

Probabilistische Vorhersage von Fahrstreifenwechseln für hochautomatisiertes Fahren auf Autobahnen

Zur Erlangung des akademischen Grades eines

Doktors der Ingenieurwissenschaften

der KIT-Fakultät für Maschinenbau
Karlsruher Institut für Technologie (KIT)
genehmigte

Dissertation

von

DIPL.-ING. ANDREAS WEISER

Tag der mündlichen Prüfung: 28. 11. 2017
Hauptreferent: Prof. Dr.-Ing. Christoph Stiller
Korreferent: Prof. Dr. Wolfgang Rosenstiel

Vorwort

Die vorliegende Dissertation entstand während meiner dreijährigen Tätigkeit als Doktorand in der Volkswagen Konzernforschung und privat in deutlich zu vielen weiteren Jahren danach. Bildhaft formuliert: Seit Beginn der Arbeit ist der mittlere Meeresspiegel um drei Zentimeter gestiegen, gab es drei neue Bundespräsidenten und drei verschiedene Generationen VW Golf. Somit möchte ich drei persönliche Erkenntnisse vorweg preisgeben: Erstens, echtes Forschen dauert länger und zweitens länger als man denkt. Drittens, wenn niemand mehr an eine Fertigstellung der Dissertation glaubt, ist es Zeit mit dem Forschen aufzuhören und das Gegenteil zu beweisen. *q. e. d.*

An dieser Stelle danke ich den Menschen, die mich während dieser Zeit beruflich und persönlich unterstützt haben. Der erste Dank gilt meinem Doktorvater Prof. Christof Stiller für die Möglichkeit der Promotion und die langjährige Betreuung der Arbeit. Herrn Prof. Wolfgang Rosenstiel danke ich für die Übernahme des Zweitgutachtens. Meinem ehemaligem Chef Dr. Arne Bartels danke ich für die mehr als ausdauernde organisatorische Betreuung, der Volkswagen AG für die zur Verfügung gestellten Ressourcen.

Ein großes Dankeschön geht an meine ehemaligen Kollegen im Team Automatisches Fahren, insbesondere Dr. Marek Musial, Dr. Simon Steinmeyer und Dr. Alexander Hans. Ohne unsere modulare Umfeldwahrnehmungsplattform hätte die Grundlage für diese Arbeit gefehlt.

Alexander, Martin, Diana, Thorben, Mathias, Nadja, Lars, Raziye, Axel, Jana, Lukas und Ekatarina, Ihr habt als studentische MitarbeiterInnen meine Arbeit durch Eure Praktika, Studien-, Bachelor-, und Diplomarbeiten bereichert und meinen Fokus stets zurück auf die Dissertation gelenkt. Danke, es war mir eine Freude mit Euch zusammenzuarbeiten.

Einen besonderen Dank gilt meinen Eltern, welche mir ein Studium ermöglicht und somit den Grundstein zu dieser Arbeit gelegt haben. Zu guter Letzt möchte ich mich herzlich bei meiner Freundin Dr. Karen Puttkammer für Ihre Unterstützung bedanken. Ohne ihre Geduld, ihr Verständnis und ihren Beistand wäre der Abschluss der Arbeit weitaus schwieriger und die Zeit bis dahin weniger erfüllt gewesen.

Disclaimer

Die Ergebnisse, Meinungen und Schlüsse dieser Dissertation sind nicht notwendigerweise die der Volkswagen AG.

