



Technische Universität München  
Fakultät für Elektrotechnik und Informationstechnik  
Fachgebiet für Geometrische Optimierung und Maschinelles Lernen

# Entwicklung einer semi-parametrischen Methode zur probabilistischen Prädiktion von Fahrzeugtrajektorien auf Basis von Flottendaten

**Dipl.-Ing. Univ. Justus Wilhelm Jordan**

Vollständiger Abdruck der von der Fakultät für Elektrotechnik und Informationstechnik der Technischen Universität München zur Erlangung des akademischen Grades eines

**Doktor-Ingenieurs (Dr.-Ing.)**

genehmigten Dissertation.

**Vorsitzender:** Prof. Dr. sc. tech. Gerhard Kramer

**Prüfer der Dissertation:**

1. Priv.-Doz. Dr. rer. nat. Martin Kleinsteuber
2. Prof. Dr.-Ing. Gerhard Rigoll

Die Dissertation wurde am 19. Juli 2017 bei der Technischen Universität München eingereicht und durch die Fakultät für Elektrotechnik und Informationstechnik am 6. Februar 2018 angenommen.



# Danksagung

Diese Arbeit entstand während meiner Zeit bei der Forschung und Technik GmbH der BMW Group in Zusammenarbeit mit dem Fachgebiet für Geometrische Optimierung und Maschinelles Lernen an der Fakultät für Elektrotechnik und Informationstechnik der Technischen Universität München.

Mein besonderer Dank gilt Priv.-Doz. Martin Kleinsteuber, der mir als Doktorvater ermöglichte, dass ich in diesem faszinierenden Themenfeld arbeiten konnte und, wann immer nötig, für eine wissenschaftliche Diskussion zur Verfügung stand.

Des Weiteren danke ich Dr. Felix Klanner und Dr. Horst Klöden, die mir organisatorisch den Rücken freigehalten haben. Zudem möchte ich Christian Ruhhammer, Prof. Byron Boots, Dr. Andreas Rauch und Dr. Martin Liebner danken, die im fachlichen Austausch stets für weitere Ideen und alternative Blickrichtungen gesorgt haben.

Mein Dank gilt weiterhin Prof. Gerhard Rigoll für die Anfertigung des Zweitgutachtens sowie Prof. Gerhard Kramer, der sich bereiterklärt hat, den Vorsitz der Prüfungskommission zu übernehmen.

Schließlich danke ich meinen Eltern, die mich auf meinem Lebensweg unterstützt, mir meine akademische Ausbildung ermöglicht und mich zu jeder Zeit ermuntert haben.

München, im Juli 2017

Justus Wilhelm Jordan



Für Juliane



# Kurzfassung

Für die Entwicklung von zukünftigen Fahrerassistenzsystemen über das hochautomatisierte Fahren bis hin zu autonomen Formen der individuellen Mobilität müssen komplexe Fahrsituationen selbstständig vom System des jeweiligen Automatisierungsgrades gemeistert werden. Ein wesentlicher Bestandteil ist dabei die möglichst exakte Vorhersage des Verhaltens anderer Verkehrsteilnehmer. Daher wird ein Modell benötigt, welches die Interaktion der Teilnehmer im Situationskontext berücksichtigt - sowohl untereinander als auch mit der Umwelt. In dieser Arbeit wird eine generische Architektur für solche Modelle, welche diese Anforderungen erfüllen, vorgestellt und auf Basis von Daten realer Fahrzeugflotten werden konkrete Modelle entworfen.

Im Vergleich zum Stand der Technik besteht ein wesentlicher Vorteil darin, dass die vorgestellte Methode formal-parametrische Beschreibungen – soweit diese bekannt sind – und gelernte Zusammenhänge kombiniert. Komplexeres Fahrverhalten wird so auf Basis der analysierter Daten einer Fahrzeugflotte modelliert. Dies wird durch eine rekursive, bayessche Filter-Architektur erreicht, die durch Gauß-Prozesse erweitert wird, um das Verhalten von Verkehrsteilnehmern zu präzisieren respektive eine probabilistische Aussage über deren zukünftige Trajektorie zu treffen. Die allgemeine Vorhersagegenauigkeit wird durch die vorgestellte Methode gesteigert ohne die Robustheit für spezielle Fahrsituationen einzubüßen, die evtl. nicht ausreichend im analysierten Datensatz vertreten waren.





# Inhaltsverzeichnis

|  |             |
|--|-------------|
| <b>Kurzfassung</b>   | <b>VII</b>  |
| <b>Abbildungsverzeichnis</b>   | <b>XIII</b> |
| <b>Tabellenverzeichnis</b>   | <b>XVII</b> |
| <b>Symbolverzeichnis</b>   | <b>XIX</b>  |
| <b>1 Einleitung</b>  | <b>1</b>    |
| 1.1 Problemstellung . . . . .  | 2           |
| 1.2 Wissenschaftlicher Neuwert . . . . .                               | 3           |
| 1.3 Struktur der Arbeit . . . . .                                      | 3           |
| <b>2 Aggregation von Daten aus Fahrzeugflotten</b>                     | <b>5</b>    |
| 2.1 Datenerhebung aus Fahrzeugflotten . . . . .                        | 5           |
| 2.1.1 Fahrzeugsensorik . . . . .                                       | 5           |
| 2.1.2 Extraktion der Fahrzeugdaten . . . . .                           | 6           |
| 2.1.3 Bereitstellung in der Datenbank . . . . .                        | 7           |
| 2.2 Entkopplung von Funktion und Sensorik . . . . .                    | 8           |
| 2.2.1 Datenrepräsentation im Umfeldmodell . . . . .                    | 8           |
| 2.2.2 Transformation in Frenet-Koordinaten . . . . .                   | 9           |
| <b>3 Indexierung einer Datenbank mit Fahrdaten aus Fahrzeugflotten</b> | <b>13</b>   |
| 3.1 Definition von Fahrsituationen und -manövern . . . . .             | 14          |
| 3.1.1 Fahrstreifengebundene Fahrsituationen . . . . .                  | 15          |
| 3.1.2 Fahrstreifenwechsel . . . . .                                    | 15          |

|          |  |           |
|----------|--|-----------|
| 3.1.3    | Einscheren von Fremdfahrzeugen . . . . .   | 16        |
| 3.2      | Klassifikation von Flottendaten . . . . .  | 16        |
| 3.2.1    | Architektur der Klassifikation . . . . .   | 17        |
| 3.2.2    | Beschreibung der Datengrundlage . . . . .  | 17        |
| 3.2.3    | Random Forest . . . . .  | 20        |
| 3.2.4    | Classification and Decision Trees . . . . .                                      | 21        |
| 3.3      | Evaluation der Klassifikation . . . . .  | 22        |
| 3.3.1    | Klassifikation fahrstreifengebundener Fahrsituationen . . . . .                  | 22        |
| 3.3.2    | Klassifikation von Fahrstreifenwechseln . . . . .                                | 27        |
| 3.3.3    | Klassifikation von Einscherern . . . . .   | 33        |
| 3.4      | Modellierung der zeitlichen Zusammenhänge . . . . .                              | 37        |
| 3.5      | Zusammenfassung . . . . .  | 41        |
| <b>4</b> | <b>Semi-parametrische Zustandsprädiktion</b>                                     | <b>43</b> |
| 4.1      | Einordnung in den Anwendungskontext . . . . .                                    | 43        |
| 4.2      | Lösungsansatz . . . . .  | 44        |
| 4.3      | Parametrische Methode . . . . .  | 45        |
| 4.3.1    | Tracking mit kinematischen Bewegungsmodellen . . . . .                           | 46        |
| 4.3.2    | Messmodell als Verknüpfung von Umfeldmodell und Sensor-<br>wahrnehmung . . . . . | 47        |
| 4.3.3    | Initialisierung neuer Objekte . . . . .  | 48        |
| 4.4      | Semi-parametrische Methode . . . . .   | 49        |
| 4.4.1    | Der Gauß-Prozess . . . . .   | 52        |
| 4.4.2    | Optimierung der Hyperparameter . . . . .   | 54        |
| 4.4.3    | Approximationsmethoden . . . . .   | 55        |
| 4.5      | Modellierung und Evaluation der Prädiktion . . . . .                             | 57        |
| 4.5.1    | Laterale Dynamik . . . . .   | 57        |
| 4.5.2    | Longitudinale Dynamik . . . . .  | 63        |
| 4.6      | Zusammenfassung . . . . .  | 66        |

---

|          |  |               |
|----------|--|---------------|
| <b>5</b> | <b>Vorhersage der Fahrstreifenrelevanz</b>                           | <b>69</b>     |
| 5.1      | Längsregelung als Anwendungskontext . . . . .                        | 69            |
| 5.2      | Stand der Technik . . . . .  | 69            |
| 5.3      | Analyse der prädizierten Wahrscheinlichkeitsdichtefunktion . . . . . | 70            |
| 5.3.1    | Unimodale Prädiktion . . . . .                                       | 70            |
| 5.3.2    | Multimodale Prädiktion . . . . .                                     | 71            |
| 5.4      | Evaluation der Relevanzerkennung . . . . .                           | 74            |
| 5.5      | Zusammenfassung . . . . .  | 78            |
| <b>6</b> | <b>Diskussion und Ausblick</b>                                       | <b>79</b>     |
| <b>A</b> | <b>Anhang</b>  | <b>81</b>     |
| A.1      | Koordinatentransformationen . . . . .                                | 81            |
| A.1.1    | Transformation der Sensorkoordinaten . . . . .                       | 81            |
| A.1.2    | Rücktransformation entkrümmter Koordinaten . . . . .                 | 86            |
| A.2      | Rekursive bayessche Zustandsschätzung . . . . .                      | 87            |
| A.2.1    | Das Kalman Filter . . . . .  | 88            |
| A.2.2    | Das Unscented Kalman Filter . . . . .                                | 89            |
| A.2.3    | Das Partikel Filter . . . . .  | 91            |
|          | <b>Literaturverzeichnis</b>  | <b>XXVII</b>  |
|          | <b>Publikationen</b>   | <b>XXIX</b>   |
|          | <b>Patente</b>   | <b>XXXI</b>   |
|          | <b>Betreute studentische Arbeiten</b>                                | <b>XXXIII</b> |



# Abbildungsverzeichnis

|     |   |    |
|-----|---|----|
| 2.1 | Sensorkonfiguration der Fahrzeuge. . . . .  | 5  |
| 2.2 | Datenfluss von der Erhebung der Bus-Daten im einzelnen Fahrzeug bis zur Bereitstellung für den Anwender. . . . .  | 7  |
| 2.3 | Prozessschritte zur Darstellung der Daten im UFM. . . . .   | 9  |
| 2.4 | (a) Detektion eines weiteren Fahrzeugs (grün) im Umfeld des Ego-Fahrzeugs, beschrieben im Sensorkoordinatensystem $S$ . (b) Beschreibung der selben Situation im Frenet-System $F$ auf Grundlage der Straßengeometrie. Die Mitte des Ego-Fahrstreifen wird dabei als Referenzkurve verwendet. . . . . | 10 |
| 3.1 | Ableitung der Fahrsituation aus der Fahrszene durch einen Prozess der Informationsauswahl und Verknüpfung verschiedener Fahrsituationen durch Fahrmanöver. . . . .  | 14 |
| 3.2 | FSW nach links. . . . .   | 16 |
| 3.3 | Einscheren von rechts. . . . .  | 17 |
| 3.4 | Architekturdiagramm für die automatisierte Indexierung der Szenariendatenbank. . . . .  | 18 |
| 3.5 | Definition der verwendeten Merkmale aus dem UFM zur Klassifikation der Fahrmanöver. . . . .   | 19 |
| 3.6 | Klassifikation von Folgefahrt und freier Fahrt. . . . .   | 23 |
| 3.7 | Parameteroptimierung für die Klassifikation von Folgefahrt und freier Fahrt. (a) AUC über Anzahl der Merkmale $m$ für unterschiedliche Baumtiefen, beschränkt durch $N_{\min}$ . (b) AUC über Gesamtanzahl der Knoten im Ensemble bei unterschiedlichen Ensemblegrößen mit $B$ Bäumen. . . . .        | 24 |
| 3.8 | Normierte Zunahme des Klassifikationsfehlers bei permutiertem Merkmal für die Erkennung einer Folgefahrt. . . . .   | 26 |
| 3.9 | (a) ROC-Kurve und (b) MCC über Entscheidungswert $\eta$ für die Klassifikation von Folgefahrten. . . . .  | 27 |

|      |   |    |
|------|---|----|
| 3.10 | Zweistufige Klassifikation von FSW. . . . .   | 28 |
| 3.11 | Parameteroptimierung für die Klassifikation von FSW. (a) AUC über Anzahl der Merkmale $m$ für unterschiedliche Baumtiefen, beschränkt durch $N_{\min}$ . (b) AUC über Gesamtanzahl der Knoten im Ensemble bei unterschiedlichen Ensemblegrößen mit $B$ Bäumen. . . . .  | 29 |
| 3.12 | Normierte Zunahme des Klassifikationsfehlers bei permutiertem Merkmal für die Erkennung von FSW. . . . .  | 30 |
| 3.13 | (a) ROC und (b) MCC über Entscheidungswert $\eta$ für die Klassifikation von FSW. . . . .   | 30 |
| 3.14 | Wahrscheinlichkeit für FSW $P(\text{FSW})$ auf Basis der Klassifikation für den gewählten Entscheidungswert $\eta = 0,33$ . . . . .   | 31 |
| 3.15 | (a) ROC-Kurve und (b) MCC über Entscheidungswert $\eta$ für die Klassifikation, ob der Fahrstreifen nach links oder rechts gewechselt wird. . . . .   | 32 |
| 3.16 | Zweistufige Klassifikation von Einscherern. . . . .   | 33 |
| 3.17 | Parameteroptimierung für die Klassifikation von Einscherern. (a) AUC über Anzahl der Merkmale $m$ für unterschiedliche Baumtiefen, beschränkt durch $N_{\min}$ . (b) AUC über Gesamtanzahl der Knoten im Ensemble bei unterschiedlichen Ensemblegrößen mit $B$ Bäumen. . . . .  | 34 |
| 3.18 | Normierte Zunahme des Klassifikationsfehlers bei permutiertem Merkmal für die Erkennung von Einscherern. . . . .  | 35 |
| 3.19 | (a) ROC-Kurve und (b) MCC über Entscheidungswert $\eta$ für die Klassifikation von Einscherern. . . . .   | 36 |
| 3.20 | Wahrscheinlichkeit für das Einscheren $P(E)$ auf Basis der Klassifikation für den gewählten Entscheidungswert $\eta = 0,10$ . . . . .   | 36 |
| 3.21 | (a) ROC-Kurve und (b) MCC über Entscheidungswert $\eta$ für die Klassifikation, ob von links oder rechts eingeschert wird. . . . .  | 37 |
| 3.22 | Zustandsgraph des HMM für FSW mit den Transitionen $\mathbf{T}$ und Evidenzen $\mathbf{E}_t$ , welche für einen Zustand zum Zeitpunkt $t$ vom Klassifikator ausgegeben werden. . . . .  | 38 |
| 3.23 | Glättung der Klassifikation von FSW nach links. (a) zeigt die Grundwahrheit, (b) die ursprüngliche Ausgabe des Klassifikators sowie (c) die geglättete Klassifikation. Gestrichelte Linien geben die Wahrscheinlichkeit $P$ für die Manöverklasse an. Wenn $P \geq 50\%$ ist, wird für den Vergleich mit der Grundwahrheit die Klassifikation als zutreffend angenommen (durchgezogene Linien). . . . . | 40 |
| 4.1  | Architektur der Umfeldprädiktion: Das Verhalten jedes Fahrzeugs wird durch das Systemmodell festgelegt. Vor jedem Prädiktionsschritt werden relevante Informationen über die Fahrzeuge in der Szene ausgetauscht. . . . .   | 44 |
| 4.2  | Parametrisches Fahrzeugmodell mit linearem Systemmodell $\mathbf{F}$ , nicht-linearem Messmodell $\mathbf{h}$ sowie der Kalmanverstärkung $\mathbf{K}$ . . . . .  | 45 |

|      |  |    |
|------|--|----|
| 4.3  | Das semi-parametrische Systemmodell setzt sich aus dem parametrischen Anteil $\mathbf{F}$ und der nicht-parametrischen Funktion $\mathbf{f}$ zusammen. | 50 |
| 4.4  | GP Approximation.  | 55 |
| 4.5  | FITC: Alle latenten Trainings- und Testfunktionen sind bedingt unabhängig bei gegebenem $\mathbf{u}$ .   | 56 |
| 4.6  | Beschreibung der Testfahrt.  | 58 |
| 4.7  | Verdichtung des Merkmalraumes durch Projektion $\mathbf{circ}(y)$ der lateralen Position in den Einheitskreis.   | 59 |
| 4.8  | GP für die Korrektur des lateralen CV Priors.  | 60 |
| 4.9  | Prädiktionsfehler der lateralen Dynamik.   | 62 |
| 4.10 | GP für die Korrektur des longitudinalen CA Priors.   | 64 |
| 4.11 | Prädiktionsfehler der longitudinalen Dynamik.  | 65 |
| 5.1  | Laterale Position und Zuordnung des aktuell relevanten Fahrstreifens für vier FSW nach links.  | 71 |
| 5.2  | Prädizierte Wahrscheinlichkeitsdichte des UKF für vier FSW-Manöver nach links über $0\text{ s} < t_+ \leq 15\text{ s}$ .                               | 72 |
| 5.3  | Prädizierte Wahrscheinlichkeitsdichte des PF für vier FSW-Manöver nach links über $0\text{ s} < t_+ \leq 15\text{ s}$ .                                | 73 |
| 5.4  | Darstellung der Binomialkoeffizienten im Pascalschen Dreieck.  | 75 |
| 5.5  | Prädiktion eines FSW nach links ( $t_+ = 15\text{ s}$ ).   | 76 |
| 5.6  | Auswertung der Fahrstreifenwechsel (FSW)-Prädiktion bei 3,50 m Fahrstreifenbreite.   | 78 |
| A.1  | Zusammenhang zwischen Beobachtung im $S$ - und $E$ -System.  | 81 |
| A.2  | Transformation von der Absolutposition des Ego-Fahrzeugs im erdfesten $E$ -System ins krümmungszentrierte $C$ -System.                                 | 83 |
| A.3  | Umrechnung der kartesischen Koordinaten des $C$ -Systems ins Polarsystem $P$ .   | 84 |
| A.4  | Transformation der Polarkoordinaten des $P$ -Systems ins entkrümmte Bezugssystem $F$ .   | 85 |
| A.5  | Zeitliche Entwicklung eines Hidden Markov Model (HMM).   | 87 |





# Tabellenverzeichnis

|     |  |    |
|-----|--|----|
| 3.1 | Verteilung der Klassen im Datensatz. . . . .   | 18 |
| 3.2 | Konfusionsmatrix. . . . .  | 22 |
| 3.3 | Kenngößen zur Bewertung von Klassifikatoren. . . . .   | 23 |
| 3.4 | Bewertung der Klassifikation zur Detektion von Folgefahrern als fahrstreifengebundene Fahrsituation für $\eta = 0,50$ . . . . .  | 27 |
| 3.5 | Konfusionsmatrix für FSW für den Entscheidungswert $\eta = 0,33$ . In Klammern ist die Veränderung der Prozentpunkte gegenüber $\eta = 0,50$ angegeben (vorteilhaft grün, nachteilig rot). . . . .   | 28 |
| 3.6 | Bewertung der Klassifikation für FSW. . . . .  | 31 |
| 3.7 | Konfusionsmatrix für das Einscheren ( $\eta = 0,10$ ). . . . .   | 35 |
| 3.8 | Bewertung der Klassifikation für Einscherer. . . . .   | 36 |
| 3.9 | Konfusionsmatrix für die FSW-Manöver nach der Glättung. In Klammern sind die Änderungen in Prozentpunkten gegenüber einer Klassifikation ohne Glättung angegeben (vorteilhaft grün, nachteilig rot). . . . .   | 39 |
| 4.1 | Messunsicherheiten der Objektpositionen $(\sigma_x, \sigma_y)$ , Inertialsensorik für die Dynamik des Ego-Fahrzeugs $(\sigma_v, \sigma_a, \sigma_{\dot{\varphi}})$ und Straßentopologie auf Basis der Kamera $(\sigma_c, \sigma_l, \sigma_\alpha)$ . . . . . | 48 |
| 5.1 | Auswertung der FSW-Prädiktion. . . . .   | 77 |
| A.1 | Odometriedaten des Ego-Fahrzeugs. . . . .  | 82 |
| A.2 | Parameter zur Beschreibung der Straßentopologie. . . . .   | 83 |
| A.3 | Lineare Operatoren des dynamischen Systems . . . . .   | 88 |



# Symbolverzeichnis

## Abkürzungen

|      |  |
|------|--|
| ACC  | Genauigkeit                            |
| API  | Application Programming Interface      |
| AUC  | Area Under Curve                       |
| BLOB | Binary Large Object                    |
| CA   | Constant Acceleration                  |
| CAN  | Controller Area Network                |
| CART | Classification and Decision Trees      |
| CP   | Constant Position                      |
| CTRA | Constant Turn Rate and Acceleration    |
| CTRV | Constant Turn Rate and Velocity        |
| CV   | Constant Velocity                      |
| DTC  | Deterministic Training Conditional     |
| EKF  | Extended Kalman Filter                 |
| F1   | F1-Maß                                 |
| FAS  | Fahrerassistenzsysteme                 |
| FITC | Fully Independent Training Conditional |
| FN   | False Negative                         |
| FOT  | Field Operational Tests                |
| FP   | False Positive                         |
| FSW  | Fahrstreifenwechsel                    |
| GDI  | Gini Diversitätsindex                  |

|         |  |
|---------|--|
| GLONASS | Global Navigation Satellite System     |
| GMM     | Gaussian Mixture Model                 |
| GNSS    | Globales Navigationssatellitensystem   |
| GP      | Gauß-Prozess                           |
| GPB     | Google Protocol Buffer                 |
| GPS     | Global Positioning System              |
| HAF     | hochautomatisiertes Fahren             |
| HMM     | Hidden Markov Model                    |
| IP      | Internet Protocol                      |
| IT      | Informationstechnologie                |
| JSON    | JavaScript Object Notation             |
| KF      | Kalman Filter                          |
| MCC     | Matthews Correlation Coefficient       |
| OOB     | Out-Of-Bag                             |
| PF      | Partikel Filter                        |
| PKW     | Personenkraftwagen                     |
| PLV     | Projected Latent Variables             |
| PPV     | Präzision                              |
| REST    | Representational State Transfer        |
| RF      | Random Forest                          |
| RMS     | Effektivwert                           |
| ROC     | Receiver-Operating-Characteristic      |
| SMC     | Sequenzielle Monte-Carlo Methode       |
| SPGP    | Sparse Pseudo-input Gaussian Processes |
| SVM     | Support Vector Machine                 |
| THW     | Time Headway                           |
| TN      | True Negative                          |
| TNR     | Spezifität                             |
| TOR     | Übernahmeaufforderung                  |

---

|        |                            |
|--------|----------------------------|
| TP     | True Positive              |
| TPR    | Sensitivität               |
| UFM    | Umfeldmodell               |
| UKF    | Unscented Kalman Filter    |
| UT     | Unscented Transformation   |
| VAF    | vollautomatisiertes Fahren |
| WGS-84 | World Geodetic System 1984 |
| XML    | Extensible Markup Language |

### Notation

|          |                     |               |
|----------|---------------------|---------------|
| Skalare  | kursiv              | $x, X$        |
| Vektoren | klein, fett, kursiv | $\mathbf{x}$  |
| Matrizen | groß, fett, kursiv  | $\mathbf{X}$  |
| Mengen   | groß, kalligrafisch | $\mathcal{X}$ |

### Sub- und Superskripte

Die Sub- und Superskripte, welche im Rahmen dieser Arbeit verwendet werden, dienen zur Unterscheidung von Variablen gleichen Typs. Dabei werden i. d. R. Bezeichner für die allgemeine Unterscheidbarkeit als Subskripte rechts neben die Variablen geschrieben – insbesondere für den jeweiligen Zeitschritt. Ist eine weitere Unterscheidung nötig, wird ein Superskript rechts ergänzt. Um eine Verwechslung mit dem Potenzieren einer Variablen zu verhindern, wird dieses Superskript in Klammern gesetzt. Wird im Rahmen von Koordinatentransformationen ein Subskript links neben einer Variablen verwendet, gibt dieses an, in welchem Koordinatensystem die jeweilige Variable angegeben ist.

## Operatoren, Funktionen und Definitionen

|  |   |
|--|---|
| $ x ,  \mathbf{X} ,  \mathcal{X} $                         | Betrag von $x$ , Determinante von $\mathbf{X}$ oder Mächtigkeit bzw. Anzahl der Elemente von $\mathcal{X}$  |
| $\mathbf{x} \times \mathbf{y}$                             | Kreuzprodukt von $\mathbf{x}$ und $\mathbf{y}$  |
| $\mathbf{X}^\top, \mathbf{X}^{-1}$                         | Transponierte oder Inverse von $\mathbf{X}$   |
| $\text{tr}(\mathbf{X}), \text{diag}(\mathbf{X})$           | Spur oder Diagonale von $\mathbf{X}$  |
| $\mathbf{x} \circ \mathbf{y}, \mathbf{X} \circ \mathbf{Y}$ | elementweise Multiplikation von Vektoren oder Matrizen  |
| $\text{sgn}(x)$  | Signumfunktion von $x$  |
| $\ln(x)$   | Natürlicher Logarithmus von $x$   |
| $E(x), E(\mathbf{X})$                                      | Erwartungswert von $x$ oder $\mathbf{X}$  |
| $\text{var}(x)$  | Varianz von $x$   |
| $\text{cov}(x_i, x_j)$                                     | Kovarianz von $x_i$ und $x_j$   |
| $\text{cor}(x_i, x_j)$                                     | Korrelation von $x_i$ und $x_j$   |
| $\mathbf{I}$   | Einheitsmatrix  |
| $P(A B)$   | Wahrscheinlichkeit des Ereignis $A$ gegeben das Ereignis $B$  |
| $p(x), p(\mathbf{x})$                                      | Wahrscheinlichkeitsdichtefunktion über $x$ (univariat) oder $\mathbf{x}$ (multivariat)                      |
| $z^{-1}(\mathbf{x}_k)$                                     | Verzögerung des Zustandsvektors $\mathbf{x}_k$ um einen Zeitschritt   |
| $\mathbf{x}^{(i)}$   | $i$ -ter Sigma-Punkt bzw. Partikel zur Repräsentation einer multivariaten Wahrscheinlichkeitsdichtefunktion |

# Kapitel 1

## Einleitung

Die Entwicklung selbstfahrender Fahrzeuge, das hochautomatisierte (HAF) bzw. vollautomatisierte Fahren (VAF), gewinnt immer weiter an Schwung. HAF stellt eine große Innovation für die Automobilhersteller dar. Die Erforschung und Umsetzung dieser Technologie hat das Potential, große Veränderungen der alltäglichen Mobilität und in der Gesellschaft als Ganzes hervorzurufen. Auch ermöglicht es den Herstellern selbst sowie neuen Mitbewerbern im Automobilssektor wie Tesla Motors ganz neue Geschäftsfelder zu erschließen. Insbesondere auch Unternehmen aus dem Silicon Valley wie das Google Driverless Car Projekt, Uber und Apple investieren hohe Summen und Ressourcen in diese Technologie.

Für den Gesetzgeber spielt bei dieser Technologie v. a. die weitere Reduzierung der Verkehrstoten eine Rolle: Die Zahl der Verkehrstoten auf deutschen Straßen ist vom historischen Tiefstand im Jahr 2013 mit 3339 Toten in den Jahren 2014 und 2015 mit 3377 respektive 3495 Toten wieder leicht angestiegen [1, 2]. Im Rahmen eines Verkehrssicherheitsprogramms des Bundesministeriums für Verkehr und digitale Infrastruktur werden seit 2011 Maßnahmen identifiziert und durchgeführt, die zur Verbesserung der Verkehrssicherheit beitragen. Neben den Rahmenbedingungen, der europäischen Einordnung [3], Aufklärungs-, Informations- sowie Infrastrukturmaßnahmen wird als Aktionsfeld u. a. die Fahrzeugtechnik genannt, damit die Anzahl der Getöteten im Straßenverkehr bis 2020 um weitere 40 % sinkt.

Auf diesem Feld liefern Fahrerassistenzsysteme (FAS) bereits heute einen Beitrag zur Verkehrssicherheit. In Situationen, in denen der Fahrer potentiell überfordert ist, wird er mit der Ausgabe einer Warnung frühzeitig auf potentielle Gefahren hingewiesen oder es werden mit einem Eingriff in die Fahrdynamik durch ein Notbrems- oder Ausweichmanöver Kollisionen vermieden bzw. deren Folgen gemindert. Ein Notbremsassistent ist laut Verordnung der Europäischen Union für Neufahrzeuge seit November 2015 verpflichtend vorgeschrieben [4]. Selbst nach dem Aufprall vermindern aktive Systeme wie bspw. eine aktive Motorhaube noch die Unfallfolgeschäden für Fußgänger.

Bei genauerer Betrachtung der Ursachen für 302 435 Unfälle mit Personenschaden in Deutschland im Jahr 2014 wird deutlich, dass in 68,3 % der Fälle der Fahrer eines Personenkraftwagens (PKW) als Hauptverursacher festgestellt wurde [1]. Um dennoch der propagierten *Vision Zero – Null Verkehrstote* [5] zu folgen, wird in For-

schungsprojekten wie *AdaptIVE* [6] und *Ko-HAF* [7] das selbstfahrende Fahrzeug erforscht, um den Fahrer weitgehend von der aktiven Fahrzeugführung und Kontrollaufgabe zu entlasten. Das HAF bzw. VAF wird hier sicher einen Beitrag für die Verkehrssicherheit leisten.

Zudem rücken auch Fahrsituationen wie Staus und ausgedehnte Autobahnfahrten in den Fokus, bei denen der Fahrer eher unterfordert ist, sich gerne aus der Fahraufgabe zurückziehen und mit anderen Tätigkeiten beschäftigen möchte. Unter diesem Aspekt wird auch der Fahrkomfort durch HAF bzw. VAF enorm gesteigert. Verschwendete der durchschnittliche Autofahrer in Deutschlands staugeplagtester Stadt, Stuttgart, 2015 im Mittel 73 h zusätzlich im Stau [8], so sind es in Europas Stauhauptstadt, London, bereits 101 h [9].

So lässt sich auch anschaulich die Motivation der IT-Unternehmen erklären, in Technologien für das selbstfahrende Auto zu investieren: Die Zeit, welche viele Pendler hinter dem Steuer ihres Fahrzeugs verbringen, steht für diese Unternehmen momentan nur sehr begrenzt für die Interaktion mit ihren Kunden zur Verfügung. Ist das Fahrzeug nun in der Lage selbstständig ans Ziel zu navigieren, wird diese Zeit frei und für die angebotenen Dienstleistungen nutzbar.

Diese Arbeit ist im Rahmen der Forschung und Entwicklung selbstfahrender Fahrzeuge entstanden und trägt dazu bei, diese Technologie auf der Straße Realität werden zu lassen. Im Folgenden wird die zentrale Problemstellung dieser Arbeit ausgeführt. Im Anschluss daran wird der wissenschaftliche Neuwert gegenüber den vorhandenen Lösungen ausgewiesen und der Aufbau der Arbeit erläutert.

## 1.1 Problemstellung

Damit komplexe Szenarien vom Fahrer mit Hilfe zukünftiger FAS oder insbesondere bei HAF und VAF vom Fahrzeug selbst gemeistert werden, stellt die exakte Vorhersage des Verhaltens anderer Verkehrsteilnehmer eine wesentliche Herausforderung dar. Die Kenntnis über zukünftige Aufenthaltsorte und damit letztlich über die Trajektorien anderer Verkehrsteilnehmer ermöglicht es warnenden wie auch aktiv in die Fahrdynamik eingreifenden Systemen, rechtzeitig und situativ angepasst zu reagieren.

Um mit einer erweiterten Vorausschau zukünftige FAS zu befähigen, sollen daher verbesserte Prädiktionsmodelle für Fahrzeugtrajektorien entwickelt werden. Dafür sollen Datensätze seriennaher Fahrzeugflotten erhoben werden, um den Aufwand der Datengenerierung zu begrenzen und in kurzer Zeit aktuelle Datensätze für die Entwicklung zur Verfügung stellen zu können. Zudem muss die bereitgestellte Lösung eine generische Architektur besitzen, um auch auf neue, komplexe Szenarien mit vertretbarem Aufwand angepasst werden zu können.

Für die Entwicklung und Bewertung der Prädiktionsmodelle muss zudem eine Methode entwickelt werden, die es ermöglicht, definierte Fahrsituationen und -manöver in Datensätzen zuverlässig auszuweisen respektive wiederzuerkennen. Für einen effektiven Zugriff müssen die angesprochenen Datensätze in der Datenbank identifiziert und indexiert, d. h. mit einer entsprechenden Kennzeichnung versehen, werden.



## 1.2 Wissenschaftlicher Neuwert

Um die genannten Herausforderungen einer Lösung zuzuführen, besteht der wissenschaftliche Neuwert dieser Arbeit insbesondere aus nachfolgend genannten Punkten:

1. Entwicklung einer datengetriebenen Klassifikation zeitlich ausgedehnter Fahr-situationen und -manöver auf Basis seriennaher Datensequenzen aus einer Fahrzeugflotte.
2. Entwicklung von semi-parametrischen Modellen zur probabilistischen Prädik-tion der Längs- und Querdynamik von Fahrzeugen auf Straßen mit mehrstrei-figen Richtungsfahrbahnen unter Berücksichtigung von Kontextinformationen.
3. Entwicklung einer Methode zur Vorhersage der Fahrstreifenrelevanz auf Grund-lage des semi-parametrischen Querdynamikmodells.

Zusätzlich zu den explizit aufgeführten Punkten wurden im Verlauf dieser Arbeit mehrere Konferenzbeiträge und Veröffentlichungen verfasst sowie Patente angemel-det und erteilt.

## 1.3 Struktur der Arbeit

Die sich anschließenden Kapitel der Arbeit gliedern sich wie folgt: Kapitel 2 gibt einen Überblick über die Daten, welche die Grundlage dieser Arbeit darstellen und erläutert das Konzept des entkrümmten, kurvilinearen Umfeldmodells (UFM) und die dafür nötige Transformation. In Kapitel 3 wird die entwickelte Methode zur datengetriebenen Klassifikation für relevante Fahrsituationen und -manöver vorge-stellt, um anschließend in Kapitel 4 semi-parametrische Modelle zur Trajektorien-prädiktion von Verkehrsteilnehmern für die Längs- und Querdynamik zu entwickeln. Im darauf folgenden Kapitel 5 wird aufgrund der entwickelten Modelle gezeigt, wie frühzeitig der zukünftig relevante Fahrstreifen eines Verkehrsteilnehmers vorherge-sagt wird. Letztlich geht Kapitel 6 nochmals zusammenfassend auf die wesentlichen Punkte dieser Arbeit ein und gibt einen Ausblick auf zukünftige Forschungsfelder.



# Aggregation von Daten aus Fahrzeugflotten

Im Rahmen dieser Arbeit werden Daten aus einer Flotte von Serienfahrzeugen aggregiert, um auf Basis dieser Daten Analysen und Entwicklungen durchzuführen. Durch die Verwendung seriennaher Fahrzeugdaten soll der Nutzen und das Potential bisher vorhandener Daten von aktuell im Markt verfügbaren Lösungen veranschaulicht werden.

## 2.1 Datenerhebung aus Fahrzeugflotten

Um die Daten für die geplanten Entwicklungsumfänge zu erheben, wird im Folgenden auf die Datengrundlage, Kommunikation im Fahrzeug und Datenspeicherung eingegangen.

### 2.1.1 Fahrzeugsensorik



Abbildung 2.1: Sensorkonfiguration der Fahrzeuge.

In Abbildung 2.1 ist die Sensorkonfiguration gezeigt, wie sie in heutigen Serienfahrzeugen bereits verfügbar ist. Dabei ist die Grafik auf die in dieser Arbeit verwendeten Informationsquellen beschränkt. Hauptsächlich werden die perzeptiven Sensorsysteme – Kamera und Radar – zur Umfelderkennung verwendet.

Der Radar bildet in aktuellen Serienfahrzeugen die Grundlage, um während der Fahrt Position, Geschwindigkeit und Abmaße anderer Verkehrsteilnehmer zuverlässig in bis zu 150 m Entfernung wahrzunehmen. Neben der Objektfusion von radar- und kamerabasierter Wahrnehmung, liefert die Kamera zudem Informationen über die Beschaffenheit der Straße: Fahrstreifenmarkierungen werden erkannt und klassifiziert. Zusätzlich werden der Krümmungsverlauf der Straße und die Orientierung des Fahrzeugs im Fahrstreifen geschätzt.

Prinzipiell gibt es noch weitere Sensortypen zur Umfeldwahrnehmung, wie bspw. Ultraschallsensoren oder Laserscanner, die mit anderen physikalischen Messprinzipien arbeiten. Ultraschallsensorik besitzt ihren hauptsächlichen Anwendungsbereich bei Park- und Parkierfunktionen. Laserscanner werden bereits zu Forschungszwecken in Fahrzeugen eingesetzt und besitzen aufgrund ihres Messprinzips eine hohe Positionsauflösung und -messgüte. Der erste Einsatz in einem Serienfahrzeug ist mit dem Audi A8 (D5) ab 2017 geplant.

Für die bessere Bestimmung von Position und Orientierung werden zusätzlich Odometriedaten ausgewertet. Anhand der verbauten Odometrie- und Inertialsensorik misst das Fahrzeug seinen eigenen Zustand. Diese Daten werden für die Koppelnavigation verwendet.

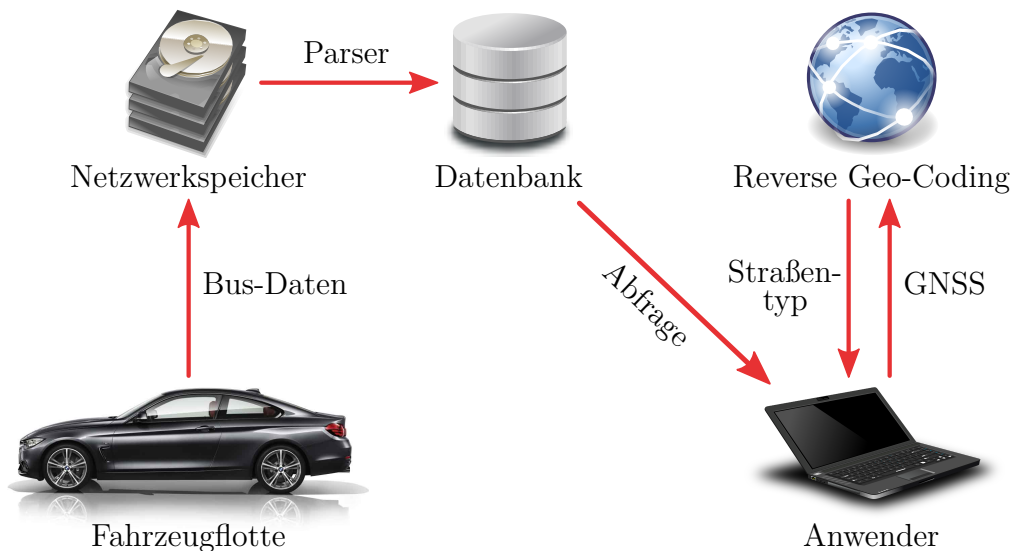
Globale Navigationssatellitensysteme (GNSS) wie bspw. das Global Positioning System (GPS) der Vereinigten Staaten von Amerika, das *Galileo*-System der Europäischen Union oder das Global Navigation Satellite System (GLONASS) der Russischen Föderation, stellen Daten zur Verfügung, welche die globale, dreidimensionale Position eines Fahrzeugs auf Basis bspw. des Referenzellipsoides des World Geodetic System 1984 (WGS-84) beschreiben. Die globale Fahrzeugposition wird für die Bestimmung des befahrenen Straßentyps verwendet. Für weitergehende Fragestellungen in dieser Arbeit besitzt diese jedoch keine Relevanz, da GNSS-Messungen in aktuellen Serienfahrzeugen Ungenauigkeiten von mehreren Metern aufweisen.

### 2.1.2 Extraktion der Fahrzeugdaten

Als Datengrundlage für die Entwicklungen dieser Arbeit werden Daten einer Flotte bestehend aus Serienfahrzeugen verwendet. Mit sogenannten Field Operational Tests (FOT) werden große Mengen Flottendaten akquiriert, um für spezielle Fragestellungen, z. B. für die Entwicklung und Absicherung von FAS, eine Datengrundlage für Analysen zur Verfügung zu stellen. Im Folgenden wird ein Abriss über die Infrastrukturmaßnahmen gegeben, welche nötig waren, um die relevanten Datensätze persistent und einfach zugänglich zur Verfügung zu stellen. Abbildung 2.2 gibt einen Überblick über die Prozessschritte, angefangen von der Datenerhebung im Fahrzeug bis zur Bereitstellung für den Anwender.

#### Controller Area Network Bus

Die Kommunikation im Fahrzeug läuft vorrangig über Bussysteme, auf welchen Sensoren und Steuergeräte Informationen bereitstellen. Bei einer Versuchsflotte werden während der Fahrt ausgewählte Datenbusse mitgelesen. Bevorzugt werden Nachrichtenpakete vom Controller Area Network (CAN) aufgezeichnet. Das CAN ist ein serielles Bussystem, das 1983 von Bosch entwickelt und als ISO 11898 international



**Abbildung 2.2:** Datenfluss von der Erhebung der Bus-Daten im einzelnen Fahrzeug bis zur Bereitstellung für den Anwender.

standardisiert wurde. Es dient der Vernetzung der Steuergeräte im Fahrzeug. Nachrichten werden auf dem CAN-Bus nicht über eine Zieladresse, wie z. B. beim Internet Protocol (IP), sondern über einen eindeutigen Nachrichten-Identifizierer gekennzeichnet. Damit wird ein Broadcast-Verfahren realisiert: Von den Steuergeräten werden Nachrichten auf die jeweiligen Bussysteme des Fahrzeugs gelegt. Ein Empfänger entscheidet dann selbst, welche Nachrichten für ihn interessant sind und welche er ignoriert.

