellen, die sich ein Fahrzeug pro Simulationsschritt bewegt, bestimmt werden kann. Das Modell wurde außerdem von Krauss u. a. [Kra+96] in eine kontinuierliche Beschreibung überführt. Alle bisher betrachteten Modelle gehen davon aus, dass der Fahrer auf kleinste Änderungen des Abstandes und der relativen Geschwindigkeit reagiert. Allerdings sind menschliche Fahrer häufig nicht in der Lage, kleine Änderungen unmittelbar wahrzunehmen. Um dies in einem Fahrermodell abzubilden führt Wiedemann [Wie74] Wahrnehmungsschwellen ein, bis zu der ein Fahrer einen

sich ändernden Abstand nicht wahrnimmt. Auf diese Weise soll ein fluktuierender Abstand bei längeren Folgefahrten simuliert werden.

Bei der Analyse von Spurwechselmodellen werden drei verschiedene Kategorien betrachtet. Die Erste stellen regelbasierte Ansätze dar. Die Entscheidung, ob und wann ein Spurwechsel durchgeführt wird, wird anhand eines einmalig definierten Regelsatzes getroffen. P. G. Gipps [Gip86] betrachtet hierzu drei Faktoren: Die Möglichkeit eines Spurwechsels, die Notwendigkeit eines Spurwechsels und die Vorteile, die ein potentieller Spurwechsel bietet. Alle Kriterien werden in einem Entscheidungsbaum abgebildet, sodass am Ende eine positive oder negative Entscheidung für einen Spurwechsel zum aktuellen Zeitpunkt resultiert. Das Modell sieht keine Variabilität vor, womit die Abbildung unterschiedlicher Fahrertypen nicht möglich ist. Eine weiterer Ansatz ist die Verwendung von datenbasierten Modellen, die mit Hilfe von überwachten Lernmethoden und aufgenommenen Daten trainiert werden. Hierzu können beispielsweise Künstliche Neuronale Netzwerke verwendet werden (siehe Hunt und Lyons [HL94]). Ein entscheidender Nachteil stellt die nicht nachvollziehbare Entscheidung im Falle einer unvollständigen Abdeckung des Eingangsdatenraums der Trainingsdaten dar. Sobald eine Situation entsteht, die nicht in den zum Training verwendeten Daten enthalten ist, kann eine sinnvolle Entscheidung nicht mehr garantiert werden. Als dritte Kategorie werden anreizbasierte Spurwechselmodelle betrachtet. Die Spurwechselentscheidung basiert auf einer vergleichenden Bewertung der aktuellen und benachbarten Spuren. Kesting u. a. [Kes+07] schlagen das Modell MOBIL (*Minimal Overall Braking Induced by Lane change*) vor. Für die Durchführung eines Spurwechsels muss zunächst ein Anreiz vorhanden und anschließend ein Sicherheitskriterium erfüllt sein. Für beide Teilaspekte wird die Beschleunigung, die mit Hilfe eines Fahrzeugfolgmodells berechnet wird, als Kriterium verwendet. Ein Spurwechsel gilt dabei als sicher, wenn die Verzögerung des Folgefahrzeugs auf der Zielspur im Falle eines Spurwechsels einen Schwellwert nicht übersteigt. Für die Bestimmung des Anreizes wird der Vorteil des Ego-Fahrzeugs durch einen Spurwechsel (mögliche Beschleunigung) gegenüber dem Nachteil des neuen Folgefahrzeugs, der durch den Spurwechsel des Ego-Fahrzeugs entsteht, abgewogen. Ein weiteres anreizbasiertes Spurwechselmodell wird von Schakel u. a. [Sch+12] vorgestellt. Das LMRS Modell (*Lane change Model with integrated Relaxation and Synchronization*) betrachtet insgesamt drei Arten von Anreizen für einen Spurwechsel: Folgen der Route, Erreichen der Wunschgeschwindigkeit und Umsetzung des Rechtsfahrgebotes. Auf Basis der gewichteten Summe wird die Spurwechselentscheidung getroffen. Dabei werden für größere Anreize kleinere Lücken zur Durchführung des Manövers akzeptiert, wobei jederzeit ein Sicherheitskriterium erfüllt sein muss. Zusätzlich modelliert der Ansatz einen langsamen Aufbau des Sicherheitsabstandes des Folgefahrzeugs nach einem Einfädelvorgang.

Die Analyse der Ansätze aus der Literatur zeigt, dass Fahrermodelle aus der mikroskopischen Verkehrssimulation die in Abschnitt A.1.1 definierten Anforderungen zum großen Teil erfüllen. Daher wird in der Simulationsumgebung das IDM und ein regelbasiertes Spurwechselmodell verwendet.

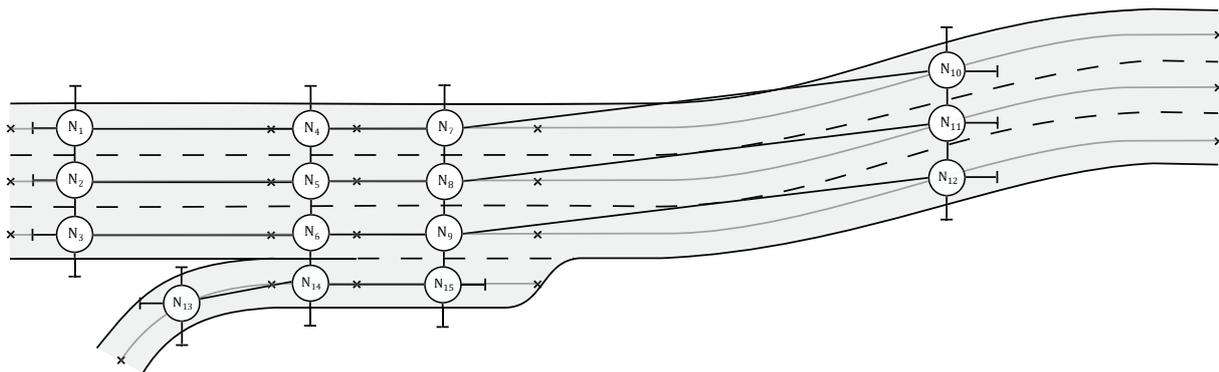


Abbildung A.1.: Beispielszenario in der Simulationsumgebung. Es wird eine Auffahrt auf eine dreispurige Autobahn inklusive anschließender leichter S-Kurve erstellt. Für das gesamte Szenario müssen 15 Knoten definiert und durch Kanten miteinander verbunden werden.