Kurzfassung

Die vorliegende Arbeit stellt ein Konzept zur zeitlichen Vorhersage von Fahrstreifenwechselmanövern auf Autobahnen für Systeme zur automatischen Fahrzeugführung vor. Derartige Systeme benötigen ein Verständnis der Fahrumgebung zur konfliktfreien und nachvollziehbaren Durchführung der Fahraufgabe. Dies beinhaltet die Wahrnehmung und Interpretation der Fahrumgebung zur Erkennung und Vorhersage von Fahrmanövern des umgebenden Verkehrs. Der erste Teil der Arbeit beschreibt das Konzept zur Wahrnehmung von Fahrmanövermerkmalen und darauf aufbauend der Fahrstreifenwechselvorhersage mithilfe eines Dynamischen Bayes'schen Netzwerks (BN). Über dieses werden kausale Zusammenhänge bzgl. der Fahrmanövermerkmale in Form eines probabilistisch grafischen Modells abgebildet und die Zeit bis zu einem Fahrstreifenwechsel geschätzt. Der zweite Teil der Arbeit widmet sich der maschinellen Bestimmung der Struktur und Parameter des BN aus Realfahrdaten. Dazu wird eine Prozesskette entwickelt, die eine Referenzdatenerstellung, eine informationstheoretische Bestimmung der diskreten Zustandsräume der Fahrmanövermerkmale sowie ein mehrstufiges Vorgehen zur Strukturbestimmung des BN beinhaltet. Beginnend mit einem naiven BN zur Merkmalsauswahl wird die Netzwerkstruktur über ein hierarchisch naives BN zu einem Dynamischen BN entwickelt. Hierbei wird das hierarchisch naive Bayes Model zur Identifikation latenter Variablen und ein evolutionärer Algorithmus zur Bestimmung temporaler Abhängigkeiten verwendet. Insgesamt gelingt es mit der vorliegenden Arbeit ein Gesamtkonzept zur Fahrstreifenwechselvorhersage vorzustellen, dessen Funktionsweise anhand von Realfahrdaten nachgewiesen wird.

Schlagerworte: Automatisches Fahren, Dynamische Bayes'sche Netzwerke, Fahrumgebungserfassung, Maschinelles Lernen, Fahrstreifenwechsel

Abstract

A concept for time-related forecasts of lane change maneuvers in highway scenarios is presented within the present thesis. Automated driving systems rely on understanding the driving environment to fulfil their driving task transparently and safely. This involves the perception of the driving environment as well as its interpretation to detect and predict driving maneuvers of road users. The first part of this thesis focuses on the perception of lane change situation features and the lane change prediction based on a dynamic Bayesian network (BN). With this, probabilistic temporal relationships between situation features are represented in a probabilistic graphical model to estimate the time to lane change according to the configuration of situation features. The second part of the thesis deals with BN structure and parameter learning from natural driving data. For this purpose a toolchain is developed. It includes a retrospective ground truth data labeling as well as the determination of discrete states spaces for all situation features by use of information theory principles and a multi-stage approach to determine the structure of the dynamic BN. Starting with a naive BN to select an optimal set of situation features, the network is evolved via a hierarchical naive BN to a dynamic BN, using the hierarchical naive Bayes model to identify latent variables and evolutionary algorithms to determine temporal relationships. To sum up, this thesis contributes an overall concept for lane change prediction on highways that is proven to be operational on natural driving data.

Keywords: automated driving, dynamic Bayesian networks, environment perception, machine learning, lane change

Inhaltsverzeichnis

Abkürzungsverzeichnis	XI
1 Einführung	1
1.1 Beitrag der Arbeit	2
1.2 Aufbau & Vorgehen	4
1.3 Automatisches Fahren	6
1.3.1 Begriffsklärung	6
1.3.2 Automatisches Fahren - Forschungsarbeiten	6
1.3.3 HAVEit - Temporary Autopilot	10
2 Modellierung von Wissen und Verhalten	15
2.1 Fahrumgebungserfassung	16
2.1.1 Sensorik	16
2.1.2 Umfeldmodellierung	20
2.1.3 Diskussion	24
2.2 Methoden zur Modellierung	25
2.2.1 Logik	26
2.2.2 Automaten	28
2.2.3 Unscharfe Mengen - Fuzzy-Logik	29
2.2.4 Probabilistische Methoden - Bayes'sches Konzept	30
2.2.5 Probabilistische Methoden - Evidenztheorie	33
2.2.6 Künstliche Neuronale Netzwerke	36
2.3 Bayes'sche Netzwerke	37
2.3.1 Konzept des Bayes'schen Netzwerks	37
2.3.2 Inferenz und Schlussfolgern	43
2.3.3 Maschinelle Lernverfahren	47
2.4 Diskussion	58