Nach Fahrtabschluss werden die Aufzeichnungen automatisiert auf einem Netzwerkspeicher abgelegt. Die Dateien auf dem Netzwerkspeicher sind aufgrund der Datenformate, der systembedingten Unterteilung der Fahrten in mehrere Teildatensätze und der begrenzten Vorhaltdauer auf dem Speicher für die Nutzung zu Analyse- und Entwicklungszwecken nur bedingt geeignet. Daher wird eine Datenbank aufgesetzt, um die Daten dauerhaft und einfach zugänglich zu machen.

### 2.1.3 Bereitstellung in der Datenbank

Anhand eines speziell für diese Daten entwickelten Parsers wird das Netzlaufwerk in regelmäßigen Intervallen auf neue Datensätze überprüft und ausgewählte, neu hinzugekommene Nachrichtensignale automatisiert in die Datenbank übertragen. Zusätzlich werden die Datensätze mit Metainformationen angereichert, wie bspw. der GNSS-Position.

#### Google Protocol Buffer

Um flexibel auf potentielle Änderungen der CAN-Nachrichtendefinitionen reagieren zu können, werden die Signale nicht direkt in die Datenbank geschrieben, sondern das von Google entwickelte, plattformunabhängige Dateiformat Google Protocol Buffer (GPB) verwendet. Es wurde 2008 veröffentlicht und wird zur Serialisierung strukturierter Daten genutzt. Die asynchron empfangenen Nachrichten vom CAN-Bus werden sekundlich zusammengefasst und mit Hilfe der GPB-Bibliothek

zu einem Bitstrom bzw. Binary Large Object (BLOB) umgewandelt. Diese Konvertierung gewährleistet Datensparsamkeit und ist unter gewissen Randbedingungen sowohl auf- als auch abwärtskompatibel.

Der BLOB wird dann mit den Positionskordinaten des GNSS in der Datenbank georeferenziert abgelegt. Durch den generische Ansatz, die Nutzdaten als BLOB in die Datenbank zu schreiben und damit die Datenbankstruktur unabhängig von den Änderungen der GPB-Nachrichtendefinition zu gestalten, wurde für den Entwicklungszeitraum eine hohe Flexibilität sichergestellt.

### Reverse Geo-Coding

Da im Rahmen dieser Arbeit v. a. Fahrscenen auf mehrstreifigen Richtungsfahrbahnen betrachtet werden, wird jeder BLOB in einem Vorverarbeitungsschritt auf dieses Kriterium hin gefiltert. Da der Straßentyp in den aggregierten Daten nicht vorliegt, wird er nachträglich durch Auswertung der GNSS-Position bestimmt. Dafür wird ein Representational State Transfer (REST) Webservice verwendet [10].

Das verwendete RESTful Application Programming Interface (API) stellt auf Basis des Längen- und Breitengrades mittels des Reverse-Geo-Coding-Verfahrens Informationen über diese GNSS-Position bereit. Auf eine Anfrage antwortet der Webservice mit einem Report wahlweise im JavaScript Object Notation (JSON) oder Extensible Markup Language (XML) Format. Der Report enthält dabei auch ein Element, welches Auskunft über den Straßentyp gibt.

Die Straßentypen, welche den definierten Anforderungen an mehrstreifige Richtungsfahrbahnen genügen, wurden aufgrund von Expertenwissen und zusätzlichen Stichproben festgelegt. Letztlich wird für jeden georeferenzierten BLOB die Straßentypinformation per RESTful API angefragt und mit den zuvor festgelegten, gesuchten Typen verglichen. Bei Übereinstimmung wird dieser BLOB als valide gekennzeichnet und für die weiteren Entwicklungsschritte im Rahmen dieser Arbeit verwendet.

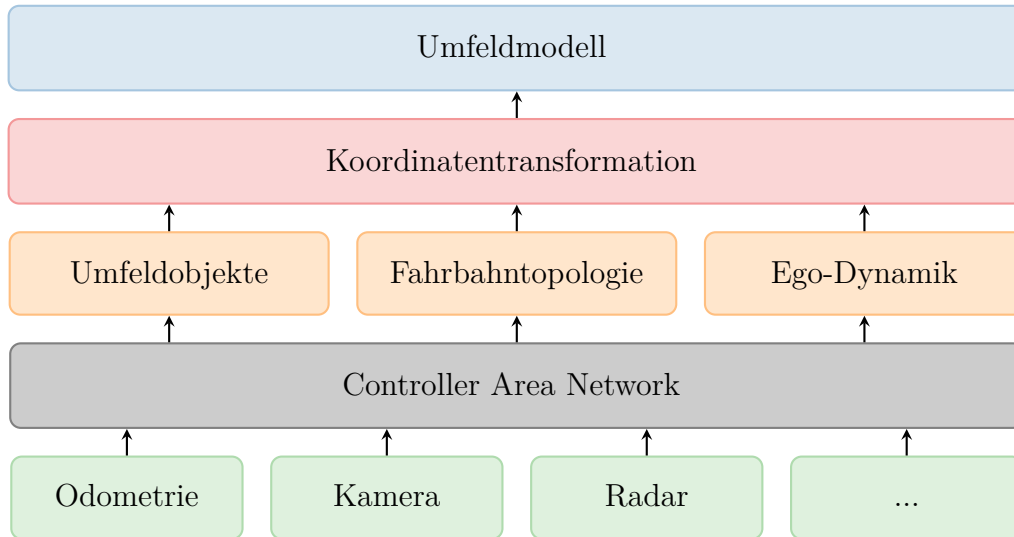
## 2.2 Entkopplung von Funktion und Sensorik

Die Aufgaben, welche von zukünftigen FAS unterstützt oder gar vollständig übernommen werden, nehmen an Komplexität stetig zu. Durch die Verwendung unterschiedlicher Sensorsysteme, verschiedener geometrischer Einbaupositionen derselben und dem i. d. R. unterschiedlichen Informationsbedarf einzelner Fahrerassistenzfunktionen wird eine konsolidierte Beschreibung des Fahrzeugumfelds notwendig [11, 12]: das Umfeldmodell (UFM).

### 2.2.1 Datenrepresentation im Umfeldmodell

Zwischen den einzelnen Sensoren und den Funktionen der FAS wird eine weitere Ebene zur logischen Abstraktion eingeführt. Diese logische Trennung von Funktion- und Sensorebene wird durch das UFM umgesetzt. Zentral für alle nachgelagerten Funktionen werden durch Datenfusion im UFM die Qualität und Verfügbarkeit der einzelnen Signale gesteigert, Fehlerkennungen reduziert und auch neue Informationen generiert, wie bspw. die Klassifikation und Unterscheidung von Umfeldobjekten in unterschiedliche Fahrzeugtypen. Damit beinhaltet es alle wichtigen Informationen

über das Fahrzeugumfeld und die Funktionsentwicklung ist nicht mehr unmittelbar von einzelnen Sensoren abhängig. Insbesondere beschreibt es alle relevanten Informationen der Fahrscene, welche zur Durchführung der Fahraufgabe bzw. Bestimmung der Fahrsituation benötigt werden, wie u. a. die Position, Orientierung und Geschwindigkeit von Umfeldobjekten sowie der Verlauf der Fahrbahnmarkierungen. In Abbildung 2.3 sind die einzelnen Prozessschritte von der Sensormessung bis zur Erstellung des UFM abgebildet, welche im Rahmen dieser Arbeit verwendet werden.



**Abbildung 2.3:** Prozessschritte zur Darstellung der Daten im UFM.

Nach der Messung durch die Sensoren, stehen die Informationen als Nachrichtepakete auf dem CAN-Bus des Fahrzeugs zur Verfügung. Hierbei sind insbesondere detektierte Objekte in der Umgebung des Ego-Fahrzeugs, Informationen über die Fahrbahntopologie sowie die Dynamikdaten des Ego-Fahrzeugs von besonderem Interesse. Durch eine Koordinatentransformation werden im Rahmen dieser Arbeit die Umfeldobjekte in entkrümmten Frenet-Koordinaten dargestellt. Die Straßenkrümmung wird so bei der Umfeldbeschreibung implizit berücksichtigt. Diese Darstellung wird als entkrümmtes UFM bezeichnet. Im Folgenden wird die dafür nötige Transformationsvorschrift definiert.

### 2.2.2 Transformation in Frenet-Koordinaten

Das Ego-Fahrzeug bewegt sich über Grund in einer planen Umgebung. Auch das Umfeld eines Fahrzeuges wird im Rahmen dieser Arbeit in einer Ebene beschrieben. Im Allgemeinen wird daher ein zweidimensionaler Ortsvektor  $\mathbf{r} \in \mathbb{R}^2$  mit seinen beiden Ableitungen, der Geschwindigkeit  $\mathbf{v}$  und Beschleunigung  $\mathbf{a}$ , betrachtet. Zusammen beschreiben sie den Zustand  $\mathbf{x}$  eines Objektes.

$$\mathbf{x} = \begin{bmatrix} \mathbf{r} \\ \mathbf{v} \\ \mathbf{a} \end{bmatrix} = \begin{bmatrix} x \\ y \\ \dot{x} \\ \dot{y} \\ \ddot{x} \\ \ddot{y} \end{bmatrix}. \quad (2.1)$$


Für die Ableitungen des Ortsvektors  $\mathbf{r}$  nach der Zeit in einem sich mit der Winkelgeschwindigkeit  $\boldsymbol{\omega}$  drehenden Koordinatensystem gilt

$$\mathbf{v} = \dot{\mathbf{r}} + \boldsymbol{\omega} \times \mathbf{r} \quad (2.2)$$

$$\mathbf{a} = \dot{\mathbf{v}} + \boldsymbol{\omega} \times \mathbf{v} \quad (2.3)$$

$$= \ddot{\mathbf{r}} + \dot{\boldsymbol{\omega}} \times \mathbf{r} + 2 \boldsymbol{\omega} \times \dot{\mathbf{r}} + \boldsymbol{\omega} \times (\boldsymbol{\omega} \times \mathbf{r}) . \quad (2.4)$$

Anhand der verbauten Sensorik wird bspw. der Positionsvektor  ${}_S\mathbf{r}_b$  eines Objekts  $b$  im Sensorkoordinatensystem  $S$  relativ zum Ego-Fahrzeug detektiert. Für die Notation der Beschreibung des Zustands in einem bestimmten Koordinatensystem wird ein Subskript links neben der Variablen verwendet.



**Abbildung 2.4:** (a) Detektion eines weiteren Fahrzeugs (grün) im Umfeld des Ego-Fahrzeugs, beschrieben im Sensorkoordinatensystem  $S$ . (b) Beschreibung der selben Situation im Frenet-System  $F$  auf Grundlage der Straßengeometrie. Die Mitte des Ego-Fahrfahrbahnen wird dabei als Referenzkurve verwendet.

Betrachtet man in Abbildung 2.4 die Relativposition und Orientierung der dargestellten Fahrzeuge in einer unstrukturierten Umgebung, würde i. d. R. davon ausgegangen werden, dass sich beide auf einer Kollisionstrajektorie befänden und in naher Zukunft mit einem Verkehrsunfall zu rechnen sei. Wird dieselbe Situation im Kontext der vorhandenen Fahrbahnmarkierungen betrachtet, erscheint ein Konflikt wesentlich unwahrscheinlicher, da davon ausgegangen wird, dass beide Fahrer sich entlang ihrer Fahrbahnen bewegen.

Fahrer richten ihre Fahrzeugführung quer zur Fahrbahn an den Fahrbahnmarkierungen aus. Die vorhandenen Fahrbahnmarkierungen, die ebenfalls sensorisch erfasst werden, helfen Fahrern zudem dabei, die Fahrmanöver anderer Verkehrsteilnehmer relativ zur Straße früher zu erkennen und damit deren Absolutbewegungen über Grund zu präzisieren [13].



## Entkrümmte Koordinaten

Dieser Sachverhalt führt dazu, dass im Rahmen der Arbeit die Trajektorien aller Fahrzeuge  ${}_S\mathbf{x}_b = [{}_S\mathbf{r}_b, {}_S\mathbf{v}_b, {}_S\mathbf{a}_b]^\top$ , ursprünglich angegeben im relativen Sensorkoordinatensystem  $S$ , für die Darstellung im UFM umgerechnet und in Frenet-Koordinaten  ${}_F\mathbf{x}_b$  beschrieben werden. Die Referenzkurve für die Transformation  ${}_F\mathbf{x}_b = T_{FS}({}_S\mathbf{x}_b)$  stellt dabei die Mitte des aktuellen Ego-Fahrstreifens dar. Die Kurve ist aus sensorischen Gründen mit einer konstanten Krümmung  $c$  beschrieben und wird daher in der Koordinatentransformation als Kreis mit Radius  $r = \frac{1}{c}$  verwendet. Eine detaillierte Beschreibung der einzelnen Schritte, Annahmen und Rahmenbedingungen der verwendeten Transformation ist im Anhang A.1 angegeben.



## Indexierung einer Datenbank mit Fahrdaten aus Fahrzeugflotten

Im Rahmen dieser Arbeit werden Prädiktionsmodelle für die Längs- und Querdynamik von Fahrzeugen entwickelt. Um relevante Fahrsituationen und -manöver, wie bspw. einen Fahrstreifenwechsel (FSW), einen charakteristischen, zeitlich ausgedehnten Vorgang, zu analysieren, wird im Verlauf dieses Kapitels ein Verfahren zur Indexierung einer Szenarien-Datenbank entwickelt. Dabei soll jeder Dateninstanz zugeordnet werden, ob sie Teil eines zuvor festgelegten Vorgangs ist.

Im Stand der Technik werden dafür bisher sogenannte regelbasierte Ansätze genutzt. Fahrsituationen bzw. Fahrmanöver werden dabei durch empirische Regeln definiert und extrahiert. Regelbasierte Ansätze führen allerdings zu keiner allgemeinen Beschreibung aller möglichen Fahrsituationen. Im Gegenteil, für jedes einzelne, gesuchte Manöver müssen teils sehr komplexe Bedingungen entworfen und implementiert werden, um eine zufriedenstellende Extraktion des Manövers aus einem Datensatz zu ermöglichen. Eine Aussage über die Unsicherheit bei der Auswahl der Szenarien durch diese „Wenn-Dann“-Regeln kann i. d. R. nicht getroffen werden.

Die neu entwickelte Methode basiert daher auf einem überwachten, maschinellen Lernverfahren, das auf Fahrzeugflottendaten angewendet wird. Dadurch lässt sich im Vergleich zu den regelbasierten Ansätzen eine Verallgemeinerung erreichen, sofern eine ausreichend große Menge an Flottendaten zur Verfügung steht. Mit der Bestimmung der Wahrscheinlichkeiten für die Klassenzugehörigkeiten der gesuchten Fahrsituationen bzw. -manöver wird eine Aussage über die Unsicherheit bei der Klassifikation möglich.

Das Kapitel ist dabei wie folgt strukturiert: Zunächst werden die Fahrsituationen und -manöver definiert, welche im Rahmen dieser Arbeit betrachtet werden. Nachdem die Grundlagen der Manöverklassifikation und der verwendeten Architektur dargelegt wurden, werden die Ergebnisse der Klassifikation der einzelnen Dateninstanzen für die ausgewählten Situationen und Manöver vorgestellt. Abschließend werden die zeitlichen Zusammenhänge der gesuchten Sequenzen ausgenutzt und eine Markovkette modelliert. Durch eine Glättung anhand des Markov-Modells wird die Qualität der Klassifikation weiter gesteigert. Dies wird exemplarisch für FSW-Manöver gezeigt.

### 3.1 Definition von Fahrsituationen und -manövern

Im Laufe dieses Abschnitts werden die relevanten Fahrsituationen

- Freie Fahrt
- Folgefahrt

und Manöver

- Fahrstreifenwechsel nach links / rechts
- Einscheren von links / rechts


eingeführt und definiert. Weitere Manöver wie bspw. Einparken oder Abbiegen werden nicht betrachtet.

#### Fahrsituation

In der Literatur gibt es keine Einigkeit über die Situationsdefinition. Eine ausführliche Zusammenstellung der Thematik ist in [14] gegeben. Im Rahmen dieser Arbeit wird im Wesentlichen die Definition aus [15] verwendet. Eine Situation besteht dabei aus einer Untermenge an Information einer gesamten Fahrszene, welche zur Erfüllung der jeweiligen Aufgabe relevant ist. Abhängig von der durchzuführenden Aufgabe können sich aus der gleichen Fahrszene somit unterschiedliche Fahrsituationen ergeben.

#### Fahrmanöver

Ein Fahrmanöver ist als Aktion (oder Reihung mehrerer Aktionen) definiert, welche die aktuelle Fahrsituation in eine neue Fahrsituation (evtl. auch der gleichen Art) überführt. Bspw. ist ein FSW ein Fahrmanöver. Dabei führt der Fahrer nach der Reihe verschiedene Aktionen durch, wie Schulterblick, setzen des Fahrtrichtungsanzeigers, einleiten und durchführen des FSW durch entsprechende Lenkbewegungen. Ein Überblick ist in Abbildung 3.1 gegeben.



**Abbildung 3.1:** Ableitung der Fahrsituation aus der Fahrszene durch einen Prozess der Informationsauswahl und Verknüpfung verschiedener Fahrsituationen durch Fahrmanöver.

### 3.1.1 Fahrstreifengebundene Fahrsituationen

Als die Menge der fahrstreifengebundenen Fahrsituationen  $\mathcal{M}_{\text{FSG}}$  werden die Zustände betrachtet, welche die Situation des Fahrzeugs in seinem Fahrstreifen beschreiben. Ein Fahrer fährt auf der Autobahn in longitudinaler Richtung entweder frei, d. h. es findet keine Beeinflussung durch ein relevantes Vorderfahrzeug statt, oder er folgt einem vorausfahrenden Fahrzeug, welches das Fahrverhalten des Fahrers beeinflusst.

$$\mathcal{M}_{\text{FSG}} = \left\{ \begin{array}{l} \text{Folgefahrt} \\ \text{freie Fahrt} \end{array} \right\} \quad (3.1)$$

Bei der Folgefahrt wird einem vorausfahrenden Fahrzeug gefolgt, wobei sich im eingeschwungenen Zustand die Geschwindigkeiten ungefähr entsprechen [16]. Der Fahrer regelt auf das Zielfahrzeug und hält damit den Zeitabstand  $t_{\text{THW}}$  (engl. „time headway“) relativ konstant.

Fährt das eigene Fahrzeug in seinem Fahrstreifen, kann im Realfall ein Wechsel von freier Fahrt zu Folgefahrt eintreten, wenn sich das eigene Fahrzeug einem vorausfahrenden Fahrzeug annähert und dieses erst in hinreichender Nähe zum eigenen Fahrzeug als relevantes Zielfahrzeug erkannt wird. Entsprechend kann von der Folgefahrt in freies Fahren übergegangen werden, wenn das bisherige Vorderfahrzeug keine Relevanz für das eigene Fahrverhalten mehr besitzt – bspw. auch dadurch, dass es die Sensorreichweite oder den eigenen Fahrstreifen verlässt. Da bei großen Zeitabständen die Beeinflussung des Ego-Fahrzeugs durch das vorausfahrende Fahrzeug als vernachlässigbar angenommen wird, wird die Folgefahrt auf Zeitabstände  $t_{\text{THW}} \leq 3\text{ s}$  beschränkt. Bei größeren Zeitabständen wird im Rahmen dieser Arbeit definitionsgemäß von einer Freifahrt ausgegangen.

### 3.1.2 Fahrstreifenwechsel

Als laterale Manöver des eigenen Fahrzeugs werden FSW nach links bzw. rechts definiert. Da sich ein Fahrzeug nicht ständig in einem FSW-Manöver befindet, wird zur vollständigen Beschreibung der Manövermenge  $\mathcal{M}_{\text{FSW}}$  das komplementäre Ereignis  $\neg\text{FSW}$  ergänzt. Dieses beschreibt, dass aktuell kein FSW durchgeführt wird.

$$\mathcal{M}_{\text{FSW}} = \left\{ \begin{array}{l} \text{Fahrstreifenwechsel nach links} \\ \text{Fahrstreifenwechsel nach rechts} \\ \neg\text{Fahrstreifenwechsel} \end{array} \right\} \quad (3.2)$$

Dabei ist der Beginn eines FSW-Manövers durch den Zeitpunkt definiert, sobald das Fahrzeug die Fahrstreifenmarkierung erreicht, welche die zwei relevanten Fahrstreifen trennt. Es endet, sobald das Fahrzeug sich vollständig auf dem Zielfahrstreifen befindet und die Fahrstreifenmarkierung verlassen hat. In Abbildung 3.2 ist beispielhaft ein FSW nach links dargestellt. Das eigene Fahrzeug wechselt im Intervall  $T_{\text{FSW},l}$  den Fahrstreifen. Dieser zeitlich ausgedehnte Vorgang wird als FSW-Manöver definiert. Am Zeitpunkt  $t_{\text{FSW},l}$  überquert es die Fahrbahnmarkierung. Auf diesen Zeitpunkt wird in Kapitel 5 Bezug genommen.

Ein FSW des eigenen Fahrzeugs ist oft Ursache für einen Wechsel zwischen freier Fahrt und Folgefahrt. Befindet sich auf dem ursprünglichen Fahrstreifen ein zu überholendes Vorderfahrzeug und der Fahrer befindet sich momentan in einer Folgefahrt,




Abbildung 3.2: FSW nach links.

ist dieses Fahrzeug nach einem FSW irrelevant für das longitudinale Fahrverhalten. Auf dem Zielfahrstreifen befindet sich dabei entweder ein neues Vorderfahrzeug, d. h. es findet ein Wechsel des relevanten Objekts statt, oder der Zielfahrstreifen ist frei und damit befindet sich der Fahrer in einer freien Fahrt.

### 3.1.3 Einscheren von Fremdfahrzeugen

Als laterale Manöver von Fremdfahrzeugen sind Einscherer in den Fahrschlauch des eigenen Fahrzeugs von Interesse. Die Menge der möglichen Ereignisse ist definiert mit

$$\mathcal{M}_E = \left\{ \begin{array}{l} \text{Einscheren von links} \\ \text{Einscheren von rechts} \\ \neg\text{Einscheren} \end{array} \right\}. \quad (3.3)$$

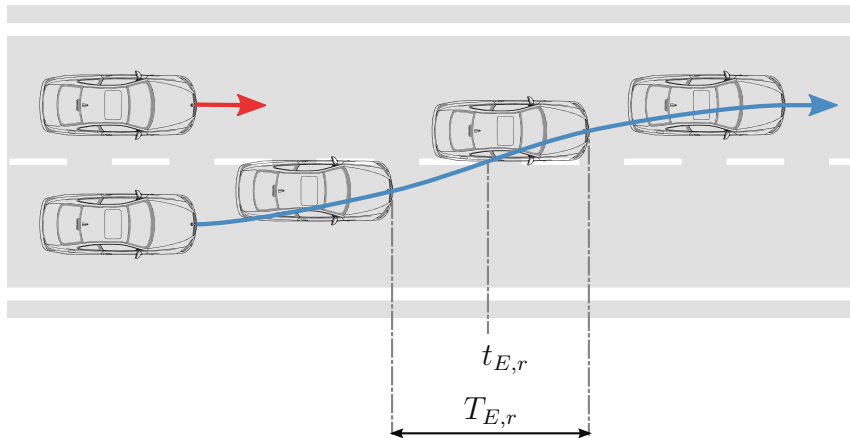
Dabei ist  $\neg$ Einscheren das komplementäre Ereignis, welches anzeigt, dass momentan kein Einschermanöver vorliegt.

Einschermanöver sind so definiert, dass das einscherende Fahrzeug nach dem Einschervorgang das neue Zielfahrzeug für eine Folgefahrt des eigenen Fahrzeugs ist. In Abbildung 3.3 ist beispielhaft ein Einschervorgang von rechts dargestellt. Ein anderes Fahrzeug fährt ursprünglich auf dem rechten Nachbarfahrstreifen. Im Intervall  $T_{E,r}$  wechselt das Fremdfahrzeug auf den Fahrstreifen des eigenen Fahrzeugs und wird das neue Zielfahrzeug. Die Definition des Intervalls  $T_{E,r}$  ist analog zu der eines FSW. Zum Zeitpunkt  $t_{E,r}$  überquert das Fremdfahrzeug dabei die Fahrbahnmarkierung.

Einscherer sind von besonderem Interesse, da sich bei einem solchen Manöver für geschwindigkeitsregelnde FAS plötzlich verringerte Zeitlücken zum relevanten Zielfahrzeug ergeben. Die Zeitlücke ist dabei definiert als Quotient aus Relativabstand zum Zielfahrzeug und der Geschwindigkeit des eigenen Fahrzeugs. Sie ist eine der wichtigsten Regelgrößen für diese Art von Systemen.

## 3.2 Klassifikation von Flottendaten

Zur Erstellung der Szenarien-Datenbank sollen Fahrsituationen und -manöver auf Grundlage von Daten aus einer Fahrzeugflotte automatisiert erkannt werden. Es



**Abbildung 3.3:** Einschernen von rechts.

handelt sich hierbei um ein klassisches Problem des überwachten Lernens, einem Teilgebiet des maschinellen Lernens, um Gesetzmäßigkeiten in den Daten automatisiert zu erkennen. Zunächst wird der Merkmalsvektor jeder Dateninstanz unabhängig klassifiziert, bevor in Kapitel 3.4 der zeitliche Zusammenhang zwischen verschiedenen Dateninstanzen berücksichtigt und die Klassifikation von Fahrsituationen und -manövern auf Sequenzen erweitert wird.

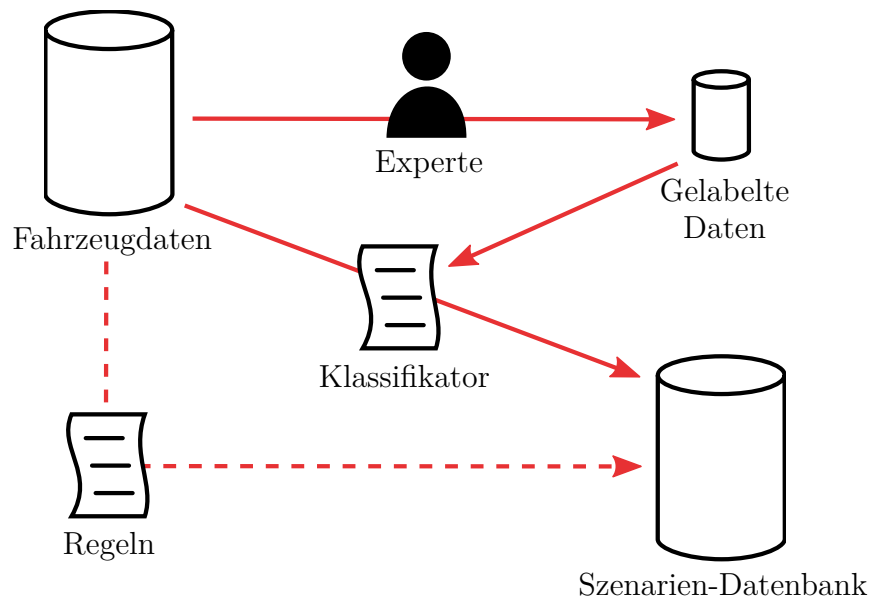
### 3.2.1 Architektur der Klassifikation

In Abbildung 3.4 ist, neben dem herkömmlichen, regelbasierten Ansatz, das neue Verfahren zur Erstellung der Szenarien-Datenbank gezeigt. Für das Training des Klassifikators wird ein Teil der Daten von einem Experten gelabelt. Dabei wird auch auf Videosequenzen zurückgegriffen, welche für den applizierten Klassifikator später nicht zur Verfügung stehen. Aufgrund der gelabelten Daten wird der Klassifikator entworfen und getestet. Schließlich wird die Klassifikation weiterer Daten durchgeführt.

Wie bereits bei der Definition von Fahrsituationen und -manövern in Kapitel 3.1 angeführt wurde, werden im Rahmen dieser Arbeit grundsätzlich drei Überklassen von Situationen und Manövern betrachtet: Bei fahrfahrbahngebundenen Situationen soll eine Entscheidung zwischen Folgefahrt und freier Fahrt getroffen werden. Darüber hinaus soll für das eigene Fahrzeug festgestellt werden, ob ein FSW durchführt und ob dieses nach links oder rechts ausgeführt wird. Für Fremdfahrzeuge soll in ähnlicher Weise festgestellt werden, ob ein Einschermanöver durchgeführt wird und ob dieses von links oder rechts erfolgt.

### 3.2.2 Beschreibung der Datengrundlage

Für den Datensatz, welcher zum Training und zur Evaluation des Klassifikators aufgeteilt wird, wurde die Grundwahrheit für jede Klasse und jeden Datenpunkt auf Basis von Expertenbewertungen bestimmt. Der Datensatz umfasst dabei  $N = 126\,140$  Instanzen von insgesamt 22 Fahrten, welche mit einer Abtastrate von  $\Delta T = 200$  ms vorliegen. Dies entspricht einer Fahrzeit von ca. 7 h und einer gefahrenen Strecke von ca. 935 km. Die Verteilung der Klassen im Datensatz ist in Tabelle 3.1 angegeben.



**Abbildung 3.4:** Architekturdiagramm für die automatisierte Indexierung der Szenarien-Datenbank.

| Klasse                | Instanzen | Ratio  |
|-----------------------|-----------|--------|
| Freie Fahrt           | 64745     | 51,3 % |
| Folgefahrt            | 61401     | 48,7 % |
| FSW nach links        | 3594      | 2,9 %  |
| FSW nach rechts       | 3676      | 2,9 %  |
| Einscherer von links  | 337       | 0,3 %  |
| Einscherer von rechts | 682       | 0,6 %  |


**Tabelle 3.1:** Verteilung der Klassen im Datensatz.



In Abbildung 3.5 sind die Merkmale auf Basis des entkrümmten Koordiantensystems angegeben, welche für den Merkmalsvektor

$$\mathbf{x} = [y_{\text{ego}}, \dot{x}_{\text{ego}}, \dot{y}_{\text{ego}}, x_f, y_f, \dot{x}_f, \dot{y}_f, x_l, y_l, \dot{x}_l, \dot{y}_l, x_r, y_r, \dot{x}_r, \dot{y}_r]^\top \quad (3.4)$$

einer Dateninstanz zu einem Zeitpunkt verwendet werden. Neben dem Ego-Fahrzeug werden drei weitere Fahrzeuge betrachtet. Die Relevanz und Zuordnung ( $f = \text{front}$ ,  $l = \text{links}$ ,  $r = \text{rechts}$ ) der Umfeldobjekte wird durch mehrere parallele Fahrstreife realisiert, deren Breite  $b_{FS}$  der Fahrstreifenbreite entspricht (rot, blau, grün).



**Abbildung 3.5:** Definition der verwendeten Merkmale aus dem UFM zur Klassifikation der Fahrmanöver.

Die laterale Position  $y_{\text{ego}}$  des eigenen Fahrzeugs wird relativ zur Fahrstreifenmitte angegeben. Der relevante Fahrstreifen des eigenen Fahrzeugs ist dabei immer der Fahrstreifen, auf dem sich das Fahrzeug momentan befindet. Dieser ändert sich bei einem FSW entsprechend. Die Längsgeschwindigkeit  $\dot{x}_{\text{ego}}$  des eigenen Fahrzeugs ist absolut über Grund angegeben. Um eine möglichst kompakte Repräsentation zu erhalten, sind die weiteren Positions- und Geschwindigkeitsangaben über Fremdfahrzeuge alle relativ zum eigenen Fahrzeug angegeben. Für das eigene Fahrzeug und die relevanten Umfeldobjekte sind neben den abgebildeten Größen auch die zeitlichen Ableitungen, die lateralen und longitudinalen Geschwindigkeiten, bekannt.

Insgesamt stehen somit  $M = 15$  Merkmale zur Verfügung. Es werden dabei nur Merkmale verwendet, welche mit aktueller, seriennaher Sensorik auf Grundlage des Fahrzeugumfelds erfasst werden. Da dies auch für das eigene Fahrzeug gilt und bspw. Informationen wie der Status des Fahrtrichtungsanzeigers oder der Lenkradwinkel nicht verwendet werden, besteht prinzipiell die Möglichkeit, das entwickelte Verfahren auf andere Fahrzeuge im Umfeld anzuwenden.

Im Fall, dass ein Fahrzeug von der Sensorik nicht erkannt wird, wird davon ausgegangen, dass i. d. R. auch kein Fahrzeug vorhanden ist. Dies stellt für die aktuelle Szene also eine wichtige Information dar. Obwohl Entscheidungsbäume mit fehlender Information umgehen können [17], werden in einem solchen Fall die Variablen, welche sonst die Eigenschaften des nun fehlenden Fahrzeugs beschreiben, auf konstante, vorgegebene Werte gesetzt. Somit fehlt nicht die Information über das Fahrzeug, sondern es wird über ein nicht vorhandenes Fahrzeug informiert.

### 3.2.3 Random Forest

Für die Klassifikation einzelner Instanzen wird aufgrund folgender Eigenschaften ein Random Forest (RF) Algorithmus nach Breiman eingesetzt [18]:

- Hohe Klassifikationsqualität
- Gute Skalierbarkeit auf große Datenmengen
- Anwendung mit einer hohen Anzahl von Merkmalen ohne vorausgehende Auswahl oder Normalisierung möglich
- Sehr robust gegen Überanpassung
- Liefert Abschätzung über die Wichtigkeit einzelner Merkmale

Dabei werden einzelne Entscheidungsbäume zu einem Ensemble zusammengefasst (engl. „bootstrap aggregating“ oder „bagging“). Das endgültige Klassifikationsergebnis ergibt sich aus dem Abstimmungsverhältnis der Bäume im Ensemble.

Als diskriminative Methode wird die bedingte Wahrscheinlichkeit der Klasse  $C$  mit der a posteriori Verteilung  $p(C|\mathbf{x})$  durch den RF direkt gelernt. Bei ausreichenden vielen Trainingsdaten ist davon auszugehen, dass ein geringerer Modellfehler erreicht wird als bei vergleichbaren generativen Ansätzen [19]. Die Annäherung an den asymptotischen Fehler findet bei diskriminativen Modellen dafür i. d. R. langsamer statt.

Durch wiederholtes Ziehen mit Zurücklegen von zwei Dritteln der Trainingsdaten  $\mathcal{D}$  (engl. „bootstrapping“),  $N = |\mathcal{D}|$ , wird für das Training des  $i$ -ten Entscheidungsbaums ein jeweils eigener Datensatz  $\mathcal{D}_i \subset \mathcal{D}$  zusammengestellt („in-the-bag“). Die Wahrscheinlichkeit, dass eine Instanz nicht für den Trainingsdatensatz ausgewählt wird, ergibt sich somit zu

$$\lim_{N \rightarrow \infty} \left(1 - \frac{1}{N}\right)^{\frac{2}{3}N} \approx 51,3\% . \quad (3.5)$$

Die Instanzen, welche nicht zum Training verwendet werden, bilden die Out-Of-Bag (OOB) Daten  $\mathcal{D}_{i,\text{OOB}} = \mathcal{D} \setminus \mathcal{D}_i$ . Diese können für diesen Baum als Testdatensatz angesehen werden.

Trainings- und Testdatensatz sind damit ungefähr gleich groß. Bei ungleich verteilten Trainingsdaten wird die in der Realität zu erwartende Verteilung empirisch aus den Trainingsdaten bestimmt und beim Ziehen der Trainingsdaten berücksichtigt, sodass die jeweiligen Klassen entsprechend ihrer empirischen Häufigkeit im Trainingsdatensatz repräsentiert sind.

Klassifiziert man die OOB-Daten mit dem Baum, kann der OOB-Fehler bestimmt werden. Dafür werden alle falsch klassifizierten Datenpunkte ins Verhältnis zu allen Daten gesetzt, für welche die Klassifizierung durchgeführt wurde. Mit dessen Hilfe können u. a. Rückschlüsse auf die Wichtigkeit einzelner Merkmale für die Klassifikation gezogen werden.

In [18] wurde gezeigt, dass der Klassifikationsfehler maßgeblich von der Korrelation der Bäume untereinander sowie der Stärke der einzelnen Bäume im Ensemble

abhängt. Erhöht sich die Korrelation bzw. nimmt die Stärke der einzelnen Klassifikatoren ab, so steigt der Fehler.

Beim Training eines Baumes werden die Daten an einem Knotenpunkt auf Basis des gewählten Kriteriums optimal geteilt, wobei dafür stets nur eine zufällige Untermenge von  $m < M$  Merkmalen verwendet wird. Ein kleines  $m$  verringert sowohl Korrelation als auch Stärke. Ein großes steigert beide. Das optimale  $m$  ergibt sich durch die Auflösung dieses Zielkonfliktes. In der Literatur wird oft  $m = \sqrt{M}$  gewählt und über das gesamte Training konstant gehalten.

Aus dem *Gesetz der großen Zahlen* folgt, dass durch das Hinzufügen weiterer Bäume keine zusätzliche Gefahr der Überanpassung (engl. „overfitting“) auf die Trainingsdaten besteht [18]. Vielmehr ergibt sich ein Grenzwert für den Generalisierungsfehler. Nichts desto trotz kann Überanpassung auftreten, welcher durch die Begrenzung der Baumtiefe und Überprüfung des Validierungsfehlers entgegen gewirkt werden kann. In diesem Fall wird für das Training der Bäume mit  $N_{\min}$  festgelegt, dass in einem beliebigen Blattknoten  $k$  mindestens  $N_k \geq N_{\min}$  Instanzen vorhanden sein müssen.

Zur Bestimmung der optimalen Konfiguration des RF für das jeweilige Problem werden folgende Parameter untersucht:

- Anzahl der Bäume im Ensemble  $B$
- Anzahl der Merkmale  $m$
- Tiefe der Entscheidungsbäume, abhängig vom Parameter  $N_{\min}$

### 3.2.4 Classification and Decision Trees

Für die einzelnen Entscheidungsbäume im RF wird der Classification and Decision Trees (CART) Algorithmus von Breiman [17] verwendet. Als Kriterium zum Aufteilen der  $N_k$  Instanzen eines Knotens  $k$  eines Baumes wird die sogenannte Reinheit mit dem Gini Diversitätsindex (GDI) bewertet. Der  $\text{GDI} \in [0; 1]$  an einem Knoten  $k$  ist

$$\text{GDI}(k) = 1 - \sum_{i=1}^C \left( \frac{n_{k,i}}{N_k} \right)^2 . \quad (3.6)$$

Es wird dabei die Summe über  $C$  Klassen am jeweiligen Knoten betrachtet.  $\frac{n_{k,i}}{N_k}$  entspricht dabei dem Anteil der Instanzen mit Klasse  $i$  im Knoten  $k$  im Verhältnis zur Gesamtanzahl  $N_k = \sum_{i=1}^C n_{k,i}$ . Bei binärer Aufteilung der Daten des Elternknotens  $k$  in genau zwei Kindknoten  $k_1$  und  $k_2$  ergibt sich zur Bewertung

$$\text{GDI}(k) = \frac{N_{k_1}}{N_k} \text{GDI}(k_1) + \frac{N_{k_2}}{N_k} \text{GDI}(k_2) , \quad (3.7)$$

wobei der GDI in den Kindknoten mit dem jeweiligen Anteil der zugewiesenen Instanzen  $N_{k_1}$  bzw.  $N_{k_2}$  gewichtet wird. Die Auswahl des zur Aufteilung verwendeten Merkmals und entsprechenden Schwellwerts erfolgt so, damit  $\text{GDI}(k)$  minimal ist. Jeder Baum kann so weit ausgebaut werden, d. h. die Knoten solange aufgeteilt werden, bis jeder Blattknoten am Ende nur Instanzen einer einzigen Klasse beinhaltet und somit rein ist. Dann gilt  $\text{GDI} = 0$ . Soll ein Baum dennoch nicht voll ausgebaut werden, wird die minimale Anzahl der Instanzen pro Blattknoten nach unten beschränkt:  $N_k \geq N_{\min} > 1$

### 3.3 Evaluation der Klassifikation

Für die Evaluation wird eine 10-fache Kreuzvalidierung durchgeführt und die Trainingsdaten zufällig in 10 gleichgroße Teildatensätze aufgeteilt. Somit werden stets 90 % der Daten für das Training des Klassifikators und 10 % für Test bzw. Validierung verwendet. Ist bei der Auswertung nichts weiter angegeben, wird immer das über die einzelnen Kreuzvalidierungsschritte gemittelte Ergebnis verwendet.

|            |   | Grundwahrheit |    |
|------------|---|---------------|----|
|            |   | T             | F  |
| Vorhersage | T | TP            | FP |
|            | F | FN            | TN |

**Tabelle 3.2:** Konfusionsmatrix.

Zur Beurteilung eines Klassifikators wird die Konfusionsmatrix betrachtet. Wie in Tabelle 3.2 gezeigt, ergeben sich grundsätzlich vier Möglichkeiten:

- True Positive (TP): Wahres Ereignis wurde korrekt erkannt.
- False Positive (FP): Gegenereignis wurde falsch als Ereignis erkannt.
- True Negative (TN): Gegenereignis wurde korrekt erkannt.
- False Negative (FN): Ereignis wurde falsch als Gegenereignis erkannt.