A.2. Driving Environment Simulation

In diesem Abschnitt wird die in der vorliegenden Arbeit genutzte Simulationsumgebung **Driving Environment Simulation (DESIM)** in Teilen beschrieben. Zunächst wird die Modellierung der Straßentopologie sowie die zur Entwicklung bereit gestellte Visualisierung dargelegt. Anschließend wird näher auf das verwendete laterale Fahrermodell eingegangen.

A.2.1. Modellierung der Straßentopologie und Visualisierung

Um die Entwicklung von Funktionen im Bereich der Situationsanalyse, Entscheidungsfindung und Trajektorienplanung zu ermöglichen, wird eine Simulationsumgebung vorgestellt, die direkt an die speziellen Anforderungen angepasst ist. Im vorliegenden Fall ist die Simulation dabei ausschließlich auf Autobahnszenarien ausgerichtet. Für die Definition möglichst vielseitiger Szenarien wird eine graphenbasierte Struktur zur Darstellung der Straßentopologie genutzt, bei der einzelne Spurabschnitte als Knoten definiert und mittels Kanten verbunden werden. Die Verbindung zwischen benachbarten Knoten beinhaltet zusätzliche Informationen, wie beispielsweise die Art der Spurmarkierung. Innerhalb der einzelnen Knoten sind der Spurverlauf des repräsentierten Abschnitts, die Breite der Spur sowie geltende Verkehrsregeln beschrieben. Mit dieser Struktur lassen sich eine Vielzahl von Autobahnszenarien erstellen. Dies umfasst unter anderem Auf- und Abfahrten, beliebig viele parallele oder endende und sich öffnende Spuren. Ein Beispielszenario mit den zu definierenden Knoten ist in Abbildung A.1 dargestellt. Generell, liegt der Fokus eher auf kleinen Szenarien, in denen einzelne Verkehrssituationen abgebildet werden können, und weniger auf der Simulation großer Autobahnabschnitte.

Neben der Definition von Szenarien ist auch die Visualisierung auf die Anforderungen zugeschnitten. Es wurde bewusst auf eine aufwendige drei-dimensionale Darstellung der Situation verzichtet, da zu keiner Zeit ein menschlicher Fahrer zur Steuerung des Ego-Fahrzeugs vorgesehen ist. Des Weiteren wird auf die exakte Abbildung einzelner Sensoren verzichtet (siehe 3.2), sodass lediglich das resultierende Umfeldmodell

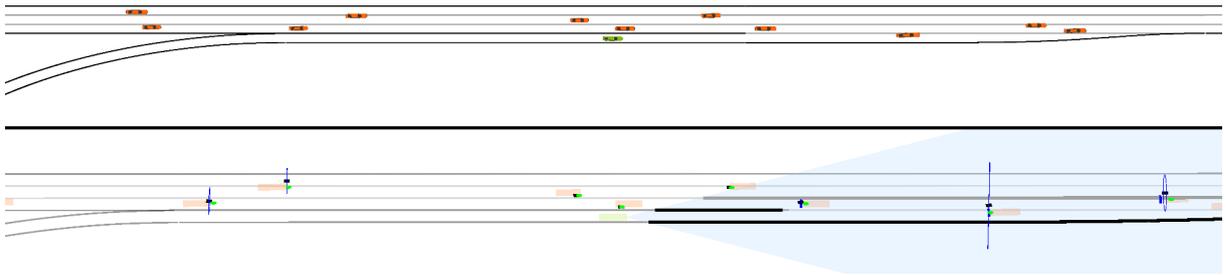


Abbildung A.2.: Visualisierung eines Ausschnitts des in Abbildung A.1 definierten Szenarios in der Simulationsumgebung. Im oberen Abschnitt ist eine Übersicht über den Spurverlauf und alle im Szenario befindlichen Fahrzeuge zu sehen. Im unteren Bildabschnitt sind alle aktuell vom Sensorsetup wahrgenommenen Objekte und die detektierten Spurmarkierungen dargestellt. Zusätzlich ist die Referenz leicht transparent unterlagert. Die schwarzen Punkte stellen Radar-Reflexionen und die blauen Ellipsen deren Unsicherheit dar. Die grünen Punkte zeigen die fusionierten und getrackten Objekte. Erkannte durchgezogene Spurmarkierungen werden als schwarze und gestrichelte Spurmarkierungen als graue Linien dargestellt.

visualisiert werden muss. Ein Ausschnitt der entsprechenden Visualisierung ist in Abbildung A.2 zu sehen. Es sind generell zwei Teilbereiche zu erkennen. Im oberen Teil ist ein Übersicht über die Simulation mit allen Fahrzeugen und dem Straßenverlauf dargestellt und im unteren Bereich eine Ansicht der im Umfeldmodell enthaltenen Informationen.

Für eine effektive Entwicklung und ausgiebige Tests ist die Simulationsgeschwindigkeit von zentraler Bedeutung. Aus diesem Grund ist die Simulationsumgebung vollständig in C und C++ programmiert. Außerdem kann für automatisierte Test auf die Visualisierung verzichtet werden, um so eine schnellere Ausführung zu erreichen.