3	Stand der Technik	61
3.1	Das Fahrstreifenwechselmanöver	61
3.1.1	Einordnung in die Fahraufgabe	62
3.1.2	Empirische Analysen des Fahrstreifenwechsels	63
3.1.3	Fahrstreifenwechselmodelle	68
3.2	Ansätze zur Fahrstreifenwechselvorhersage	70
3.2.1	Eigenfahrzeugvorhersage	70
3.2.2	Fremdfahrzeugvorhersage	75
3.3	Zusammenfassung & Diskussion	84
4	Konzept der Fahrstreifenwechselvorhersage	87
4.1	Anforderungen	87
4.1.1	Anforderungen aus der Applikation	87
4.1.2	Anforderungen aus der Datenbasis	88
4.1.3	Diskussion	89
4.2	Architektur und Vorgehen	90
4.2.1	Architektur	91
4.2.2	Vorgehen	91
4.3	Umfeldwahrnehmungsplattform	94
4.3.1	Sensorik und Versuchsfahrzeug	94
4.3.2	Umfeldmodell und Sensordatenfusion	96
4.4	Klassen- und Evidenzvariablen	102
4.4.1	Definition Klassenvariable	103
4.4.2	Definition Evidenzvariablen	104
4.5	Eingangsdatenberechnung	108
4.5.1	Fahrbahn und Verkehrsfluss	108
4.5.2	Umgebender Verkehr	114
4.6	Diskussion	117

5	Datengetriebene Ermittlung von Netzwerkparametern	119
5.1	Datenbasis	120
5.1.1	Messdatenaufnahme	120
5.1.2	Referenzdaten	122
5.1.3	Eigenschaften	124
5.2	Diskretisierung	131
5.2.1	Verfahren zur Diskretisierung	131
5.2.2	Vorbetrachtung Diskretisierung	134
5.2.3	Bewertung der Diskretisierung	138
5.2.4	Diskussion der Diskretisierungsergebnisse	141
5.3	Reduktion des Merkmalsraumes	143
5.3.1	Verfahren zur Merkmalsauswahl	145
5.3.2	Vorgehen zur Merkmalsauswahl	150
5.3.3	Ergebnisse und Diskussion	156
5.4	Struktursuche zeitinvariante Bayes'sche Netzwerke	160
5.5	Struktursuche Dynamische Bayes'sche Netzwerke	166
5.5.1	Definition des Genotyps	166
5.5.2	Durchführung und Ergebnis	169
5.6	Diskussion des Schätzergebnisses	172
5.7	Diskussion angrenzender Fragestellungen	176
5.7.1	Expertengestützte vs. datengetriebene Struktursuche .	176
5.7.2	Berücksichtigung von weicher Evidenz	180
5.7.3	Einfluss von Qualität & Verfügbarkeit der Fahrungs- gebungsdaten auf die Vorhersage	182
5.7.4	Vergleich mit alternativer Methode	183
6	Zusammenfassung und Ausblick	187

A Anhang	193
A.1 Information und Transinformation	193
A.2 Hard- & Softwareumgebung	194
A.3 Herleitung des Eingangsmerkmals T_{tlc}	196
A.4 Gewählte Diskretisierungsverfahren	197
A.4.1 MDLP-Diskretisierung	197
A.4.2 Gini Diskretisierung	198
A.4.3 Chi-Merge Diskretisierung	199
A.4.4 Äquidistante Diskretisierung (ÄDD)	199
A.4.5 Häufigkeitsbasierte Diskretisierung (HBD)	200
A.4.6 K-Means Cluster-Algorithmus	200
A.5 Algorithmus BN-IPFP-1	201
A.6 Komplexitätsanalyse Wrapper-Verfahren	201
A.6.1 Wrapper mit Brute-Force Verfahren	201
A.6.2 Wrapper-Verfahren mit gerichteter Suche	202
A.7 Konfusionsmatrizen	204
Tabellenverzeichnis	205
Abbildungsverzeichnis	207
Literaturverzeichnis	211

Abkürzungsverzeichnis

ACC	Adaptive Cruise Control
ÄDD	Äquidistante Diskretisierung
BIC	Bayesian information criterion
BlogReg	Bayesian logistic regression
BN	Bayes'sche(s) Netzwerk(e)
BN-IPFP	Bayesian network - iterative proportional fitting procedure
CAN	Controller Area Network
Car2x	Fahrzeug zu Fahrzeug bzw. Infrastruktur Kommunikation
CFS	Correlation based filter
CPT	Conditional probability table
DBN	Dynamisches Bayes'sches Netzwerk
EM	Expectation Maximization
FAS	Fahrerassistenzsystem(e)
FS	Fahrstreifen
FCBF	Fast correlation based filter
FSW	Fahrstreifenwechsel
GNSS	Global Navigation Satellite System
GPS	Global Positioning System
HBD	Häufigkeitsbasierte Diskretisierung
HNB	Hierarchical Naive Bayes
KI	Künstliche Intelligenz
KNN	Künstliches Neuronales Netzwerk
MDLP	Minimum description length principle
mRMR	Minimum redundancy maximum relevance selection
RNN	Rekurrentes Neuronales Netzwerk
SBMLR	Sparse Bayesian multinomial logistic regression
SPEC	Spectral feature selection
TAP	Temporary Autopilot
TTC	Time to collision