Aus diesen Werten werden weitere Kenngrößen für die Bewertung abgeleitet (Tabelle 3.3): Sensitivität (TPR), engl. „recall“ oder „true positive rate“, Spezifität (TNR), engl. „true negative rate“, die Präzision (PPV), engl. „positive predictive value“, Genauigkeit (ACC), engl. „accuracy“, sowie das F1-Maß (F1) und der Matthews Correlation Coefficient (MCC). Bis auf den MCC sind alle Kenngrößen auf dem Intervall  $[0; 1]$  definiert. Der MCC beschreibt die Korrelation zwischen wahrer und vorhergesagter Klassifikation und ist auf dem Intervall  $[-1; 1]$  definiert. Da alle Einträge der Konfusionsmatrix verwendet werden, ist er auch für die Bewertung sehr ungleich verteilter Klassen hilfreich.


Zudem hilft die Receiver-Operating-Characteristic (ROC) bzw. Grenzwertoptimierungskurve bei der Bewertung. Dabei wird für variierende Entscheidungswerte des Klassifikators die TPR über  $(1 - \text{TNR})$  aufgetragen. Die Fläche unter der ROC-Kurve, die Area Under Curve (AUC), ist dabei wiederum eine statistische Kennzahl zur Bewertung der Klassifikatorqualität – unabhängig vom Entscheidungswert.

#### 3.3.1 Klassifikation fahrstreifengebundener Fahrsituationen


Bei der Klassifizierung, ob sich das Fahrzeug in freier Fahrt befindet oder eine Folgefahrt vorliegt, handelt es sich um ein binäres Klassifikationsproblem, da entweder die eine oder andere Klasse zutreffend ist (Abbildung 3.6). Zudem handelt es sich nach Tabelle 3.1 um ein sehr ausgeglichenes Klassifikationsproblem bzgl. der Verteilung der Klassen im Datensatz.

| Kenngröße                         | Abkürzung | Definition  |
|-----------------------------------|-----------|---|
| Sensitivität                      | TPR       | $\frac{TP}{TP+FN}$  |
| Spezifität                        | TNR       | $\frac{TN}{FP+TN}$  |
| Präzision                         | PPV       | $\frac{TP}{TP+FP}$  |
| Genauigkeit                       | ACC       | $\frac{TP+TN}{TP+FP+TN+FN}$   |
| F1-Maß                            | F1        | $\frac{2 \cdot TP}{2 \cdot TP+FP+FN}$                                   |
| Matthews Correlation Coefficient  | MCC       | $\frac{TP \cdot TN - FP \cdot FN}{\sqrt{(TP+FP)(TP+FN)(TN+FP)(TN+FN)}}$ |
| Receiver-Operating-Characteristic | ROC       | TPR über $(1 - TNR)$  |
| Area Under Curve                  | AUC       | $f(\text{ROC})$   |

**Tabelle 3.3:** Kenngrößen zur Bewertung von Klassifikatoren.



**Abbildung 3.6:** Klassifikation von Folgefahrt und freier Fahrt.



**Abbildung 3.7:** Parameteroptimierung für die Klassifikation von Folgefahrt und freier Fahrt. (a) AUC über Anzahl der Merkmale  $m$  für unterschiedliche Baumtiefen, beschränkt durch  $N_{\min}$ . (b) AUC über Gesamtanzahl der Knoten im Ensemble bei unterschiedlichen Ensemblegrößen mit  $B$  Bäumen.

Es wird untersucht, welche Anzahl Merkmale  $m$  für die Klassifikation in diesem Fall optimal ist. In Abbildung 3.7 ist der AUC über der Anzahl  $m$ , der für die Teilung der Knoten auszuwählenden Merkmale, dargestellt. AUC bewertet die Qualität des Klassifikators ohne den Entscheidungswert  $\eta$  bereits festlegen zu müssen. Die Parameterauswahl kann damit unabhängig vom Entscheidungswert  $\eta$  getroffen werden. Im vorliegenden Fall erreicht der AUC-Wert bei  $m = 6$  sein Maximum. Für die weiterführende Analyse werden daher immer  $m = 6$  Merkmale zufällig an einem Baumknoten ausgewählt.

Die Entscheidung, wie viele Bäume pro Ensemble verwendet werden, hängt dabei maßgeblich von den zur Verfügung stehenden Ressourcen ab. Ist bekannt, wie viele Ressourcen zur Verfügung stehen (z. B. Speicher, Rechenleistung), ist von Interesse, welche Konfiguration von Anzahl und Tiefe der Bäume gewählt werden soll. Unter der Annahme, dass keine parallele Klassifikation bei den Bäumen im Ensemble stattfindet, ist die Gesamtanzahl der Knoten im Ensemble der entscheidende Einflussfaktor.


Es ist ersichtlich, dass ab einer gewissen Anzahl an Entscheidungsbäumen durch zusätzliche Bäume kaum mehr ein weiterer Vorteil erreicht wird. Das Ensemble ist konvergiert. Für kleine Ensemble ist zu erkennen, dass tiefe Bäume schlechter generalisieren und hier die Baumtiefe beschränkt werden muss. In diesem Fall generalisieren flachere, nicht voll ausgebaute Bäume besser. Zudem ist zu beachten, dass ein kleines Ensemble durch die geringe Baumanzahl eine hohe Varianz im Ergebnis induziert, da potentiell „Ausreißer“-Bäume einen größeren Einfluss auf die Klassifikation haben.

Ganz allgemein gilt, umso mehr Bäume im Ensemble vorhanden sind, desto besser die Klassifikation. Werden ausreichend viele Bäume verwendet, konvergiert das Ensemble. Bei einem Ensemble mit vielen, voll ausgebauten Bäumen ( $B = 300$ ,  $N_{\min} = 1$ ) wird in diesem Fall das beste Ergebnis erreicht.

Eine entscheidende Information ist zudem, wie groß der Beitrag einzelner Merkmale zum Klassifikationsergebnis ist. Unwichtige Merkmale werden nicht zur Klassifikation benötigt und können i. d. R. vernachlässigt werden. Dafür werden die OOB-Daten genutzt. Einzelne Merkmale werden zufällig permutiert und die Veränderung des Klassifikationsergebnisses, i. d. R. eine Verschlechterung, wird für jeden Baum bestimmt. Durch Bildung des Mittelwerts über das gesamte Ensemble und Normalisierung mit der Standardabweichung werden die Ergebnisse der Kreuzvalidierung in Abbildung 3.8 als Box-Whisker-Plots gezeigt. Dabei werden Ausreißer außerhalb des 1,5-fachen des Interquartilabstandes als rote Kreuze dargestellt. Große Werte deuten auf wichtige Merkmale hin.

Diese Bewertung kann nur als Hinweis verstanden werden, da starke, jedoch korrelierte Merkmale hier auch niedrige Werte erreichen können: Wird ein starkes Merkmal permutiert, fällt die Klassifikationsleistung nicht entsprechend ab, wenn ein weiteres korreliertes Merkmal für die Klassifikation zur Verfügung steht. Dieses Verhalten ist nicht spezifisch für RF, sondern gilt für die meisten modellbasierten Verfahren zur Merkmalsauswahl.

Für die Entscheidung, ob eine Folgefahrt vorliegt, ist das Vorhandensein eines Vorderfahrzeugs maßgeblich. Dies ist anhand der hohen Wichtigkeit von  $x_f$  ersichtlich.




**Abbildung 3.8:** Normierte Zunahme des Klassifikationsfehlers bei permutiertem Merkmal für die Erkennung einer Folgefahrt.

Auch die restlichen Variablen  $y_f$ ,  $\dot{x}_f$  und  $\dot{y}_f$ , welche das Vorderfahrzeug beschreiben, sind relevant – vor allem im Vergleich zu den Merkmalen der Fahrzeuge auf den Nebenfahrstreifen. Die hohe Wichtigkeit der Geschwindigkeit des eigenen Fahrzeugs  $\dot{x}_{ego}$  für die Entscheidung zwischen freier Fahrt oder Folgefahrt ist u. a. damit zu erklären, dass langsame Geschwindigkeiten auch eher auf ein erhöhtes Verkehrsaufkommen hinweisen. Eine hohe Geschwindigkeit  $\dot{x}_{ego}$  deutet tendenziell auf eine freie Fahrt hin. Die Quergeschwindigkeit des eigenen Fahrzeugs  $\dot{y}_{ego}$  deutet auf einen FSW hin, was in Kapitel 3.3.2 später noch erläutert wird. Ein FSW führt i. d. R. zu einem zumindest zeitweisen Verlust des Vorderfahrzeugs und damit zur Änderung der Klassifikation.

Führt man die Ergebnisse der Kreuzvalidierung für alle 10 Validierungsdatensätze zusammen, kann die ROC und der MCC in Abhängigkeit des Entscheidungswertes  $\eta$  in Abbildung 3.9 angegeben werden. Die Unterscheidung zwischen Folgefahrt und freier Fahrt gelingt sehr gut. Das Maximum des MCC liegt als Resultat aus dem sehr ausgeglichenen Auftreten beider Klassen nahezu mittig im Definitionsbereich des Entscheidungswertes bei  $\eta = 0,50$ . Auch die in Tabelle 3.4 zur Beurteilung der Klassifikationsqualität angeführten Kenngrößen weisen sehr gute Werte aus.

Nach der ROC-Kurve sowie Tabelle 3.4, in der zur Beurteilung der Klassifikationsqualität die zuvor eingeführte Kenngrößen angegeben sind, werden Folgefahrten sehr gut von der freien Fahrt unterschieden. Der Entscheidungswert wird auf Grundlage des MCC bestimmt.





**Abbildung 3.9:** (a) ROC-Kurve und (b) MCC über Entscheidungswert  $\eta$  für die Klassifikation von Folgefahrten.

| TPR    | TNR    | PPV    | ACC    | F1     | MCC   | AUC   |
|--------|--------|--------|--------|--------|-------|-------|
| 96,1 % | 97,1 % | 97,0 % | 96,6 % | 96,5 % | 0,932 | 0,994 |

**Tabelle 3.4:** Bewertung der Klassifikation zur Detektion von Folgefahrten als fahrstreifengebundene Fahr situation für  $\eta = 0,50$ .

Dieser erreicht sein Maximum in Nähe von  $\eta = 0,50$ . Somit gilt für die Wahrscheinlichkeit, dass das Fahrzeug sich in einer Folgefahrt befindet direkt

$$P(\text{Folgefahrt}) = 1 - P(\text{freie Fahrt}) = \eta . \quad (3.8)$$

Der Entscheidungswert des RF wird also direkt als Wahrscheinlichkeit zur Klassenzugehörigkeit interpretiert.

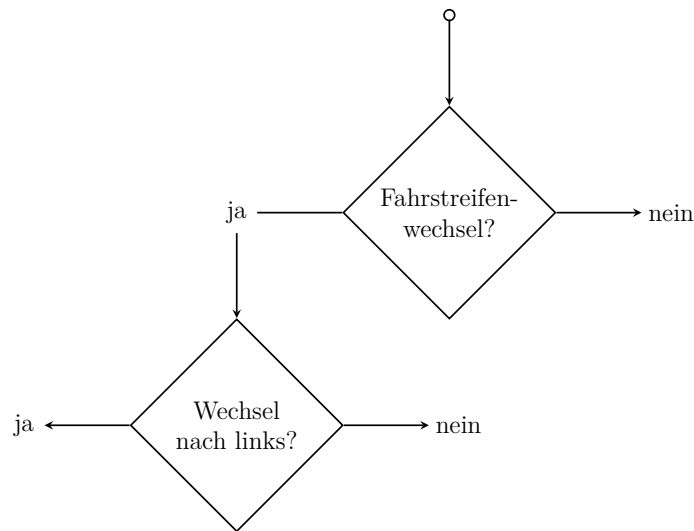
### 3.3.2 Klassifikation von Fahrstreifenwechseln

Die Klassifikation von FSW-Manövern wird in einem zweistufigen Klassifikationsverfahren durchgeführt. Zuerst wird festgestellt, ob ein FSW vorliegt. Dabei wird zunächst nicht unterschieden, ob nach links oder rechts. Erst in einem zweiten Schritt wird diese Unterscheidung dann vorgenommen. Das Verfahren ist in Abbildung 3.10 dargestellt.

#### Fahrstreifenwechsel?

Aus Tabelle 3.1 ist ersichtlich, dass FSW nur 5,8 % aller Daten ausmachen. Bei der Entscheidung, ob ein FSW vorliegt, handelt es sich daher um ein Problem mit unausgeglichener bzw. schiefer Klassenverteilung im Datensatz. Die nachgelagerte Klassifikation, ob nach links oder rechts gewechselt wird, ist wiederum annähernd gleich verteilt.

Für die Auswahl der optimalen Parameter des Klassifikators wird Abbildung 3.11 betrachtet. Der AUC erreicht sein Maximum bei voll ausgebauter Baumtiefe und



**Abbildung 3.10:** Zweistufige Klassifikation von FSW.

für  $m = 4$  Merkmale. Im weiteren wird daher die Klassifikation für FSW mit  $m = 4$  Merkmalen durchgeführt. Sind in einem Ensemble nur wenige Bäume, nimmt der AUC-Wert für tiefe Bäume ab. Ab einer Ensemblegröße von  $B = 139$  Bäumen führen zunehmende Baumtiefen zu keinem Rückgang der Klassifikationsqualität mehr bezüglich AUC. Bei vergleichbarer Gesamtanzahl an Knoten, erreichen Ensemble mit vielen Bäumen und reduzierter Tiefe eine schlechtere Klassifikationsqualität als Ensemble mit weniger, jedoch voll ausgebauten, Bäumen.

In Abbildung 3.12 wird ersichtlich, dass ein FSW maßgeblich an der aufgebauten Quergeschwindigkeit  $\dot{y}_{\text{ego}}$  des Fahrzeugs erkannt wird. Zudem sind die Längsgeschwindigkeit  $\dot{x}_{\text{ego}}$  und die Querablage  $y_{\text{ego}}$  wichtige Merkmale zur Identifikation von FSW.

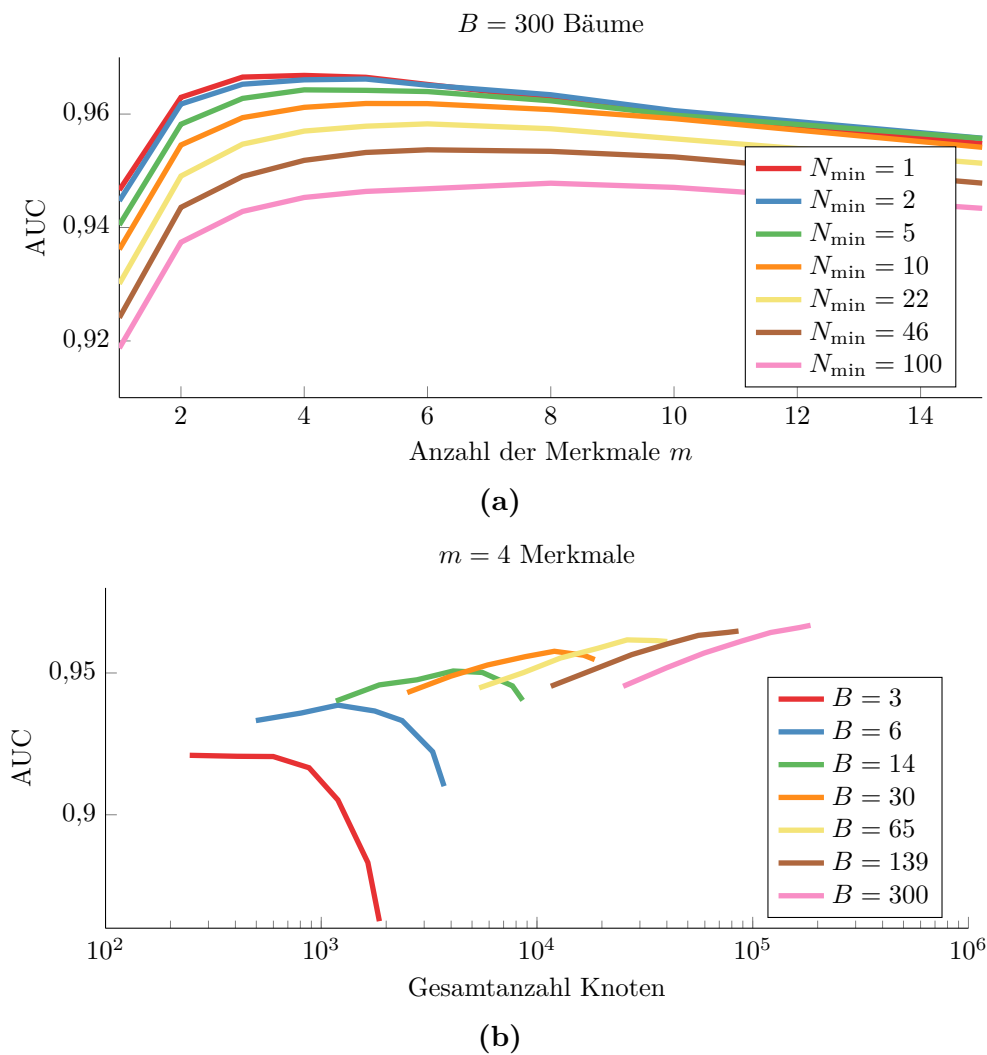
Die ROC in Abbildung 3.13 zeigt, dass FSW prinzipiell gut identifiziert werden können. Bei der Wahl des Entscheidungswertes  $\eta$  fällt auf, dass der MCC sein Maximum bei  $\eta = 0,33$  erreicht. Für die Klassifikation ist ein Entscheidungswert  $\eta \neq 0,50$  günstiger, da eine ungleiche Verteilung der Klassen vorliegt.

In der Tabelle 3.5 sind die Konfusionsmatrizen für den Entscheidungswert  $\eta = 0,50$  und  $\eta = 0,33$  angegeben. Mit  $\eta = 0,50$  werden von 5,8 % FSW im Datensatz


|            |      | Grundwahrheit |               |
|------------|------|---------------|---------------|
|            |      | FSW           | −FSW          |
| Vorhersage | FSW  | 4,2 (+1,1) %  | 1,9 (+1,1) %  |
|            | −FSW | 1,6 (-1,0) %  | 92,3 (-1,2) % |

**Tabelle 3.5:** Konfusionsmatrix für FSW für den Entscheidungswert  $\eta = 0,33$ . In Klammern ist die Veränderung der Prozentpunkte gegenüber  $\eta = 0,50$  angegeben (vorteilhaft grün, nachteilig rot).

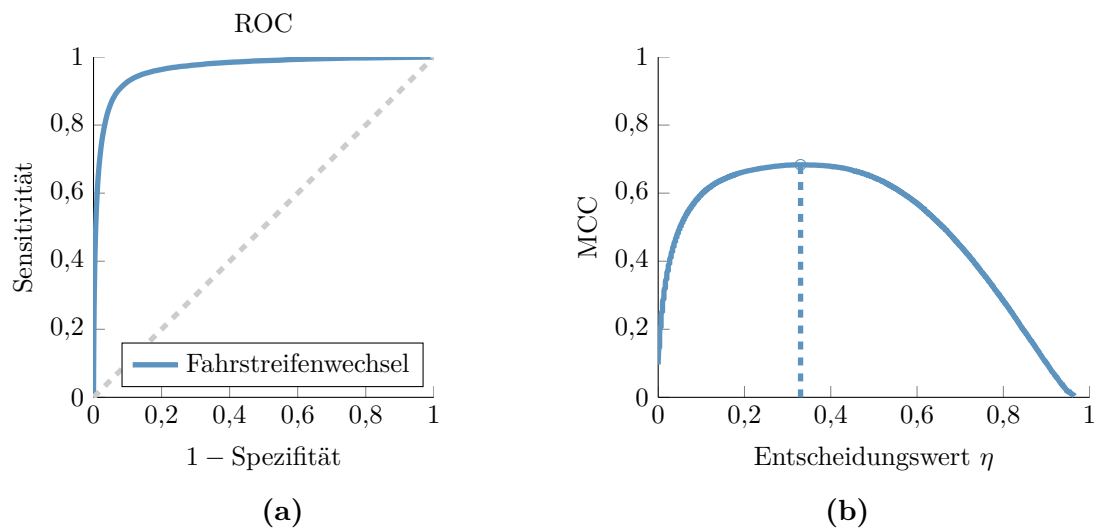
3,1 % richtig erkannt, also nur etwas mehr als die Hälfte. Es wird im Vergleich dreimal häufiger ein Spurhalten falsch als FSW klassifiziert (0,8 %) als ein FSW



**Abbildung 3.11:** Parameteroptimierung für die Klassifikation von FSW. (a) AUC über Anzahl der Merkmale  $m$  für unterschiedliche Baumtiefen, beschränkt durch  $N_{\min}$ . (b) AUC über Gesamtanzahl der Knoten im Ensemble bei unterschiedlichen Ensemblegrößen mit  $B$  Bäumen.



**Abbildung 3.12:** Normierte Zunahme des Klassifikationsfehlers bei permutiertem Merkmal für die Erkennung von FSW.



**Abbildung 3.13:** (a) ROC und (b) MCC über Entscheidungswert  $\eta$  für die Klassifikation von FSW.


als Spurhalten (2,6%). Dies liegt ebenso an der ungleichen Klassenverteilung im Datensatz. Die Klasse mit vielen Instanzen ( $\neg$ FSW), die Majoritätsklasse, erhält in diesem Fall wesentlich häufiger den Zuschlag als die Minoritätsklasse (FSW) – fälschlicherweise.

Mit  $\eta = 0,33$  auf Grundlage der Maximierung des MCC werden hingegen 4,2% der FSW korrekt klassifiziert, also knapp dreiviertel aller FSW. Das entspricht einer Steigerung von über einem Drittel gegenüber  $\eta = 0,50$ . Die Falschklassifikationen treten nun ausgewogen auf, obwohl die a priori Klassenverteilung sehr unausgeglichener ist.

| TPR    | TNR    | PPV    | ACC    | F1     | MCC   | AUC   | $\eta$ |
|--------|--------|--------|--------|--------|-------|-------|--------|
| 54,6 % | 99,2 % | 80,4 % | 96,6 % | 65,0 % | 0,646 | 0,966 | 0,50   |
| 72,4 % | 97,9 % | 68,1 % | 96,5 % | 70,2 % | 0,683 | 0,966 | 0,33   |

**Tabelle 3.6:** Bewertung der Klassifikation für FSW.

Die Güte des Klassifikators wird in Tabelle 3.6 bei unterschiedlichen Entscheidungswerten  $\eta$  angegeben. Die erste Zeile entspricht dabei  $\eta = 0,50$ , die zweite  $\eta = 0,33$ . Wie bereits erwähnt ist der AUC-Wert unabhängig von  $\eta$  und somit in beiden Fällen identisch. Der PPV fällt für  $\eta = 0,33$  sichtlich ab. Dies ist durch die wesentlich gestiegenen FP-Fälle gegenüber  $\eta = 0,50$  begründet. Insgesamt wird die Güte des Klassifikators für  $\eta = 0,33$  als vorteilhaft bewertet.



**Abbildung 3.14:** Wahrscheinlichkeit für FSW  $P(\text{FSW})$  auf Basis der Klassifikation für den gewählten Entscheidungswert  $\eta = 0,33$ .

Für die Klassifikation, ob ein FSW vorliegt, wird  $\eta = 0,33$  als Grenzwert gewählt. Am neu gewählten Grenzwert  $\eta = 0,33$  soll für die Wahrscheinlichkeit der Klassenzugehörigkeit  $P(\text{FSW}) = 50\%$  gelten. Für einen Entscheidungswert  $\eta \neq 0,50$  muss daher das Intervall  $\eta \in [0; 1]$  für die Ausgangswerte der Klassifikation auf die Wahrscheinlichkeit  $P \in [0; 1]$  in Abhängigkeit des gewählten Entscheidungsgrenzwertes projiziert werden. Diese Umrechnung ist mit der stückweise linearen Funktion  $f$  realisiert und in Abbildung 3.14 gezeigt. Somit ergibt sich für die Wahrscheinlichkeit, dass ein FSW vorliegt

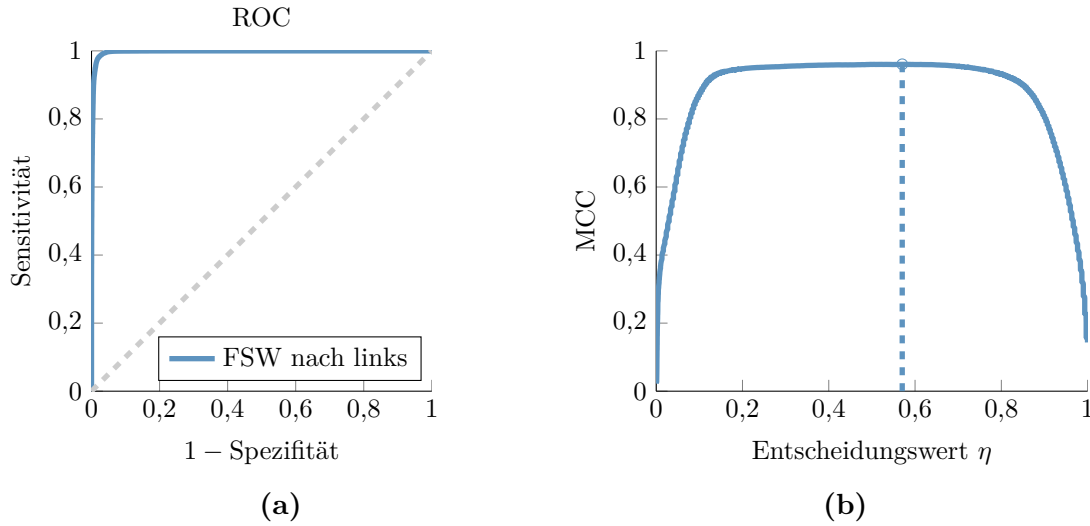
$$P(\text{FSW}) = 1 - P(\neg\text{FSW}) = f(\eta) , \quad (3.9)$$

wobei  $P(\neg\text{FSW})$  die Wahrscheinlichkeit beschreibt, dass kein FSW vorliegt.

### Fahrstreifenwechsel nach links oder rechts?

Hat man einen FSW detektiert, muss noch entschieden werden, ob dieser nach links oder rechts ausgeführt wird. Daher werden nun ausschließlich Instanzen betrachtet, welche ein FSW-Manöver beinhalten. Setzt man als bekannt voraus, dass ein FSW stattfindet, muss also die bedingte Wahrscheinlichkeit  $P(\text{links}|\text{FSW})$  bestimmt werden.

In Abbildung 3.15 ist die Qualität dieser Klassifikation auf Grundlage aller Instanzen, die einen FSW beinhalten, dargestellt. Die besten Ergebnisse wurden dabei mit



**Abbildung 3.15:** (a) ROC-Kurve und (b) MCC über Entscheidungswert  $\eta$  für die Klassifikation, ob der Fahrstreifen nach links oder rechts gewechselt wird.

den Parametern  $B = 300$ ,  $m = 4$  und  $N_{\min} = 1$  erzielt. Da der MCC ein breites Plateau konstant guter Werte bildet, wird als Entscheidungsgrenzwert  $\eta = 0,50$  beibehalten, obwohl das Maximum des MCC empirisch mit 0,57 davon leicht abweicht.

Die Entscheidung, welche Art von FSW vorliegt, wird von der aufgebauten Quergeschwindigkeit  $\dot{y}_{\text{ego}}$  des Fahrzeugs dominiert. Dies ist aus Expertensicht nachvollziehbar und ergibt sich auch bei der Betrachtung der OOB-Daten, wenn einzelne Merkmale permutiert werden.

Für die bedingte Wahrscheinlichkeit für einen FSW nach links oder rechts gilt

$$P(\text{links}|\text{FSW}) = 1 - P(\text{rechts}|\text{FSW}) . \quad (3.10)$$

Die Verbundwahrscheinlichkeiten für einen FSW nach links respektive rechts ergeben sich schließlich durch Multiplikation der bedingten Wahrscheinlichkeiten mit der Wahrscheinlichkeit eines durchgeführten FSW-Manövers.

$$P(\text{FSW}, \text{links}) = P(\text{links}|\text{FSW}) P(\text{FSW}) \quad (3.11)$$

$$P(\text{FSW}, \text{rechts}) = P(\text{rechts}|\text{FSW}) P(\text{FSW}) \quad (3.12)$$

Damit sind alle Wahrscheinlichkeiten der Manöver aus  $\mathcal{M}_{\text{FSW}}$  bestimmt und es gilt

$$P(\text{FSW}, \text{links}) + P(\text{FSW}, \text{rechts}) + P(\neg\text{FSW}) = 1 . \quad (3.13)$$

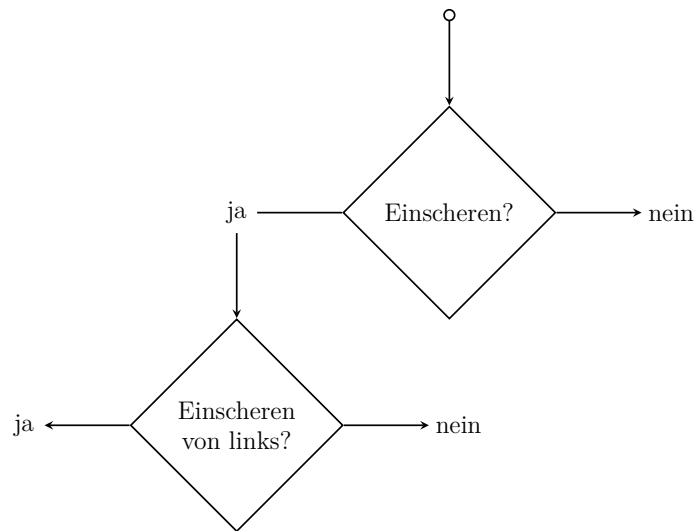


Abbildung 3.16: Zweistufige Klassifikation von Einscherern.

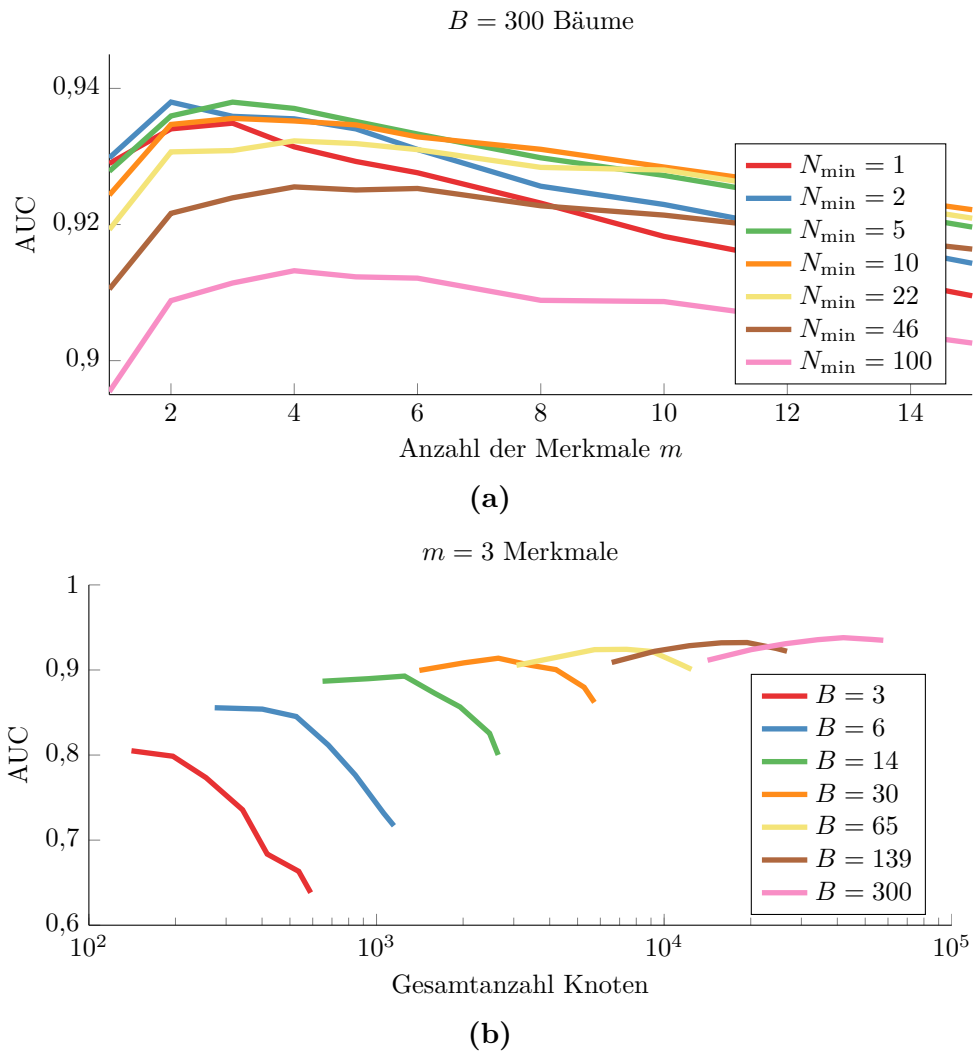
### 3.3.3 Klassifikation von Einscherern

Analog zu FSW wird wieder ein zweistufiges Klassifikationsverfahren verwendet, welches in Abbildung 3.16 visualisiert ist. Es handelt sich hier nach Tabelle 3.1 um ein noch unausgeglicheneres Problem als zuvor. Lediglich 0,8 %, also 1019 der Instanzen im Datensatz sind von Experten überhaupt mit Einscherern assoziiert worden.

#### Einscheren?


In Abbildung 3.17 ist die Abhängigkeit zwischen  $m$  und AUC gezeigt. Bezogen auf den AUC-Wert ist ersichtlich, dass vollständig ausgebaute Bäume ( $N_{\min} = 1$ ) keine optimale Klassifikationsqualität liefern. Ensemble mit flacheren Bäumen erreichen höhere AUC-Werte ( $2 \leq N_{\min} \leq 10$ ). Im Gegensatz zu Abbildungen 3.7 und 3.11 deutet der Verlauf des AUC-Werts in Abbildung 3.17 darauf hin, dass bei diesem Problem sogar für ein sehr großes Ensemble mit  $B = 300$  Bäumen der Klassifikator noch nicht komplett konvergiert ist. Zudem ist auch erkennbar, dass sich bei entsprechend günstiger Wahl  $N_{\min} = 5$  der maximal erreichbare AUC-Wert ab einer Ensemblegröße von ca.  $B = 65$  Bäumen nur noch unwesentlich ändert. Daher werden in diesem Fall für Ensemble mit  $B = 300$  Bäumen  $m = 3$  Merkmale gewählt und die Baumtiefe mit  $N_{\min} = 5$  beschränkt.

Waren bisher vor allem die Merkmale des eigenen Fahrzeugs für die Klassifikation als wichtig beschrieben worden, so sind in Abbildung 3.18 vor allem die Merkmale, welche das Fahrzeugumfeld beschreiben, entscheidend; insbesondere die Position  $x_f, y_f$  und die Quergeschwindigkeit  $\dot{y}_f$  des vorausfahrenden Fahrzeugs. Nach der Definition eines Einscherernmanövers in Kapitel 3.1.3 und der verwendeten Umfeldbeschreibung (Abbildung 3.5) wird der Einscherer im Verlauf des Manövers das neue Zielobjekt auf dem Fahrstreifen des eigenen Fahrzeugs. Dabei ändert sich die Zuordnung der Fahrzeuge und damit die Merkmale im Merkmalsvektor: Im ersten Teil des Manövers wird der Einscherer, der sich noch auf dem Nebenfahrstreifen befindet, durch  $[x_l, y_l, \dot{x}_l, \dot{y}_l]$  bzw.  $[x_r, y_r, \dot{x}_r, \dot{y}_r]$  beschrieben; im zweiten Teil stets durch  $[x_f, y_f, \dot{x}_f, \dot{y}_f]$ . Im Allgemeinen ist erkennbar, dass die Klassifikation von Einscher-



**Abbildung 3.17:** Parameteroptimierung für die Klassifikation von Einscherern. (a) AUC über Anzahl der Merkmale  $m$  für unterschiedliche Baumtiefen, beschränkt durch  $N_{\min}$ . (b) AUC über Gesamtanzahl der Knoten im Ensemble bei unterschiedlichen Ensemblegrößen mit  $B$  Bäumen.





**Abbildung 3.18:** Normierte Zunahme des Klassifikationsfehlers bei permutiertem Merkmal für die Erkennung von Einscherern.

manövern nicht wie bisher von einigen wenigen Merkmalen dominiert wird, sondern lediglich im Zusammenspiel von vielen Merkmalen gelingt.

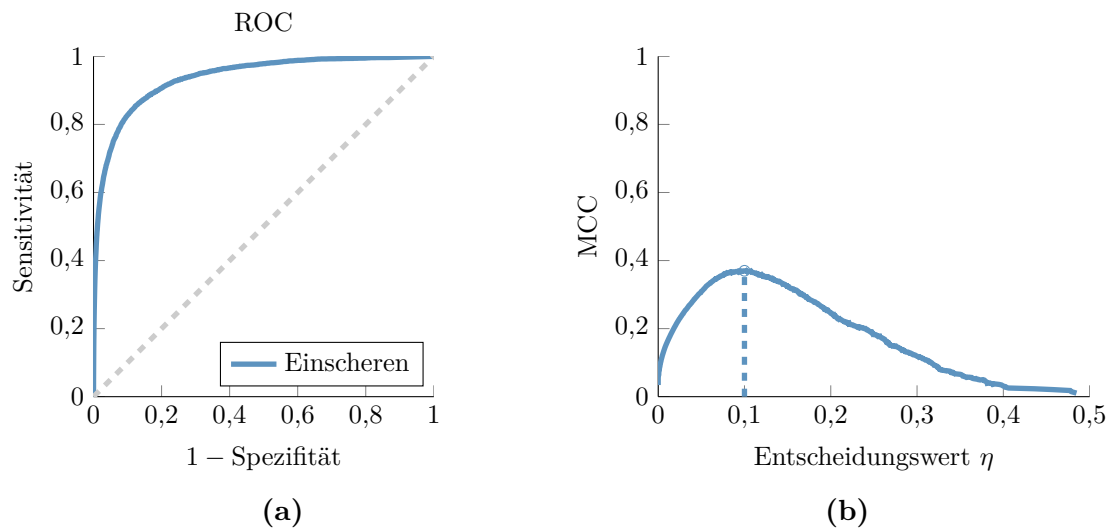
Die Komplexität der Klassifikation von Einscherern ist auch an der ROC in Abbildung 3.19 zu erkennen. Zudem liegt das Maximum für den MCC bei  $\eta = 0,10$  und bereits für  $\eta > 0,48$  werden alle Testinstanzen der Majoritätsklasse „kein Einscheren“ zugeordnet. Daher ist für größere  $\eta$  der MCC nicht definiert. Die Güte des Klassifikators für Einscherer wird mit der Konfusionsmatrix in Tabelle 3.7 und weiteren Kenngrößen in Tabelle 3.8 beschrieben.

|            |                   | Grundwahrheit |                   |
|------------|-------------------|---------------|-------------------|
|            |                   | Einscheren    | $\neg$ Einscheren |
| Vorhersage | Einscheren        | 0,3 %         | 0,5 %             |
|            | $\neg$ Einscheren | 0,5 %         | 98,7 %            |

**Tabelle 3.7:** Konfusionsmatrix für das Einscheren ( $\eta = 0,10$ ).

Für die Einscherklassifikation mit dem gewählten Entscheidungsgrenzwert  $\eta = 0,10$  wird der Ausgangswert der Klassifikation auf die Wahrscheinlichkeit der Klassenzugehörigkeit projiziert. Die verwendete Funktion  $f$  ist in Abbildung 3.14 gezeigt. Für die Wahrscheinlichkeit des Einscherens gilt damit


$$P(\text{Einscherer}) = 1 - P(\neg\text{Einscherer}) = f(\eta) . \quad (3.14)$$



**Abbildung 3.19:** (a) ROC-Kurve und (b) MCC über Entscheidungswert  $\eta$  für die Klassifikation von Einscherern.

| TPR    | TNR    | PPV    | ACC    | F1     | MCC   | AUC   | $\eta$ |
|--------|--------|--------|--------|--------|-------|-------|--------|
| 36,6 % | 99,5 % | 38,4 % | 99,0 % | 37,5 % | 0,370 | 0,937 | 0,10   |

**Tabelle 3.8:** Bewertung der Klassifikation für Einscherer.




**Abbildung 3.20:** Wahrscheinlichkeit für das Einscheren  $P(E)$  auf Basis der Klassifikation für den gewählten Entscheidungswert  $\eta = 0,10$ .

### Einscheren von links oder rechts?

Analog zum FSW wird mit einer nachgelagerten binären Klassifikation die bedingte Wahrscheinlichkeit für das Einscheren von links bzw. rechts bestimmt; unter der Bedingung, dass ein Einschermanöver vorliegt. Dafür wird ein Datensatz generiert, der ausschließlich Instanzen mit Einschermanövern enthält. Die Wahrscheinlichkeit für das Einscheren von links bzw. rechts ergibt sich damit zu

$$P(\text{Einscheren, links}) = P(\text{links}|\text{Einscheren}) P(\text{Einscheren}) \quad (3.15)$$

$$P(\text{Einscheren, rechts}) = P(\text{rechts}|\text{Einscheren}) P(\text{Einscheren}) . \quad (3.16)$$



**Abbildung 3.21:** (a) ROC-Kurve und (b) MCC über Entscheidungswert  $\eta$  für die Klassifikation, ob von links oder rechts eingeschert wird.