A.2.2. Laterales Fahrermodell

Der Entscheidungsprozess für einen Spurwechsel eines Simulationsfahrzeugs ist in Abbildung A.3 dargestellt. $g_{\text{end}}^{(k)}$ beschreibt dabei den Abstand des Fahrzeugs k zum Ende der aktuellen Spur. Sobald sich das Fahrzeug weniger als \hat{t}_{end} s mit der aktuellen Geschwindigkeit oder \hat{g}_{end} m auf der Spur fortbewegen kann, wird ein notwendiger Spurwechsel eingeleitet. Sollte dieser Fall nicht eintreten, wird geprüft, ob ein langsames Führungsfahrzeug die Fahrt mit der Wunschgeschwindigkeit verhindert. Um einen Überholvorgang mit sehr kleinen Geschwindigkeitsdifferenzen zu verhindern, muss ein zusätzlicher Schwellwert Δv_{des} überschritten werden, um einen wünschenswerten Spurwechsel nach links anzustreben. Schlussendlich wird das Rechtsfahrgebot umgesetzt, wenn auf der rechten Spur eine ungehinderte Fahrt für $t_r^{(k)}$ s möglich ist. Bevor der eigentliche Spurwechsel umgesetzt werden kann, muss überprüft werden, ob die erforderliche Lücke auf der Zielspur vorhanden ist. Die benötigte Lücke hängt dabei von der relativen Geschwindigkeit zum Führung- und Folgefahrzeug und von der Geschwindigkeit des eigenen Fahrzeugs ab. Generell gilt, für höhere Geschwindigkeiten sowie für große Relativgeschwindigkeiten wird eine größere Lücke benötigt. Die kritische Lücke $g_{\text{dir,crit}}^{(k)}(t_n)$ beschreibt den Grenzfall, für den ein Spurwechsel noch

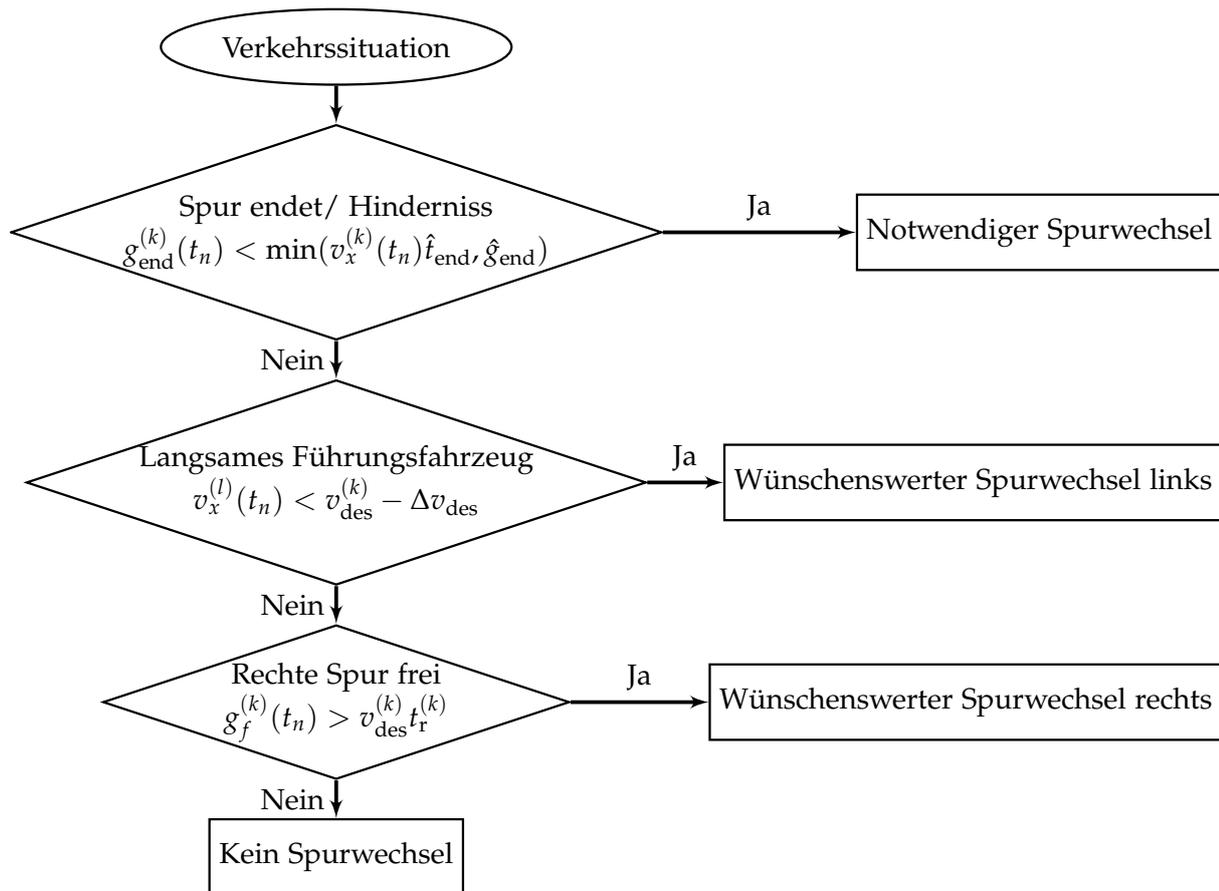


Abbildung A.3.: Entscheidungsbaum anhand dessen die aktuelle Verkehrssituation bewertet wird und eine Entscheidung bezüglich eines notwendigen oder wünschenswerten Spurwechsel getroffen wird.