1 Einführung

Bis Ende des 19. Jahrhunderts stellte die Fortbewegung per Pferd eine gehobene Form der Individualmobilität dar. Bedingt durch angeborene instinktive Verhaltensweisen und in Abhängigkeit von Dressur und individueller kognitiver Leistung des Tieres bot es dem Reiter in Form von intelligentem Verhalten einen gewissen Grad an Automation in der Führung seines Fortbewegungsmittels. So ist das Pferd durchaus in der Lage im Sinne seines Reiters einem Pfad zu folgen, Hindernissen auszuweichen oder vor diesen selbsttätig zu halten. Mit der Einführung des Automobils am Anfang des 20. Jahrhunderts verschwand diese Eigenschaft der Fortbewegungsmittel zunächst. Seit Anfang des 21. Jahrhunderts kehrte diese in Form von Fahrerassistenzsystemen zurück, welche den Fahrer bei der Durchführung seiner Fahraufgabe unterstützen, z. B. durch Adaptive Distanzregelung (ACC), Spurhalte- oder Notbremsassistent. Getrieben durch das Streben nach der *Vision Zero*¹, nach einer stetigen Erhöhung des Fahrkomforts u. a. durch freie Zeitgestaltung während der Fahrt, und der Aussicht auf lukrative Geschäftsmodelle im Bereich der *Sharing Economy*² mit Diensten zur individuellen Personenbeförderung wird durch Forschung und Industrie eine vollautomatische Fahrfunktion³ angestrebt, in der die Fahrzeugführung durch den Fahrer einen optionalen Charakter einnimmt, vgl. Tesla: [Lambert 2016], Uber, Volvo: [Kalanick 2016], Google, Fiat Chrysler: [Ziegler 2016], Lyft, General Motors: [Bhuyian 2016].

Die Verhaltensgenerierung automatischer Fahrsysteme basiert auf der Wahrnehmung des Verkehrsumfeldes sowie des eigenen Fahrzustandes und der kognitiven Verarbeitung dieser Information mithilfe einer Wissensbasis zu einer sicheren und nachvollziehbaren Handlung. Ein ACC-System misst beispielsweise die Entfernung zu vorausfahrenden Objekten und kann unter Berücksichtigung von akkumuliertem Wissen bzgl. der Systemdynamik, Objektrelevanz oder auch gesetzlicher Vorgaben wie Mindestwerte für Zeitlücken das Zielobjekt auswählen und einen passenden Beschleunigungsollwert bestimmen.

¹ Strategie zur Vermeidung tödlicher und schwerer Unfälle im Straßenverkehr für das Jahr 2020, vgl. [Eichendorf 2012].

² Geschäftsmodell zur gemeinsamen, zeitlich begrenzten Nutzung von Ressourcen.

³ Umgangssprachlich auch als autonomes Fahren bezeichnet, vgl. Unterabschnitt 1.3.1.

Für Systeme mit einer höherstufigen Automatisierung ist neben der reinen Wahrnehmung ein tiefgreifenderes Verständnis der Fahrumgebung notwendig, um die Verhaltensgenerierung konfliktfrei an zukünftige Aktionen und mögliche Handlungsoptionen anderer Verkehrsteilnehmer anzupassen.

Während des Wahrnehmungsprozesses werden Messwerte von Sensoren mit bisherigen Messungen fusioniert und in einem Umfeldmodell zu einer maschinellen Abbildung der Fahrumgebung aggregiert. Diese ist prozessbedingt unsicher, fehlerbehaftet und gegebenenfalls unvollständig, was im folgenden Verarbeitungsschritt Berücksichtigung finden sollte. Wenngleich es dem menschlichen Vorgehen zur Wissensverarbeitung und Schlussfolgerung scheinbar mühelos gelingt, unter vergleichbaren Umständen intelligentes Verhalten zur Fahrzeugführung zu generieren, stellt dies für technische Systeme nach derzeitigem Stand eine enorme Herausforderungen dar. Die Anwendung von Methoden aus dem Fachgebiet der künstlichen Intelligenz auf den kognitiven Informationsverarbeitungsprozess einer automatisierten Fahrfunktion stellt somit ein vielversprechendes Forschungsfeld dar.