In Abbildung 3.21 ist gezeigt, dass die Unterscheidung, ob ein Fahrzeug von links oder rechts auf den eigenen Fahrstreifen einschert, mit  $AUC = 0,992$  sehr gut funktioniert. Das Maximum des MCC tritt bei  $\eta = 0,47$  auf. Als Entscheidungsgrenzwert wird daher  $\eta = 0,50$  gewählt und somit gilt direkt

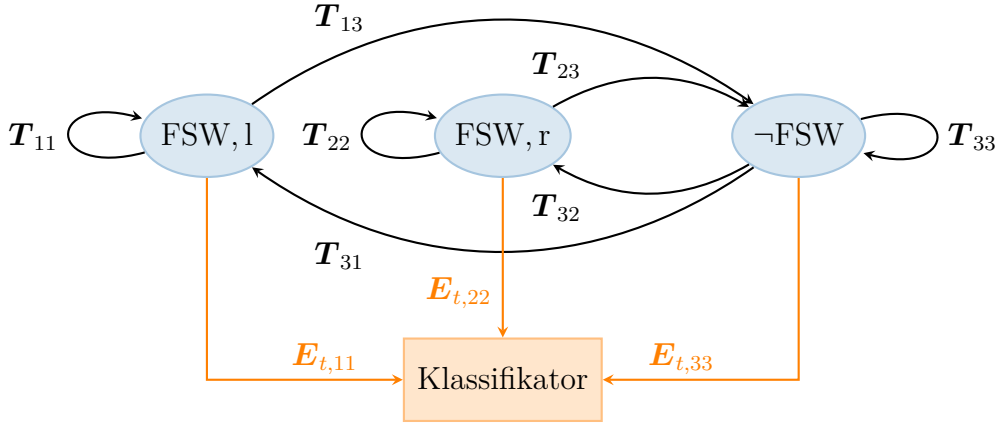
$$P(\text{links}|\text{Einscheren}) = 1 - P(\text{rechts}|\text{Einscheren}) = \eta \quad (3.17)$$

und

$$P(\text{Einscheren, links}) + P(\text{Einscheren, rechts}) + P(\neg\text{Einscheren}) = 1 . \quad (3.18)$$

## 3.4 Modellierung der zeitlichen Zusammenhänge

Bisher wurde zur Klassifikation der unterschiedlichen Fahrsituationen und Manöver jede Instanz als unabhängig von einander betrachtet. Bei der Klassifikation des aktuellen Zeitschritts werden Ergebnisse der benachbarten Zeitschritte ignoriert. Dadurch können sehr sprunghafte Änderungen der Klassifikationsergebnisse im Verlauf einer Fahrt auftreten. In Realität besteht jedoch natürlich ein zeitlicher Zusammenhang zwischen den Dateninstanzen, da alle Fahrsituationen und -manöver zeitlich ausgedehnte Vorgänge sind. Falls die Klasse im aktuellen Zeitschritt bekannt ist, gilt



**Abbildung 3.22:** Zustandsgraph des HMM für FSW mit den Transitionen  $\mathbf{T}$  und Evidenzen  $\mathbf{E}_t$ , welche für einen Zustand zum Zeitpunkt  $t$  vom Klassifikator ausgegeben werden.

es als wahrscheinlich, dass auch vor und nach diesem Zeitschritt diese Klassifikation zutreffend ist.

Um den Zusammenhang zwischen der Klassifikation vorausgegangener, aktueller und zukünftiger Zeitschritte zu berücksichtigen und auf zeitlich ausgedehnte Sequenzen zu erweitern, werden die endgültigen Klassenzugehörigkeiten als latente Zustände  $X$  einer Markov-Kette, einem HMM, modelliert [20]. Für die Klassifikation von FSW ist ein entsprechender Graph in Abbildung 3.22 gezeigt.

Zur Beschreibung der Übergangswahrscheinlichkeiten der Klassen untereinander wird die Transitionsmatrix  $\mathbf{T}$  bestimmt.

$$\mathbf{T}_{ij} = P(X_t = i | X_{t-1} = j) \quad (3.19)$$

Die stochastische Matrix  $\mathbf{T}$  beschreibt die Wahrscheinlichkeit in einem Zeitschritt von Zustand  $i$  auf Zustand  $j$  zu wechseln. Für die Zeilensumme gilt

$$\sum_j \mathbf{T}_{ij} = 1, \quad (3.20)$$

da die Gesamtwahrscheinlichkeit, um von einem Zustand  $i$  in alle anderen Zustände zu wechseln, gleich 1 sein muss.

Die Wahrscheinlichkeiten auf Basis der Klassifikation werden als Evidenzen für bzw. gegen eine Klasse verwendet. Anhand des Vorwärts-Rückwärts-Algorithmus (engl. „forward-backward“) wird mit den Evidenzen des Klassifikators die Sequenz mit den wahrscheinlichsten Klassenzuständen für  $1 \leq t \leq T$  bestimmt. Die Diagonalmatrix  $\mathbf{E}_t$  beschreibt dabei die Evidenz zum Zeitschritt  $t$  für die latenten Zustände des Modells, d. h. die einzelnen Klassen.

Die Vorwärts-Wahrscheinlichkeit der latenten Zustände auf Grundlage der vorangegangenen Werte wird mit dem Zeilenvektor  $\mathbf{f}_t$  angegeben. Dieser ergibt sich aus der iterativen Vorschrift

$$\mathbf{f}_t^\top \sim \mathbf{E}_t \mathbf{T}^\top \mathbf{f}_{t-1}^\top. \quad (3.21)$$

Für den Initialzustand  $\mathbf{f}_0 = \boldsymbol{\pi} = [P(\text{FSW}, l), P(\text{FSW}, r), P(-\text{FSW})]$  wird die empirische a priori Verteilung der Klassen im Datensatz verwendet. Der Spaltenvektor  $\mathbf{b}_t$

gibt die Rückwärts-Wahrscheinlichkeit der Zustände auf Grundlage der zukünftigen Werte an. Diese ergibt sich iterativ nach

$$\mathbf{b}_{t-1} \sim \mathbf{T} \mathbf{E}_t \mathbf{b}_t \quad (3.22)$$

mit  $\mathbf{b}_T = [1, \dots, 1]^\top$ . Werden die zuvor ermittelten Wahrscheinlichkeiten mit  $\circ$  elementweise multipliziert, erhält man

$$\boldsymbol{\gamma}_t \sim \mathbf{f}_t \circ \mathbf{b}_t^\top \quad (3.23)$$

mit den zeitlich geglätteten Zustandswahrscheinlichkeiten  $\boldsymbol{\gamma}_t$  für alle Zeitpunkte  $t$ .

Für die zeitliche Glättung bei der Klassifikation von FSW wurde die Transitionsmatrix empirisch zu

$$\mathbf{T} = \begin{bmatrix} 0,96 & 0 & 0,04 \\ 0 & 0,96 & 0,04 \\ 0,25 & 0,25 & 0,50 \end{bmatrix} \quad (3.24)$$

gewählt. Die Ergebnisse für einen FSW nach links eines ausgewählten zweieinhalb minütigen Fahrabschnitts sind in Abbildung 3.23 gezeigt.


Grundsätzlich ist erkennbar, dass nach der Vorwärts-Rückwärts-Glättung die Klassifikation besser mit der Grundwahrheit übereinstimmt. Im Bereich ab 100 s ist nach wie vor die korrekte Erkennung der zwei FSW gezeigt. Die Wahrscheinlichkeiten nach Anwendung der Glättung sind jedoch viel ausgeprägter als zuvor. Am augenscheinlichsten ist der vom Klassifikator im Bereich von 10 s nicht als hinreichend wahrscheinlich beschiedene FSW. Nach Anwendung der Glättung wird dieser FSW-Vorgang korrekt erkannt. Weiterhin wird bei der Klassifikation ohne Glättung zusätzlich ein zweifelhafter, ursprünglich falsch klassifizierter FSW ausgewiesen. Dieser wird nach der Glättung korrekterweise nicht mehr als FSW nach links klassifiziert.

Der verbleibende Klassifikationsfehler entsteht hauptsächlich an den Übergängen, d. h. an den Start- und Endzeitpunkten der Klassenübergänge. Dort unterscheiden sich die geglättete Klassifikation und die Grundwahrheit für kurze Zeit. Die Klassifikationswahrscheinlichkeit während der zu klassifizierenden Manöver ist hingegen sehr stabil.


|            |        | Grundwahrheit |              |               |
|------------|--------|---------------|--------------|---------------|
|            |        | FSW, l        | FSW, r       | ¬FSW          |
| Vorhersage | FSW, l | 2,6 (+1,0) %  | 0 %          | 0,9 (+0,4) %  |
|            | FSW, r | 0 %           | 2,7 (+0,6) % | 1,1 (+0,2) %  |
|            | ¬FSW   | 1,3 (-1,4) %  | 1,5 (-1,2) % | 89,9 (+0,3) % |

**Tabelle 3.9:** Konfusionsmatrix für die FSW-Manöver nach der Glättung. In Klammern sind die Änderungen in Prozentpunkten gegenüber einer Klassifikation ohne Glättung angegeben (vorteilhaft grün, nachteilig rot).


Für den Testdatensatz ist in Tabelle 3.9 die Konfusionsmatrix der Klassifikation unter Anwendung der Glättung angegeben. Unter Verwendung des vorgestellten HMM steigert sich die Qualität des Klassifikationsergebnisses sowohl visuell, wie



(a) Grundwahrheit.



(b) Klassifikation.



(c) Klassifikation mit Glättung unter Verwendung des HMM.

**Abbildung 3.23:** Glättung der Klassifikation von FSW nach links. (a) zeigt die Grundwahrheit, (b) die ursprüngliche Ausgabe des Klassifikators sowie (c) die geglättete Klassifikation. Gestrichelte Linien geben die Wahrscheinlichkeit  $P$  für die Manöverklasse an. Wenn  $P \geq 50\%$  ist, wird für den Vergleich mit der Grundwahrheit die Klassifikation als zutreffend angenommen (durchgezogene Linien).

in Abbildung 3.23 dargestellt, als auch messbar. Vor allem die eher seltenen FSW-Ereignisse profitieren von der Modellierung als Markov-Kette.

Stehen beim Einsatz des Klassifikators bereits während der Fahrt lediglich Vergangenheitswerte zur Verfügung, wird nur der Vorwärtsschritt des Algorithmus ausgeführt. Damit wird ein rekursives Filter realisiert.

## 3.5 Zusammenfassung

Im Laufe dieses Kapitels wurde ein Klassifikationsverfahren entwickelt. Im Gegensatz zum derzeitigen Stand der Technik – den regelbasierten Ansätzen – wurde dabei eine Datenbank, welche Datensequenzen aus Fahrzeugflotten enthält, mit Hilfe von Algorithmen des maschinellen Lernens indexiert. Zur Analyse relevanter Fahrsituationen und -manöver wurde ein Klassifikator für einzelne Instanzen auf Basis eines RF Algorithmus nach Breiman parametrisiert. Um den zeitlichen Zusammenhang von aufeinanderfolgenden Zeitschritten zu berücksichtigen, wurde ein HMM entworfen, welches die Ergebnisse des Klassifikators als Evidenzen für die wahren Klassen modelliert. Anhand von Vorwärts-Rückwärts-Glättung wurde das Klassifikationsergebnis optimiert und die wahrscheinlichste Klasse für die jeweilige Instanz robust bestimmt. Bei der Fragestellung, ob ein FSW vorliegt und ob dieser nach links oder rechts ausgeführt wird, wurden so bspw. 95,2% der Instanzen korrekt klassifiziert. Der Großteil des verbliebenen Klassifikationsfehlers entsteht hauptsächlich an den Übergängen zwischen den einzelnen Klassen.





# Semi-parametrische Zustandsprädiktion

Im vorangegangenen Kapitel wurde eine Methode zur Klassifikation von Fahrsituationen und -manövern für die Indexierung einer Datenbank mit Hilfe maschineller Lernverfahren vorgestellt. Unter Verwendung der gleichen Umfeldinformation wird in diesem Kapitel eine neue Methode entwickelt, um Fahrzeugtrajektorien zu präzisieren. Dafür wird nicht nur der fahrzeugeigene Zustand verwendet, sondern auch Kontextinformationen, wie bspw. Fahrbahnmarkierungen und der Einfluss des Vorderfahrzeugs. Als Datengrundlage dienen wiederum die Daten der FOT-Flotte mit seriennaher Sensorqualität.

## 4.1 Einordnung in den Anwendungskontext

Beim HAF übernimmt das Fahrzeug für eine gewisse Zeit vollständig die Fahraufgabe. Der Fahrer muss den Verkehr und das System bis zum Zeitpunkt der Übernahmeaufforderung (TOR), engl. „take over request“, nicht mehr überwachen. Fordert das System die Übernahme an, muss der Fahrer die Fahraufgabe wieder selbst übernehmen. Die Zeitspanne, von der Übernahmeaufforderung des Systems bis zur tatsächlichen Übernahme der Fahraufgabe mit Brems- und Lenkeingriffen durch den Fahrer, wird mit  $t_{\text{TOR}}$  bezeichnet.

In [21, 22] werden noch für Zeiten von  $t_{\text{TOR}} = 7\text{ s}$  Nachwirkungen der Automatisierung auf die Fahrleistung beobachtet. Neben sicherheitskritischen Betrachtungen spielt auch die komfortable Auslegung der Systeme eine Rolle. Aus Komfortsicht wird für HAF eine Übernahmezeit von mindestens  $t_{\text{TOR}} = 6\text{ s}$  abgeleitet [23]. Ein vorausschauendes und damit berechenbar agierendes FAS erhöht mit längeren Übernahmezeiten das Vertrauen des Fahrers in das System und bietet somit einen direkten Mehrwert bei der assistierten Fahrt.

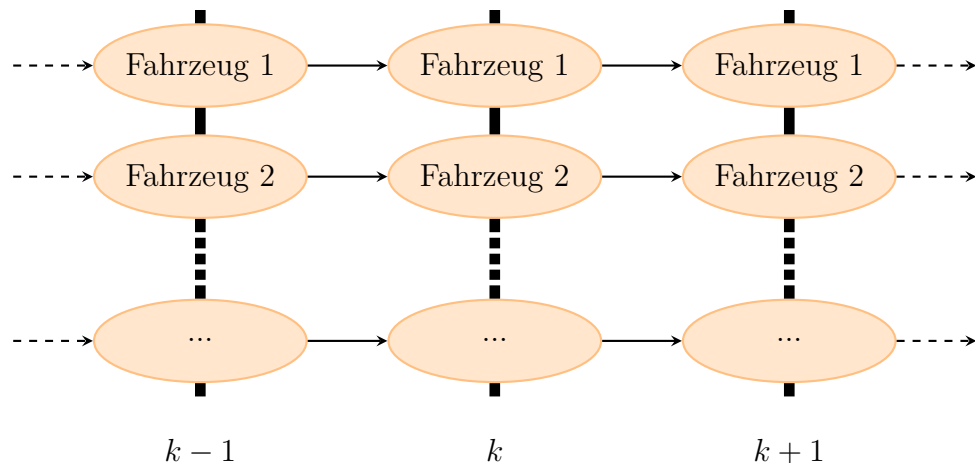
Diese beiden Aspekte zeigen, dass die Entwicklung zuverlässiger und leistungsstarker Prädiktionsalgorithmen für die Funktion zukünftiger FAS eine entscheidende Rolle spielt. Umfeldobjekte müssen erkannt und es muss entschieden werden, ob sie im momentanen Situationskontext relevant sind. Für die Entscheidung, ob ein Fahrzeug relevant ist respektive von ihm eine potentielle Gefahr ausgeht, spielen Fahrzeugtrajektorien eine zentrale Rolle. Die Trajektorien selbst beinhalten dabei den gesamten Verlauf der Fahrzeugzustände über der Zeit bis hin zum vorherge-

sagten Prädiktionshorizont. Ein Ansatz, der Trajektorien von Verkehrsteilnehmern inkl. eines Unsicherheitsmaßes prädiziert, wird im Folgenden vorgestellt.

## 4.2 Lösungsansatz

Das Architekturdiagramm in Abbildung 4.1 beschreibt das grundsätzliche Vorgehen bei der Prädiktion einer Fahrscene mit mehreren Fahrzeugen. An einem diskreten Zeitpunkt  $k$  liegen alle relevanten Informationen aller Fahrzeuge vor. Vor jedem Prädiktionsschritt werden für jedes Fahrzeug die Größen, welche auf die Prädiktion des einzelnen Fahrzeugs Einfluss haben, aus der Fahrscene, der Gesamtheit aller Fahrzeuge, extrahiert (z. B. Relativabstände und -geschwindigkeiten). Der Prädiktionsschritt erfolgt dann für jedes Fahrzeug getrennt auf Basis seines Systemmodells. Eben dieses Systemmodell wird im Rahmen der vorliegenden Arbeit entwickelt und evaluiert.

Um die Übertragbarkeit des Modells auf umliegende Verkehrsteilnehmer zu gewährleisten, werden dabei nur Fahrzeugzustände verwendet, welche durch die Perception der fahrzeuglokalen Sensorik auch von den umliegenden Verkehrsteilnehmern direkt erfasst werden können. Ein so geartetes Prädiktionsmodell basiert lediglich auf der bereits ausgeprägten Dynamik von Fahrzeugen und greift nicht auf Annahmen über die situative Intention des jeweiligen Fahrers zurück. Die Inferenz der Fahrerintention aufgrund der vorliegenden Fahrscene ist ein komplexes Problem, welches in der vorliegenden Arbeit nicht weiter behandelt wird. Ergebnisse einer Inferenz der Fahrerintention können dabei unkompliziert als weitere Eingangsgrößen in den entwickelten Modellen dieser Arbeit dienen.




**Abbildung 4.1:** Architektur der Umfeldprädiktion: Das Verhalten jedes Fahrzeugs wird durch das Systemmodell festgelegt. Vor jedem Prädiktionsschritt werden relevante Informationen über die Fahrzeuge in der Szene ausgetauscht.

Das Prädiktionsproblem lässt sich als Teil des Tracking- bzw. Filterproblems beschreiben, bei welchem die Korrektur der Zustände durch Messungen unterbleibt. Im Rahmen dieser Arbeit wird daher ein Algorithmus zum Objekttracking entwickelt, welcher bei ausbleibenden Messungen die Zustände der zu trackenden Objekte prädiziert.

Parametrische Modelle werden zum Objekttracking bereits erfolgreich angewendet: Unter Zuhilfenahme bekannter physikalischer Zusammenhänge lässt sich das Verhalten eines Objekts beschreiben. Getroffene Annahmen und Vereinfachungen beeinträchtigen bzw. beschränken jedoch die Leistungsfähigkeit der verwendeten Modelle. Parametrische Systemmodelle stellen jedoch i. d. R. wertvolles a priori Wissen über das Verhalten eines Objekts bereit. In der neu entwickelten Methode wird daher ein parametrisches Systemmodell und ein nicht-parametrisches Modell, ein Gauß-Prozess (GP), für eine rekursive bayessche Zustandsschätzung kombiniert und erstmals für die Prädiktion von Fahrzeugtrajektorien angewendet. So lassen sich die systematischen Fehler parametrischer Modelle korrigieren. Zudem können Zusammenhänge und Informationen mit einbezogen werden, für die aus analytischer Sicht keine Beschreibungen vorliegen.

Die zu prüfende Hypothese ist, ob durch die Verwendung der entwickelten semi-parametrischen Prädiktionsmethode Beschränkungen der parametrischen Modelle aufgehoben werden können und die Qualität der Prädiktion von Fahrzeugtrajektorien, insbesondere im Bereich von  $0\text{ s} < t \leq 5\text{ s}$ , gesteigert wird. Zudem soll die neue, semi-parametrische Methode so entworfen werden, dass bei hohen Unsicherheiten des auf Grundlage von Daten trainierten, nicht-parametrischen Anteils – v. a. aufgrund fehlender Trainingsdaten in bestimmten Bereichen des Zustandsraums – das parametrische a priori Modell als Rückfallebene verwendet wird.

### 4.3 Parametrische Methode



**Abbildung 4.2:** Parametrisches Fahrzeugmodell mit linearem Systemmodell  $F$ , nichtlinearem Messmodell  $h$  sowie der Kalmanverstärkung  $K$ .

Für die rekursive Zustandsschätzung können lineare und nichtlineare System- bzw. Messmodelle mit den entsprechenden Filterkonzepten kombiniert werden. Wird, wie in Abbildung 4.2 gezeigt, ein lineares Systemmodell  $F$  und ein nichtlineares Messmodell  $h$  verwendet, kann der Prädiktionsschritt effizient mit einem linearen Kalman Filter (KF) durchgeführt werden. Der Einsatz eines nichtlinearen Filters bringt in diesem Fall keinen weiteren Vorteil, da der KF für lineare Systeme ein optimales Filter ist. Für das nichtlineare Messmodell  $h$  wird jedoch ein Unscented Kalman Filter (UKF) verwendet, der neben dem Extended Kalman Filter (EKF) eine Variante des KF für nichtlineare Systeme darstellt. Die Grundlagen der rekursiven Zustandsschätzung sowie eine Einführung der relevanten Gleichung des in dieser Arbeit verwendeten KF und UKF sind im Anhang A.2 beschrieben.

Für den prädizierten Fahrzeugzustand  $\mathbf{x}_k$  zum Zeitpunkt  $k$ , respektive dessen a priori Wahrscheinlichkeitsverteilung auf Grundlage des vorangegangenen Zustands  $\mathbf{x}_{k-1}$ , gilt

$$p(\mathbf{x}_k|\mathbf{x}_{k-1}) = \mathcal{N}(\mathbf{F}\mathbf{x}_{k-1}, \mathbf{Q}) . \quad (4.1)$$

Dabei wird der Prädiktionsfehler als gaußverteilt mit der konstanten Kovarianz  $\mathbf{Q}$  angenommen. Die Wahrscheinlichkeit einer Messung  $\mathbf{z}_k$  bei gegebenem Zustand  $\mathbf{x}_k$  wird durch das nichtlineare Messmodell

$$p(\mathbf{z}_k|\mathbf{x}_k) = \mathcal{N}(\mathbf{h}(\mathbf{x}_k, \mathbf{s}_k), \mathbf{R}) \quad (4.2)$$

beschrieben. Der Messfehler wird wiederum als gaußverteilt angenommen und mit der konstanten Kovarianz  $\mathbf{R}$  des Messrauschens berücksichtigt. Die eingeführte Hilfsgröße  $\mathbf{s}_k$  enthält hierbei zusätzliche Information, um analog zu Kapitel 2.2.2 die Rücktransformation  $T_{SF}$  des Fahrzeugzustands im entkrümmten Koordinatensystem  $F$  des UFM in das Sensorkoordinatensystem  $S$  durchzuführen. Bspw. sind dafür Kenntnisse über die Dynamik des Ego-Fahrzeugs und die Straßentopologie notwendig, die im Anhang in den Tabellen A.1 und A.2 angegeben sind.

### 4.3.1 Tracking mit kinematischen Bewegungsmodellen

Die grundsätzliche Idee aller Bewegungsmodelle ist, dass eine Masse sich nicht beliebig bewegt, sondern ihrer Trägheit unterworfen ist. Einfache Modelle basieren somit auf dem newtonschen Trägheitsgesetz und es wird entweder eine lineare oder gleichförmig beschleunigte Bewegung angenommen. Nach der gängigen Nomenklatur werden diese nach den Größen bezeichnet, welche über die Zeit als annähernd konstant angenommen werden.

In [24] werden Bewegungsmodelle für das Objekttracking mit Anwendung im Bereich Fahrzeugtracking untersucht. Bei Fahrsituationen, in denen hohe Drehraten der Verkehrsteilnehmer zu erwarten sind, sollten Modelle verwendet werden, welche die Drehrate explizit modellieren. Dies ist z. B. beim nichtlinearen Constant Turn Rate and Velocity (CTRV) bzw. Constant Turn Rate and Acceleration (CTRA) Modell der Fall. Auf Autobahnen und insbesondere nach der Transformation in das Koordinatensystem des UFM treten i. d. R. jedoch kaum hohe Drehraten auf. Zudem ist die Bestimmung der Orientierung eines Objekts i. d. R. sensorisch schwierig und erfolgt daher oft indirekt über den Geschwindigkeitsvektor unter Vernachlässigung des Schwimmwinkels.

Im Rahmen dieser Arbeit werden daher für die Bewegungen der Fahrzeuge die linearen Constant Velocity (CV)

$$\mathbf{F}_{CV} = \begin{bmatrix} 1 & \Delta T \\ 0 & 1 \end{bmatrix} \quad (4.3)$$

bzw. Constant Acceleration (CA) Modelle

$$\mathbf{F}_{CA} = \begin{bmatrix} 1 & \Delta T & \Delta T^2 \\ 0 & 1 & \Delta T \\ 0 & 0 & 1 \end{bmatrix} \quad (4.4)$$

untersucht. Dabei ist  $\Delta T$  die diskrete Zeitschrittweite der Prädiktion und Sampling-Frequenz des Filters. Als triviales Systemmodell wird zudem das Constant Position (CP) Modell mit

$$F_{\text{CP}} = 1 \quad (4.5)$$

verwendet. Die Bewegung eines Fahrzeugs wird dabei auf Grundlage der Repräsentation in Kapitel 2.2.1 und der Überlegungen aus Kapitel 2.2.2 in einen jeweils unabhängigen lateralen und longitudinalen Anteil aufgeteilt.

Stimmt die errechnete Unsicherheit des Filters mit der wahren, gegenüber einer Grundwahrheit beobachteten Unsicherheit überein, so spricht man von einem konsistenten Filter. Abweichend davon kann sich das Filter auch unter- bzw. überschätzen. Eine Überschätzung der Filterqualität ist in der praktischen Anwendung zumeist kritischer als ein Unterschätzen, da im Falle des Überschätzens das Wissen über den Zustand als sicherer angenommen wird, als es in Wirklichkeit der Fall ist. Um dieser Situation entgegenzuwirken, wird das Prozess- bzw. Messrauschen in der praktischen Anwendung oft etwas größer gewählt und so ein eher konservativeres Filter realisiert.

### Prozessrauschen

Bei der Bestimmung des Prozessrauschens wird die Bewegung des Ego-Fahrzeugs auf Grundlage seiner Odometrie in der Ebene betrachtet. Aus oben erwähnten Gründen wird das Messrauschen der Odometriesensorik vernachlässigt, welches ohnehin gegenüber der Umfeldperzeption gering ausfällt. Das Prozessrauschen für die Bewegung eines Fahrzeugs ergibt sich zu

$$\mathbf{Q} = \text{E} \left( (\mathbf{x}_k - \mathbf{F}\mathbf{x}_{k-1})(\mathbf{x}_k - \mathbf{F}\mathbf{x}_{k-1})^\top \right) \quad (4.6)$$

und ist problemspezifisch. Dabei gilt, je agiler das beobachtete Objekt ist, desto höher muss das Prozessrauschen angesetzt werden, um Zustandsänderungen zuzulassen, die vom gewählten Modell nicht abgebildet bzw. vernachlässigt werden.

### 4.3.2 Messmodell als Verknüpfung von Umfeldmodell und Sensorwahrnehmung

Das nichtlineare Messmodell  $\mathbf{h}(\mathbf{x}_k, \mathbf{s}_k)$  wird von der Transformationsvorschrift  $T_{SF}$  abgeleitet und ist im Anhang A.1.2 detailliert beschrieben. Es rechnet die 6 Bewegungszustände eines Objekts, angegeben im Koordinatensystem  $F$  des entkrümmten UFM, in eine zweidimensionale Positionsmessung im Sensorsystem  $S$  um.

#### Messrauschen

Die Standardabweichungen  $\sigma_x$  und  $\sigma_y$  beschreiben die Unsicherheiten entlang der longitudinalen und lateralen Koordinatenrichtung des Sensorsystems  $S$ . Für die Kovarianzmatrix des Messrauschens gilt

$$\mathbf{R} = \begin{bmatrix} \sigma_x^2 & 0 \\ 0 & \sigma_y^2 \end{bmatrix}. \quad (4.7)$$

Für die Umrechnung der Objekte vom UFM werden zusätzlich die Messunsicherheiten der Hilfsgröße  $\mathbf{s}_k$  bzgl. der Dynamik des Ego-Fahrzeugs ( $\sigma_v$ ,  $\sigma_a$  und  $\sigma_{\dot{\varphi}}$ ) sowie der Straßentopologie ( $\sigma_c$ ,  $\sigma_l$  und  $\sigma_\alpha$ ) verwendet.

| Messunsicherheit         | Wert                                 | Beschreibung                                 |
|--------------------------|--------------------------------------|--|
| $\sigma_x$               | 0,2 m                                | Longitudinale Objektposition im Sensorsystem |
| $\sigma_y$               | 0,3 m                                | Laterale Objektposition im Sensorsystem      |
| $\sigma_v$               | 0,01 $\frac{\text{m}}{\text{s}}$     | Geschwindigkeit des Ego-Fahrzeugs            |
| $\sigma_a$               | 0,2 $\frac{\text{m}}{\text{s}^2}$    | Beschleunigung des Ego-Fahrzeugs             |
| $\sigma_{\dot{\varphi}}$ | 0,02 $\frac{\text{rad}}{\text{s}}$   | Drehrate des Ego-Fahrzeugs                   |
| $\sigma_c$               | $5 \cdot 10^{-5} \frac{1}{\text{m}}$ | Krümmung der Fahrbahn                        |
| $\sigma_l$               | 0,1 m                                | Fahrstreifenbreite                           |
| $\sigma_\alpha$          | $2 \cdot 10^{-3} \text{ rad}$        | Orientierung im Fahrstreifen                 |

**Tabelle 4.1:** Messunsicherheiten der Objektpositionen ( $\sigma_x, \sigma_y$ ), Inertialsensorik für die Dynamik des Ego-Fahrzeugs ( $\sigma_v, \sigma_a, \sigma_{\dot{\varphi}}$ ) und Straßentopologie auf Basis der Kamera ( $\sigma_c, \sigma_l, \sigma_\alpha$ ).

Im Rahmen dieser Arbeit wurden die Rauschparameter empirisch und unter der Verwendung von Expertenwissen festgelegt. Die verwendeten Werte sind in Tabelle 4.1 aufgelistet. Der normierte Abstand  $h$  des Ego-Fahrzeugs zur Fahrstreifenmitte wird als exakt angenommen. Dieser tritt immer im Zusammenhang mit der Fahrstreifenbreite  $l$  auf, für deren Messunsicherheit  $\sigma_l$  angegeben ist.

### 4.3.3 Initialisierung neuer Objekte

Um möglichst schnell gute Filterergebnisse für neu erkannte Umfeldobjekte zu erhalten und lange Einschwingphasen zu vermeiden, müssen die Bewegungszustände eines Objekts initialisiert werden. Für die Initialisierung neuer Objekte wird aufgrund der Sensorinformation nur die 2D-Position  ${}_S\mathbf{r}_b = [{}_Sx_b, {}_Sy_b]^\top$  von detektierten Objekten in Sensorkoordinaten  $S$  verwendet.

Die absoluten Unsicherheiten bei Positionsmessungen eines Umfeldobjekts gegenüber einer Referenzposition sind relativ groß, da die Reflexionsbereiche der detektierten Objekte stark abhängig von der gegenseitigen Relativposition und Orientierung sind: Bei einer Folgefahrt bilden sich Reflexionen bevorzugt im Bereich des Hecks des Vorderfahrzeugs aus. Die Länge des Vorderfahrzeugs ist gleichzeitig bei direkter Folgefahrt nur schwer bestimmbar und die Korrektur der Detektion im Heckbereich nur ungenau möglich. Bei Überholvorgängen und damit versetzter Relativposition treten die Reflexionen bevorzugt wiederum im Seitenbereich auf.

Die zeitlichen Ableitungen der Positionen – Geschwindigkeiten und Beschleunigungen – werden über die Zeit vom Filter geschätzt und müssen auf Grundlage der 2D-Position ebenfalls initialisiert werden. Unter der Annahme, dass  ${}_Sx_b$  und  ${}_Sy_b$  unabhängig sind, wird die Initialisierung der Ableitungen beispielhaft für eine

eindimensionale Ortskoordinate  $r$  angegeben. Nach der Finite-Differenzen-Methode ergibt sich aus den seriellen Positionsmessungen eines Umfeldobjekts

$$v_k = \frac{r_k - r_{k-1}}{\Delta T} \quad (4.8)$$

$$a_k = \frac{v_k - v_{k-1}}{\Delta T} = \frac{r_k - 2r_{k-1} + r_{k-2}}{\Delta T^2} . \quad (4.9)$$

Berücksichtigt man die Korrelation  $\rho = \text{cor}(\cdot) = \frac{\text{cov}(\cdot)}{\sigma^2} \in [-1; 1]$  aufeinander folgender Positions- bzw. Geschwindigkeitsmessungen, gilt für die initialen Unsicherheiten

$$\begin{aligned} \sigma_v^2 &= \text{var}\left(\frac{r_k - r_{k-1}}{\Delta T}\right) = \frac{\text{var}(r_k) + \text{var}(r_{k-1}) - 2 \text{cov}(r_k, r_{k-1})}{\Delta T^2} \\ &= \frac{2}{\Delta T^2} (1 - \rho_r) \sigma_r^2 \end{aligned} \quad (4.10)$$

$$\sigma_a^2 = \frac{4}{\Delta T^4} (1 - \rho_r)(1 - \rho_v) \sigma_r^2 \quad (4.11)$$

mit den Korrelationskoeffizienten  $\rho_r$  und  $\rho_v$ . Die Positionsunsicherheit  $\sigma_r \in \{\sigma_x, \sigma_y\}$  sowie die Kovarianzen werden als zeitlich konstant angenommen. Damit ergibt sich für die Korrelationskoeffizienten  $\rho_r$  und  $\rho_v$

$$\sigma_r^2 = \text{var}(r_k) = \text{var}(r_{k-1}) = \text{var}(r_{k-2}) \quad (4.12)$$

$$\rho_r = \text{cor}(r_k, r_{k-1}) = \text{cor}(r_{k-1}, r_{k-2}) \quad (4.13)$$

$$\rho_v = \text{cor}(v_k, v_{k-1}) . \quad (4.14)$$

Es wird angenommen, dass sich während der Periodendauer  $\Delta T = 0,2\text{s}$  die Relativposition zwischen messendem und gemessenem Fahrzeug kaum ändert. Dies gilt insbesondere in Situationen mit gleichen oder ähnlichen Geschwindigkeiten der Objekte und damit nur geringfügig auftretenden Relativgeschwindigkeiten. Diese Annahme ist bspw. auch für den Großteil des Verkehrs auf der Autobahn erfüllt. Daher werden die zeitlich aufeinanderfolgenden Messungen als sehr korreliert betrachtet und  $\rho_r = \rho_v = 0,95$  gewählt. Abschließend wird das inverse Messmodell  $\mathbf{h}^{-1}$  bzw. die Transformation  $T_{FS}$  verwendet, um die gefundene Initialisierung der Zustände und Unsicherheiten im UFM in Frenet-Koordinaten darzustellen.

## 4.4 Semi-parametrische Methode


Um die Leistungsfähigkeit bei der Prädiktion durch maschinelle Lernverfahren zu steigern, gibt es in der Literatur bereits viele Ansätze. U. a. stellen die Autoren von [25] eine Manövererkennung vor. Dabei wird eine Trajektorie für einen FSW bzw. Spurhaltevorgang durch Minimierung einer Gütefunktion aus einem finiten Satz an Beispieltrajektorien ausgewählt, welche zuvor in Testfahrten aufgezeichnet wurden. Für eine Prädiktion über längere Zeiträume wird die endgültige Trajektorie dabei als gewichtete Summe aus der Trajektorie der Manövererkennung und der eines parametrischen Bewegungsmodells bestimmt.

In [26] wird eine Darstellung von Trajektorien als Koeffizienten von Chebyshev-Polynomen vorgestellt. Die Koeffizienten werden als Zustände eines Gaussian Mixture Model (GMM) betrachtet und damit die Wahrscheinlichkeitsverteilung zukünftiger Trajektorien auf Grundlage historischer Trajektorien inferiert [27, 28].

Die Autoren in [29] berechnen aufgrund des aktuellen Fahrzeugzustands sowie weiterer Relativgrößen zum Vorderfahrzeug die zukünftige Fahrtrajektorie. Dabei wird der Zusammenhang des Regressionsproblems wiederum anhand eines GMM gelernt. Vorteilhafterweise wird die Positionsabweichung bereits unter der Annahme konstanter Geschwindigkeit trainiert, um von einer dichteren Datenrepräsentation zu lernen.

Bei der Regelung eines Roboters wird in [30] beschrieben, dass die komplexe Systemdynamik nur unzureichend mit den Gleichungen der Festkörperdynamik abgebildet wird. Effekte wie Reibung und Nachgiebigkeit des Manipulators werden oft vernachlässigt. Für den Einsatz in einer Vorsteuerung wird die Manipulatorendynamik anhand eines GP gelernt und modelliert. Dieses Vorgehen bildet im Gegensatz zum invertierten Dynamikmodell der mechanischen Gleichungen auch bisher unmodellierete, nichtlineare Effekte ab.

Unter Zuhilfenahme physikalischer Zusammenhänge aus Kapitel 4.3.1 lässt sich das Verhalten eines zu trackenden Objekts bereits gut beschreiben und dessen Zustand vorhersagen. Parametrische Systemmodelle stellen somit, wie bereits in der Literatur bekannt, wertvolles a priori Wissen über das Verhalten eines Objekts dar. Bspw. ist die Annahme konstanter Längsgeschwindigkeit oder -beschleunigung für Fahrzeuge auf Autobahnen offensichtlich in weiten Teilen zulässig – jedoch nur solange das Fahrzeug nicht durch externe Einflüsse, z. B. ein langsames Vorderfahrzeug, beeinflusst wird.



**Abbildung 4.3:** Das semi-parametrische Systemmodell setzt sich aus dem parametrischen Anteil  $F$  und der nicht-parametrischen Funktion  $f$  zusammen.

Sowohl die getroffene Annahme, die  $n$ -te Ableitung konstant zu setzen, als auch die Vernachlässigung weiterer Einflussfaktoren, induzieren systematische Prädiktionsfehler. Um diesen Fehler auszugleichen, wird die Korrekturfunktion  $f$  gelernt. Damit wird weiterhin das angesprochene, wertvolle a priori Wissen der parametrischen Modelle verwendet und zusätzlich bleibt die Datenrepräsentation, auf dessen Grundlage die Funktion  $f$  gelernt werden soll, sehr kompakt. Das neue, ergänzte Modell des Filters ist in Abbildung 4.3 gezeigt.

Auf den parametrischen Trackingmodellen aufbauend, werden durch maschinelle Lernverfahren systematische Modellfehler korrigiert und zudem Informationen verwendet, für die keine analytischen Beschreibungen vorliegen. Ein rekursiver bayes-



scher Zustandsschätzer ermöglicht dabei zu einem bestimmten Zeitpunkt die Aussage über die a posteriori Verteilung eines Zustands. Um diesen Vorteil beizubehalten, darf auch das Lernverfahren nicht nur auf ein „maximum likelihood“-Modell führen und den wahrscheinlichsten Zustand ausgeben, sondern muss eine Aussage über die a posteriori Verteilung ermöglichen. Eine Regression anhand von GP ist als bayessche Methode in der Lage, eine eben solche Aussage zu liefern.

In [31] werden für nichtlineare Probleme bayessche Filtermethoden respektive KF basierend auf einem GP vorgestellt. Dabei wird ein EKF vorgestellt, bei welchem die nötige Linearisierung für die Prädiktion der Kovarianz durch die partielle Ableitung der Mittelwertfunktion realisiert wird (GP-EKF). Ebenso wird ein Unscented Kalman Filter (GP-UKF) sowie ein Partikel Filter (GP-PF) vorgeschlagen. Die Autoren von [32] wenden ein GP-EKF bzw. GP-PF an, um das Bewegungsmuster von Fußgängern in einer zuvor festgelegten Umgebung zu lernen und vorherzusagen. In vergleichbarer Form werden in [33] Fahrzeugtrajektorien für eine T-Kreuzung auf Basis einer GP-PF-Architektur prädiziert.

Im Rahmen der vorliegenden Arbeit wird unter Berücksichtigung bisheriger Konzepte die semi-parametrische Filter-Architektur entworfen. Diese vereint die Vorteile der parametrischen und nicht-parametrischen Ansätze: Parametrisch beschriebene Zusammenhänge sind numerisch effizient, einfach nachvollziehbar und prädizieren robust für beliebige a priori Zustände a posteriori Zustandsschätzungen. Nicht-parametrische Modelle wie GP sind sehr flexibel und bilden als Methode des maschinellen Lernens auf Grundlage von Trainingsdaten komplexe Zusammenhänge ab.

Als Eingangsgrößen können sowohl der aktuelle Systemzustand  $\mathbf{x}_k$  als auch weitere Größen verwendet werden, die wiederum mit der Hilfsgröße  $\mathbf{s}_k$  zusammengefasst werden. Das Systemmodell aus (4.1) wird erweitert: Aufgrund des vorherigen Zustands  $\mathbf{x}_k$  und neu, den Trainingsdaten  $\mathcal{D}$  des nicht-parametrischen Anteils, ergibt sich

$$p(\mathbf{x}_k | \mathcal{D}, \mathbf{x}_{k-1}) = \mathcal{N}(\mathbf{F}\mathbf{x}_{k-1} + \mathbf{f}(\mathbf{x}_{k-1}, \mathbf{s}_{k-1}), \mathbf{\Sigma}(\mathbf{x}_{k-1}, \mathbf{s}_{k-1})) . \quad (4.15)$$

Der Fehler eines Prädiktionsschritts wird als unkorreliertes, additives, mittelwertfreies und gaußverteilt Rauschen mit der Varianzmatrix  $\mathbf{\Sigma}_k = \text{diag}([\sigma_1^2, \sigma_2^2, \dots, \sigma_d^2])$  modelliert, d. h. die Fehler der einzelnen Dimensionen  $d$  werden als unabhängig betrachtet. Obwohl die hinzukommende Unsicherheit mit  $\mathbf{\Sigma}_k$  im aktuellen Prädiktionsschritt  $k$  für jede Dimension als unabhängig angenommen wird, wird die Unsicherheit einer Dimension durch das Systemmodell in den nachfolgenden Prädiktionsschritten  $k+1, k+2, \dots$  auch in die übrigen Dimensionen propagiert. Im Unterschied zur konstanten Kovarianzmatrix  $\mathbf{Q}$  in (4.1) ist  $\mathbf{\Sigma}_k = \mathbf{\Sigma}(\mathbf{x}_{k-1}, \mathbf{s}_{k-1})$  tatsächlich abhängig vom aktuellen Zustand und hängt ebenfalls maßgeblich von den Trainingsdaten ab, was im anschließenden Kapitel 4.4.1 dargelegt wird.