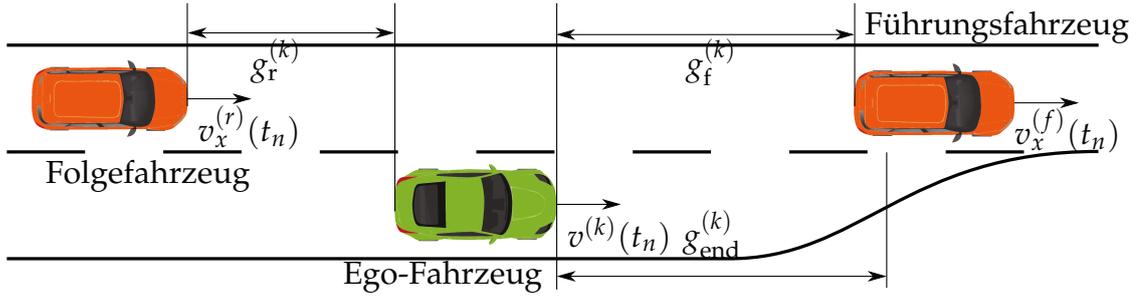


Abbildung A.4.: Abstände für die Entscheidung ob die vorhandene Lücke für einen Spurwechsel akzeptiert wird.

durchgeführt wird. Sie ist definiert durch

$$g_{\text{dir,crit}}^{(k)}(t_n) = g_{\text{dir,min}}^{(k)} + \gamma \left(\beta_{\text{dir},v}^{(k)} v_x^{(k)}(t_n) + \beta_{\text{dir},\Delta v}^{(k)} \left(v_x^{(k)}(t_n) - v_x^{(\text{dir})}(t_n) \right) \right). \quad (\text{A.2.1})$$

Dabei impliziert $\text{dir} \in \{f, r\}$ die jeweiligen Parameter und Zustände des Führung- sowie Folgefahrzeugs auf der Zielspur (siehe Abbildung A.4). Außerdem beschreibt $v_x^{(\text{dir})}(t_n)$ die aktuelle Geschwindigkeit der beiden Fahrzeuge. $g_{\text{dir,min}}^{(k)}$ ist die erforderliche minimale Lücke bei stehendem Verkehr und mit $\beta_{\text{dir},v}^{(k)}$ und $\beta_{\text{dir},\Delta v}^{(k)}$ kann der Einfluss der Fahrzeuggeschwindigkeit und der Relativgeschwindigkeiten gewichtet werden. Mit η wird der hintere Teil von Gleichung A.2.1 zusätzlich abhängig von der Art des Spurwechsels gewichtet

$$\gamma = \begin{cases} 1 & \text{für wünschenswerte Spurwechsel} \\ 1 - \exp\left(-\gamma_{\text{dir}}^{(k)} g_{\text{end}}^{(k)}\right) & \text{für notwendige Spurwechsel} \end{cases}. \quad (\text{A.2.2})$$

Die kritische benötigte Lücke wird so im Falle eines notwendigen Spurwechsels kleiner je kürzer die Distanz zum Ende der Spur wird. Damit wird ein Einfädeln in Situationen mit dichtem Verkehr, wie zum Beispiel an einer Autobahnauffahrt, ermöglicht. $\gamma_{\text{dir}}^{(k)}$ beeinflusst wie stark die erforderliche Lücke im Falle eines notwendigen Spurwechsels abnimmt. Ein angestrebter Spurwechsel kann ausgeführt werden, wenn

$$g_f^{(k)}(t_n) \geq g_{f,\text{crit}}^{(k)}(t_n) \wedge g_r^{(k)}(t_n) \geq g_{r,\text{crit}}^{(k)}(t_n) \quad (\text{A.2.3})$$

erfüllt ist. Durch die Wahl der Parameter kann mit dem Modell sowohl ein aggressiver als auch ein zurückhaltender, vorsichtiger Fahrstil abgebildet werden. Bei kleineren Werten für die Parameter $\beta_{\text{dir},v}^{(k)}$ und $\beta_{\text{dir},\Delta v}^{(k)}$ ist ein Fahrzeug eher bereit eine kleine Lücke zu akzeptieren als bei größeren.

Die Standardparameter sind sowohl für die Entscheidungsfindung als auch für die Lückenbewertung sind in Tabelle A.2 aufgeführt. In der Simulationsumgebung können die Parameter für jedes Fahrzeug individuell festgelegt werden. Außerdem gibt es die Möglichkeit für jede Ausführung neue Parameter aus einer vorab definierten Verteilung zu ziehen, um so ein stochastisches Verhalten der Verkehrsteilnehmer zu erzeugen.

Tabelle A.2.: Standard Parameter des longitudinalen und lateralen Fahrermodells.

| Parameter | Wert | Parameter | Wert | Parameter | Wert |
|--------------------------|-----------------------------------|----------------------------|------|-------------------------|---------------------------------|
| Intelligent Driver Model | | Lückenbewertung | | $\gamma_f^{(k)}$ | 0.0001 |
| $a_{\max}^{(k)}$ | $1.4 \frac{\text{m}}{\text{s}^2}$ | $g_{f,\min}^{(k)}$ | 3 m | $\gamma_f^{(k)}$ | 0.0001 |
| $b^{(k)}$ | $2 \frac{\text{m}}{\text{s}^2}$ | $g_{r,\min}^{(k)}$ | 5 m | Spurwechselentscheidung | |
| $s_0^{(k)}$ | 2 m | $\beta_{f,v}^{(k)}$ | 0.1 | \hat{g}_{end} | 250 m |
| $T^{(k)}$ | 1 s | $\beta_{r,v}^{(k)}$ | 0.2 | \hat{t}_{end} | 10 s |
| δ | 4 | $\beta_{f,\Delta v}^{(k)}$ | 0.15 | Δv_{des} | $0.1 \frac{\text{m}}{\text{s}}$ |
| | | $\beta_{r,\Delta v}^{(k)}$ | 0.4 | $t_r^{(k)}$ | 20 m |

A.3. Definitionen

A.3.1. Verteilungsfunktionen

Innerhalb des Dokumentes werden zwei verschiedene Verteilungsfunktionen verwendet. Diese werden im Folgenden definiert.

Normalverteilung

Die Normalverteilung der Dimension n_d wird durch einen Mittelwert $\boldsymbol{\mu} \in \mathbb{R}^{n_d}$ und eine Kovarianzmatrix $\boldsymbol{\Sigma} \in \mathbb{R}^{n_d \times n_d}$ beschreiben. Die Wahrscheinlichkeitsdichtefunktion $\mathcal{N}(\boldsymbol{\mu}, \boldsymbol{\Sigma}) : \mathbb{R}^{n_d} \rightarrow \mathbb{R}$ ist definiert als

$$\mathcal{N}(\mathbf{u} \mid \boldsymbol{\mu}, \boldsymbol{\Sigma}) = \frac{1}{\sqrt{(2\pi)^{n_d} \det(\boldsymbol{\Sigma})}} \exp^{-\frac{1}{2}(\mathbf{u}-\boldsymbol{\mu})^T \boldsymbol{\Sigma}^{-1}(\mathbf{u}-\boldsymbol{\mu})} \quad (\text{A.3.1})$$

für $\mathbf{u} \in \mathbb{R}^{n_d}$.