Im europäischen Forschungsprojekt HAVEit verantwortet die Volkswagen AG die teilautomatisierte Fahrfunktion TEMPORARY AUTOPILOT, vgl. Unterabschnitt 1.3.3. In diesem Zuge wurde eine modulare Umfeldwahrnehmungsplattform geschaffen, vgl. Abschnitt 4.3, welche im Rahmen dieser Arbeit um eine Manövervorhersage erweitert werden soll.

1.1 Beitrag der Arbeit

Das Ziel dieser Arbeit besteht darin, ein Konzept zur zeitlichen Vorhersage von Fahrstreifenwechselmanövern als eine Interpretation der sensierten Fahrumgebung zu entwickeln. Dieses soll sowohl anwendbar sein auf die Fahrzeuge des umgebenden Verkehrs als auch auf das Ego-Fahrzeug selbst.

Zu diesem Zweck soll das Wissen über bevorstehende Fahrstreifenwechsel von Verkehrsteilnehmern auf bundesdeutschen Autobahnen aus Realfahrdaten extrahiert und in ein probabilistisches Schätzmodell zur Vorhersage von Fahrmanövern überführt werden. Dabei wird das Fahrstreifenwechselmanöver als Realisation eines hochdimensionalen Zufallsvektors aufgefasst. Über eine zugehörige Verbundverteilungsdichtefunktion soll bestimmt werden, mit welcher Wahrscheinlichkeit eine bestimmte Konfiguration angenommen wird. Die Modellierung der Verbundverteilung erfolgt über ein Bayes'sches Netzwerk. Mit dessen Hilfe lassen sich kausale Zusammenhänge bzgl. der Situationsmerkmale der Fahrumgebung und dem Fahrverhalten der Verkehrsteilnehmer in Form eines gerichteten Graphen abbilden.

Die Schwerpunkte der Arbeit liegen auf der Wahrnehmung und Extraktion geeigneter Situationsmerkmale und der maschinellen Bestimmung von Struktur und Parametern eines Bayes'schen Netzwerks zur Fahrstreifenwechsellvorhersage.

Abgrenzung zu bestehenden Arbeiten

Während der Fahrerintentionserkennung bzw. der Vorhersage von Fahrmanövern des eigenen Fahrzeuges bereits eine beachtliche Anzahl an wissenschaftlichen Arbeiten gewidmet sind, vgl. Unterabschnitt 3.2.1, ist das Feld für die Anwendung der Vorhersage auf den umgebenden Verkehr überschaubar, vgl. Unterabschnitt 3.2.2. Hervorzuheben sind hier die Arbeiten von [Dagli 2005] und [Kasper 2013], welche die Erkennung von Einscherern⁴ zur Verbesserung eines ACC-Systems mithilfe eines Bayes'schen Netzwerks zum Ziel haben. Die vorliegende Arbeit grenzt sich insbesondere zu letztgenannten Arbeiten ab durch:

- eine probabilistische Vorhersage von Fahrstreifenwechselmanövern mit Zeitbezug gegenüber einer binären Entscheidung,
- die Verwendung eines umfangreichen domänenspezifischen Lern- und Testdatensatzes mit automatisiert retrospektiv erzeugten Referenzdaten basierend auf einem modularen Umfeldmodell,
- einen methodischen Ansatz zur datengetriebenen Bestimmung relevanter Eingangsmerkmale, Netzwerkparameter und insbesondere der Netzwerkstruktur über maschinelle Lernverfahren,
- einen informationstheoretischen Ansatz zur Bestimmung geeigneter Diskretisierungsparameter für kontinuierliche Eingangsmerkmale,
- eine Modellierung der Messunsicherheit über multimodale Verteilungen und schließlich durch
- eine Berücksichtigung von zeitlichen Abhängigkeiten durch eine Modellierung des Fahrstreifenwechsels als temporaler Prozess in Form eines Dynamischen Bayes'schen Netzwerks.

⁴ Fahrzeug, welches unmittelbar vor einem anderen Fahrzeug in dessen Fahrschlauch, d. h. Korridor entlang der zukünftige Fahrtrajektorie, wechselt.