Im Rahmen dieser Arbeit wird für das a priori Systemmodell nach der Transformation ins entkrümmte UFM angenommen, dass die laterale Dynamik von der longitudinalen unabhängig ist. Somit wird für jede Richtung ein unabhängiges Systemmodell verwendet. Das Systemmodell  $\mathbf{F}_k\mathbf{x}_{k-1} + \mathbf{f}(\mathbf{x}_{k-1}, \mathbf{s}_{k-1})$  wird zudem durch die zusätzliche, nichtlineare Korrektur  $\mathbf{f}(\mathbf{x}_{k-1}, \mathbf{s}_{k-1})$  insgesamt nichtlinear. Daher muss nun auch für den Prädiktionsschritt ein nichtlineares KF verwendet werden.

### 4.4.1 Der Gauß-Prozess

Im Folgenden wird der Gauß-Prozess (GP) als zentrale Methode dieser Arbeit vorgestellt. Bildet die Funktion  $f : \mathcal{X} \rightarrow \mathbb{R}$  einen Eingangsraum auf einen Ausgangsraum ab, so definiert

$$f \sim \text{GP}(\mu, k) \quad (4.16)$$

mit der Mittelwertfunktion  $\mu : \mathcal{X} \rightarrow \mathbb{R}$  und Kovarianzfunktion  $k : \mathcal{X} \times \mathcal{X} \rightarrow \mathbb{R}$  die Wahrscheinlichkeitsverteilung  $p(f)$  über die Funktion  $f$ . Dies entspricht einem stochastischen Modell der Form

$$y = f(\mathbf{x}) + \epsilon \quad (4.17)$$

mit additivem, mittelwertfreiem, gaußverteilterm Rauschen  $\epsilon \sim \mathcal{N}(0, \sigma_n^2)$  mit der Varianz  $\sigma_n^2$ . Die Mittelwertfunktion wird nachfolgend ohne Beschränkung der Allgemeinheit zu  $\mu = 0$  angenommen.

Am Testpunkt  $\mathbf{x}_*$  berechnet ein GP als bayessche Methode somit die a posteriori Wahrscheinlichkeitsverteilung  $p(f_* | \mathcal{D}, \mathbf{x}_*)$  des zu prädizierenden Funktionswertes  $f_*$  und gehört damit zu den diskriminativen Methoden. Die Menge der Trainingsdaten  $\mathcal{D} = \{\mathbf{X}, \mathbf{y}\}$  bestehen dabei aus der Matrix der Eingangsvektoren  $\mathbf{X} = [\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_n]$  und dem Vektor der skalaren Zielwerte  $\mathbf{y} = [y_1, y_2, \dots, y_n]$ .

Als Kovarianzfunktion zwischen zwei Vektoren  $\mathbf{x}_i$  und  $\mathbf{x}_j$  wird in diesem Fall das weitverbreitete *squared-exponential* Kernel mit automatischer Relevanzerkennung

$$k(\mathbf{x}_i, \mathbf{x}_j) = \sigma_f^2 e^{-\frac{1}{2}(\mathbf{x}_i - \mathbf{x}_j)^\top \mathbf{\Lambda}^{-1}(\mathbf{x}_i - \mathbf{x}_j)} \quad (4.18)$$

mit der Varianz  $\sigma_f^2$  und der Diagonal-Matrix  $\mathbf{\Lambda} = \text{diag}([\lambda_1^2, \lambda_2^2, \dots, \lambda_d^2])$  verwendet. Die charakteristischen Längenskalen  $\lambda_i$  definieren dabei den Einflussbereich der jeweils  $i$ -ten Dimension des Eingangsraums. Große Werte deuten in diesem Zusammenhang auf irrelevante Dimensionen hin.

Aus den Eingangsvektoren der Trainingsdaten unter Anwendung des Kernels aus (4.18) ergibt sich die Gram-Matrix

$$\mathbf{K}_{ff} = \begin{bmatrix} k(\mathbf{x}_1, \mathbf{x}_1) & k(\mathbf{x}_1, \mathbf{x}_2) & \cdots & k(\mathbf{x}_1, \mathbf{x}_n) \\ k(\mathbf{x}_2, \mathbf{x}_1) & k(\mathbf{x}_2, \mathbf{x}_2) & \cdots & k(\mathbf{x}_2, \mathbf{x}_n) \\ \vdots & \vdots & \ddots & \vdots \\ k(\mathbf{x}_n, \mathbf{x}_1) & k(\mathbf{x}_n, \mathbf{x}_2) & \cdots & k(\mathbf{x}_n, \mathbf{x}_n) \end{bmatrix} \quad (4.19)$$

mit den Einträgen  $\mathbf{K}_{ij} = k(\mathbf{x}_i, \mathbf{x}_j)$ . Ist  $k$  eine Kovarianzfunktion, so spricht man bei der Matrix  $\mathbf{K}_{ff}$  von einer Kovarianzmatrix. Mit dem Testeingangsvektor  $\mathbf{x}_*$  definiert man zusätzlich

$$\mathbf{k}_{*f} = [k(\mathbf{x}_*, \mathbf{x}_1), k(\mathbf{x}_*, \mathbf{x}_2), \dots, k(\mathbf{x}_*, \mathbf{x}_n)] \quad (4.20)$$

$$k_{**} = k(\mathbf{x}_*, \mathbf{x}_*) . \quad (4.21)$$

Die Hauptannahme des GP ist, dass die Verbundverteilung der Daten als Stichprobe einer multivariaten Gauß-Verteilung

$$p(\mathbf{f}, f_* | \mathcal{D}, \mathbf{x}_*) = \mathcal{N} \left( \mathbf{0}, \begin{bmatrix} \mathbf{K}_{ff} & \mathbf{k}_{f*} \\ \mathbf{k}_{*f} & k_{**} \end{bmatrix} \right) \quad (4.22)$$

mit  $\mathbf{k}_{f_*} = \mathbf{k}_{*f}^\top$  dargestellt wird.

Für die Inferenz des GP werden die latenten Funktionswerte  $\mathbf{f}$  ausmarginalisiert und es gilt

$$p(f_*|\mathcal{D}, \mathbf{x}_*) = \int p(\mathbf{f}, f_*|\mathcal{D}, \mathbf{x}_*) d\mathbf{f} = \frac{1}{p(\mathcal{D})} \int p(\mathbf{f}, f_*|\mathbf{x}_*)p(\mathcal{D}|\mathbf{f}) d\mathbf{f} \quad (4.23)$$

unter Anwendung des Satzes von Bayes

$$p(\mathbf{f}, f_*|\mathcal{D}, \mathbf{x}_*) = \frac{p(\mathbf{f}, f_*|\mathbf{x}_*)p(\mathcal{D}|\mathbf{f})}{p(\mathcal{D})}. \quad (4.24)$$

Für die bedingte Wahrscheinlichkeit des Modells aus (4.17),

$$p(\mathcal{D}|\mathbf{f}) = \mathcal{N}(\mathbf{f}, \sigma_n^2 \mathbf{I}), \quad (4.25)$$

wird mit  $\sigma_n^2 \mathbf{I}$  berücksichtigt, dass die latenten Funktionswerte  $\mathbf{f}$  i. d. R. nicht direkt für das Training zur Verfügung stehen, sondern lediglich die verrauschten Zielgrößen  $\mathbf{y}$  der Trainingsdaten. Die Addition einer Diagonalmatrix folgt direkt aus der Annahme unabhängigen Rauschens.

Somit ergibt sich aus der Verbundverteilung in (4.22) die bedingte, gaußverteilte, a posteriori Wahrscheinlichkeitsverteilung der Form<sup>1</sup>

$$p(f_*|\mathcal{D}, \mathbf{x}_*) = \mathcal{N}(\mathbf{k}_{*f}(\mathbf{K}_{ff} + \sigma_n^2 \mathbf{I})^{-1} \mathbf{y}, k_{**} - \mathbf{k}_{*f}(\mathbf{K}_{ff} + \sigma_n^2 \mathbf{I})^{-1} \mathbf{k}_{f*}). \quad (4.26)$$

Die beste Schätzung für den Erwartungswert stellt der Mittelwert dieser Verteilung dar:

$$y_* = f_* = \mathbf{k}_{*f}(\mathbf{K}_{ff} + \sigma_n^2 \mathbf{I})^{-1} \mathbf{y} \quad (4.27)$$

Zusätzlich zum Erwartungswert kann mit dem GP als bayesscher Methode eine Aussage über die Varianz am Testpunkt  $\mathbf{x}_*$  gemacht werden.

$$\sigma_{y_*}^2 = \sigma_{f_*}^2 + \sigma_n^2 = k_{**} - \mathbf{k}_{*f}(\mathbf{K}_{ff} + \sigma_n^2 \mathbf{I})^{-1} \mathbf{k}_{f*} + \sigma_n^2 \quad (4.28)$$

Dabei wird wieder  $\sigma_n^2$  addiert, um auf Basis der Varianz des Funktionswerts  $\sigma_{f_*}^2$  die Varianz des Zielwerts  $\sigma_{y_*}^2$  zu bestimmen.

Anhand eines GP lässt sich somit eine beliebige Funktion  $f$  annähern, welche in der Realität i. d. R. als eine Menge diskreter Stützpunkte vorliegt. Zudem zeichnet sich diese Methode durch eine hohe Transparenz und Nachvollziehbarkeit der mathematischen Berechnungen sowie Parameter aus. Als bayessche Methode lassen sich GP auf natürliche Weise mit einer KF-Architektur verbinden, da diese zusätzlich zum erwarteten Schätzwert ebenso Angaben über die zu erwartende Varianz treffen.

<sup>1</sup> Teilt man die n-dimensionale Zufallsvariable  $\mathbf{X} \sim \mathcal{N}(\boldsymbol{\mu}, \boldsymbol{\Sigma})$  wie folgt auf

$$p(\mathbf{X}_1, \mathbf{X}_2) = \mathcal{N}\left(\begin{bmatrix} \boldsymbol{\mu}_1 \\ \boldsymbol{\mu}_2 \end{bmatrix}, \begin{bmatrix} \boldsymbol{\Sigma}_{11} & \boldsymbol{\Sigma}_{12} \\ \boldsymbol{\Sigma}_{21} & \boldsymbol{\Sigma}_{22} \end{bmatrix}\right),$$

ergibt sich die Wahrscheinlichkeit für  $\mathbf{X}_2$  unter der Bedingung  $\mathbf{X}_1 = \mathbf{x}_1$  zu

$$p(\mathbf{X}_2|\mathbf{X}_1 = \mathbf{x}_1) = \mathcal{N}(\boldsymbol{\mu}_2 + \boldsymbol{\Sigma}_{21} \boldsymbol{\Sigma}_{11}^{-1}(\mathbf{x}_1 - \boldsymbol{\mu}_1), \boldsymbol{\Sigma}_{22} - \boldsymbol{\Sigma}_{21} \boldsymbol{\Sigma}_{11}^{-1} \boldsymbol{\Sigma}_{12}).$$

Die resultierende Kovarianz-Matrix ist dabei das Schur-Komplement zu  $\boldsymbol{\Sigma}_{11}$  in der ursprünglichen Kovarianz-Matrix  $\boldsymbol{\Sigma}$ . Im vorliegenden Fall gilt zudem  $\boldsymbol{\mu}_1 = \boldsymbol{\mu}_2 = \mathbf{0}$  sowie  $\boldsymbol{\Sigma}_{12} = \boldsymbol{\Sigma}_{21}^\top$ .

### 4.4.2 Optimierung der Hyperparameter

Die Parameter  $\mathcal{H} = \{\Lambda, \sigma_f, \sigma_n\}$ , welche den GP zusammen mit den Trainingsdaten definieren, werden Hyperparameter genannt.

Aus (4.22) ergibt sich unter Berücksichtigung des Rauschens die Randverteilung

$$p(\mathbf{y}|\mathbf{X}, \mathcal{H}) = \mathcal{N}(\mathbf{0}, \mathbf{K}_{ff} + \sigma_n^2 \mathbf{I}), \quad (4.29)$$

welche mit  $\mathbf{K}_{yy} = \mathbf{K}_{ff} + \sigma_n^2 \mathbf{I}$  die Wahrscheinlichkeit der Daten unter dem gegebenen Modell beschreibt. Entsprechend ist die logarithmische Randverteilung

$$\ln p(\mathbf{y}|\mathbf{X}, \mathcal{H}) = -\frac{1}{2} \mathbf{y}^\top \mathbf{K}_{yy}^{-1} \mathbf{y} - \frac{1}{2} \ln |\mathbf{K}_{yy}| - \frac{n}{2} \ln 2\pi \quad (4.30)$$

mit der Determinante  $|\cdot|$ . Der erste Term  $-\frac{1}{2} \mathbf{y}^\top \mathbf{K}_{yy}^{-1} \mathbf{y}$  beinhaltet die Trainingsziele  $\mathbf{y}$  und beschreibt damit wie gut die Daten durch das Modell abgebildet werden. Der Term  $-\frac{1}{2} \ln |\mathbf{K}_{yy}|$  bestraft die Modellkomplexität und  $-\frac{n}{2} \ln 2\pi$  ist eine Normalisierungskonstante.

Um die optimalen Modellparameter respektive Hyperparameter zu bestimmen, soll die Modellwahrscheinlichkeit maximiert werden. Dafür wird die logarithmische Randverteilung mit einem gradientenbasierten Verfahren maximiert:

$$\arg \max_{\mathcal{H}} \ln p(\mathbf{y}|\mathbf{X}, \mathcal{H}) \quad (4.31)$$

Für diesen Zweck werden die partiellen Ableitungen<sup>2</sup> bezüglich der einzelnen Hyperparameter bestimmt:

$$\frac{\partial}{\partial \mathcal{H}_i} \ln p(\mathbf{y}|\mathbf{X}, \mathcal{H}) = \frac{1}{2} \mathbf{y}^\top \mathbf{K}_{yy}^{-1} \frac{\partial \mathbf{K}_{yy}}{\partial \mathcal{H}_i} \mathbf{K}_{yy}^{-1} \mathbf{y} - \frac{1}{2} \text{tr} \left( \mathbf{K}_{yy}^{-1} \frac{\partial \mathbf{K}_{yy}}{\partial \mathcal{H}_i} \right) \quad (4.32)$$

Zur Bewertung der Prädiktionsqualität des Modells wird die Vorhersagewahrscheinlichkeit für einen Validierungsdatenpunkt  $\mathbf{x}_i$  mit  $y_i$  sowie der auf Basis von (4.26) erfolgten Vorhersage  $y_{\star|i}$  und  $\sigma_{y_{\star|i}}^2$  definiert:

$$p(y_i|\mathcal{D}, \mathcal{H}, \mathbf{x}_i) = \mathcal{N}(y_i - y_{\star|i}, \sigma_{y_{\star|i}}^2) \quad (4.33)$$

Für einen Validierungsdatensatz mit  $l$  Datenpunkten ist die logarithmische Vorhersagewahrscheinlichkeit

$$\sum_{i=1}^l \ln p(y_i|\mathcal{D}, \mathcal{H}, \mathbf{x}_i) = -\frac{l}{2} \ln 2\pi - \frac{1}{2} \sum_{i=1}^l \left( \ln \sigma_{y_{\star|i}}^2 + \frac{(y_i - y_{\star|i})^2}{\sigma_{y_{\star|i}}^2} \right) \quad (4.34)$$

und wird herangezogen, um bei der Optimierung der Hyperparameter Überanpassung zu vermeiden.

<sup>2</sup> Ableitungen der Elemente einer inversen Matrix:

$$\frac{\partial}{\partial a} \mathbf{A}^{-1} = -\mathbf{A}^{-1} \frac{\partial \mathbf{A}}{\partial a} \mathbf{A}^{-1}$$

mit der Matrix  $\frac{\partial \mathbf{A}}{\partial a}$ , welche die elementweisen Ableitungen enthält.

Für den Logarithmus der Determinante einer Matrix gilt:

$$\frac{\partial}{\partial a} \ln |\mathbf{A}| = \text{tr} \left( \mathbf{A}^{-1} \frac{\partial \mathbf{A}}{\partial a} \right)$$


### 4.4.3 Approximationsmethoden

Während des Trainings, der Optimierung der logarithmischen Randverteilung in (4.30), muss im Wesentlichen die  $n \times n$  Matrix  $\mathbf{K}_{yy}$  invertiert werden. Die Berechnungskomplexität von Standardmethoden für die Invertierung einer positiv definiten, symmetrischen Matrix beläuft sich auf  $\mathcal{O}(n^3)$  mit der Anzahl  $n$  zum Training verwendeter Datenpunkte. Bei der Inferenz wird der a posteriori Erwartungswert mit  $\mathcal{O}(n)$  und die Varianz mit  $\mathcal{O}(n^2)$  berechnet. Diese Eigenschaften beschränken den Einsatz von GP – wie andere nicht-parametrische Methoden – auf wenige (tausend) Trainingspunkte.

Um dem Nachteil der hohen Berechnungskomplexität bei umfangreichen Trainingsdatensätzen zu begegnen, werden in [34] Projected Latent Variables (PLV) bzw. der Ansatz des Deterministic Training Conditional (DTC) vorgeschlagen und dafür  $m < n$  latente Variablen  $\mathbf{u} = [u_1, \dots, u_m]$  eingeführt. Im Folgenden wird diese grundlegende Annahme der Approximationsmethoden für GP weiter ausgeführt.



- (a) Vollständiger Graph der Verbundverteilung eines GP. Alle Trainings- und Testfunktionen stehen aus Informationssicht miteinander in Kontakt.



- (b) GP unter der Annahme bedingter Unabhängigkeit der latenten Trainings- und Testfunktionen bei gegebenem  $\mathbf{u}$ . Die Kommunikation findet ausschließlich über den Vektor  $\mathbf{u}$  der latenten Variablen statt.

Abbildung 4.4: GP Approximation.

Für die Verbundverteilung gilt

$$p(f_*, \mathbf{f}) = \int p(f_*, \mathbf{f} | \mathbf{u}) p(\mathbf{u}) d\mathbf{u} \quad (4.35)$$

$$\approx \int p(f_* | \mathbf{u}) p(\mathbf{f} | \mathbf{u}) p(\mathbf{u}) d\mathbf{u} \quad (4.36)$$


mit  $p(\mathbf{u}) = \mathcal{N}(\mathbf{0}, \mathbf{K}_{uu})$ . Während die Aussage in Gleichung (4.35) noch exakt ist, stellt (4.36) bereits die Approximation eines GP dar: Die Verbundverteilung von  $\mathbf{f}$  und  $f_*$  ist bedingt unabhängig bei gegebenem  $\mathbf{u}$ . Dieser Zusammenhang ist in Abbildung 4.4 graphisch dargestellt.

Eine Zusammenfassung und vereinheitlichte Darstellung von Approximationsmethoden für GP ist in [35] gegeben. In dieser Arbeit wird als Approximationsmethode Sparse Pseudo-input Gaussian Processes (SPGP) bzw. Fully Independent Training

Conditional (FITC) nach [36] verwendet. Damit ergibt sich für die Approximation der Verbundverteilung

$$p(f_{\star}, \mathbf{f}) \approx \mathcal{N} \left( \mathbf{0}, \begin{bmatrix} \mathbf{Q}_{ff} - \text{diag}(\mathbf{Q}_{ff} - \mathbf{K}_{ff}) & \mathbf{Q}_{f\star} \\ \mathbf{Q}_{\star f} & k_{\star\star} \end{bmatrix} \right) \quad (4.37)$$

mit  $\mathbf{Q}_{ab} = \mathbf{K}_{au} \mathbf{K}_{uu}^{-1} \mathbf{K}_{ub}$ . Die Diagonale der näherungsweise Kovarianzmatrix der Trainingsdaten wird durch die exakte Varianz ersetzt. Für die Testdaten wird die exakte Kovarianzmatrix verwendet. Der Informationsaustausch zwischen den einzelnen Trainingsdaten als auch zwischen den Trainings- und Testdaten findet allein über die latenten Variablen  $\mathbf{u}$  statt (Abbildung 4.5).



**Abbildung 4.5:** FITC: Alle latenten Trainings- und Testfunktionen sind bedingt unabhängig bei gegebenem  $\mathbf{u}$ .

Die latenten Variablen  $\mathbf{u}$  korrespondieren mit der Menge der Stützpunkte  $\mathbf{X}_u$ . Während über die latenten Variablen  $\mathbf{u}$  immer marginalisiert werden kann, beeinflusst die Wahl der Stützpunkte  $\mathbf{X}_u$  das Ergebnis der Approximation. Die Stützstellen können beliebig gewählt werden und müssen keine Untermenge der Trainingsvektoren sein. Somit handelt es sich ebenfalls um frei wählbare Parameter des GP, welche analog zu den übrigen Hyperparametern optimiert werden können. Eine zufällige Untermenge aus den Trainingspunkten bietet i. d. R. gute Initialwerte für den Beginn der Optimierung.

Durch die Approximation reduziert sich der numerische Aufwand für das Training erheblich zu  $\mathcal{O}(m^2n) \ll \mathcal{O}(n^3)$  mit  $m < n$ . Die Komplexität zur Berechnung von Erwartungswert und Varianz profitiert ebenfalls und ergibt sich zu  $\mathcal{O}(m)$  respektive  $\mathcal{O}(m^2)$ . Im Rahmen dieser Arbeit wird ein Datensatz mit über 100 000 Trainingspunkten mit wenigen hundert Stützpunkten angenähert. Die benötigte Trainingszeit wird so ca. um den Faktor  $10^7$  reduziert und das Problem überhaupt erst handhabbar.

### Vektorwertiger Gauß-Prozess

In [37] werden Ansätze vorgestellt, um Kernel-Methoden wie bspw. GP auf vektorwertige Funktionen mit  $d$  Dimensionen zu erweitern. In [38] wird darauf hingewiesen, dass die Lernrate dabei effektiv der eines skalaren GP mit  $dn$  Trainingspunkten entspricht. Dies führt bei vektorwertigen GP zu einem erhöhten Trainingsaufwand von  $\mathcal{O}(d^3n^3) \gg \mathcal{O}(dn^3)$  gegenüber  $d$  unabhängigen, skalarwertigen GP. Aufgrund dieser Betrachtung und des bereits rechenintensiven Problems mit der großen Menge an Datenpunkten wird von der vektorwertigen Erweiterung von GP im Rahmen dieser Arbeit abgesehen.

## 4.5 Modellierung und Evaluation der Prädiktion

Jede Dimension der Korrekturfunktion  $\mathbf{f} = [f_1, \dots, f_d]^\top$  wird auf Basis der Trainingsdaten mit einem unabhängigen GP gelernt. Der Fehler  $\Delta \mathbf{x}_k = \mathbf{x}_k - \mathbf{F}_k \mathbf{x}_{k-1}$  des parametrischen Modells aus Kapitel 4.3 folgt bei der Betrachtung einer einzelnen Dimension daher dem skalaren, stochastischen Modell aus (4.17) mit der Form

$$\Delta x_k = f(\mathbf{x}_k, \mathbf{s}_k) + \epsilon \quad (4.38)$$

mit  $\epsilon \sim \mathcal{N}(0, \sigma^2)$ .

Für die Evaluierung der Modelle wird eine knapp 16-minütige Testfahrt zufällig ausgewählt und beim Training zurückgehalten. Eine Beschreibung der wichtigsten Größen ist in Abbildung 4.6 visualisiert.

Zu Beginn jeder Fahrt wird der momentan befahrene Fahrstreifen als Referenz festgelegt. Für die normierte, laterale Position  $y$  im Fahrstreifen sind in der Testfahrt drei Bereiche unterscheidbar: Zu Beginn ( $t < 150$  s) treten sehr viele FSW auf bevor das Fahrzeug für  $150 \text{ s} < t < 600$  s konstant auf einem Fahrstreifen fährt. Zum Ende hin treten für  $t > 600$  s wieder vermehrt FSW auf.

Betrachtet man die Geschwindigkeit  $\dot{x}$  des Ego-Fahrzeugs, fällt ganz zu Beginn die Phase großer Beschleunigung auf, bevor relativ konstant mit  $120 \frac{\text{km}}{\text{h}} = 33 \frac{1}{3} \frac{\text{m}}{\text{s}}$  gefahren wird. Im Bereich  $500 \text{ s} < t < 900$  s wird dann bis auf  $48,6 \frac{\text{m}}{\text{s}}$  beschleunigt und anschließend wieder verzögert. Am Ende erfolgt noch ein Beschleunigungsvorgang von  $24 \frac{\text{m}}{\text{s}}$  auf  $38 \frac{\text{m}}{\text{s}}$ .

Zudem sind der Relativabstand  $x_f$  und die Relativgeschwindigkeit  $\dot{x}_f$  zum jeweils relevanten Vorderfahrzeugs dargestellt – sofern ein Objekt als Vorderfahrzeug erkannt wurde. Im Verlauf der Fahrt werden 43 unterschiedliche Objekte als relevante Vorderfahrzeuge identifiziert. Bspw. sind für  $t \approx 320$  s und  $t \approx 570$  s Vorderfahrzeuge mit negativer Relativgeschwindigkeit gezeigt, welche Bremsreaktionen des eigenen Fahrzeugs bewirken.

Der evaluierte Prädiktionshorizont beträgt  $0 \text{ s} < t_+ \leq 5$  s. Zur Beurteilung wird der Effektivwert (RMS), engl. „root mean square“, des Fehlers betrachtet.

$$\text{RMS}(e) = \sqrt{\frac{1}{n} \sum_i^n e_i^2} \quad (4.39)$$

### 4.5.1 Laterale Dynamik

Es soll das laterale Verhalten eines Fahrzeugs im Kontext von Fahrstreifen gelernt werden. In Abbildung 4.7 wird die laterale Position eines Fahrzeugs in einer fünfminütigen Fahrt gezeigt. Das Fahrzeug fährt im Verlauf dieser Fahrt auf bis zu 3 verschiedenen Fahrstreifen. Auf welchen Fahrstreifen die Fahrt jedoch absolut stattfindet, wenn man diese bspw. vom rechten bis zum linken Fahrbahnrand durchnummeriert, ist i. d. R. nicht bekannt.

Ohnehin wird die Annahme getroffen, dass die laterale Fahrzeugdynamik weitgehend unabhängig vom absolut befahrenen Fahrstreifen ist. Daher wird die normierte, laterale Position des Fahrzeugs in den Einheitskreis projiziert:

$$\text{circ} : y \rightarrow \begin{bmatrix} \cos(2\pi y) \\ \sin(2\pi y) \end{bmatrix} \quad (4.40)$$

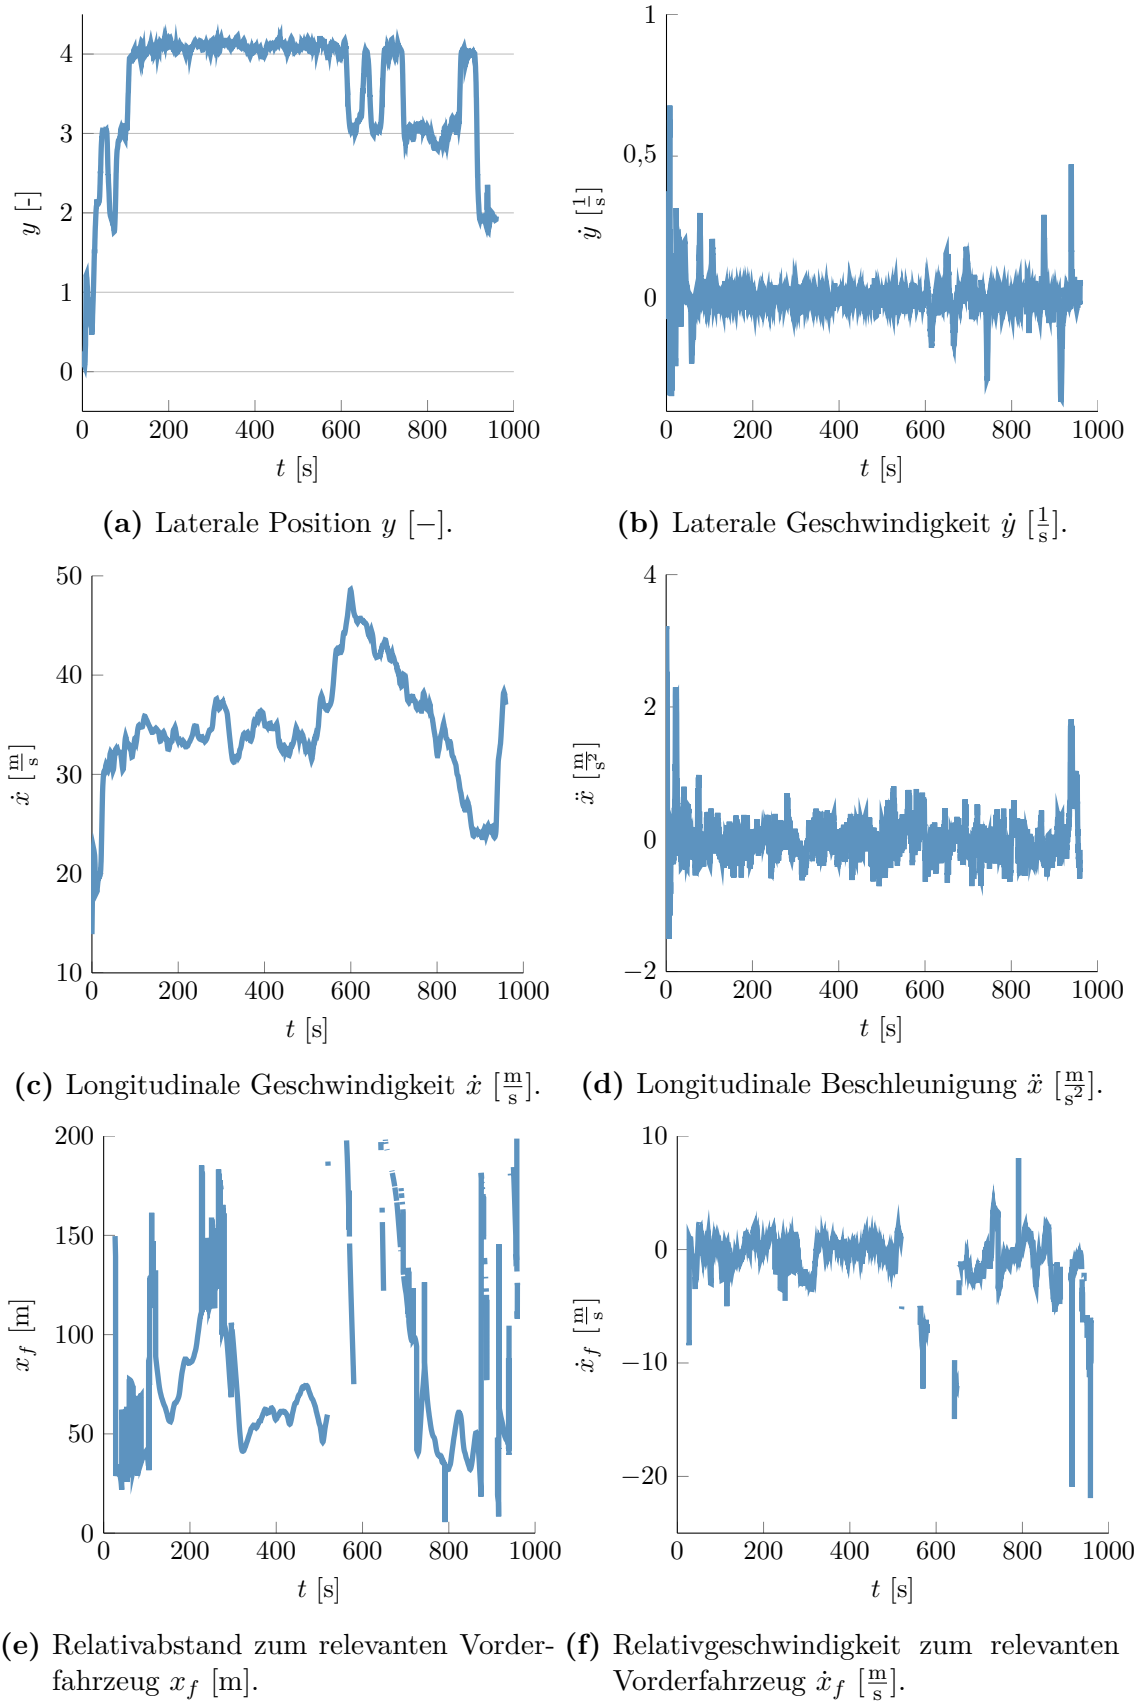




Abbildung 4.6: Beschreibung der Testfahrt.





(a) Laterale Position, normiert auf die Fahrstreifenbreite.



(b) Laterale Position als trigonometrische Funktionen im Einheitskreis.


**Abbildung 4.7:** Verdichtung des Merkmalraumes durch Projektion  $\mathbf{circ}(y)$  der lateralen Position in den Einheitskreis.

Eine einfache Modulo-Division der Art  $(y + 0.5) \bmod 1 - 0.5$  oder  $\frac{\arctan(\tan(\pi y))}{\pi}$  würde zu einer nicht stetigen Beschreibung im Verlauf eines FSW führen und die Zusammenhänge im Merkmalsraum unzureichend abbilden: Die Positionen am linken/rechten Rand des Fahrstreifens – und alle damit verknüpften Eigenschaften – lägen dann nicht in der Nähe des rechten/linken Randes des jeweiligen Nachbarfahrstreifens, sondern maximal weit entfernt. Die eingeführte Transformation in den Einheitskreis ermöglicht hier eine durchgängige Beschreibung.

Der GP zur Korrektur der lateralen Geschwindigkeit  $\dot{y}$  mit CV Prior ist in Abbildung 4.8 gezeigt.

$$\mathbf{f}_y : \begin{bmatrix} \mathbf{circ}(y) \\ \dot{y} \end{bmatrix} \rightarrow \begin{bmatrix} \Delta \dot{y} \\ \Delta \dot{y} \end{bmatrix} \quad (4.41)$$

Als Eingangsdaten werden die normierte, zirkuläre, laterale Position  $y$  sowie die laterale Geschwindigkeit  $\dot{y}$  verwendet. Der Funktionswert des GP, die Korrektur  $\Delta \dot{y}$ , ist farblich kodiert. Die Standardabweichung  $\sigma_{\Delta \dot{y}}$  wird durch ein Konturdiagramm mit 10 Höhenlinien beschrieben. Es zeigt die Unsicherheit, welche sich aufgrund der Trainingsdaten im Bereich zwischen  $0,015 \frac{1}{\text{s}}$  (unterhalb der weißen Höhenlinie) und  $0,192 \frac{1}{\text{s}}$  (oberhalb der schwarzen Höhenlinie) bewegt. In Bereichen, wo keine Trainingsdaten in der näheren Umgebung verfügbar waren, ist die Unsicherheit entsprechend hoch.



**Abbildung 4.8:** GP für die Korrektur des lateralen CV Priors.

Über einen Großteil der Fahrt befinden sich die Fahrzeuge nahe dem Koordinatenursprung  $[y, \dot{y}] \approx [0, 0]$  – im Bereich der Fahrstreifenmitte mit kaum lateraler Geschwindigkeit. Ein Fahrzeug, welches mit  $[y, \dot{y}] > [0, 0]$  leicht vom Ursprung nach links driftet, wird abgebremst ( $\Delta \dot{y} < 0 \frac{1}{\text{s}}$ ). Ein Fahrzeug, welches mit  $[y, \dot{y}] < [0, 0]$  sich nach rechts bewegt, wird beschleunigt ( $\Delta \dot{y} > 0 \frac{1}{\text{s}}$ ). In beiden Fällen wird das Fahrzeug wieder zur Fahrstreifenmitte zurückgeführt. Somit wird das CV-Modell

faktisch um einen Potentialtopf erweitert, der ungefähr um die Fahrstreifenmitte zentriert ist. Er resultiert aus den kleinen, lateralen Pendelbewegungen, die auch in den Messdaten, bspw. in Abbildung 4.7, zu beobachten sind.

Der Bereich hoher Sicherheit mit niedrigem  $\sigma_{\Delta y}$  aufgrund der hohen Anzahl von Trainingsdaten beschreibt die Form eines liegenden „H“. Dies liegt an den grundsätzlich zwei Möglichkeiten den Fahrstreifen nach links respektive rechts zu wechseln: Führt ein Fahrzeug einen FSW durch, so muss es, um den Potentialtopf zu verlassen, ausreichend Querablage und -geschwindigkeit aufbauen. Für einen FSW bewegt sich das Fahrzeug vom Ursprung auf der zirkulären  $2\pi y$ -Achse zu einem Bildrand, taucht sofort am anderen Bildrand wieder auf und kehrt zum Ursprung zurück – d. h. die Positionen am linken und rechten Bildrand in Abbildung 4.8 entsprechen sich. Im gleichen Zeitraum wird Quergeschwindigkeit auf- und wieder abgebaut. Für FSW nach links gilt i. d. R.  $\dot{y} > 0$ ; nach rechts  $\dot{y} < 0$ . Die Extrema der Quergeschwindigkeit liegen in den Bereichen, wenn das Fahrzeug die Fahrbahnmarkierung respektive den Bildrand, überschreitet. So entsteht die Menge der Datenpunkte in Form eines liegenden „H“.



Bei einem FSW nach links ist bspw. gut zu erkennen, dass das Fahrzeug nach dem Überwinden des Potentialtopfes sogar zusätzlich Geschwindigkeit in Richtung des nächsten Fahrstreifens aufbaut ( $\Delta \dot{y} > 0 \frac{1}{s}$ , roter Bereich links oben). Hat es den neuen Zielfahrstreifen erreicht, wird die Quergeschwindigkeit wieder abgebaut ( $\Delta \dot{y} < 0 \frac{1}{s}$ , blauer Bereich rechts oben) und das Fahrzeug kehrt zur nun neuen Fahrstreifenmitte zurück. Fahrzeuge, die einen FSW nach rechts ausführen, nehmen in Abbildung 4.8 den Pfad im unteren Bereich nach rechts, um dann vom linken Bildrand zur neuen Fahrstreifenmitte zu gelangen.

Die Verbesserung der semi-parametrischen gegenüber der rein parametrischen Prädiktion für die Testfahrt aus Abbildung 4.6 werden in Abbildung 4.9 aufgezeigt. Das CV-Modell erzielt erwartungsgemäß für kurze Prädiktionszeiten im Vergleich zum CP-Modell bessere Ergebnisse. Da FSW i. d. R. selten vorkommen, führt bei langen Prädiktionszeiten der Drift mit konstanter Quergeschwindigkeit beim CV-Modell im Allgemeinen zum Verlassen des Fahrstreifens und damit zu einem schlechteren Ergebnis gegenüber CP, da sich Fahrzeuge grundsätzlich an den Fahrstreifen ausrichten.

Durch die Ergänzung mit einem GP kann die Prädiktionsqualität gesteigert werden. Für das CV-Modell wurde für  $t_+ = 5$  s der Geschwindigkeitsfehler um 15% reduziert; der Positionsfehler sogar um 22%. Der Vorteil der semi-parametrischen Methode für lange Prädiktionszeiten kommt besonders in Bereichen mit vielen FSW zum Tragen ( $t < 150$  s und  $t > 600$  s). Dafür wird für  $t_+ = 5$  s die Differenz der quadratischen Fehler von semi-parametrischer und rein parametrischer Prädiktion gebildet. Werden die Werte über die Zeit akkumuliert, ergibt sich (unter Verwendung der Notation für kontinuierliche Funktionen) die Stammfunktion als unbestimmtes Integral

$$\int \left( e_{\text{GP}}^2 - e_{\text{Prior}}^2 \right)_{t_+=5\text{s}} dt . \quad (4.42)$$

Negative Werte stellen größere Fehler des parametrischen Modells dar. Insbesondere in den Bereichen mit vielen FSW zeigen die semi-parametrischen Modelle einen Vorteil gegenüber den parametrischen Modellen.

(a) Positionsfehler  $e_y$ .(b) Geschwindigkeitsfehler  $e_{\dot{y}}$ .(c) Vergleich der akkumulierten Fehlerquadrate für die Position  $y$  und den Prädiktionzeitpunkt  $t_+ = 5$  s.**Abbildung 4.9:** Prädiktionsfehler der lateralen Dynamik.

Im Bereich  $150\text{ s} < t < 600\text{ s}$  verharrt das Fahrzeug auf seinem Fahrstreifen. Dabei weicht die mittlere Position im Fahrstreifen bei der Testfahrt in dieser Zeit vom gelernten statistischen Wert der Trainingsfahrten ab ( $y \approx -0,16\text{ rad}$ ) und veranlasst insbesondere den GP mit CP Prior zu (unnötigen) Korrekturingriffen. Darunter leidet folglich die Prädiktionsqualität gegenüber dem parametrischen CP-Modell in diesem Bereich. Eine Personalisierung, d. h. die Einbeziehung der individuellen Eigenheiten des einzelnen Fahrers, stellt hier einen möglichen Ansatz zur weiteren Verbesserung des Verfahrens dar.