Gleichverteilung

Die uniforme Verteilung oder Gleichverteilung ist durch die obere und untere Grenze $r_1 \in \mathbb{R}$ sowie $r_2 \in \mathbb{R}$ mit $r_1 > r_2$ beschrieben. Sie ist durch eine konstante Wahrscheinlichkeitsdichte innerhalb des Bereiches und eine Wahrscheinlichkeitsdichte von null außerhalb charakterisiert. Die Wahrscheinlichkeitsdichtefunktion $\mathcal{U}(r_1, r_2) : \mathbb{R} \rightarrow \mathbb{R}$ ist definiert als

$$\mathcal{U}(r \mid r_1, r_2) = \begin{cases} \frac{1}{r_2-r_1} & \text{falls } r_1 \leq r \leq r_2 \\ 0 & \text{falls } r < r_1 \text{ oder } r_2 < r \end{cases} \quad (\text{A.3.2})$$

für $r \in \mathbb{R}$.

A.3.2. Die Indikatorfunktion

Die Indikatorfunktion kann lediglich zwei Funktionswerte annehmen und drückt die Zugehörigkeit eines Elements zu einer Untermenge aus. Sei u ein Element der

Menge U und V eine Teilmenge von U ($V \subset U$). Dann ist die Indikatorfunktion $\mathbb{I}_V : U \rightarrow \{0, 1\}$ definiert als

$$\mathbb{I}_V(u) = \begin{cases} 1, & \text{falls } u \in V \\ 0, & \text{falls } u \notin V \end{cases} . \quad (\text{A.3.3})$$

A.3.3. Trajektorienprädiktion mit konstanter Geschwindigkeit

Die Prädiktion einer Trajektorie mit konstanter Geschwindigkeit (CV) wird im Verlauf der Arbeit als Vergleich zu den vorgestellten Verfahren herangezogen. Das Verfahren basiert auf der Annahme, dass sich die aktuelle Geschwindigkeit eines beobachteten Fahrzeugs innerhalb des Prädiktionshorizontes T_p nicht ändert. Für ein beobachtetes Fahrzeug k mit dem aktuellen Zustand $\mathbf{x}^{(k)}(t_n) = [x, y, v_x, v_y]^T \in \mathbb{R}^4$ zum Zeitpunkt t_n werden die zukünftigen Zustände $\hat{\mathbf{x}}^{(k)}(\tau)$ für $\tau \in [t_n, t_n + T_p]$ bestimmt mit

$$\mathbf{x}^{(k)}(t_{n+1}) = \mathbf{A}_{CV} \mathbf{x}^{(k)}(t_n). \quad (\text{A.3.4})$$

Die Unsicherheit wird entsprechend Gleichung (5.2.9) bestimmt. Das Verfahren verwendet keine Informationen über den Verlauf der Straße auf dem sich das Fahrzeug bewegt. Damit sind besonders in kurvigen Szenarien Fehler in der prädizierten Trajektorie zu erwarten.

Eine Erweiterung der Trajektorienprädiktion mit konstanter Geschwindigkeit ist die Prädiktion in kurvilinearen Koordinaten (CVCL). Hierbei wird der aktuelle Zustand von Fahrzeug k zunächst in kurvilineare Koordinaten mit dem Straßenverlauf als Referenz transformiert. Die prädizierte Bewegung ist somit entlang des Straßenverlaufs definiert.

A.4. Datensätze

Der Abschnitt beschreibt die in der vorliegenden Arbeit verwendeten Datensätze. Dies umfasst zum einen den Datensatz, der mit der in Abschnitt 3 beschriebenen Simulationsumgebung erstellt wurde, und zum anderen einen Datensatz, der mit einem Versuchsfahrzeug in verschiedenen Autobahnszenarien aufgenommen wurde.

A.4.1. Datensatz aus der Simulation

Für die Erstellung des Datensatzes mit der Simulationsumgebung werden verschiedene Szenarien generiert und diese in jeder Ausführung variiert. Die Szenarien bestehen aus kurzen Autobahnabschnitten mit zwei oder drei parallelen Spuren. Zwischen den Spuren werden gestrichelte Spurmarkierungen simuliert, sodass Spurwechsel in beide Richtungen möglich sind. Für jedes Szenario wird ein Spurverlauf mit unterschiedlichen Krümmungsradien erstellt. Zusätzlich werden Szenarien mit speziellen Verkehrssituationen im Datensatz berücksichtigt. Dies umfasst eine Autobahnauffahrt auf eine zwei oder dreispurige Autobahn, wie sie in Abbildung 3.6 in Abschnitt 3.4 dargestellt ist. Jedes Szenario wird mit der Simulationsumgebung mehrfach ausgeführt. Dabei