## 4.5.2 Longitudinale Dynamik

In der longitudinalen Bewegung des Fahrzeugs treten genau zwei unterschiedliche Fahrsituationen auf: die freie Fahrt und die Fahrgefahrt. Bei der Fahrgefahrt werden zusätzlich der Abstand  $x_f$  und die Relativgeschwindigkeit  $\dot{x}_f$  zum Vorderfahrzeug als weitere Eingangsgrößen verwendet. Diese wurden im rein parametrischen Modell bisher nicht berücksichtigt. Die a priori Schätzung des CA-Modells wird entsprechend ergänzt. Die gelernten Korrekturfunktionen sind in Abbildung 4.10 gegeben.

$$\mathbf{f}_x : \left. \begin{array}{l} \begin{bmatrix} \dot{x} \\ \ddot{x} \end{bmatrix}, \text{ freie Fahrt} \\ \begin{bmatrix} \dot{x} \\ \ddot{x} \\ x_f \\ \dot{x}_f \end{bmatrix}, \text{ Fahrgefahrt} \end{array} \right\} \rightarrow \begin{bmatrix} \Delta x \\ \Delta \dot{x} \\ \Delta \ddot{x} \end{bmatrix} \quad (4.43)$$

Bei der freien Fahrt ist das Fahrzeug in longitudinaler Fahrtrichtung keinen externen Einflüssen unterworfen und das Fahrverhalten hängt allein vom Fahrzeugzustand selbst ab. Als Eingangsgrößen sind daher die Geschwindigkeit  $\dot{x}$  und Beschleunigung  $\ddot{x}$  relevant. Für die Korrektur der Geschwindigkeit  $\Delta \dot{x}$  zeigt das Konturdiagramm die Unsicherheit im Bereich  $\sigma_{\Delta \dot{x}} \in [0,039; 0,080] \frac{\text{m}}{\text{s}}$ . Bis auf einzelne Ausreißer liefert der GP im Wesentlichen eine Aussage im Bereich zwischen  $20 \frac{\text{m}}{\text{s}}$  und  $60 \frac{\text{m}}{\text{s}}$ . Insbesondere ist gut zu erkennen, wie bei hoher Unsicherheit der Korrekturwert verschwindet:  $\Delta \dot{x} \rightarrow 0$ . Aufgrund von fehlenden Trainingsdaten wird vom GP keine Korrektur durchgeführt und das Systemverhalten richtet sich allein nach dem parametrischen Prädiktionsmodell.

Beschleunigt das Fahrzeug ( $\ddot{x} > 0 \frac{\text{m}}{\text{s}^2}$ ) wird die a priori Geschwindigkeit auf Grundlage des CA-Modells tendenziell etwas reduziert (blauer Bereich). Bei einer Bremsung ( $\ddot{x} < 0 \frac{\text{m}}{\text{s}^2}$ ) wird sie angehoben (roter Bereich). Dies liegt darin begründet, dass Beschleunigungen und Verzögerungen prinzipiell zeitlich begrenzte Vorgänge sind und der Fahrer sein Einwirken auf die Fahrzeuggeschwindigkeit nach einer gewissen Zeit wieder zurücknimmt und beendet. Folglich ergibt sich im Vergleich zum parametrischen Modell eine über die Zeit reduzierte Einwirkung.

Ist ein Vorderfahrzeug vorhanden, welches das Fahrverhalten des eigenen Fahrzeugs beeinflusst, so werden als Eingangsgrößen des GP zusätzlich zum Zustand des Ego-Fahrzeugs der relative Abstand  $x_f$  und die Relativgeschwindigkeit  $\dot{x}_f$  zum Vorderfahrzeug verwendet. Diese Einflussfaktoren sind im CA-Modell gar nicht modelliert. Für eine unbeschleunigte Fahrt mit einer Geschwindigkeit von  $\dot{x} = 35 \frac{\text{m}}{\text{s}}$  ist




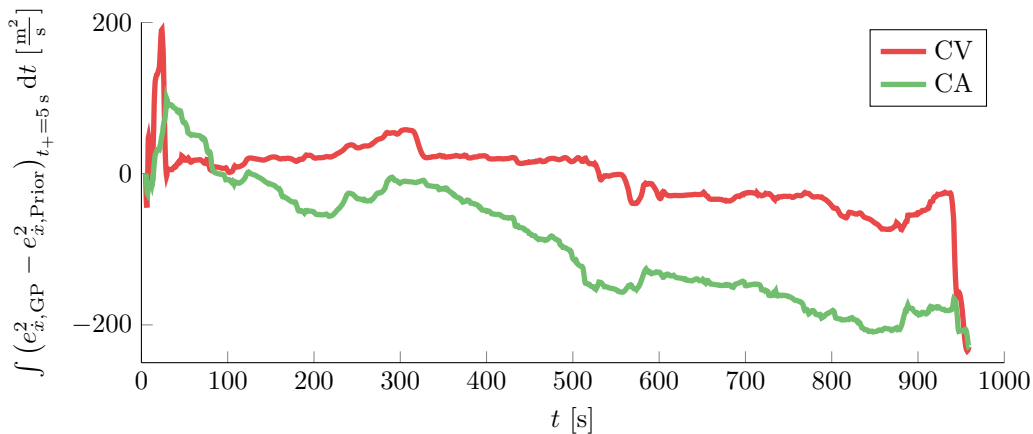


Abbildung 4.10: GP für die Korrektur des longitudinalen CA Priors.

bei einem Zeitabstand von  $t_{\text{THW}} = 1$  s ein Regelverhalten auf das Vorderfahrzeug abhängig von der Relativgeschwindigkeit  $\dot{x}_f$  zu erkennen. Führt das Vorderfahrzeug langsamer bzw. schneller, verringert bzw. erhöht auch das nachfolgende Fahrzeug seine Geschwindigkeit.

Bei Zeitabständen von  $t_{\text{THW}} < 3$  s, das entspricht  $x_f < 105$  m bei  $\dot{x} = 35 \frac{\text{m}}{\text{s}}$ , ist zu erkennen, dass bei nur geringer Relativgeschwindigkeit ( $\dot{x}_f \approx 0 \frac{\text{m}}{\text{s}}$ ) versucht wird, einen Wunschabstand zum Vorderfahrzeug einzuregeln. Bei  $t_{\text{THW}} > 3$  s ist dies nicht mehr der Fall: Trotz geringfügig positiver Relativgeschwindigkeit zum Vorderfahrzeug ( $\dot{x}_f > 0 \frac{\text{m}}{\text{s}}$ ) folgt das Ego-Fahrzeug nicht nach ( $\Delta\dot{x} < 0 \frac{\text{m}}{\text{s}}$ ).

Anhand des Konturdiagramms ist ersichtlich, dass ab einer Distanz von  $x_f > 200$  m keine sicheren Aussagen mehr möglich sind. Dies ergibt sich direkt aus der maximalen Sensorreichweite. Ab einer gewissen Entfernung werden keine Vorderfahrzeuge mehr erkannt und es existieren für diesen Fall somit auch keine Trainingsdaten. Ein Mindestabstand zum Vorderfahrzeug wird ebenfalls deutlich: Die Standardabweichung  $\sigma_{\Delta\dot{x}}$  für  $x_f \rightarrow 0$  steigt an.

(a) Positionsfehler  $e_x$ .(b) Geschwindigkeitsfehler  $e_{\dot{x}}$ .(c) Vergleich der akkumulierten Fehlerquadrate für die Geschwindigkeit  $\dot{x}$  und den Prädiktionzeitpunkt  $t_+ = 5$  s.**Abbildung 4.11:** Prädiktionsfehler der longitudinalen Dynamik.

Für die longitudinale Dynamik wird das Prädiktionsergebnis in Abbildung 4.11 angegeben. Das reine CP-Modell ist bei hohen Geschwindigkeiten des Fahrzeugs eine

unzureichende Annahme und erzielt erwartungsgemäß sehr schlechte Ergebnisse. Das parametrische CV-Modell liefert bereits gute Ergebnisse. Das reine CA-Modell ist erwartungsgemäß noch besser in der Lage die longitudinale Fahrdynamik zu beschreiben.

Mit der semi-parametrischen Methode sind die Ergebnisse für den RMS des longitudinalen Positionsfehlers  $\text{RMS}(e_x)$  für CV und CA Prior vergleichbar. Wird die Prädiktion alleine durch den nicht-parametrischen GP realisiert (mit CP als trivialem Prior), werden für lange Prädiktionszeiten vergleichbare Ergebnisse wie bei der Verwendung höherwertiger parametrischer Modelle als Prior (CV, CA) erzielt. Bei kürzeren Prädiktionszeiten hingegen ist die rein nicht-parametrische Prädiktion dem semi-parametrischen Ansatz offenbar unterlegen.

Bei der Betrachtung des Geschwindigkeitsfehlers  $\text{RMS}(e_{\dot{x}})$  ist für kurze Prädiktionszeiten das CA-Modell klar im Vorteil. Da jedoch Beschleunigung bzw. Verzögerung, wie bereits angesprochen, endliche Vorgänge sind, ist die Prädiktion auf Grundlage des CA-Modells für lange Prädiktionszeiten ab ca.  $t_+ > 4\text{ s}$  sogar schlechter als die des CV-Modells – analog zum langfristig unerwünschten lateralen Drift. Beide parametrischen Modelle profitieren von der Hinzunahme nicht-parametrischer GP. Auf die gesamte Testfahrt gesehen wird der Geschwindigkeitsfehler durch die semi-parametrische Methode für das CV-Modell um 7% reduziert; für das CA-Modell sogar um 13%.

Betrachtet man das Zustandekommen des Fehlers für  $t_+ = 5\text{ s}$  genauer, fällt auf, dass die semi-parametrische Methode mit CV Prior kaum vorteilhafte Prädiktionsergebnisse gegenüber dem reinen Prior selbst erzielt. Leichte Vorteile sind erst im Bereich ab  $t > 500\text{ s}$  zu sehen, wenn die Fahrt aufgrund des Geschwindigkeitsprofils dynamischer ist. Lediglich während des letzten Beschleunigungsvorgangs wird die Längsdynamik mit dem semi-parametrischen Modell wesentlich besser vorhergesagt als durch den CV Prior alleine. Demgegenüber steht die semi-parametrische Prädiktion mit CA Prior, welche sehr beständig, nahezu konstant über die gesamte Fahrt, bessere Prädiktionsergebnisse als das rein parametrische CA-Modell liefert.

## 4.6 Zusammenfassung

In diesem Kapitel wurden Methoden zur probabilistischen Zustandsprädiktion von Fahrzeugtrajektorien entwickelt. Für die Fahrzeugzustände, angegeben in entkrümmten Koordinaten des UFM, werden in Kapitel 4.3.1 kinematische Bewegungsmodelle als Systemmodelle eingeführt, welche auf Basis der newtonschen Gesetze im Bereich des Objekttrackings häufig zum Einsatz kommen. In Kapitel 4.3.2 wird das Messmodell als nichtlineare Transformation zwischen UFM und dem Koordinatensystem des Sensors erläutert, bevor in Kapitel 4.3.3 das Aufsetzen eines neu detektierten Objekts thematisiert wird. Damit sind die Grundlagen der bayesschen Filterarchitektur abgeschlossen, welche im Rahmen dieser Arbeit mit parametrischen System- und Messmodellen verwendet wird.

Durch die Erweiterung der parametrischen Systemmodelle durch GP in Kapitel 4.4 entsteht die neue, semi-parametrische Prädiktionsmethode. GP lassen sich als Methode der bayesschen Statistik ideal in die bestehende Filterarchitektur integrieren. Dabei gleicht der nicht-parametrische Anteil systematische Fehler des parametri-



schen Modells aus und erweitert das Modell für die Beschreibung von Vorgängen, welche analytisch bisher nicht abgebildet waren.

Greift man die zu Anfang dieses Kapitels angeführte Hypothese auf, wurde für eine knapp 16-minütige Testfahrt gezeigt, dass durch die semi-parametrische Methode über den gesamten, betrachteten Prädiktionshorizont von  $0\text{ s} < t_+ \leq 5\text{ s}$  die Prädiktionsqualität gesteigert werden konnte. Legt man insbesondere den Prädiktionszeitpunkt von  $t_+ = 5\text{ s}$  zu Grunde, wurde bspw. der laterale Positions- bzw. longitudinale Geschwindigkeitsfehler gegenüber dem parametrischen Modell um 22% respektive 13% verbessert.



## Vorhersage der Fahrstreifenrelevanz

Im letzten Kapitel wurden semi-parametrische Systemmodelle für Fahrzeuge entwickelt, welche auf Basis von statistischen Lernmethoden das Verhalten von Fahrzeugen bei der Fahrt auf markierten Fahrbahnen im Verkehr beschreiben können. Aufbauend auf kinematischen Bewegungsmodellen, welche grundsätzlich die Dynamik von Objekten ohne externe Einflüsse beschreiben, wurde anhand nicht-parametrischer GP das Prädiktionsverhalten auf Basis realer Fahrdaten verbessert. Die entwickelten Modelle entsprachen unter Verwendung zusätzlicher Kontextinformation nachweislich besser dem beobachteten Verhalten von Fahrzeugen.

### 5.1 Längsregelung als Anwendungskontext

Die Modelle werden in diesem Kapitel zur Anwendung gebracht und hinsichtlich einer konkreten Applikation evaluiert. Speziell stellt sich die Frage, welcher Fahrstreifen – und damit welches Objekt – für die Längsregelung des Fahrerassistenzsystems *Adaptive Cruise Control* relevant ist. Insbesondere vor FSW kann eine frühzeitige Absichtserkennung das Fahrverhalten verbessern und die Kundenzufriedenheit damit gesteigert werden. Bspw. kann bei der Erkennung einer Überholabsicht frühzeitig das Vorderfahrzeug, welches das bisherige Zielobjekt darstellt, als nicht mehr relevant gekennzeichnet werden. Zusätzlich wird das neue Zielobjekt auf dem wahrscheinlichen Zielfahrstreifen frühzeitig ausgewählt und darauf basierend die Längsregelung ausgeführt. Um den zukünftig relevanten Fahrstreifen aufgrund des aktuellen Fahrzustandes zu schätzen, wird im Rahmen dieser Arbeit eine Methode entwickelt, um den Aufenthalt des Fahrzeugs auf den jeweiligen Fahrstreifen probabilistisch vorherzusagen.

### 5.2 Stand der Technik

Für aktuelle und zukünftige FAS ist die Beurteilung der Fahrsituation und Vorhersage von Manövern eine zentrale Problemstellung. Entsprechend gibt es in der Literatur eine Vielzahl von Ansätzen. Eine Auswahl der relevanten Veröffentlichungen wird im Folgenden angeführt.

Die Autoren in [39] stellen ein HMM-basiertes Verfahren vor, um Fahrmanöver, insbesondere FSW, zu erkennen. Zudem sind bayessche Netze für die Manöverprä-

diktion weit verbreitet [40, 41]. Eine Modellierung der Fahrerintention an innerstädtischen Kreuzungen wird in [42, 43, 44] vorgestellt. Für die FSW-Erkennung werden in [45, 46, 47] zudem objektorientierte Paradigmen für bayessche Netze vorgestellt, um Teilnetze komplexer Architektur als wiederverwendbare Knoten zu nutzen [48].

Auf Grundlage der lateralen Dynamik des Fahrzeugs und der Betrachtung des Lenkwinkels werden FSW in [49] durch Verwendung einer Support Vector Machine (SVM) klassifiziert. Mit zusätzlicher, zeitlicher Filterung gelingt dies im Mittel fast 1,3s vor Erreichen der Fahrbahnmarkierung.

In [50] wird ein Naïve Bayes Klassifikator unter Einbeziehung umfangreicher Umfeldinformation verwendet. FSW werden bis zu 2,2s vor Erreichen der Fahrbahnmarkierung erkannt. Die Verwendung eines HMM zur zeitlichen Filterung der „winner-takes-it-all“-Klassifikation führt dabei zu keiner weiteren Verbesserung.

Im Gegensatz zu aus der Literatur bekannten Klassifikatoren, die zumeist dediziert zur Erkennung bestimmter Manöver, insbesondere FSW, entworfen werden, wird im Rahmen dieser Arbeit das laterale, semi-parametrische Systemmodell aus Kapitel 4.5.1 verwendet, um die zukünftigen Modellzustände zu schätzen. Auf Grundlage der generischen Prädiktion der Wahrscheinlichkeitsdichteverteilung wird dann auf das spezielle Manöver geschlossen.

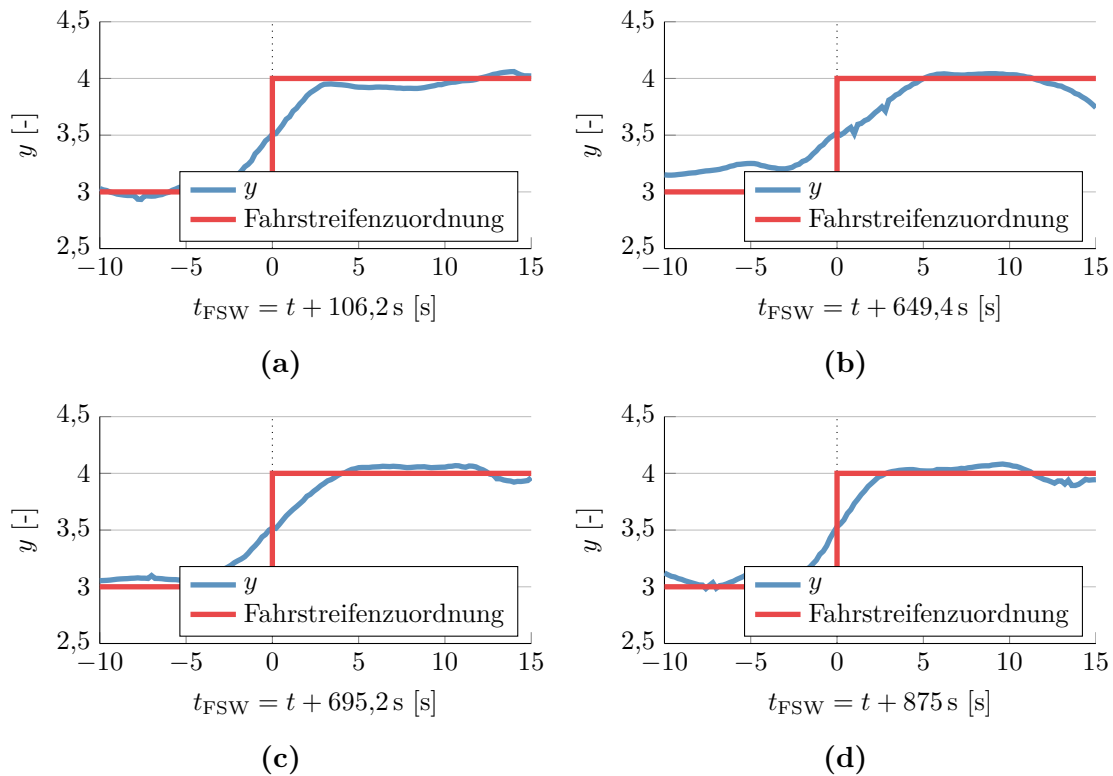
## 5.3 Analyse der prädizierten Wahrscheinlichkeitsdichtefunktion

Aus den Testdaten von Kapitel 4.5 sind in Abbildung 5.1 exemplarisch die vier FSW nach links gezeigt, bei welchen das Fahrzeug von Fahrstreifen 3 auf 4 wechselt. Zudem ist die Grundwahrheit der Fahrstreifenzuordnung angegeben. Mit dem Zeitpunkt  $t_{\text{FSW}} = 0$  ist jeweils der Moment definiert, an dem die Zuordnung des relevanten Fahrstreifens wechselt.

### 5.3.1 Unimodale Prädiktion

Auf Basis eines UKF sind für die vier FSW die Wahrscheinlichkeitsdichten für die prädizierte, laterale Position  $p(y)$  in Abbildung 5.2 angegeben (Marginalisierung über den Zustand  $\hat{y}$ ). Zusätzlich wird die Grundwahrheit sowie der vom Filter geschätzte Erwartungswert der lateralen Position  $y$  gezeigt. Die Zeit ist dabei jeweils relativ zu dem Zeitpunkt angegeben, an dem das Fahrzeug die Fahrstreifenmarkierung überschreitet und sich die Fahrstreifenzuordnung wechselt ( $t_{\text{FSW}} = 0$ ). Die Prädiktion beginnt in den gezeigten Beispielszenarien 10, 2 oder 1s vor diesem Zeitpunkt. Der Prädiktionshorizont erstreckt sich auf  $t_+ \leq 15$ s. Damit wird sichergestellt, dass alle auf Grundlage der Fahrdynamik bereits erkennbar eingeleiteten FSW-Manöver innerhalb des Prädiktionshorizonts abgeschlossen werden und das Fahrzeug wieder stabil in einem Fahrstreifen fährt.

Beginnt die Prädiktion an einem frühen Zeitpunkt (10s), ergibt die Analyse der Wahrscheinlichkeitsdichte, dass aufgrund des aktuellen Fahrzustands kein FSW vorhergesagt wird. Der geschätzte Zustand verbleibt auf demselben Fahrstreifen. Ist das FSW-Manöver bereits eingeleitet und ausreichend weit fortgeschritten (1s), wird die zukünftige Position korrekt auf den linken Nachbarfahrstreifen prädiziert.



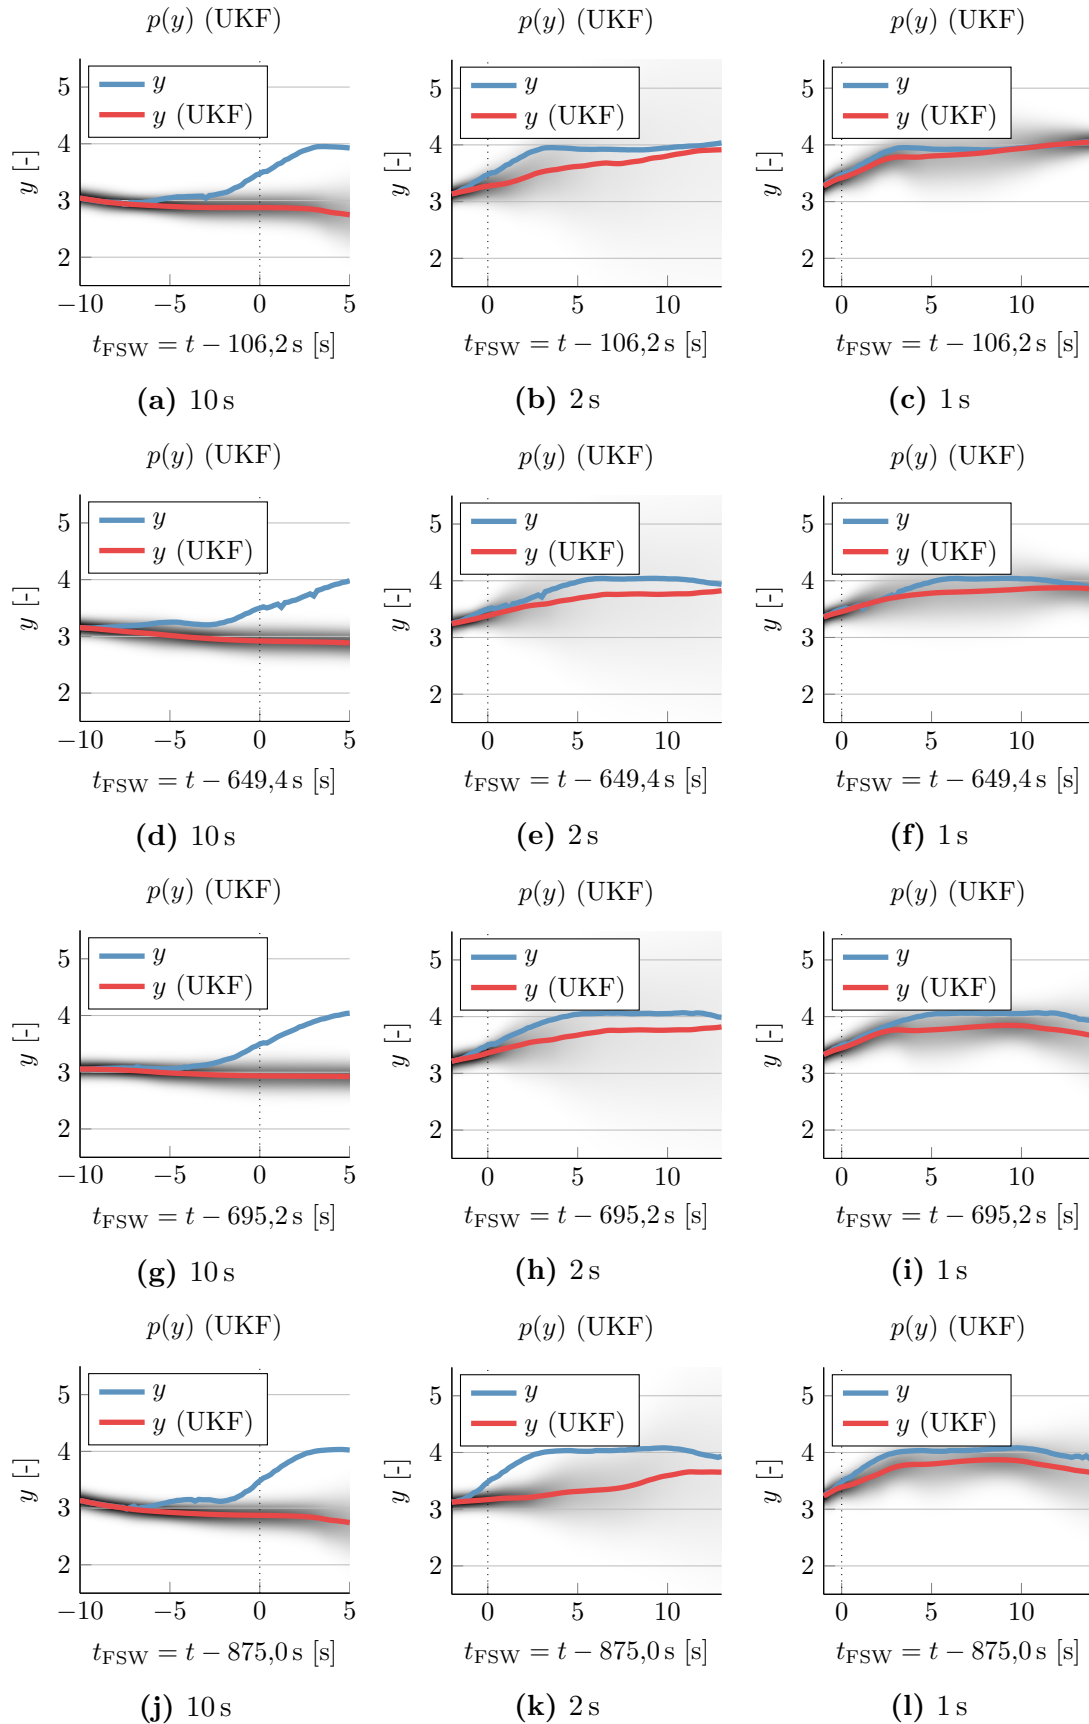
**Abbildung 5.1:** Laterale Position und Zuordnung des aktuell relevanten Fahrstreifens für vier FSW nach links.

Für die Dichteschätzung fällt auf, dass insbesondere dann, wenn aufgrund eines ambivalenten Anfangszustandes bei der Prädiktion mehrere Hypothesen für den zukünftigen Fahrstreifen wahrscheinlich werden, die geschätzte Unsicherheit stark ansteigt (2s): Die einzelnen Sigma-Punkte  $\mathbf{x}^{(i)}$  des UKF, welche die Wahrscheinlichkeitsverteilung beschreiben, folgen dabei unterschiedlichen Fahrstreifenhypothesen. Diese Divergenz bei der Prädiktion der einzelnen Sigma-Punkte führt zu einem ungewöhnlich starken Anstieg der Unsicherheit. Auch der Erwartungswert  $y$  zeigt streckenweise ein unrealistisches Verhalten und liegt lange Zeit mittig zwischen beiden Fahrstreifenhypothesen. Es ist offensichtlich, dass die prädizierten Verläufe das in der Realität beobachtete FSW-Verhalten nur unzureichend abbilden.

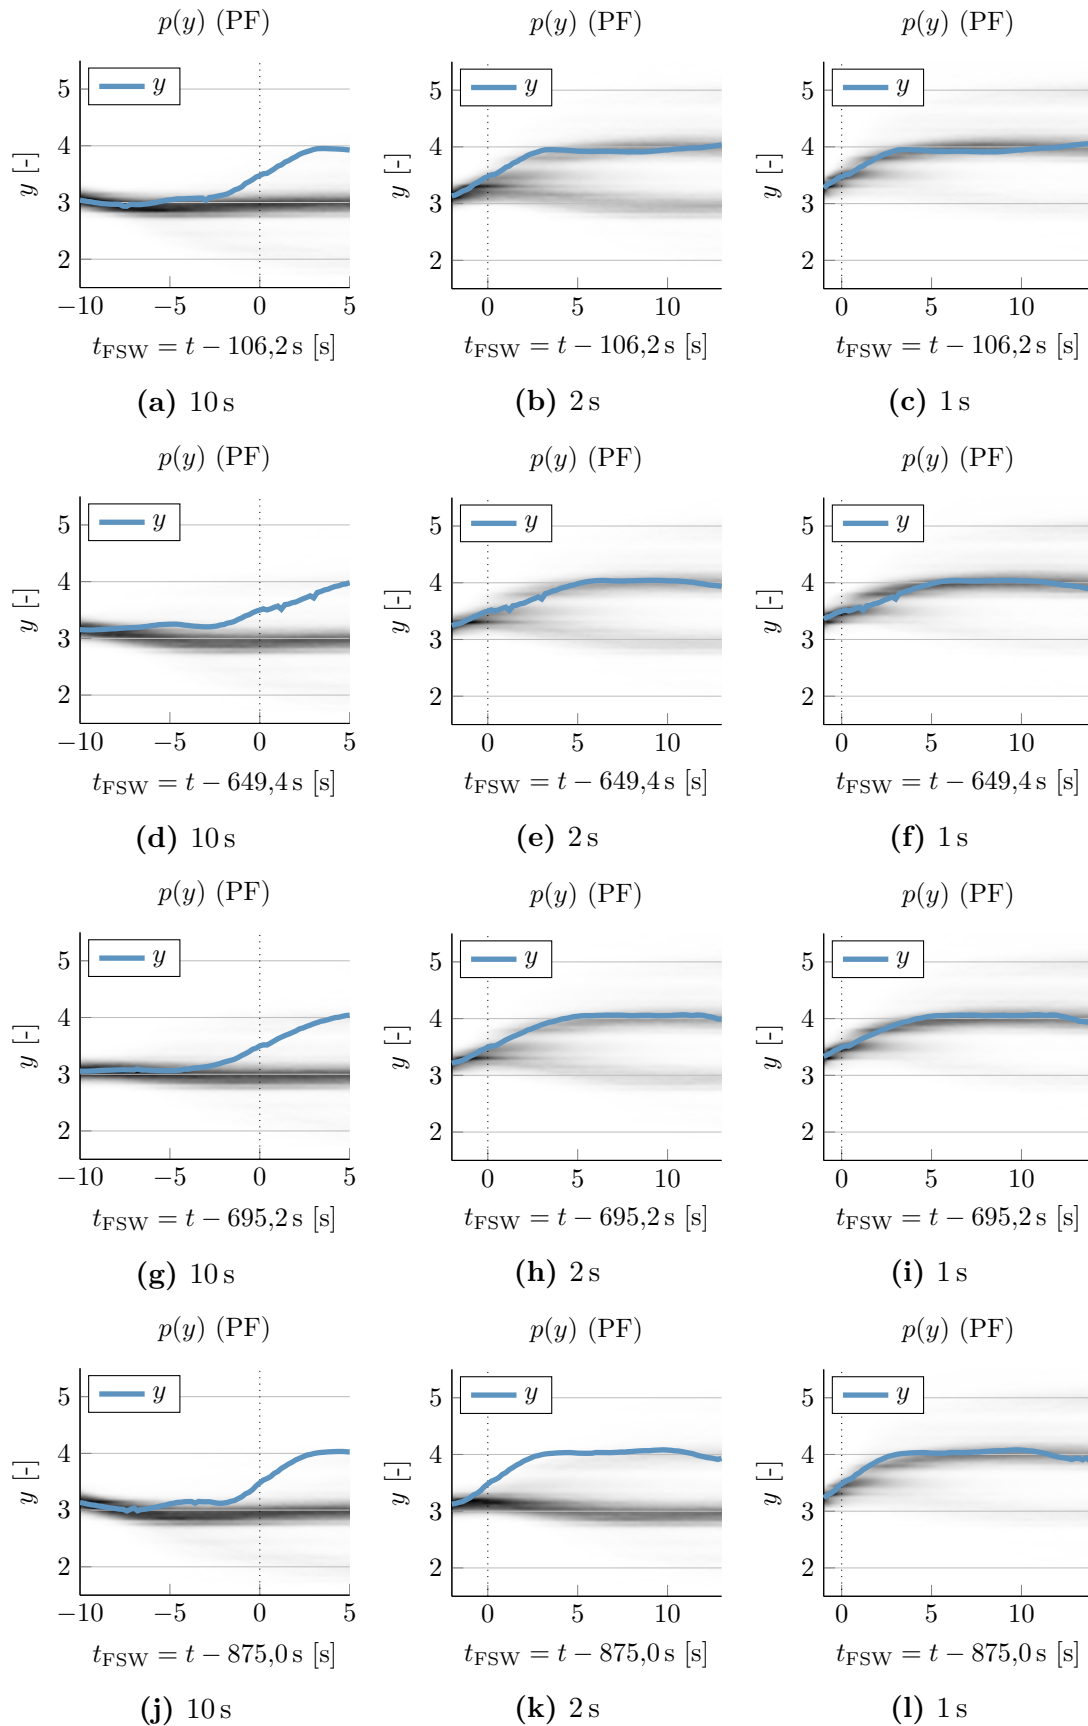
Ist die Beschreibung für die Wahrscheinlichkeitsdichte der lateralen Fahrzeugposition im Fahrstreifen durch eine unimodale Verteilung i. d. R. zulässig, so ist diese Annahme einer unimodalen Verteilung im speziellen Fall eines FSW augenscheinlich verletzt. In diesen Momenten führt die in Realität bi- bzw. multimodale Wahrscheinlichkeitsdichte zu einer großen Positionsvarianz der unimodalen Verteilung. Um diese Einschränkung zu überwinden, bietet sich die Sequenzielle Monte-Carlo Methode (SMC) zur Zustandsschätzung an. Auf Grundlage des semi-parametrischen Dynamikmodells wird daher im Folgenden ein Partikel Filter (PF) verwendet.

### 5.3.2 Multimodale Prädiktion

Die Wahrscheinlichkeitsdichte für die vier FSW nach links auf Basis eines PF sind in Abbildung 5.3 gegeben. Zudem ist wiederum die Grundwahrheit  $y$  der lateralen Position gezeigt.



**Abbildung 5.2:** Prädizierte Wahrscheinlichkeitsdichte des UKF für vier FSW-Manöver nach links über  $0 \text{ s} < t_+ \leq 15 \text{ s}$ .



**Abbildung 5.3:** Prädizierte Wahrscheinlichkeitsdichte des PF für vier FSW-Manöver nach links über  $0 \text{ s} < t_+ \leq 15 \text{ s}$ .

Grundsätzlich entspricht die gefundene Verteilung der Erwartung aus Beobachtungen der Realität. Je nach initialem Zustand zu Beginn der Prädiktion ist entweder der eine oder andere Fahrstreifen wahrscheinlicher. Eine laterale Position in der Mitte zwischen zwei Fahrstreifen ist eher unwahrscheinlich. Bspw. ist für den FSW bei 875,0s mit dem Prädiktionsbeginn 2s vor dem Ereignis der Verbleib auf dem Fahrstreifen aufgrund des Fahrzeugzustandes sehr viel wahrscheinlicher als ein Wechsel – irrtümlicherweise, da kurz darauf ein FSW durchgeführt wird. Zu Beginn der Prädiktion liegt jedoch keine ungewöhnliche Querablage  $y$  und Quergeschwindigkeit  $\dot{y}$  vor, welche aufgrund der Dynamik diesen Rückschluss zu diesem Zeitpunkt zugelassen hätte. Eine Erweiterung der Prädiktion unter Berücksichtigung der longitudinalen Situation sowie die Inferenz der Fahrerintention können hier weitere Indizien für eine frühzeitige Erkennung liefern. Dies wird im Rahmen dieser Arbeit jedoch nicht weiter ausgeführt.

Es wurde eine passende Methode entwickelt, um die Zustände der lateralen Systemdynamik auf Basis realer Fahrdaten probabilistisch und multimodal vorherzusagen. Im Folgenden wird beschrieben, wie dieses Modell verwendet werden kann, um frühzeitig eine probabilistische Aussage zu generieren, ob ein FSW durchgeführt wird.

## 5.4 Evaluation der Relevanzerkennung

Zur Erkennung von FSW wird der Prädiktionszeitpunkt  $t_+ = 15$ s gewählt und ausgehend vom aktuellen Zustand jeweils bis zu diesem prädiziert. In Abbildung 5.5 wird mit der kumulativen Verteilungsfunktion

$$P(y > \bar{y}) = \int_{\bar{y}}^{\infty} \int_{-\infty}^{\infty} p(\mathbf{x}_{k+\frac{t_+}{\Delta T}|k}) d\dot{y} dy \quad (5.1)$$

bestimmt, welcher Anteil der prädizierten Wahrscheinlichkeitsdichte der lateralen Position  $y$  den Fahrstreifen 3 nach links Richtung Fahrstreifen 4 verlassen hat ( $y > \bar{y} = \frac{3+4}{2}$ ). Dabei wird über die laterale Geschwindigkeit  $\dot{y}$  marginalisiert. Aufgrund der Wahrscheinlichkeitsdichte des PF kann dabei näherungsweise die Wahrscheinlichkeit

$$P(y > \bar{y}) \approx \sum_i w_{k+\frac{t_+}{\Delta T}}^{(i)} \forall i \in \{i | y_{k+\frac{t_+}{\Delta T}}^{(i)} > \bar{y}\} \quad (5.2)$$

berechnet werden, indem der Anteil der Partikel bestimmt wird, für die  $y_{k+\frac{t_+}{\Delta T}}^{(i)} > \bar{y}$  gilt.

Bereits 10s vor dem FSW wird auf Basis dieses Verfahrens eine gewisse Wahrscheinlichkeit für einen FSW beobachtet. Aufgrund des Fahrzeugzustandes liegt i. d. R. jedoch zu diesem Zeitpunkt noch kein Indiz für einen FSW vor. Da FSW eher seltene Ereignisse sind, wird die Wahrscheinlichkeit des Eintretens von FSW als Poissonverteilung mit der Ereignishäufigkeit  $\lambda > 0$  modelliert. Die Wahrscheinlichkeit von  $n$  Ereignissen in einem festgelegten Zeitintervall ergibt sich zu

$$P_\lambda(n) = \frac{\lambda^n}{n!} e^{-\lambda} . \quad (5.3)$$

Empirisch werden ca. 90 FSW pro Stunde beobachtet. Für den Prädiktionshorizont von  $t_+ \leq 15$ s ergibt sich  $\lambda = 90 \frac{15s}{3600s}$ . Unter der Annahme, dass FSW nach links



und rechts gleich wahrscheinlich sind, ergibt sich die Anzahl der kombinatorischen Möglichkeiten für  $n$  FSW, um auf einem bestimmten Fahrstreifen zu enden, aus dem Pascalschen Dreieck (Abbildung 5.4). Die relevanten Binomialkoeffizienten, damit das Fahrzeug am Ende der Prädiktion sich mindestens auf dem Nebenfahrstreifen einer zuvor definierten Seite befindet, sind rot dargestellt.

|         |   |   |   |   |   |
|---------|---|---|---|---|---|
| $n = 0$ |   |   |   | 1 |   |
| $n = 1$ |   |   | 1 | 1 |   |
| $n = 2$ |   | 1 | 2 | 1 |   |
| $n = 3$ | 1 | 3 | 3 | 1 |   |
| $n = 4$ | 1 | 4 | 6 | 4 | 1 |

**Abbildung 5.4:** Darstellung der Binomialkoeffizienten im Pascalschen Dreieck.

Pro Zeile  $n$  wird die Summe aller relevanten Koeffizienten zur Zeilensumme  $2^n$  ins Verhältnis gesetzt. Die Wahrscheinlichkeit für  $n$  FSW aufgrund der Poissonverteilung  $P_\lambda(n)$  wird dann mit diesem Verhältnis multipliziert. Schließlich ergibt sich die a priori Wahrscheinlichkeit  $P_b$  für einen FSW im betrachteten Prädiktionshorizont durch Auswertung der Reihe

$$P_b = \frac{1}{2} \sum_{k=0}^{\infty} P_\lambda(2k+1) + P_\lambda(2k) \left(1 - \frac{\binom{2k}{k}}{2^{2k}}\right) = 14,4\% . \quad (5.4)$$

Aufgrund der ungeraden bzw. geraden Anzahl an Binomialkoeffizienten pro Zeile des Pascalschen Dreiecks wird nach geraden und ungeraden  $n$  unterschieden. Die mittleren Binomialkoeffizienten im Dreieck sind für  $n = 2k$  mit  $k \in \mathbb{N}_0$  gegeben durch  $\binom{2k}{k}$ .

Dieser Zusammenhang beschreibt die Ausbreitung der Wahrscheinlichkeitsdichtefunktion zu einer definierten Seite, welche innerhalb von 15 s zu erwarten ist – und zwar ohne Inferenz auf Basis des Fahrzeugzustandes, sondern rein aufgrund der empirischen Häufigkeit von FSW. Im betrachteten Fall bedeutet dies, dass erst ab einer Wahrscheinlichkeit von  $P(y > \bar{y}) > P_b$  ein Indiz dafür vorliegt, dass das Fahrzeug aufgrund des Fahrzeugzustandes seinen Fahrstreifen wechselt.

Analog resultiert die Wahrscheinlichkeit des Gegenereignisses

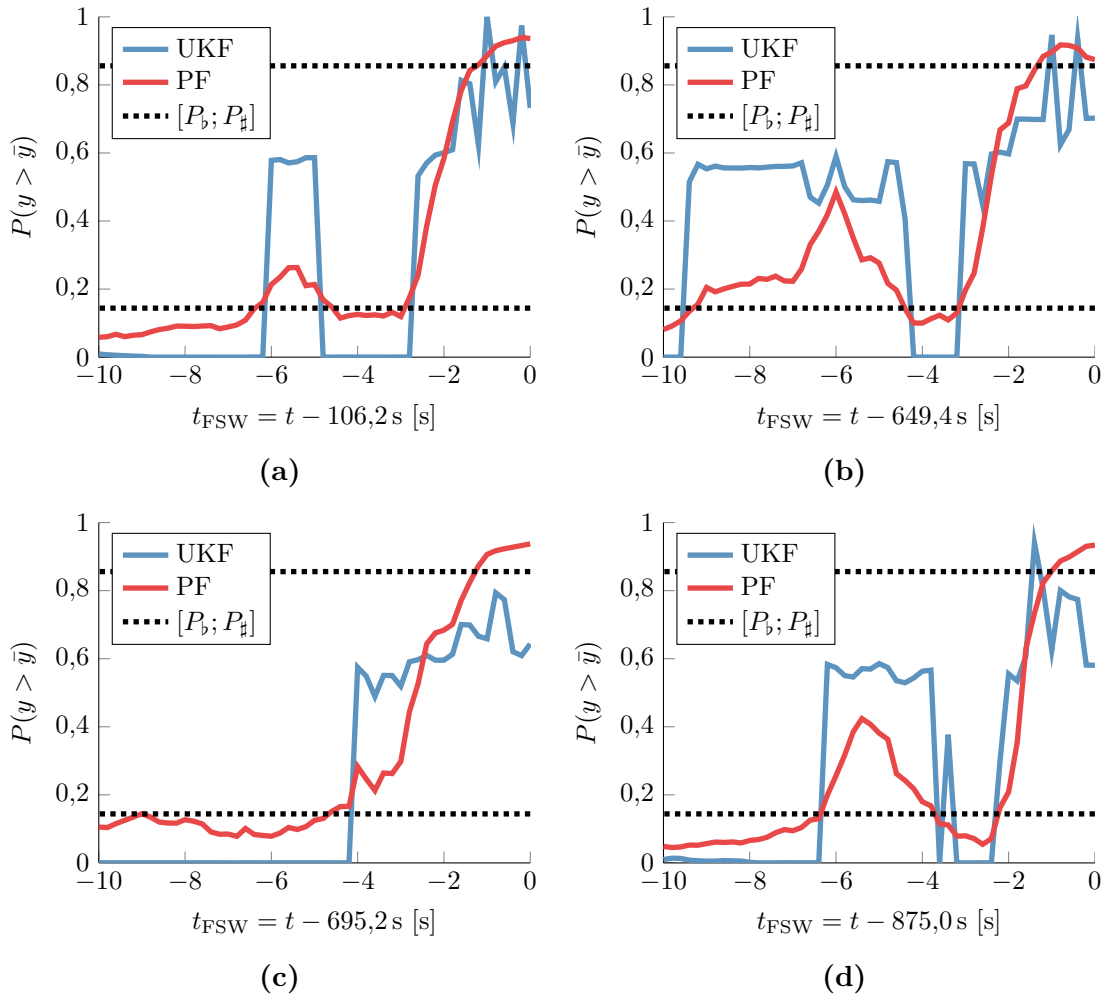
$$P_{\ddagger} = 1 - P_b = 85,6\% \quad (5.5)$$

aus der Ausbreitung der Wahrscheinlichkeitsdichtefunktion im Verlauf der Prädiktion, die der FSW-Hypothese zur definierten Seite widerspricht. Wird dieses Niveau an Wahrscheinlichkeit erreicht, gilt die FSW-Hypothese als gesichert angenommen.

Die Methode, aufgrund des aktuellen Zustandes einen zukünftigen FSW vorherzusagen, muss im Kontext der empirischen Häufigkeit von FSW und der damit verbundenen a priori Wahrscheinlichkeiten  $P_b$  und  $P_{\ddagger}$  getroffen werden: Ein zu kurzer Prädiktionshorizont  $t_+$  führt dazu, dass die Verteilung zum Zeitpunkt der Auswertung auf anderen Fahrstreifen noch nicht ausgeprägt ist, obwohl dies aufgrund des

Systemmodells bei längerer Prädiktion noch passieren würde. Ein langer Prädiktionshorizont  $t_+$  erhöht den Einfluss der a priori FSW-Wahrscheinlichkeiten und verkleinert somit das Intervall  $[P_b; P_{\ddagger}]$ . Für den Grenzfall  $t_+ \rightarrow \infty$  gilt  $P_b = P_{\ddagger} = 50\%$ . Das Intervall degeneriert und es ist keine sinnvolle, probabilistische Aussage aufgrund der prädizierten Verteilung mehr möglich. Die Ausbreitung der Wahrscheinlichkeitsdichte wird vom Prozessrauschen dominiert; der Einfluss des konkreten Ausgangszustandes zu Beginn der Prädiktion wird vernachlässigbar.

Prinzipiell zeigen UKF und PF vergleichbares Verhalten. Die Ergebnisse des UKF sind jedoch sehr sprunghaft: ein Symptom der Prädiktion auf Basis einer unimodalen Wahrscheinlichkeitsverteilung, was bereits in Kapitel 5.3.1 erläutert wurde.

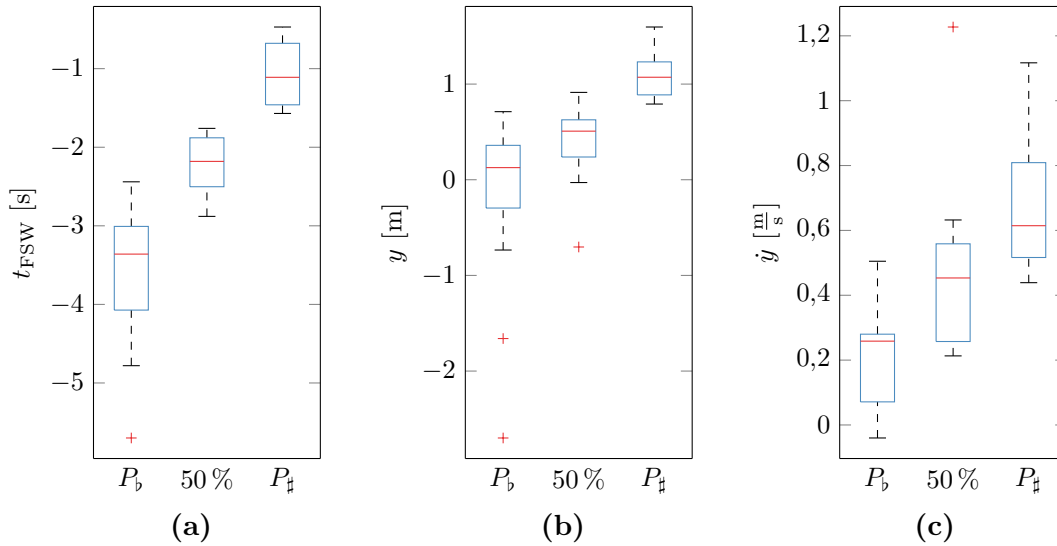


**Abbildung 5.5:** Prädiktion eines FSW nach links ( $t_+ = 15$  s).

Eine detaillierte Auswertung von insgesamt 13 FSW der Testfahrt ist in Tabelle 5.1 gegeben. Für die FSW wurde dabei der Vorhersagezeitpunkt sowie die laterale Position und Geschwindigkeit für jeweils 3 unterschiedliche Wahrscheinlichkeitsniveaus  $P(y > \bar{y}) \in \{P_b, 50\%, P_{\ddagger}\}$  angegeben. Zur einheitlichen Darstellung wird eine standardisierte Fahrstreifenbreite von 3,50 m und eine Fahrzeugbreite von 1,60 m angenommen: Wird das Wahrscheinlichkeitsniveau  $P_b$  als erstes Indiz für einen FSW betrachtet, wird dieser Schwellwert im Mittel bereits bei  $t_{\text{FSW}} = -3,59$  s erreicht. Jedoch sind hier aufgrund von Pendelbewegungen, auf welche nicht unmittelbar ein FSW folgt, auch viele FP-Fälle zu erwarten, wie in Abbildung 5.5 ersichtlich ist.

| FSW                                  | $P$      | $t_{\text{FSW}}$ [s] | $y$ [rad]   | $\dot{y}$ [ $\frac{1}{\text{s}}$ ] |
|--------------------------------------|----------|----------------------|-------------|------------------------------------|
| $t = 27,8 \text{ s}$<br>nach links   | $P_b$    | -5,70                | -0,95 $\pi$ | 0,08                               |
|                                      | 50 %     | -2,51                | -0,02 $\pi$ | 0,18                               |
|                                      | $P_{\#}$ | -1,19                | 0,50 $\pi$  | 0,22                               |
| $t = 41,8 \text{ s}$<br>nach links   | $P_b$    | -3,00                | 0,28 $\pi$  | 0,01                               |
|                                      | 50 %     | -2,50                | 0,32 $\pi$  | 0,07                               |
|                                      | $P_{\#}$ | -1,45                | 0,53 $\pi$  | 0,14                               |
| $t = 59,6 \text{ s}$<br>nach rechts  | $P_b$    | -3,01                | 0,01 $\pi$  | -0,08                              |
|                                      | 50 %     | -2,18                | -0,18 $\pi$ | -0,16                              |
|                                      | $P_{\#}$ | -0,95                | -0,69 $\pi$ | -0,22                              |
| $t = 78,4 \text{ s}$<br>nach links   | $P_b$    | -3,80                | -0,42 $\pi$ | 0,07                               |
|                                      | 50 %     | -2,25                | 0,02 $\pi$  | 0,16                               |
|                                      | $P_{\#}$ | -1,11                | 0,51 $\pi$  | 0,28                               |
| $t = 106,2 \text{ s}$<br>nach links  | $P_b$    | -3,10                | 0,12 $\pi$  | 0,02                               |
|                                      | 50 %     | -2,38                | 0,25 $\pi$  | 0,08                               |
|                                      | $P_{\#}$ | -1,49                | 0,47 $\pi$  | 0,17                               |
| $t = 614,8 \text{ s}$<br>nach rechts | $P_b$    | -3,97                | 0,09 $\pi$  | -0,08                              |
|                                      | 50 %     | -1,94                | -0,42 $\pi$ | -0,13                              |
|                                      | $P_{\#}$ | -0,67                | -0,82 $\pi$ | -0,18                              |
| $t = 649,4 \text{ s}$<br>nach links  | $P_b$    | -3,36                | 0,41 $\pi$  | -0,01                              |
|                                      | 50 %     | -2,63                | 0,43 $\pi$  | 0,06                               |
|                                      | $P_{\#}$ | -1,57                | 0,61 $\pi$  | 0,13                               |
| $t = 666,2 \text{ s}$<br>nach rechts | $P_b$    | -3,37                | -0,20 $\pi$ | -0,07                              |
|                                      | 50 %     | -1,76                | -0,52 $\pi$ | -0,12                              |
|                                      | $P_{\#}$ | -0,47                | -0,91 $\pi$ | -0,15                              |
| $t = 695,2 \text{ s}$<br>nach links  | $P_b$    | -4,78                | 0,14 $\pi$  | 0,02                               |
|                                      | 50 %     | -2,88                | 0,30 $\pi$  | 0,07                               |
|                                      | $P_{\#}$ | -1,50                | 0,56 $\pi$  | 0,13                               |
| $t = 743,4 \text{ s}$<br>nach rechts | $P_b$    | -2,70                | -0,01 $\pi$ | -0,08                              |
|                                      | 50 %     | -1,82                | -0,21 $\pi$ | -0,15                              |
|                                      | $P_{\#}$ | -0,71                | -0,70 $\pi$ | -0,26                              |
| $t = 875,0 \text{ s}$<br>nach links  | $P_b$    | -2,44                | 0,24 $\pi$  | 0,01                               |
|                                      | 50 %     | -1,90                | 0,29 $\pi$  | 0,07                               |
|                                      | $P_{\#}$ | -1,24                | 0,45 $\pi$  | 0,18                               |
| $t = 913,0 \text{ s}$<br>nach rechts | $P_b$    | -3,10                | -0,07 $\pi$ | -0,08                              |
|                                      | 50 %     | -1,78                | -0,34 $\pi$ | -0,13                              |
|                                      | $P_{\#}$ | -0,68                | -0,69 $\pi$ | -0,22                              |
| $t = 916,0 \text{ s}$<br>nach rechts | $P_b$    | -4,38                | 1,54 $\pi$  | -0,14                              |
|                                      | 50 %     | -2,06                | -0,40 $\pi$ | -0,35                              |
|                                      | $P_{\#}$ | -0,53                | -0,73 $\pi$ | -0,32                              |

**Tabelle 5.1:** Auswertung der FSW-Prädiktion.



**Abbildung 5.6:** Auswertung der FSW-Prädiktion bei 3,50 m Fahrstreifenbreite.

Wenn der FSW nach links bzw. rechts wahrscheinlicher wird als der Verbleib auf dem Fahrstreifen, im Mittel bei  $t_{\text{FSW}} = -2,2$  s, liegen zwischen der Fahrbahnmarkierung zugewandten Fahrzeugaußenseite und der Markierung selbst noch im Mittel 0,57 m. Für den getesteten Zeitraum bis 10 s vor dem FSW ist für 13 Testfälle dabei kein einziger FP zu beobachten. In der Abbildung 5.6 sind Box-Whisker-Plots dargestellt, welche die Prädiktion der Fahrstreifenrelevanz bei 3,50 m Fahrstreifenbreite für die unterschiedlichen Wahrscheinlichkeitsniveaus zusammenfassen. Für FSW nach rechts sind die Werte für  $y$  und  $\dot{y}$  in einem Vorverarbeitungsschritt mit  $-1$  multipliziert worden, um die Vorzeichen zu tauschen und die Ergebnisse mit den FSW nach links vergleichbar zu machen. Ausreißer, Datenpunkte außerhalb des 1,5-fachen des Interquartilsabstandes, sind als rote Kreuze eingezeichnet.

## 5.5 Zusammenfassung

In diesem Kapitel wurde eine Methode entwickelt, um für eine geregelte Längsführung durch das Fahrerassistenzsystem *Adaptive Cruise Control* den relevanten Fahrstreifen zu präzisieren. Dafür wird auf dem im vorigen Kapitel 4 entwickelten, semi-parametrischen, lateralen Systemmodell aufgesetzt.

Ist es i. d. R. ausreichend, die laterale Fahrzeugposition mit einer unimodalen Verteilung, bspw. anhand eines UKF, zu beschreiben, so ist diese Annahme insbesondere bei FSW unzureichend. Um multimodale Wahrscheinlichkeitsdichtefunktionen zur Beschreibung mehrerer Fahrstreifenhypothesen abbilden zu können, wird ein PF verwendet.

Durch die entwickelte Methode zur Relevanzerkennung ist es lediglich durch Analyse der lateralen Dynamik eines Fahrzeugs mit dem semi-parametrischen Prädiktionsmodell möglich, den zukünftigen Fahrstreifen frühzeitig zu erkennen. In den untersuchten Szenarien lag der Erkennungszeitpunkt im Mittel bei 2,2 s, bevor die Fahrzeugmitte die Fahrbahnmarkierung überschreitet und sich die Fahrstreifenzuordnung ändert. Bei 3,50 m Fahrbahnbreite beträgt zu diesem Zeitpunkt der Abstand der Fahrzeugmitte zur Fahrbahnmarkierung im Mittel noch 1,37 m und die Quergeschwindigkeit lediglich 0,46  $\frac{\text{m}}{\text{s}}$ .

## Diskussion und Ausblick

Für die Entwicklung von zukünftigen FAS wurde die präzise Vorhersage des Verhaltens von Verkehrsteilnehmern als Problemstellung ausgemacht. Im Rahmen der Arbeit wurde daher eine semi-parametrische Prädiktion von Fahrzeugtrajektorien auf Basis von Flottendaten entwickelt.

Aufgrund der beachtlichen Komplexität auftretender Fahrsituationen und -manöver in der verwendeten Datenbank lag der Fokus hierbei zuerst auf einer datengetriebenen Methode, die auf Grundlage definierter Merkmale die Regeln zur Klassifikation bzw. Identifikation selbständig erlernt. Basis des Lernprozesses sind dabei Datensätze, die als Grundwahrheit dem Lernalgorithmus zur Verfügung gestellt werden.

Dabei ist festzustellen, dass neben der Auswahl des RF als Klassifikationsalgorithmus insbesondere die zur Klassifikation verwendeten Merkmale sowie die Optimierung der Parameter des Algorithmus einen Einfluss auf die Leistungsfähigkeit der Methode haben. Zudem sind Fahrsituationen und -manöver keine sporadisch auftretenden Einzelereignisse, sondern zeitlich ausgedehnte Sequenzen. Dieser Eigenschaft wurde im Rahmen der Arbeit Rechnung getragen, indem die zuerst zeitlich unabhängig betrachteten Dateninstanzen als Markov-Kette modelliert wurden. Die Klassifikationsgenauigkeit wurde durch eine Vorwärts-Rückwärts-Glättung so zusätzlich gesteigert – für FSW-Manöver bspw. von 93,3 % auf 95,2 %.

Neben der effizienten und erweiterbaren Indexierung von Datensätzen wurden ausgehend von einer KF-Architektur mit parametrischen Prädiktionsmodellen semi-parametrische Modelle auf Basis von GP entwickelt. Systematische Fehler der parametrischen Modelle, welche vor allem auf nicht abgebildete Zusammenhänge zurückzuführen sind, werden mit GP gelernt und anhand der resultierenden nicht-parametrischen Regressionsmodelle korrigiert. Ein großer Vorteil dieser Methode ist deren Robustheit, da gewährleistet ist, dass in den Bereichen des Merkmalsraums, in denen während des maschinellen Lernprozesses keine Trainingsdaten zur Verfügung standen, automatisch auf das parametrische Modell als Rückfallebene zurückgegriffen wird.

Begründet durch Drift-Effekte erzielt das CP-Modell für die laterale Position bei langen Prädiktionshorizonten (ab ca. 4s) bessere Ergebnisse als das komplexere CV-Modell. Analog fällt der Geschwindigkeitsfehler der Längsdynamik mit dem CV-

Modell für längere Prädiktionshorizonte geringer aus als unter Verwendung des CA-Modells. Für kürzere Prädiktionszeiten wurde gezeigt, dass die jeweils komplexeren Modelle verwendet werden sollten. Insbesondere auch, wenn die zeitlichen Ableitungen von Interesse sind, welche durch simplere Modelle nicht ausreichend berücksichtigt werden. Führt man die semi-parametrische Prädiktion in der KF-Architektur durch – mit dem durch einen GP korrigierten parametrischen Prior – wird bei der Prädiktion über 5 s der laterale Positionsfehler des CV-Modells bspw. um 22 % und der longitudinale Geschwindigkeitsfehler des CA-Modells um 13 % verbessert; jeweils im Vergleich zum entsprechenden rein parametrischen Modell.

Bei der Modellierung der Lateraldynamik und Betrachtung der gelernten Korrekturfunktion wurde ein Potentialtopf identifiziert, der bei kleinen Auslenkungen und Quergeschwindigkeiten Fahrzeuge prinzipiell mit einer gedämpften Pendelbewegung im aktuellen Fahrstreifen hält. Ab einem gewissen Maß an Querablage und Quergeschwindigkeit wird dieser überwunden. Dies resultiert bei der Prädiktion eines FSW dann in einer aktiven Beschleunigung in Richtung des nächsten Fahrstreifens.

Die im Rahmen dieser Arbeit entwickelten Dynamikmodelle zur probabilistischen Prädiktion von Fahrzeugtrajektorien bilden die Grundlage, um eine generische Lösung für weitergehende Fragestellungen umzusetzen, insbesondere die Vorhersage der Fahrstreifenrelevanz. Diese wurden im Stand der Technik bisher v. a. als eigenständige Klassifikationsprobleme behandelt: Wird die Wahrscheinlichkeitsdichtefunktion, die anhand des semi-parametrischen Lateraldynamikmodells rein auf Grundlage der Querablage und -geschwindigkeit prädiziert wurde, für die einzelnen Fahrstreifen ausgewertet, wird die sich wechselnde Fahrstreifenrelevanz – ein FSW – im Mittel 2,2 s vor dem eigentlichen Überqueren der Fahrstreifenmarkierung in allen betrachteten Szenarien ohne Falschklassifikationen korrekt vorhergesagt. Betrachtet man die Prädiktionszeit, entsprechen die erzielten Ergebnisse im Wesentlichen dem Stand der Technik. Gleichzeitig wird jedoch auf komplexe UFM-Beschreibungen und weitere Eingangsgrößen verzichtet. Die Hinzunahme weiterer, aussagekräftiger Merkmale, wie z. B. die Relativgeschwindigkeit zum Vorderfahrzeug, die unkompliziert in die entwickelten Modelle integriert werden können, verspricht dabei eine Steigerung der Prädiktionsqualität über die Ergebnisse der vorliegenden Arbeit hinaus.

Zukünftige Arbeiten sollten die Weiterentwicklung der vorgestellten, probabilistischen, semi-parametrischen Fahrdynamikmodelle verfolgen sowie weitere Einflussgrößen untersuchen und integrieren, die zur Steigerung der Prädiktionsqualität beitragen. Insbesondere sind hier Merkmale zu nennen, welche die situative Intention des jeweiligen Fahrzeugführers berücksichtigen. Die Erhöhung der Anzahl verwendeter Merkmale wird durch die Weiterentwicklung der GP-Approximationsmethoden begünstigt. Zusätzlich kann die Prädiktion auf Trajektorienebene von vektorwertigen GP profitieren, wenn die Struktur des Problems, insbesondere die zeitlichen Ableitungen, bereits explizit bei der Bildung des Kernels berücksichtigt werden. Abschließend bietet sich an, die entwickelten Modelle mit noch umfassenderen Datensätzen aus Fahrzeugflotten zu trainieren und die Prädiktionsergebnisse durch Experten und Probandenstudien quantitativ bewerten zu lassen.

# Anhang


## A.1 Koordinatentransformationen

Im Folgenden werden die Transformationsvorschriften angegeben, welche die Umrechnung zwischen dem Sensorkoordinatensystem  $S$  und dem entkrümmten Frenet-Koordinatensystem  $F$  ermöglichen.

### A.1.1 Transformation der Sensorkoordinaten

Ein Objekt mit dem Zustandsvektor  ${}_S\mathbf{x}_b = [{}_S\mathbf{r}_b, {}_S\mathbf{v}_b, {}_S\mathbf{a}_b]^\top$  ist im Sensorsystem  $S$  beschrieben.

Sensor  $S \rightarrow$  Erdfest  $E$



**Abbildung A.1:** Zusammenhang zwischen Beobachtung im  $S$ - und  $E$ -System.

Der Zusammenhang zwischen dem Ego-Fahrzeug, einem detektierten Objekt und dem erdfesten Koordinatensystem in Fahrzeugrichtung ist in Abbildung A.1 dargestellt. Zur Verdeutlichung sind die Koordinatensysteme versetzt gezeichnet, i. d. R. gilt jedoch  $\varphi = 0$  sowie  ${}_S\mathbf{r}_{es} = \mathbf{0}$ .

Die zeitliche Ableitung von  ${}_S\mathbf{r}_b$  erfolgt im beschleunigten Sensor-Bezugssystem des Fahrzeugs. Zudem sollen die Geschwindigkeit und Beschleunigung des beobachteten Objekts absolut über Grund angegeben werden. Dazu wird die Dynamik des Ego-Fahrzeugs respektive die Geschwindigkeit  $v$ , Beschleunigung  $a$  sowie Drehrate  $\dot{\varphi}$  aus Tabelle A.1 berücksichtigt.

| Parameter       | Beschreibung  |
|-----------------|---|
| $v$             | Longitudinale Geschwindigkeit in Fahrzeugorientierung $\varphi$ |
| $a$             | Longitudinale Beschleunigung in Fahrzeugorientierung $\varphi$  |
| $\dot{\varphi}$ | Drehrate des Fahrzeugs um seine Hochachse                       |

**Tabelle A.1:** Odometriedaten des Ego-Fahrzeugs.

Die absolute Beobachtung  ${}_E\mathbf{x}_b$  ergibt sich aus der Umrechnung  $T_{ES}$  der Sensormessungen  ${}_S\mathbf{x}_b$  im beschleunigten Sensor-System  $S$  ins erdfeste System  $E$ :

$${}_E\mathbf{r}_b = {}_S\mathbf{r}_b + \underbrace{{}_S\mathbf{r}_{es}}_{=0} = \begin{bmatrix} {}_E x_b \\ {}_E y_b \end{bmatrix} = \begin{bmatrix} {}_S x_b \\ {}_S y_b \end{bmatrix} \quad (\text{A.1})$$

$${}_E\mathbf{v}_b = {}_S\dot{\mathbf{r}}_b + \boldsymbol{\omega}_{es} \times {}_S\mathbf{r}_b + {}_S\mathbf{v}_{es} = \begin{bmatrix} {}_E \dot{x}_b \\ {}_E \dot{y}_b \end{bmatrix} = \begin{bmatrix} {}_S \dot{x}_b - \dot{\varphi} {}_S y_b + v \\ {}_S \dot{y}_b + \dot{\varphi} {}_S x_b \end{bmatrix} \quad (\text{A.2})$$

$${}_E\mathbf{a}_b = {}_S\dot{\mathbf{v}}_b + \boldsymbol{\omega}_{es} \times {}_S\mathbf{v}_b + {}_S\mathbf{a}_{es} = \begin{bmatrix} {}_E \ddot{x}_b \\ {}_E \ddot{y}_b \end{bmatrix} = \begin{bmatrix} {}_S \ddot{x}_b - 2\dot{\varphi} {}_S \dot{y}_b - \dot{\varphi}^2 {}_S x_b + a \\ {}_S \ddot{y}_b + 2\dot{\varphi} {}_S \dot{x}_b - \dot{\varphi}^2 {}_S y_b + \dot{\varphi} v \end{bmatrix} \quad (\text{A.3})$$

Die Winkelbeschleunigung des Ego-Fahrzeugs ist sensorisch nicht verfügbar. Unter der Annahme meist stationärer Fahrt wird diese daher mit  $\ddot{\varphi} = 0$  angenommen.

### Erdfest $E \rightarrow$ Kartesisch-Krümmungszentriert $C$

Transformation  $T_{CE}$  vom erdfesten Koordinatensystem  $E$  in ein kartesisches Koordinatensystem  $C$ , welches seinen Ursprung im Krümmungsmittelpunkt des Fahrbahnverlaufs hat (Abbildung A.2):

$${}_C\mathbf{r}_b = \mathbf{R}_{CEE} {}_E\mathbf{r}_b + {}_C\mathbf{r}_c = \begin{bmatrix} {}_C x_b \\ {}_C y_b \end{bmatrix} = \begin{bmatrix} -\sin(\alpha) & -\cos(\alpha) \\ \cos(\alpha) & -\sin(\alpha) \end{bmatrix} \begin{bmatrix} {}_E x_b \\ {}_E y_b \end{bmatrix} + \begin{bmatrix} \frac{1}{c} - hl \\ 0 \end{bmatrix} \quad (\text{A.4})$$

$${}_C\mathbf{v}_b = \underbrace{\dot{\mathbf{R}}_{CEE}}_{=0} {}_E\mathbf{r}_b + \mathbf{R}_{CEE} \dot{\mathbf{r}}_b + \underbrace{{}_C\dot{\mathbf{r}}_c}_{=0} = \begin{bmatrix} {}_C \dot{x}_b \\ {}_C \dot{y}_b \end{bmatrix} = \begin{bmatrix} -\sin(\alpha) & -\cos(\alpha) \\ \cos(\alpha) & -\sin(\alpha) \end{bmatrix} \begin{bmatrix} {}_E \dot{x}_b \\ {}_E \dot{y}_b \end{bmatrix} \quad (\text{A.5})$$

$${}_C\mathbf{a}_b = \underbrace{\dot{\mathbf{R}}_{CEE}}_{=0} \dot{\mathbf{r}}_b + \mathbf{R}_{CEE} \ddot{\mathbf{r}}_b = \begin{bmatrix} {}_C \ddot{x}_b \\ {}_C \ddot{y}_b \end{bmatrix} = \begin{bmatrix} -\sin(\alpha) & -\cos(\alpha) \\ \cos(\alpha) & -\sin(\alpha) \end{bmatrix} \begin{bmatrix} {}_E \ddot{x}_b \\ {}_E \ddot{y}_b \end{bmatrix} \quad (\text{A.6})$$

Dabei wird auf Information über das statische Umfeld von der Kamera zurückgegriffen, welche die aktuellen Eigenschaften der Straße enthält. Die verwendeten Parameter sind in Tabelle A.2 angegeben.


Die Translation  $\frac{1}{c} - hl$  ist dabei der effektive Radius auf dem sich das Ego-Fahrzeug momentan bewegt. Da von den Parametern des Straßenmodells keine Information über weitere Ableitungen zur Verfügung stehen, gilt

$$\dot{\alpha} = \dot{c} = \dot{h} = \dot{l} = 0. \quad (\text{A.7})$$





### Kartesisch-Krümmungszentriert $C \rightarrow$ Polar-Krümmungszentriert $P$



**Abbildung A.3:** Umrechnung der kartesischen Koordinaten des  $C$ -Systems ins Polarsystem  $P$ .

Transformation  $T_{PC}$  von dem kartesischen Koordinatensystem  $C$  in Polarkoordinaten  $P$  mit Winkel  ${}_P x_b$  und Radius  ${}_P y_b$  (Abbildung A.3):

$${}_P \mathbf{r}_b = \begin{bmatrix} {}_P x_b \\ {}_P y_b \end{bmatrix} = \begin{bmatrix} \arctan\left(\frac{{}_C y_b}{{}_C x_b}\right) \\ \text{sgn}(c) \sqrt{{}_C x_b^2 + {}_C y_b^2} \end{bmatrix} \quad (\text{A.8})$$


$${}_P \mathbf{v}_b = \begin{bmatrix} {}_P \dot{x}_b \\ {}_P \dot{y}_b \end{bmatrix} = \begin{bmatrix} \frac{{}_C x_b {}_C \dot{y}_b - {}_C y_b {}_C \dot{x}_b}{{}_C x_b^2 + {}_C y_b^2} \\ \text{sgn}(c) \frac{{}_C x_b {}_C \dot{x}_b - {}_C y_b {}_C \dot{y}_b}{\sqrt{{}_C x_b^2 + {}_C y_b^2}} \end{bmatrix} \quad (\text{A.9})$$

$${}_P \mathbf{a}_b = \begin{bmatrix} {}_P \ddot{x}_b \\ {}_P \ddot{y}_b \end{bmatrix} = \begin{bmatrix} \frac{{}_C x_b {}_C \ddot{y}_b - {}_C y_b {}_C \ddot{x}_b}{{}_C x_b^2 + {}_C y_b^2} - 2 \frac{({}_C x_b {}_C \dot{y}_b - {}_C y_b {}_C \dot{x}_b)({}_C x_b {}_C \dot{x}_b + {}_C y_b {}_C \dot{y}_b)}{({}_C x_b^2 + {}_C y_b^2)^2} \\ \text{sgn}(c) \left( \frac{{}_C x_b {}_C \ddot{x}_b + {}_C \dot{x}_b^2 + {}_C y_b {}_C \ddot{y}_b + {}_C \dot{y}_b^2}{\sqrt{{}_C x_b^2 + {}_C y_b^2}} - \frac{{}_C x_b {}_C \dot{x}_b + {}_C y_b {}_C \dot{y}_b}{({}_C x_b^2 + {}_C y_b^2)^{\frac{3}{2}}} \right) \end{bmatrix} \quad (\text{A.10})$$

Die Krümmung  $c$  des Straßenverlaufs ist vorzeichenbehaftet, was mit der Signum-Funktion  $\text{sgn}(\cdot)$  berücksichtigt wird.

$$\text{sgn}(c) = \begin{cases} +1 & \text{Linkskurve} \\ -1 & \text{Rechtskurve} \end{cases} \quad (\text{A.11})$$

Da der Frontradar nur Objekte vor dem Ego-Fahrzeug detektiert, gilt  ${}_C y_b > 0$ . Für Linkskurven, bei positiver Krümmung, befindet sich der Krümmungsmittelpunkt links der Fahrbahn, wie ihn Abbildung A.3 gezeigt. Für Winkel und Radius gilt  $[_P x_b, {}_P y_b]^\top > \mathbf{0}$ . Für Rechtskurven, bei negativer Krümmung, befindet sich der Krümmungsmittelpunkt rechts der Fahrbahn und für Winkel und Radius gilt  $[_P x_b, {}_P y_b]^\top < \mathbf{0}$ .



**Abbildung A.4:** Transformation der Polarkoordinaten des  $P$ -Systems ins entkrümmte Bezugssystem  $F$ .

### Polar-Krümmungszentriert $P \rightarrow$ Frenet $F$

Abschließend ist die Transformation  $T_{FP}$  von Polarkoordinaten  $P$  in das Frenet-Koordinatensystem  $F$  (Abbildung A.4):

$${}^F\mathbf{r}_b = \begin{bmatrix} {}^F x_b \\ {}^F y_b \end{bmatrix} = \begin{bmatrix} \frac{{}^P x_b}{c} \\ \frac{1}{c} - \frac{{}^P y_b}{l} \end{bmatrix} \quad (\text{A.12})$$

$${}^F\mathbf{v}_b = \begin{bmatrix} {}^F \dot{x}_b \\ {}^F \dot{y}_b \end{bmatrix} = \begin{bmatrix} \frac{{}^P \dot{x}_b}{c} \\ -\frac{{}^P \dot{y}_b}{l} \end{bmatrix} \quad (\text{A.13})$$

$${}^F\mathbf{a}_b = \begin{bmatrix} {}^F \ddot{x}_b \\ {}^F \ddot{y}_b \end{bmatrix} = \begin{bmatrix} \frac{{}^P \ddot{x}_b}{c} \\ -\frac{{}^P \ddot{y}_b}{l} \end{bmatrix} + \begin{bmatrix} 0 \\ \frac{{}^P \dot{x}_b^2}{cl} \end{bmatrix} \quad (\text{A.14})$$

Durch seine Trägheit bedingt, unterliegt ein Körper, der sich auf einer Kreisbahn bewegt, der Zentrifugalkraft. Zum Kreismittelpunkt gerichtet wirkt die Zentripetalkraft dieser entgegen und hält den Körper weiterhin auf der Kreisbahn. Bei einem Fahrzeug wird die Zentripetalkraft i. d. R. durch die Reifen aufgebracht und hält das Fahrzeug auch bei einer Kurvenfahrt auf seiner Bahn – ohne weiteren Einfluss auf Quergeschwindigkeit  ${}^F \dot{y}_b$  und Querversatz  ${}^F y_b$ . Die Querbeschleunigung, welche durch die Kurvengeschwindigkeit induziert wird, wird daher durch den zusätzlichen Term  $\frac{{}^P \dot{x}_b^2}{cl} = \frac{{}^F \dot{x}_b^2 c}{l}$  korrigiert.

Für die gesamthafte Transformationsvorschrift  $T_{FS}$  zur Umrechnung von Messungen im Sensor-Koordinatensystem  $S$  ins entkrümmte System  $F$  werden die einzelnen Transformationen nacheinander ausgeführt:

$$T_{FS} = T_{FP} \leftarrow T_{PC} \leftarrow T_{CE} \leftarrow T_{ES} \quad (\text{A.15})$$

## A.1.2 Rücktransformation entkrümmter Koordinaten

### Frenet $F \rightarrow$ Polar-Krümmungszentriert $P$

Für die Transformation  $T_{PF}$  vom Frenet-Koordinatensystem  $F$  in Polarkoordinaten  $P$  gilt:

$${}^P\mathbf{r}_b = \begin{bmatrix} {}^Px_b \\ {}^Py_b \end{bmatrix} = \begin{bmatrix} {}^Fx_b c \\ \frac{1}{c} - {}^Py_b l \end{bmatrix} \quad (\text{A.16})$$

$${}^P\mathbf{v}_b = \begin{bmatrix} {}^P\dot{x}_b \\ {}^P\dot{y}_b \end{bmatrix} = \begin{bmatrix} {}^F\dot{x}_b c \\ -{}^F\dot{y}_b l \end{bmatrix} \quad (\text{A.17})$$

$${}^P\mathbf{a}_b = \begin{bmatrix} {}^P\ddot{x}_b \\ {}^P\ddot{y}_b \end{bmatrix} = \begin{bmatrix} {}^F\ddot{x}_b c \\ -{}^F\ddot{y}_b l \end{bmatrix} + \begin{bmatrix} 0 \\ {}^F\dot{x}_b^2 c \end{bmatrix} \quad (\text{A.18})$$

Dabei wird wiederum die Querbewegung, welche aus der Kurvengeschwindigkeit resultiert, mit dem Term  ${}^F\dot{x}_b^2 c$  berücksichtigt.

### Polar-Krümmungszentriert $P \rightarrow$ Kartesisch-Krümmungszentriert $C$

Die Polarkoordinaten  $P$  werden mit der Vorschrift  $T_{CP}$  in das kartesische System  $C$  transformiert:

$${}^C\mathbf{r}_b = \begin{bmatrix} {}^Cx_b \\ {}^Cy_b \end{bmatrix} = \begin{bmatrix} {}^Py_b \cos({}^Px_b) \\ {}^Py_b \sin({}^Px_b) \end{bmatrix} \quad (\text{A.19})$$

$${}^C\mathbf{v}_b = \begin{bmatrix} {}^C\dot{x}_b \\ {}^C\dot{y}_b \end{bmatrix} = \begin{bmatrix} {}^P\dot{y}_b \cos({}^Px_b) - {}^Py_b {}^P\dot{x}_b \sin({}^Px_b) \\ {}^P\dot{y}_b \sin({}^Px_b) + {}^Py_b {}^P\dot{x}_b \cos({}^Px_b) \end{bmatrix} \quad (\text{A.20})$$

$${}^C\mathbf{a}_b = \begin{bmatrix} {}^C\ddot{x}_b \\ {}^C\ddot{y}_b \end{bmatrix} = \begin{bmatrix} ({}^P\ddot{y}_b - {}^Py_b {}^P\dot{x}_b^2) \cos({}^Px_b) - (2{}^P\dot{y}_b {}^P\dot{x}_b + {}^Py_b {}^P\ddot{x}_b) \sin({}^Px_b) \\ ({}^P\ddot{y}_b - {}^Py_b {}^P\dot{x}_b^2) \sin({}^Px_b) + (2{}^P\dot{y}_b {}^P\dot{x}_b + {}^Py_b {}^P\ddot{x}_b) \cos({}^Px_b) \end{bmatrix} \quad (\text{A.21})$$

### Kartesisch-Krümmungszentriert $C \rightarrow$ Erdfest $E$

Die Transformation  $T_{EC}$  von kartesischen Koordinaten  $C$  in das Bezugssystem  $E$  ist gegeben zu

$$\begin{aligned} {}^E\mathbf{r}_b &= \mathbf{R}_{EC}({}^C\mathbf{r}_b + {}^C\mathbf{r}_c) \\ &= \begin{bmatrix} {}^Ex_b \\ {}^Ey_b \end{bmatrix} = \begin{bmatrix} -\sin(\alpha) & \cos(\alpha) \\ -\cos(\alpha) & -\sin(\alpha) \end{bmatrix} \left( \begin{bmatrix} {}^Cx_b \\ {}^Cy_b \end{bmatrix} - \begin{bmatrix} \frac{1}{c} - h l \\ 0 \end{bmatrix} \right) \end{aligned} \quad (\text{A.22})$$

$$\begin{aligned} {}^E\mathbf{v}_b &= \underbrace{\dot{\mathbf{R}}_{EC}}_{=0}({}^C\mathbf{r}_b + {}^C\mathbf{r}_c) + \mathbf{R}_{EC}({}^C\dot{\mathbf{r}}_b + \underbrace{\dot{{}^C\mathbf{r}}_c}_{=0}) \\ &= \begin{bmatrix} {}^E\dot{x}_b \\ {}^E\dot{y}_b \end{bmatrix} = \begin{bmatrix} -\sin(\alpha) & \cos(\alpha) \\ -\cos(\alpha) & -\sin(\alpha) \end{bmatrix} \begin{bmatrix} {}^C\dot{x}_b \\ {}^C\dot{y}_b \end{bmatrix} \end{aligned} \quad (\text{A.23})$$

$${}^E\mathbf{a}_b = \underbrace{\dot{\mathbf{R}}_{EC}}_{=0} {}^C\dot{\mathbf{r}}_b + \mathbf{R}_{EC} {}^C\ddot{\mathbf{r}}_b = \begin{bmatrix} {}^E\ddot{x}_b \\ {}^E\ddot{y}_b \end{bmatrix} = \begin{bmatrix} -\sin(\alpha) & \cos(\alpha) \\ -\cos(\alpha) & -\sin(\alpha) \end{bmatrix} \begin{bmatrix} {}^C\ddot{x}_b \\ {}^C\ddot{y}_b \end{bmatrix} \quad (\text{A.24})$$

mit  $\mathbf{R}_{EC} = \mathbf{R}_{CE}^\top$ .