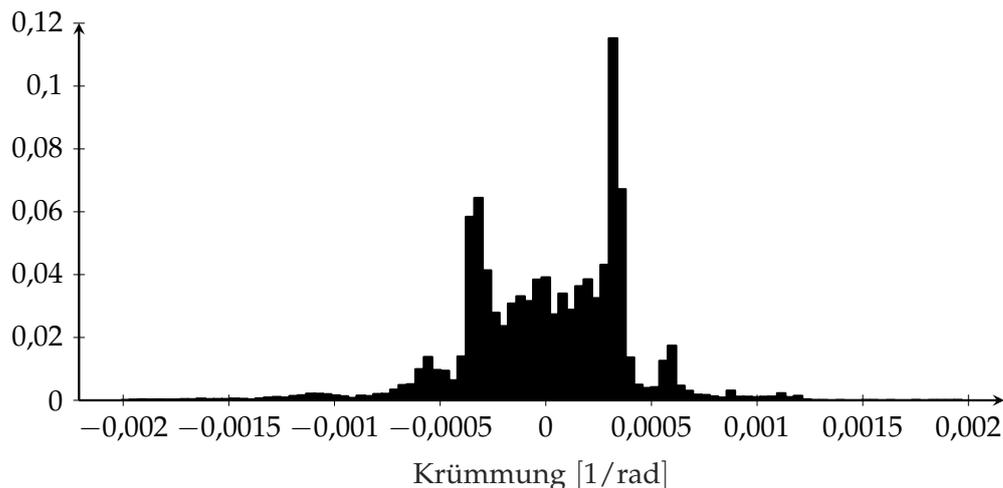


Abbildung A.5.: Auftretende Krümmungen der Fahrbahn im Datensatz, der mit dem Versuchsfahrzeug aufgezeichnet wurde.

wird zum einen die Verkehrsdichte der unterschiedlichen Spuren und zum anderen die Parameter der Fahrermodelle des Umgebungsverkehrs zufällig variiert.

Mit der beschriebenen Vorgehensweise wurde ein Datensatz erstellt, der aus Sicht des Ego-Fahrzeugs einer Gesamtfahrzeit von 127930,2 s (mehr als 35 Stunden und 32 Minuten) entspricht. Der gesamte Datensatz enthält 2750 Spurwechselmanöver, die vom Ego-Fahrzeug beobachtet wurden. Diese untergliedern sich in 1506 Spurwechsel nach links und 1244 Spurwechsel nach rechts.

A.4.2. Datensatz aus dem Versuchsfahrzeug

Für die Aufnahme des Datensatzes mit dem Versuchsfahrzeug wird auf eine bestehende Sensordatenverarbeitung und Objektfusion zurückgegriffen. Der berechneten Werte werden als Ausgang für die in dieser Arbeit vorgestellten Verfahren verwendet. Auch dieser Datensatz besteht ausschließlich aus Szenarien auf Autobahnen mit unterschiedlichen Straßentopologien und Krümmungen. Die auftretenden Krümmungen werden anhand der von der Kamera geschätzten Spurmarkierungen ermittelt, sodass die tatsächliche Krümmung von der hier dargestellten abweichen kann. Es ist allerdings anzunehmen, dass die Verteilung eine ausreichend gute Abschätzung zulässt. Die ermittelten Krümmungen werden genutzt, um ähnliche Szenarien in der Simulationsumgebung zu erzeugen.

Mit dem Versuchsfahrzeug wurden Daten mit einer Gesamtlänge von 38 327,4 sec aufgenommen. Das entspricht mehr als 10 Stunden und 38 Minuten. Im vollständigen Datensatz sind 309 Spurwechsel von beobachteten Verkehrsteilnehmern enthalten, die sich in 115 Spurwechsel nach links und 194 Spurwechsel nach rechts untergliedern.

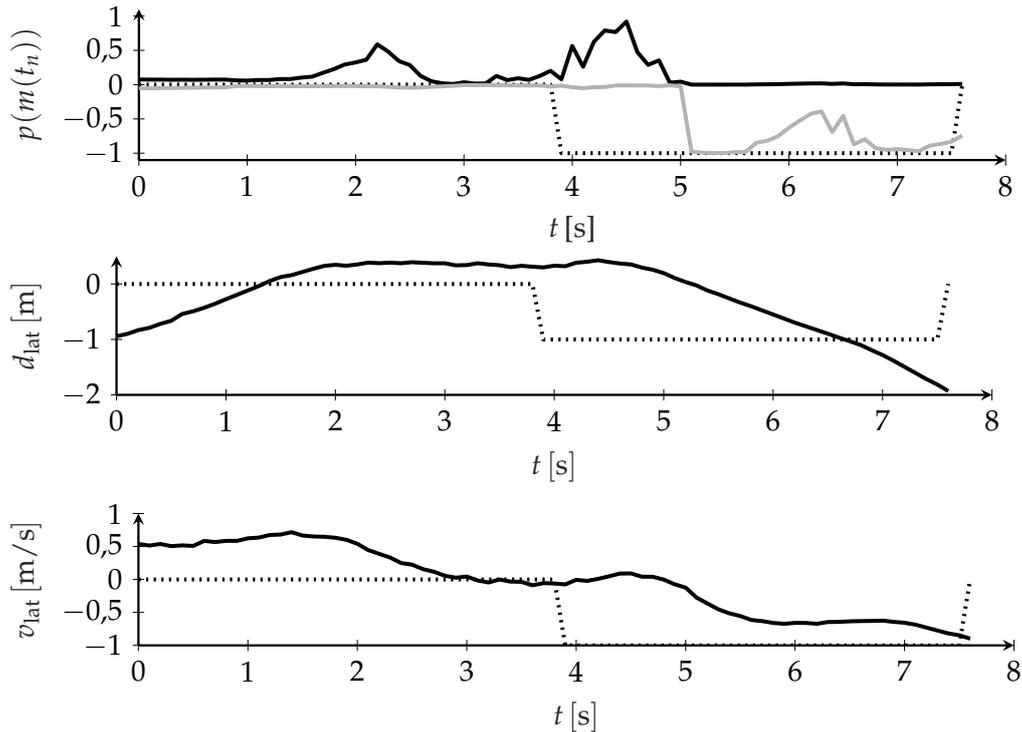


Abbildung A.6.: Falsch klassifizierte Beispiele für einen Spurwechsel nach rechts und die entsprechenden Merkmale d_{lat} und v_{lat} . Zu Beginn des Labels werden die Beispiele als Spurwechsel nach links klassifiziert.

A.5. Beispiel für eine fehlerhafte Manöverklassifikation

Fehlerhafte Schätzung der Spurwechselrichtung

Wie in den Auswertungen in Abschnitt 4.4 anhand der Genauigkeit und der dargestellten Konfusionsmatrix gezeigt, werden einzelne Beispiele fehlerhaft klassifiziert. Gerade wenn ein Spurwechselmanöver nach rechts in die entgegengesetzte Richtung klassifiziert wird, ist der Grund nicht direkt ersichtlich, da vor allem die objektbasierten Merkmale eine eindeutige Zuordnung, aber vor allem einen Ausschluss der entgegengesetzten Klasse erlauben sollten. Als Beispiel wird der Spurwechsel in Abbildung A.6 herangezogen. Es ist zu erkennen, dass zunächst eine größere Wahrscheinlichkeit für einen Spurwechsel nach links erzeugt wird. Der Grund ist in dem lateralen Abstand zur Spurmitte zu Beginn des Labels zu finden. Das beobachtete Fahrzeug fährt kurz vor dem Manöver sehr weit links in der Spur und macht eine leichte Pendelbewegung in Richtung der linken Spur, sodass ein Spurwechsel nach links vorhergesagt wird.

Fehlerhafte Merkmale im Datensatz aus dem Versuchsfahrzeug

Eines der größten Probleme ist Wahrnehmung der Spurmarkierungen durch die im Testfahrzeug verbaute Kamera. Diese werden häufig nur innerhalb einer Distanz von unter 80 m detektiert. Da die Repräsentation mit Polynomen dritter Ordnung keine zuverlässige Extrapolation erlaubt, ist nur innerhalb dieser Reichweite eine sichere Be-

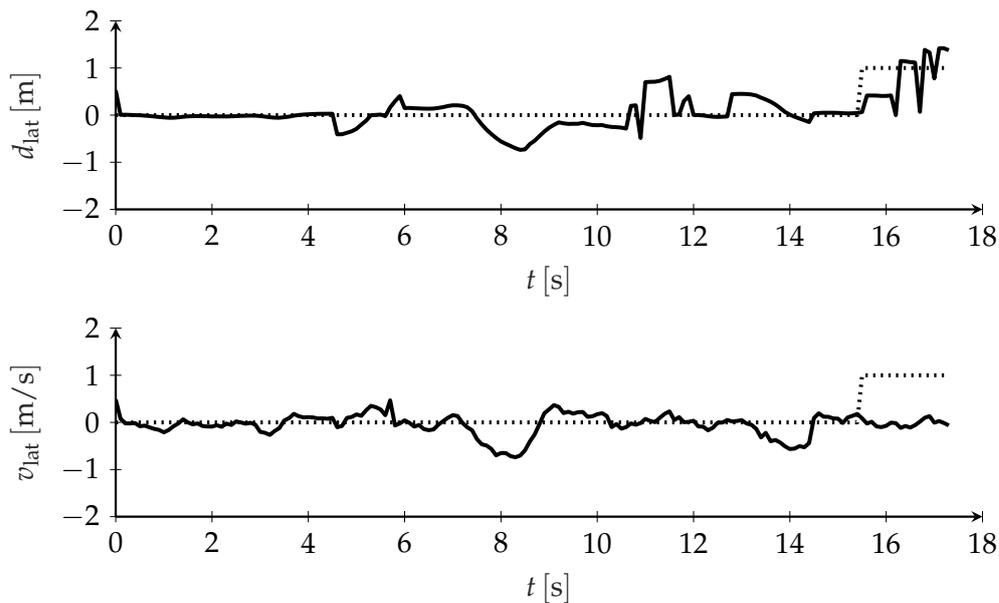


Abbildung A.7.: Beispielverlauf der lateralen Distanz zur Spurmitte d_{lat} (oben) und der lateralen Geschwindigkeit relativ zur Spur v_{lat} (unten) mit dem zugehörigen Label (gepunktete Linie).

stimmung der Spurzuordnung durchführen. Allerdings bewegen sich die beobachteten Fahrzeuge häufig außerhalb der detektierten Spurmarkierungen, sodass die Spurzuordnung in aufeinander folgenden Zyklen nicht konsistent vorgenommen werden kann. In Abbildung A.7 ist der Verlauf des lateralen Abstandes und der entsprechenden lateralen Geschwindigkeit für mehrfache inkonsistente Spurzuordnungen dargestellt. Gerade im Bereich des eigentlichen Spurwechsels ändert sich die Zuordnung zu einer Spur mehrfach, wobei diese jeweils einen Sprung des lateralen Abstandes zur Folge haben. Aufgrund der Inkonsistenzen kann die laterale Geschwindigkeit nicht direkt als Ableitung der lateralen Distanz bestimmt werden. Statt dessen wird das Signal zusätzlich gefiltert, wodurch sich in diesem Beispiel kein aussagekräftiger Wert für die laterale Geschwindigkeit ergibt. Eine sinnvolle Prädiktion auf Basis dieser Merkmale ist ebenfalls nicht zu erwarten.

A.6. Monte Carlo Simulation

Das interaktionsbasierte Verfahren zur Trajektorienprädiktion in Kapitel 8 nutzt eine *Monte Carlo Simulation* zur Approximation der Verteilung der prädizierten Zustände. Dieser Abschnitt umfasst zum einen die abschließende Gruppierung aller simulierten Trajektorien eines Agenten und zum anderen eine anschauliche Darstellung des Vorgehens der *Monte Carlo Simulation* in Form eines Algorithmus.

Gruppierung von ähnlichen Trajektorien

Das Ziel der interaktionsbasierten Trajektorienprädiktion ist die Vorhersage aller möglichen Entwicklungen der aktuellen Verkehrssimulation. Allerdings ist es innerhalb

der Bewegungsplanung des Ego-Fahrzeugs nicht möglich, die Trajektorien jeder einzelnen *Monte Carlo* Simulationsiteration zu berücksichtigen, sodass diese in einer geringen Anzahl von Gruppen zusammengefasst werden müssen. Die Repräsentation der prädizierten Verteilung wird analog zu der manöverbasierten Trajektorienprädiktion gewählt. Jede prädizierte Entwicklung der Situation wird mit einer Sequenz von normalverteilten Zuständen repräsentiert, die mit der Wahrscheinlichkeit für diese Entwicklung gewichtet wird.