**Erdfest  $E \rightarrow$  Sensor  $S$** 

Um die Beobachtung  ${}_S\mathbf{x}_b$  im beschleunigten Sensorsystem zu bestimmen, wird die Transformation  $T_{SE}$  definiert:

$${}_S\mathbf{r}_b = {}_E\mathbf{r}_b - \underbrace{{}_S\mathbf{r}_{es}}_{=0} = \begin{bmatrix} {}_Sx_b \\ {}_Sy_b \end{bmatrix} = \begin{bmatrix} {}_Ex_b \\ {}_Ey_b \end{bmatrix} \quad (\text{A.25})$$

$${}_S\mathbf{v}_b = {}_E\dot{\mathbf{r}}_b - \boldsymbol{\omega}_e \times {}_S\mathbf{r}_b - {}_S\mathbf{v}_{es} = \begin{bmatrix} {}_S\dot{x}_b \\ {}_S\dot{y}_b \end{bmatrix} = \begin{bmatrix} {}_E\dot{x}_b + \dot{\varphi} {}_Ey_b - v \\ {}_E\dot{y}_b - \dot{\varphi} {}_Ex_b \end{bmatrix} \quad (\text{A.26})$$

$${}_S\mathbf{a}_b = {}_S\dot{\mathbf{v}}_b - \boldsymbol{\omega}_e \times {}_S\mathbf{v}_b - {}_S\mathbf{a}_{es} = \begin{bmatrix} {}_S\ddot{x}_b \\ {}_S\ddot{y}_b \end{bmatrix} = \begin{bmatrix} {}_E\ddot{x}_b + 2\dot{\varphi} {}_S\dot{y}_b + \dot{\varphi}^2 {}_Sx_b - a \\ {}_E\ddot{y}_b - 2\dot{\varphi} {}_S\dot{x}_b + \dot{\varphi}^2 {}_Sy_b - \dot{\varphi}v \end{bmatrix} \quad (\text{A.27})$$


Für die Winkelbeschleunigung des Ego-Fahrzeugs gilt  $\ddot{\varphi} = 0$ .

Die Transformationsvorschrift  $T_{SF}$  bildet die Zustände, angegeben im entkrümmten System  $F$ , auf die Messungen im Sensor-Koordinatensystem  $S$  ab:

$$T_{SF} = T_{SE} \leftarrow T_{EC} \leftarrow T_{CP} \leftarrow T_{PF} \quad (\text{A.28})$$

**A.2 Rekursive bayessche Zustandsschätzung**

Ein Hidden Markov Model (HMM) beschreibt einen Markov Prozess mit dem un beobachteten Zustandsvektor  $\mathbf{x}$  und dem beobachteten Messvektor  $\mathbf{z}$ . In Abbildung A.5 ist ein Graph eines solchen Prozessmodells abgebildet.



**Abbildung A.5:** Zeitliche Entwicklung eines HMM.

Besitzt ein stochastischer Prozess die Markov-Eigenschaft, so nennt man diesen auch einen Markov Prozess; d. h. die bedingte Wahrscheinlichkeitsverteilung des aktuellen Zustands hängt nur vom vorherigen Zustand ab:

$$p(\mathbf{x}_k | \mathbf{x}_{k-1}, \mathbf{x}_{k-2}, \dots, \mathbf{x}_0) = p(\mathbf{x}_k | \mathbf{x}_{k-1}) \quad (\text{A.29})$$

Ebenfalls ist auch die Messung nur vom aktuellen Zustand abhängig und damit von allen anderen Zuständen bedingt unabhängig:

$$p(\mathbf{z}_k | \mathbf{x}_k, \mathbf{x}_{k-1}, \dots, \mathbf{x}_0) = p(\mathbf{z}_k | \mathbf{x}_k) \quad (\text{A.30})$$

Nach dem Satz von Bayes<sup>1</sup> ergibt sich für die bedingte Wahrscheinlichkeit des Zustands  $p(\mathbf{x}_k | \mathcal{Z}_k)$  auf Grundlage aller bisheriger Messungen  $\mathcal{Z}_k = \{\mathbf{z}_k, \mathbf{z}_{k-1}, \dots\}$

$$p(\mathbf{x}_k | \mathcal{Z}_k) \propto p(\mathbf{z}_k | \mathbf{x}_k) p(\mathbf{x}_k | \mathcal{Z}_{k-1}) \quad (\text{A.31})$$

mit der Likelihood  $p(\mathbf{z}_k|\mathbf{x}_k)$  und dem Prior  $p(\mathbf{x}_k|\mathcal{Z}_{k-1})$ . Für die Transition respektive die Prädiktion des Zustands  $\mathbf{x}_k$  auf Grundlage des vorangegangenen Zustands  $\mathbf{x}_{k-1}$  wird über alle potentiell möglichen Zustände marginalisiert und es gilt

$$p(\mathbf{x}_k|\mathcal{Z}_{k-1}) = \int p(\mathbf{x}_k|\mathbf{x}_{k-1}) p(\mathbf{x}_{k-1}|\mathcal{Z}_{k-1}) d\mathbf{x}_{k-1} \quad (\text{A.32})$$

mit der Transitionsdichte  $p(\mathbf{x}_k|\mathbf{x}_{k-1})$  des Systemmodells.

### A.2.1 Das Kalman Filter

Das Kalman Filter (KF) ist ein rekursiver bayesscher Zustandsschätzer. Für lineardynamische, zeitdiskrete Systeme der Form

$$\mathbf{x}_k = \mathbf{F}_k \mathbf{x}_{k-1} + \mathbf{B}_k \mathbf{u}_k + \mathbf{v}_k \quad (\text{A.33})$$

$$\mathbf{z}_k = \mathbf{H}_k \mathbf{x}_k + \mathbf{D}_k \mathbf{u}_k + \mathbf{w}_k \quad (\text{A.34})$$

ist das lineare KF ein optimales Filter für die Minimierung des mittleren, quadratischen Schätzfehlers. In Tabelle A.3 werden die linearen Operatoren des Systems beschrieben. Im Allgemeinen beinhaltet die Herleitung des KF keine Annahme über

| Operator       | Beschreibung  |
|----------------|---------------|
| $\mathbf{F}_k$ | Systemmodell  |
| $\mathbf{B}_k$ | Steuereingang |
| $\mathbf{H}_k$ | Messmodell    |
| $\mathbf{D}_k$ | Durchgriff    |

**Tabelle A.3:** Lineare Operatoren des dynamischen Systems

die Verteilung der Fehler. Im speziellen Fall normalverteilter Fehler liefert das Filter jedoch die exakte Schätzung für die bedingte Wahrscheinlichkeitsverteilung des Zustands [51]. Dabei wird für das Prozessrauschen  $\mathbf{v}_k$  und Messrauschen  $\mathbf{w}_k$  mittelwertfreies, weißes, gaußverteiltes Rauschen mit den Kovarianzen  $\mathbf{Q}_k = \text{E}(\mathbf{v}_k \mathbf{v}_k^\top)$  respektive  $\mathbf{R}_k = \text{E}(\mathbf{w}_k \mathbf{w}_k^\top)$  angenommen. Für die Wahrscheinlichkeitsverteilungen des Zustands, des Prädiktions- sowie des Messmodells ergeben sich

$$p(\mathbf{x}_k|\mathcal{Z}_k) = \mathcal{N}(\mathbf{x}_k, \mathbf{P}_k) \quad (\text{A.35})$$

$$p(\mathbf{x}_k|\mathbf{x}_{k-1}, \mathbf{u}_k) = \mathcal{N}(\mathbf{F}_k \mathbf{x}_{k-1} + \mathbf{B}_k \mathbf{u}_k, \mathbf{Q}_k) \quad (\text{A.36})$$

$$p(\mathbf{z}_k|\mathbf{x}_k, \mathbf{u}_k) = \mathcal{N}(\mathbf{H}_k \mathbf{x}_k + \mathbf{D}_k \mathbf{u}_k, \mathbf{R}_k) \quad (\text{A.37})$$

mit dem Zustand  $\mathbf{x}_k$  und dessen Kovarianz  $\mathbf{P}_k$ .

<sup>1</sup> Die zweimalige Anwendung des Satz von Bayes und die Aufteilung der Verbundwahrscheinlichkeiten in bedingte und a priori Wahrscheinlichkeiten ergibt

$$\begin{aligned} p(\mathbf{x}_k|\mathcal{Z}_k) &= \frac{p(\mathcal{Z}_k|\mathbf{x}_k) p(\mathbf{x}_k)}{p(\mathcal{Z}_k)} = \frac{p(\mathbf{z}_k, \mathcal{Z}_{k-1}|\mathbf{x}_k) p(\mathbf{x}_k)}{p(\mathbf{z}_k, \mathcal{Z}_{k-1})} = \frac{p(\mathbf{z}_k|\mathcal{Z}_{k-1}, \mathbf{x}_k) p(\mathcal{Z}_{k-1}|\mathbf{x}_k) p(\mathbf{x}_k)}{p(\mathbf{z}_k|\mathcal{Z}_{k-1}) p(\mathcal{Z}_{k-1})} \\ &= \frac{p(\mathbf{z}_k|\mathcal{Z}_{k-1}, \mathbf{x}_k) p(\mathbf{x}_k|\mathcal{Z}_{k-1}) p(\mathcal{Z}_{k-1}) p(\mathbf{x}_k)}{p(\mathbf{z}_k|\mathcal{Z}_{k-1}) p(\mathcal{Z}_{k-1}) p(\mathbf{x}_k)} = \frac{p(\mathbf{z}_k|\mathbf{x}_k) p(\mathbf{x}_k|\mathcal{Z}_{k-1})}{p(\mathbf{z}_k|\mathcal{Z}_{k-1})} \end{aligned}$$

Zur vereinfachten Darstellung wird im Folgenden für die bedingte Wahrscheinlichkeit  $p(\mathbf{x}_k|\mathcal{Z}_k)$  des Zustands, welcher die Information aller Messungen bis zum Zeitpunkt  $k$  beinhaltet, die Notation

$$p(\mathbf{x}_{k|k}) = p(\mathbf{x}_k|\mathcal{Z}_k) \quad (\text{A.38})$$

eingeführt. Entsprechend ist  $\mathbf{x}_{k|k-1}$  der prädizierte Zustand zum Zeitpunkt  $k$ , in welchem die Messungen  $\mathcal{Z}_{k-1}$  bereits berücksichtigt sind.

Das Prädiktionsmodell des Systems liefert die a priori Zustandsschätzung

$$\mathbf{x}_{k|k-1} = \mathbf{F}_k \mathbf{x}_{k-1|k-1} + \mathbf{B}_k \mathbf{u}_k \quad (\text{A.39})$$

$$\mathbf{P}_{k|k-1} = \mathbf{F}_k \mathbf{P}_{k-1|k-1} \mathbf{F}_k^\top + \mathbf{Q}_k \quad (\text{A.40})$$

für den Zeitpunkt  $k$  auf Grundlage der Information des Zeitpunktes  $k-1$ . Die a posteriori Schätzung

$$\mathbf{x}_{k|k} = \mathbf{x}_{k|k-1} + \mathbf{K}_k \tilde{\mathbf{y}}_k \quad (\text{A.41})$$

$$\mathbf{P}_{k|k} = (\mathbf{I} - \mathbf{K}_k \mathbf{H}_k) \mathbf{P}_{k|k-1} \quad (\text{A.42})$$

erhält man durch die Korrektur der a priori Schätzung mit der Messung  $\mathbf{z}_k$ . Dabei ist  $\mathbf{I}$  die Einheitsmatrix. Dafür werden die Innovationen

$$\tilde{\mathbf{y}}_k = \mathbf{z}_k - (\mathbf{H}_k \mathbf{x}_{k|k-1} + \mathbf{D}_k \mathbf{u}_k) \quad (\text{A.43})$$

$$\mathbf{S}_k = \mathbf{H}_k \mathbf{P}_{k|k-1} \mathbf{H}_k^\top + \mathbf{R}_k \quad (\text{A.44})$$

sowie die optimale Kalman-Verstärkung

$$\mathbf{K}_k = \mathbf{P}_{k|k-1} \mathbf{H}_k^\top \mathbf{S}_k^{-1} \quad (\text{A.45})$$

benötigt.

## A.2.2 Das Unscented Kalman Filter

Für ein nichtlineares, zeitdiskretes System der Form

$$\mathbf{x}_k = \mathbf{f}(\mathbf{x}_{k-1}, \mathbf{u}_k) + \mathbf{v}_k \quad (\text{A.46})$$

$$\mathbf{z}_k = \mathbf{h}(\mathbf{x}_k, \mathbf{u}_k) + \mathbf{w}_k \quad (\text{A.47})$$

kann das Extended Kalman Filter (EKF) verwendet werden. Dieses erweitert die Berechnung der Zustandsschätzung auf nichtlineare Funktionen. Die vektorwertigen, nichtlinearen Funktionen  $\mathbf{f}$  und  $\mathbf{h}$  werden für die Durchführung der Matrixoperationen lokal linearisiert, d. h. die Jakobi-Matrizen von  $\mathbf{f}$  und  $\mathbf{h}$  bestimmt. Für stark nichtlineare Zusammenhänge leidet die Schätzqualität des EKF jedoch unter dieser lokalen Linearisierung.

### Unscented Transformation

Das Unscented Kalman Filter (UKF) umgeht das Problem der Linearisierung durch eine deterministische Sampling-Technik, die Unscented Transformation (UT). Dabei

wird die unimodale Wahrscheinlichkeitsverteilung des Zustands durch eine begrenzte Anzahl symmetrisch angeordneter Sigma-Punkte dargestellt [52]. Diese Punkte werden anschließend durch die nichtlinearen Funktionen propagiert.

Für die  $2L + 1$  Sigma-Punkte  $\mathbf{x}^{(i)}$  mit den entsprechenden Gewichten  $w_m^{(i)}$  und  $w_c^{(i)}$  gilt

$$\mathbf{x}^{(0)} = \mathbf{x} \quad (\text{A.48})$$

$$\mathbf{x}^{(i)} = \mathbf{x} + \left( \sqrt{(L + \lambda)\mathbf{P}} \right)_i, \quad i = 1, \dots, L \quad (\text{A.49})$$

$$\mathbf{x}^{(i)} = \mathbf{x} - \left( \sqrt{(L + \lambda)\mathbf{P}} \right)_{i-L}, \quad i = L + 1, \dots, 2L \quad (\text{A.50})$$

$$w_m^{(0)} = \frac{\lambda}{L + \lambda} \quad (\text{A.51})$$

$$w_c^{(0)} = \frac{\lambda}{L + \lambda} + (1 - \alpha^2 + \beta) \quad (\text{A.52})$$

$$w_m^{(i)} = w_c^{(i)} = \frac{1}{2(L + \lambda)}, \quad i = 1, \dots, 2L \quad (\text{A.53})$$

mit der Dimension  $L$  von  $\mathbf{x}$  und dem Designparameter  $\lambda = \alpha^2(L + \kappa) - L$  [53]. Die  $i$ -te Spalte der Matrixquadratwurzel  $\left( \sqrt{(L + \lambda)\mathbf{P}} \right)_i$  kann z. B. mit der Cholesky-Zerlegung effizient und stabil berechnet werden.

Die Parameter  $\alpha$  und  $\kappa$  beeinflussen die Streuung der Sigma-Punkte.  $\beta$  steht im Zusammenhang mit der zugrundeliegenden Verteilung von  $\mathbf{x}$ . Empirisch wird im Rahmen dieser Arbeit  $\alpha = 10^{-3}$  sowie  $\beta = 2$  als optimal für gaußverteilte  $\mathbf{x}$  gewählt [54].

Für eine beliebige, symmetrische Verteilung mit Wölbung bzw. Kurtosis  $k$  gilt mit  $0 < L + \lambda \leq k$ , dass die Schätzung des Mittelwerts und der Kovarianz besser sind als die eines EKF [55]. Die Fehler werden dabei im 4-ten und höheren Momenten induziert. Wählt man  $L + \lambda = k$ , so wird der Fehler der Kurtosis minimiert. Mit  $\kappa = \frac{1.5}{\alpha^2} - L$  wird unter Annahme einer Gaußverteilung (Kurtosis  $k = 3$ ) ein Kompromiss zwischen Stabilität (Instabilität für  $L + \lambda \rightarrow 0$ ) und Qualität angestrebt:  $L + \lambda = 1.5$

Für die Prädiktion werden die a priori Sigma-Punkte berechnet.

$$\mathbf{x}_{k|k-1}^{(i)} = \mathbf{f}(\mathbf{x}_{k-1|k-1}^{(i)}), \quad i = 0, \dots, 2L \quad (\text{A.54})$$

Anschließend wird der Erwartungswert und die Kovarianz der Verteilung rekombiniert, wobei additives Rauschen angenommen wird.

$$\mathbf{x}_{k|k-1} = \sum_{i=0}^{2L} w_m^{(i)} \mathbf{x}_{k|k-1}^{(i)} \quad (\text{A.55})$$

$$\mathbf{P}_{k|k-1} = \sum_{i=0}^{2L} w_c^{(i)} (\mathbf{x}_{k|k-1}^{(i)} - \mathbf{x}_{k|k-1})(\mathbf{x}_{k|k-1}^{(i)} - \mathbf{x}_{k|k-1})^\top + \mathbf{Q}_k \quad (\text{A.56})$$

Für die Messung werden die Sigma-Punkte anhand des Messmodells in den Messraum projiziert.

$$\mathbf{z}_{k|k-1}^{(i)} = \mathbf{h}(\mathbf{x}_{k|k-1}^{(i)}), \quad i = 0, \dots, 2L \quad (\text{A.57})$$



Die gewichteten Sigma-Punkte im Messraum werden zur propagierten Messung und Messkovarianz unter der Annahme additiven Messrauschens rekombiniert.

$$\mathbf{z}_{k|k-1} = \sum_{i=0}^{2L} w_m^{(i)} \mathbf{z}_{k|k-1}^{(i)} \quad (\text{A.58})$$

$$\mathbf{P}_{z_k z_k} = \sum_{i=0}^{2L} w_c^{(i)} (\mathbf{z}_{k|k-1}^{(i)} - \mathbf{z}_{k|k-1}) (\mathbf{z}_{k|k-1}^{(i)} - \mathbf{z}_{k|k-1})^\top + \mathbf{R}_k \quad (\text{A.59})$$

Mit Hilfe der Kreuzkovarianz

$$\mathbf{P}_{\mathbf{x}_k z_k} = \sum_{i=0}^{2L} w_c^{(i)} (\mathbf{x}_{k|k-1}^{(i)} - \mathbf{x}_{k|k-1}) (\mathbf{z}_{k|k-1}^{(i)} - \mathbf{z}_{k|k-1})^\top \quad (\text{A.60})$$

zwischen Zustand und Messung wird die Verstärkung des UKF

$$\mathbf{K}_k = \mathbf{P}_{\mathbf{x}_k z_k} \mathbf{P}_{z_k z_k}^{-1} \quad (\text{A.61})$$

berechnet. Die a posteriori Zustandsschätzung ist damit

$$\mathbf{x}_{k|k} = \mathbf{x}_{k|k-1} + \mathbf{K}_k (\mathbf{z}_k - \mathbf{z}_{k|k-1}) \quad (\text{A.62})$$

$$\mathbf{P}_{k|k} = \mathbf{P}_{k|k-1} - \mathbf{K}_k \mathbf{P}_{z_k z_k} \mathbf{K}_k^\top \quad (\text{A.63})$$

### A.2.3 Das Partikel Filter

In Kapitel A.2.2 wurden die Sigma-Punkte  $\mathbf{x}^{(i)}$  des UKF durch die UT nach einem deterministischen Schema ausgewählt, um eine kontinuierliche, symmetrische und unimodale Verteilung durch nichtlineare Funktionen zu propagieren. Wird dieses Konzept verallgemeinert, um eine beliebige Wahrscheinlichkeitsdichte durch eine begrenzte Zahl diskreter Punkte  $\mathbf{x}^{(i)}$  einer Stichprobe zu beschreiben, erhält man ein PF [56, 57, 58]. Die zufällig gezogenen Punkte der Stichprobe werden in diesem Zusammenhang auch Partikel genannt. Die kontinuierliche Verteilung des Zustands

$$p(\mathbf{x}_{k|k}) \approx \sum_{i=1}^n w_k^{(i)} \delta(\mathbf{x}_{k|k} - \mathbf{x}_k^{(i)}) \quad (\text{A.64})$$

wird durch  $n$  diskreten Partikel

$$\mathbf{x}_k^{(i)} \sim p(\mathbf{x}_{k|k}) \quad (\text{A.65})$$

approximiert. Da die Partikel nun zufällig und nicht mehr deterministisch aus der Verteilung gezogen werden, muss in der praktischen Anwendung eine hohe Anzahl an Partikeln verwendet werden, um die Verteilung ausreichend genau abzubilden ( $i \gg 1$ ). Jedem Partikel ist dabei ein individuelles Gewicht zugeordnet. Die Gewichte werden mit

$$w_k^{(i)} = \frac{1}{n} \quad (\text{A.66})$$

initialisiert. Diese sind normiert und damit gilt stets

$$\sum_{i=1}^n w_k^{(i)} = 1 \quad (\text{A.67})$$

Der Prädiktionsschritt wird durch die Transitionsdichte

$$p(\mathbf{x}_k^{(i)} | \mathbf{x}_{k-1}^{(i)}) = \mathcal{N}(\mathbf{f}(\mathbf{x}_{k-1}^{(i)}), \boldsymbol{\Sigma}_k^{(i)}) \quad (\text{A.68})$$

für jeden der  $n$  Partikel beschrieben. Dabei wird der konkrete Zustand jedes Partikels nach der Anwendung der Transitionsfunktion  $\mathbf{f}$  individuell verwechselt. Es gilt

$$\mathbf{x}_k^{(i)} \sim \mathbf{f}(\mathbf{x}_{k-1}^{(i)}) + \mathbf{v}_k^{(i)} \quad (\text{A.69})$$

mit  $\mathbf{v}_k^{(i)} = \mathcal{N}(\mathbf{0}, \boldsymbol{\Sigma}_k^{(i)})$ .

Eine Messung beeinflusst die Gewichte nach (A.31) derart, dass

$$w_k^{(i)} \propto w_{k-1}^{(i)} \frac{p(\mathbf{z}_k | \mathbf{x}_k^{(i)}) p(\mathbf{x}_k^{(i)} | \mathbf{x}_{k-1}^{(i)})}{p(\mathbf{x}_k^{(i)} | \mathbf{x}_{k-1}^{(i)}, \mathbf{z}_k)}. \quad (\text{A.70})$$

Unter der Annahme, dass  $p(\mathbf{x}_k^{(i)} | \mathbf{x}_{k-1}^{(i)}) = p(\mathbf{x}_k^{(i)} | \mathbf{x}_{k-1}^{(i)}, \mathbf{z}_k)$  vereinfacht sich die Vorschrift zu

$$w_k^{(i)} \propto w_{k-1}^{(i)} p(\mathbf{z}_k | \mathbf{x}_k^{(i)}) \quad (\text{A.71})$$

mit der Likelihood  $p(\mathbf{z}_k | \mathbf{x}_k^{(i)}) = \mathcal{N}(\mathbf{z}_k | \mathbf{h}(\mathbf{x}_k^{(i)}), \mathbf{R})$  der Messung.

In [56] wurde gezeigt, dass bei fortlaufender Filterung die Varianz der Gewichte stetig ansteigt, d. h. es gibt letztlich ein paar wenige Partikel mit hohem Gewicht und entsprechend viele mit sehr kleinem Gewicht. Grundsätzlich soll jedoch der numerische Aufwand vermieden werden, Partikel zu berechnen, deren Einfluss auf  $p(\mathbf{x}_{k|k})$  sehr klein ist. Dieses Phänomen der Degeneration der approximierten Wahrscheinlichkeitsdichte kann anhand der effektiven Anzahl  $n_{\text{eff}}$  der Partikel in der Stichprobe detektiert werden. Eine Schätzung liefert

$$n_{\text{eff}} \approx \frac{1}{\sum_{i=1}^n (w_k^{(i)})^2}. \quad (\text{A.72})$$

Dabei gilt  $1 \leq n_{\text{eff}} \leq n$  und bspw. bei  $n_{\text{eff}} < \frac{2}{3}n$  findet ein Resampling statt: Partikel und Gewichte werden neu justiert.

Beim Resampling wird die Wahrscheinlichkeitsdichte des Zustands durch ein GMM der Form

$$p(\mathbf{x}_{k|k}) \approx \sum_{i=1}^n w_k^{(i)} \mathcal{N}(\mathbf{f}(\mathbf{x}_{k-1}^{(i)}), \boldsymbol{\Sigma}_k^{(i)}) \quad (\text{A.73})$$

approximiert. Daraus werden dann analog zu (A.65) die neuen Partikel gezogen: Dabei wird jeweils zufällig eine Komponente  $c$  des GMM ausgewählt und daraus ein neues Partikel gezogen.

$$P(c = i) = w_k^{(i)} \quad (\text{A.74})$$

$$\mathbf{x}_k^{(i)} \sim \mathcal{N}(\mathbf{x}_k^{(c)}, \boldsymbol{\Sigma}_k^{(c)}) \quad (\text{A.75})$$

Dies führt dazu, dass von sehr unwahrscheinlichen Komponenten des GMM keine neuen Partikel gezogen werden und damit diese Partikel mit niedrigem Gewicht und geringem Einfluss auf die Verteilung nicht weiter propagiert werden. Aus Komponenten mit hohem Gewicht werden dafür mehrere Partikel gezogen. Abschließend werden alle Gewichte nach (A.66) reinitialisiert.

# Literaturverzeichnis

- [1] Statistisches Bundesamt, „Verkehrsunfälle Zeitreihen 2014“, Tech. Rep., 2015.
- [2] Statistisches Bundesamt, „Verkehrsunfälle Fachserie 8 Reihe 7“, Tech. Rep., 2016.
- [3] Europäische Kommission, „Leitlinien für die Politik im Bereich der Straßenverkehrssicherheit 2011-2020“, 2011.
- [4] Europäisches Parlament und Rat, „Verordnung (EG) Nr. 661/2009“, S. 1–24, 2009.
- [5] Verkehrsclub Deutschland, „VCD-Masterplan: Vision Zero“, 2009.
- [6] Europäische Union, „AdaptIVE“, <https://www.adaptive-ip.eu>, 2014.
- [7] Bundesministerium für Wirtschaft und Energie, „Ko-HAF“, <https://www.ko-haf.de>, 2015.
- [8] INRIX, „Deutschlands Staukarte“, Tech. Rep., 2015.
- [9] INRIX, „Guide to congestion in the UK“, Tech. Rep., 2015.
- [10] GeoNames, „GeoNames RESTful API“, <https://www.geonames.org>, 2014.
- [11] K. Bengler, K. Dietmayer, B. Farber, M. Maurer, C. Stiller und H. Winner, „Three Decades of Driver Assistance Systems: Review and Future Perspectives“, *IEEE Intelligent Transportation Systems Magazine*, Vol. 6, Nr. 4, S. 6–22, Jan. 2014.
- [12] H. Winner, S. Hakuli, F. Lotz und C. Singer, *Handbuch Fahrerassistenzsysteme*, 3. Aufl. Springer, 2015.
- [13] M. Werling, „Ein neues Konzept für die Trajektoriengenerierung und -stabilisierung in zeitkritischen Verkehrsszenarien“, Dissertation, Karlsruher Institut für Technologie, 2011.
- [14] F. Schuldt, S. Ulbrich, T. Menzel, A. Reschka und M. Maurer, „Definition der Begriffe Szene, Situation und Szenario für das automatisierte Fahren“, in *Fahrerassistenzworkshop Walting*, Sep. 2015.

- 
- [15] K. P. Wershofen und V. Graefe, *Autonome Mobile Systeme 1996*, Serie Informatik aktuell, G. Schmidt und F. Freyberger, Hrsgg. Berlin, Heidelberg: Springer Berlin Heidelberg, 1996.
- [16] W. Fastenmeier, „Fahrerunterstützung durch ACC“, *7. Aachener Kolloquium Fahrzeug- und Motorentchnik, VKA, RWTH*, S. 567–582, 1998.
- [17] L. Breiman, J. Friedman, C. Stone und R. Olshen, *Classification and Regression Trees (Wadsworth Statistics/Probability)*, 1. Aufl. Chapman and Hall/CRC, 1984.
- [18] L. Breiman, „Random Forests“, *Machine Learning*, Vol. 45, Nr. 1, S. 5–32, Okt. 2001.
- [19] A. Y. Ng und M. I. Jordan, „On Discriminative vs. Generative Classifiers: A comparison of logistic regression and naive Bayes“, in *Advances in Neural Information Processing Systems*, 2002, S. 841–848.
- [20] S. Thrun, W. Burgard und D. Fox, *Probabilistic Robotics (Intelligent Robotics and Autonomous Agents)*. MIT Press, 2005.
- [21] C. Gold, D. Damböck, L. Lorenz und K. Bengler, „"Take over!" How long does it take to get the driver back into the loop?“, *Proceedings of the Human Factors and Ergonomics Society Annual Meeting*, Vol. 57, Nr. 1, S. 1938–1942, Sep. 2013.
- [22] L. Lorenz, P. Kerschbaum und J. Schumann, „Designing take over scenarios for automated driving: How does augmented reality support the driver to get back into the loop?“, *Proceedings of the Human Factors and Ergonomics Society Annual Meeting*, Vol. 58, Nr. 1, S. 1681–1685, Okt. 2014.
- [23] D. Damböck, M. Farid, L. Toenert und K. Bengler, „Übernahmezeiten beim hochautomatisierten Fahren“, in *5. Tagung Fahrerassistenz*, München, 2012.
- [24] R. Schubert, E. Richter und G. Wanielik, „Comparison and evaluation of advanced motion models for vehicle tracking“, S. 1–6, 2008.
- [25] A. Houenou, P. Bonnifait und V. Cherfaoui, „Vehicle trajectory prediction based on motion model and maneuver recognition“, in *2013 IEEE/RSJ International Conference on Intelligent Robots and Systems*. IEEE, Nov. 2013, S. 4363–4369.
- [26] C. Hermes, J. Wiest, C. Wöhler, U. Kressel und F. Kummert, „Manifold-based Motion Prediction Conclusion“, in *6. Dortmunder Auto-Tag*, 2011.
- [27] J. Wiest, M. Hoffken, U. Kressel und K. Dietmayer, „Probabilistic trajectory prediction with Gaussian mixture models“, in *2012 IEEE Intelligent Vehicles Symposium*. IEEE, Juni 2012, S. 141–146.
- [28] J. Wiest, F. Kunz, U. Kressel und K. Dietmayer, „Incorporating Categorical Information for Enhanced Probabilistic Trajectory Prediction“, in *2013 12th International Conference on Machine Learning and Applications*, Vol. 1. IEEE, Dez. 2013, S. 402–407.

- [29] J. Schlechtriemen, A. Wedel, G. Breuel und K.-D. Kuhnert, „A probabilistic long term prediction approach for highway scenarios”, in *17th International IEEE Conference on Intelligent Transportation Systems (ITSC)*. IEEE, Okt. 2014, S. 732–738.
- [30] D. Nguyen-Tuong und J. Jan Peters, „Local Gaussian process regression for real-time model-based robot control”, in *2008 IEEE/RSJ International Conference on Intelligent Robots and Systems*. IEEE, Sep. 2008, S. 380–385.
- [31] J. Ko und D. Fox, „GP-BayesFilters: Bayesian filtering using Gaussian process prediction and observation models”, in *2008 IEEE/RSJ International Conference on Intelligent Robots and Systems*. IEEE, Sep. 2008, S. 3471–3476.
- [32] D. Ellis, E. Sommerlade und I. Reid, „Modelling pedestrian trajectory patterns with Gaussian processes”, in *2009 IEEE 12th International Conference on Computer Vision Workshops, ICCV Workshops*. IEEE, Sep. 2009, S. 1229–1234.
- [33] Q. Tran und J. Firl, „Online maneuver recognition and multimodal trajectory prediction for intersection assistance using non-parametric regression”, in *2014 IEEE Intelligent Vehicles Symposium Proceedings*. IEEE, Juni 2014, S. 918–923.
- [34] M. Seeger, C. K. I. Williams und N. D. Lawrence, „Fast Forward Selection to Speed Up Sparse Gaussian Process Regression”, in *Artificial Intelligence and Statistics 9*, 2003.
- [35] J. Quiñero-Candela, C. E. Ramussen und C. K. I. Williams, „Approximation Methods for Gaussian Process Regression”, Microsoft Research, Tech. Rep., 2007.
- [36] E. Snelson und Z. Ghahramani, „Sparse Gaussian Processes using Pseudo-inputs”, in *Advances in Neural Information Processing Systems*, 2006, S. 1257–1264.
- [37] M. A. Alvarez, L. Rosasco und N. D. Lawrence, „Kernels for Vector-Valued Functions: a Review”, University of Manchester, Tech. Rep., Juni 2011.
- [38] C.-A. Cheng und H.-P. Huang, „Learn the Lagrangian: A Vector-Valued RKHS Approach to Identifying Lagrangian Systems.”, *IEEE transactions on cybernetics*, Vol. 46, Nr. 12, S. 3247–3258, Dez. 2015.
- [39] H. Berndt, J. Emmert und K. Dietmayer, „Continuous Driver Intention Recognition with Hidden Markov Models”, *11th International IEEE Conference on Intelligent Transportation Systems*, S. 1189–1194, Okt. 2008.
- [40] T. Huang, D. Koller, J. Malik, G. H. Ogasawara, B. Rao, S. J. Russell und J. Weber, „Automatic Symbolic Traffic Scene Analysis Using Belief Networks.”, in *2th National Conference on Artificial Intelligence*, Seattle, 1994, S. 966–972.

- [41] D. Meyer-Delius, C. Plagemann, G. von Wichert, W. Feiten, G. Lawitzky und W. Burgard, „A Probabilistic Relational Model for Characterizing Situations in Dynamic Multi-Agent Systems”, in *Data Analysis, Machine Learning and Applications*, Serie Studies in Classification, Data Analysis, and Knowledge Organization, C. Preisach, H. Burkhardt, L. Schmidt-Thieme und R. Decker, Hrsgg. Springer, 2008, S. 269–276.
- [42] M. Liebner, M. Baumann, F. Klanner und C. Stiller, „Driver intent inference at urban intersections using the intelligent driver model”, in *2012 IEEE Intelligent Vehicles Symposium*. IEEE, Juni 2012, S. 1162–1167.
- [43] M. Liebner, F. Klanner, M. Baumann, C. Ruhhammer und C. Stiller, „Velocity-Based Driver Intent Inference at Urban Intersections in the Presence of Preceding Vehicles”, *IEEE Intelligent Transportation Systems Magazine*, Vol. 5, Nr. 2, S. 10–21, Jan. 2013.
- [44] M. Liebner, C. Ruhhammer, F. Klanner und C. Stiller, „Generic driver intent inference based on parametric models”, in *16th International IEEE Conference on Intelligent Transportation Systems (ITSC 2013)*. IEEE, Okt. 2013, S. 268–275.
- [45] D. Kasper, G. Weidl, T. Dang, G. Breuel, A. Tamke und W. Rosenstiel, „Object-Oriented Bayesian Networks for Detection of Lane Change Maneuvers”, in *2011 IEEE Intelligent Vehicles Symposium (IV)*. IEEE, Juni 2011, S. 673–678.
- [46] 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”, *IEEE Intelligent Transportation Systems Magazine*, Vol. 4, Nr. 3, S. 19–31, Jan. 2012.
- [47] J. Zeisler, J. Cherepanov und V. Haltakov, „A driving path based target object prediction”, in *2015 IEEE Intelligent Vehicles Symposium (IV)*. IEEE, Juni 2015, S. 316–321.
- [48] D. Koller und A. Pfeffer, „Object-Oriented Bayesian Networks”, in *13th Conference on Uncertainty in Artificial Intelligence*, 1997, S. 302–313.
- [49] P. Kumar, M. Perrollaz, S. Lefevre und C. Laugier, „Learning-based approach for online lane change intention prediction”, in *2013 IEEE Intelligent Vehicles Symposium (IV)*. IEEE, Juni 2013, S. 797–802.
- [50] J. Schleichtriemen, A. Wedel, J. Hillenbrand, G. Breuel und K.-D. Kuhnert, „A lane change detection approach using feature ranking with maximized predictive power”, in *2014 IEEE Intelligent Vehicles Symposium Proceedings*. IEEE, Juni 2014, S. 108–114.
- [51] R. E. Kalman, „A New Approach to Linear Filtering and Prediction Problems”, *Journal of Basic Engineering*, Vol. 82, Nr. 1, S. 35, März 1960.
- [52] J. Uhlmann, „Dynamic Map Building and Localization: New Theoretical Foundations”, Dissertation, University of Oxford, 1995.

- 
- [53] S. J. Julier und J. K. Uhlmann, „A New Extension of the Kalman Filter to Nonlinear Systems”, in *Proceedings of SPIE - The International Society for Optical Engineering*, I. Kadar, Hrsg., Vol. 3068, Juli 1997, S. 182–193.
- [54] S. Julier, „The scaled unscented transformation”, in *Proceedings of the 2002 American Control Conference (IEEE Cat. No. CH37301)*, Vol. 6. IEEE, 2002, S. 4555–4559.
- [55] S. Julier, J. Uhlmann und H. Durrant-Whyte, „A new approach for filtering nonlinear systems”, in *American Control Conference, Proceedings of the 1995*, Vol. 3. IEEE, 1995, S. 1628–1632.
- [56] A. Doucet, S. Godsill und C. Andrieu, „On Sequential Monte Carlo Sampling Methods for Bayesian Filtering”, *Statistics and Computing*, Vol. 10, Nr. 3, S. 197–208, 2000.
- [57] A. Doucet, N. Freitas und N. Gordon, Hrsgg., *Sequential Monte Carlo Methods in Practice*. New York, NY: Springer New York, 2001.
- [58] M. Arulampalam, S. Maskell, N. Gordon und T. Clapp, „A tutorial on particle filters for online nonlinear/non-Gaussian Bayesian tracking”, *IEEE Transactions on Signal Processing*, Vol. 50, Nr. 2, S. 174–188, 2002.





# Publikationen

- [59] J. Jordan, N. Hirsenkorn, F. Klanner und M. Kleinsteuber, „Vehicle mass estimation based on vehicle vertical dynamics using a multi-model filter”, in *17th International IEEE Conference on Intelligent Transportation Systems*. IEEE, Okt. 2014, S. 2041–2046.
- [60] J. Jordan, C. Ruhhammer, H. Kloeden und M. Kleinsteuber, „Learning Driving Scene Prediction from Environmental Perception of Vehicle Fleet Data”, in *2015 IEEE 18th International Conference on Intelligent Transportation Systems*. IEEE, Sep. 2015, S. 547–552.
- [61] F. Gross, J. Jordan, F. Weninger, F. Klanner und B. Schuller, „Route and Stopping Intent Prediction at Intersections from Car Fleet Data”, *IEEE Transactions on Intelligent Vehicles*, Vol. 1, Nr. 2, S. 177 – 186, 2016.



# Patentanmeldungen

- [62] J. Jordan, N. Hirsenkorn und F. Klanner, „Fahrzeugmassenschätzungsverfahren“, DE Patent DE 10 2014 211 273 A1, 2015.
- [63] J. Jordan, N. Hirsenkorn und F. Klanner, „Bahnplanung für komplexe Dynamiken“, DE Patent DE 10 2014 215 245 A1, 2016.
- [64] P. Bankus, F. Klanner, J. Jordan und H. Klöden, „Aufpralldämpfung für ein Fahrzeug“, DE Patent DE 10 2015 202 617 A1, 2016.
- [65] J. Jordan, „Server, System und Verfahren zur Bestimmung einer Position eines Stauendes“, WO Patent WO 1613/4901 A1, 2016.
- [66] C. Ruhhammer, K. Dollinger, N. Kaempchen und J. Jordan, „Verfahren, Fahrerassistenzsystem und Fahrzeug zum Lernen einer Trajektorie eines Straßenabschnitts“, DE Patent DE 10 2015 211 150 A1, 2016.
- [67] J. Jordan, C. Ruhhammer, H. Kloeden, R. Rasshofer und F. Klanner, „Vorrichtung zur Anonymisierung von Positions- und Bewegungsdaten eines Kraftfahrzeugs“, DE Patent DE 10 2015 213 393 A1, 2015.
- [68] J. Jordan, F. Klanner, A. Rauch und N. Hirsenkorn, „Verbessertes Verfahren zum Ermitteln der Randbebauung einer Fahrbahn für die Lokalisierung von Kraftfahrzeugen“, DE Patent DE 10 2015 225 577 A1, 2016.
- [69] J. Jordan und H. Kloeden, „Semiparametrische Trajektorien-Prädiktion und Fahrstreifenrelevanzerkennung“, DE Patent DE 10 2016 215 314 A1, 2016.



# Betreute studentische Arbeiten

- [70] N. Laamouri, „Traffic Congestion Estimation Using Floating Car Data“, Diplomarbeit, Technische Universität München, 2014.
- [71] D. Hoffmann, „Potentialanalyse von Verfahren zur Bereitstellung von Verkehrsinformationen mittels Floating Car Daten für hochautomatisierte Fahrfunktionen“, Masterarbeit, Technische Universität München, 2014.
- [72] F. Groß, „Prediction of Driver Intent at Intersections from Car Fleet Data“, Masterarbeit, Technische Universität München, 2014.
- [73] N. Hirsenkorn, „Entwicklung einer Bahnplanung mit aus der Fahrdynamik erkanntem Anhänger basierend auf einem aus Flottendaten gelernten Topologie-modell“, Masterarbeit, Karlsruher Institut für Technologie, 2014.
- [74] M. Ecke, „Erkennung regelmäßiger Bedienverhalten der Komfortfunktionen im Fahrzeug mittels Deep Learning“, Masterarbeit, Technische Universität München, 2015.