Die Gruppierung wird anhand des letzten prädizierten Zustandes der einzelnen *Monte Carlo* Iterationen vorgenommen, da sich unterschiedliche Entwicklungen auf diesen am stärksten auswirken. Als erstes Kriterium wird die Spurzuordnung eines Agenten am Ende der Prädiktionsdauer verwendet. Eine Trajektorie aus der *Monte Carlo* Iteration i kann nicht der gleichen Gruppe zugeordnet werden wie die Trajektorie aus Iteration j , wenn der finale Zustand des k -ten Agenten in Iteration i auf einer anderen Spur liegt als der finale Zustand in Iteration j . Zusätzlich wird innerhalb der Spuren eine Gruppierung anhand der longitudinalen Koordinate mit Hilfe des DBSCAN-Algorithmus von Ester u. a. [Est+96] vorgenommen. Die Wahrscheinlichkeit jeder Gruppe $p_c \in [0, 1]$ wird anschließend mit

$$p_c = \frac{n_c}{n_{MC}} \quad (\text{A.6.1})$$

bestimmt. Dabei ist $n_c \in \mathbb{N}_+$ die Anzahl aller Trajektorien, die der jeweiligen Gruppe zugeordnet sind.

Algorithmus der interaktionsbasierten Trajektorienprädiktoin

In in Algorithmus A.1 werden die einzelnen Schritte der Simulation aus Abschnitt 8.2 in Form eines Programmablaufes dargestellt.

Für n_{MC} Iterationen wird der aktuelle Zustand aller beobachteten Agenten als Ausgangspunkt genutzt. Anschließend wird jedem Agenten die initiale Position als Beispiel aus der beobachteten Zustandsunsicherheit und ein initiales Manöver aus der geschätzten Manöververteilung zugewiesen. Entsprechend des Manövers wird der initiale Pfad bestimmt. Außerdem wird in jeder *Monte Carlo* Iteration ein neuer Satz von Parametern der Fahrermodelle entsprechend der in Abschnitt 8.2 definierten Verteilungen gezogen.

Nach der Initiierung wird für jeden Zeitschritt innerhalb des Prädiktionshorizonts für jeden Agenten zunächst das laterale Fahrermodell angewandt. Falls auf Basis des Fahrermodells eine neues, abweichendes Fahrmanöver bestimmt wird, wird ein neuer Manöverpfad entsprechend des Manövers generiert. Anschließend wird die longitudinale Beschleunigung mit dem longitudinalen Fahrermodell und die laterale Beschleunigung auf Basis des Manöverpfads bestimmt. Mit dieser kann mit Hilfe des Bewegungsmodells die Position des Agenten im folgenden Zeitschritt berechnet werden.

Um eine Beschreibung der Trajektorienverteilung als normalverteilte Zustände zu erhalten, werden die Trajektorien aller *Monte Carlo* Iterationen abschließend gruppiert.

Algorithmus A.1.: Algorithmus zur interaktionsbasierten Trajektorienprädiktion.

Voraussetzung: \mathcal{Z}_I : Initiale Menge der Agenten, \mathcal{S} : Repräsentation der Straßentopologie, $p(m^{(k)})$: Manöververteilung für $k \in \{1, 2, \dots, K\}$, n_{MC} : Anzahl von Monte Carlo Iterationen, T_p : Prädiktionszeit

- 1: **Für** $i = 1$ bis n_{MC}
 - 2: $\mathcal{Z} \leftarrow \mathcal{Z}_I$
 - 3: **Für** $k = 1$ bis K
 - 4: $\underline{\mathbf{x}}^{(k)}(0) \leftarrow \text{INITIALERZUSTAND}\left(\mathbf{x}^{(k)}(t_n)\right)$
 - 5: $m^{(k)}(0) \leftarrow \text{INITIALESMANÖVER}\left(p(m^{(k)})\right)$
 - 6: $\check{\mathbf{p}}_m^{(k)} \leftarrow \text{MANÖVERPFAD}\left(m^{(k)}(0), \mathcal{S}\right)$
 - 7: $\theta_{\text{Long}}^{(k)}, \theta_{\text{Lat}}^{(k)} \leftarrow \text{ZIEHEPARAMETER}()$
 - 8: **Für** $\tau = \Delta T$ bis T_p
 - 9: **Für** $k = 1$ bis K
 - 10: $m^{(k)}(\tau) \leftarrow \text{LATERALESFAHRERMODELL}\left(N_k, \theta_{\text{Long}}^{(k)}\right)$
 - 11: **Wenn** $m^{(k)}(\tau) \neq m^{(k)}(\tau - \Delta T)$ ▷ Neues Manöver
 - 12: $\check{\mathbf{p}}_m^{(k)} \leftarrow \text{MANÖVERPFAD}\left(m^{(k)}(\tau), \mathcal{S}\right)$
 - 13: $a_l^{(k)} \leftarrow \text{LONGITUDINALESFÄHRERMODELL}\left(\mathcal{Z}, \theta_{\text{Long}}^{(k)}\right)$
 - 14: $a_n^{(k)} \leftarrow \text{LATERALEBESCHLEUNIGUNG}\left(\check{\mathbf{p}}_m^{(k)}\right)$
 - 15: $\underline{\mathbf{x}}_i^{(k)}(\tau) \leftarrow \text{BEWEGUNGSMODELL}\left(\underline{\mathbf{x}}_i^{(k)}(\tau - \Delta T), \mathbf{a}^{(k)}\right)$
 - 16: **Für** $k = 1$ bis K
 - 17: $p\left(\hat{\mathbf{x}}^{(k)}(\tau)(\tau)\right) \leftarrow \text{GRUPPIERE} \text{TRAJEKTORIEN}\left(\underline{\mathbf{x}}_i^{(k)}(\tau)\right)$
- Ausgabe** $p(\hat{\mathbf{x}}^{(k)}(\tau)(\tau))$
-