1.2 Aufbau der Arbeit & Vorgehen

Nachfolgend wird der Aufbau der vorliegenden Arbeit beschrieben und das Vorgehen zum Erreichen der formulierten Zielsetzung erläutert. Die Arbeit lässt sich in folgende drei Schwerpunkte gliedern:

- einen Rekercheteil zu Methoden und Verfahren zur Modellierung von Wissen und Verhalten in Kapitel 2 sowie zu bestehenden technischen Lösungen zur Beschreibung und Vorhersage eines Fahrstreifenwechselmanövers in Kapitel 3,
- einen konzeptionellen Teil zur Erarbeitung eines Ansatzes zur Realisierung einer Fahrstreifenwechselvorhersage in Kapitel 4 und
- einen praktischen Teil zur datengetriebenen Bestimmung der Parameter und Struktur eines Bayes'schen Netzwerks zur Fahrstreifenwechselvorhersage in Kapitel 5.

Im Detail wird wie folgt vorgegangen: Nach einer kurzen Vorstellung des Forschungsprojektes HAVEit wird im weiteren Verlauf dieses Kapitels eine Erläuterung zu automatischen Fahrfunktionen unter Einbeziehung des TEMPORARY AUTOPILOT sowie bisheriger und aktueller Forschungsprojekte gegeben.

Kapitel 2 beginnt mit einer Einführung in die Techniken und Methoden zur Wahrnehmung des Verkehrsumfeldes als Datengrundlage für automatische Fahrfunktionen. Im weiteren Verlauf werden ausgewählte Konzepte aus dem Bereich der Künstlichen Intelligenz zur Modellierung von Wissen und Verhalten vorgestellt und diskutiert. Einen Schwerpunkt bildet die Wissensmodellierung mit Bayes'schen Netzwerken unter dem Aspekt von unsicherheitsbehafteten und unvollständigen Eingangsdaten.

Der Stand der Technik zur Vorhersage von Fahrstreifenwechselmanövern wird in Kapitel 3 erläutert. Ziel ist es, ein Verständnis für das Fahrstreifenwechselmanöver zu entwickeln, und bisherige Lösungsansätze auf ihre Übertragbarkeit auf die Zielsetzung dieser Arbeit zu überprüfen.

In Kapitel 4 wird das Konzept der Fahrstreifenwechselvorhersage erläutert. Aus den Anforderungen der automatischen Fahrfunktion wird das Vorhersageziel abgeleitet und der Einsatz eines Bayes'schen Netzwerks motiviert. Es erfolgt eine Einordnung der Manöर्वorhersage in die Architektur der Umfeldwahrnehmungsplattform des TEMPORARY AUTOPILOT (TAP) und eine Darstellung der notwendigen Prozessschritte. Schließlich werden die Rahmenbedingungen für die Erstellung eines Bayes'schen Netzwerks mit der

Definition der Klassenvariable Fahrstreifenwechsel und potentieller Situationsmerkmale, d. h. Evidenzvariablen, sowie deren Berechnung innerhalb der Umfeldwahrnehmungsplattform des TAP gegeben.

Kapitel 5 ist der Bestimmung der Parameter und Struktur für ein Bayes'sches Netzwerk auf Basis von Messdaten einer Realfahrstudie gewidmet. Aus den Messdaten werden die im vorhergehenden Kapitel definierten Situationsmerkmale extrahiert und gemeinsam mit einem retrospektiv erzeugten Referenzwert der Klassenvariable in eine Datenbasis überführt. Diese beinhaltet somit die Referenzdaten für die maschinelle Bestimmung der Netzwerkstruktur. Für die größtenteils in kontinuierlicher Form vorliegenden Werte der Eingangsmerkmale werden die Diskretisierungsschwellen so bestimmt, dass sowohl der Informationsverlust im Zuge der Diskretisierung als auch die Anzahl der Diskretisierungsschwellen pro Merkmal minimal wird. Die Strukturbestimmung erfolgt zunächst für ein statisches, d. h. zeitinvariantes Bayes'sches Netzwerk nach dem Hierarchical Naive Bayes (HNB) Ansatz. Ausgehend von einem Naiven Bayes'schen Netzwerk wird durch das geschickte Hinzufügen von latenten Variablen maschinell eine Netzstruktur gesucht. Da für latente Variablen keine Werte in der Datenbasis vorliegen, werden die bedingten Übergangswahrscheinlichkeiten per Expectation Maximization (EM) Algorithmus bestimmt. Vor der Anwendung des HNB-Algorithmus zur Strukturbestimmung wird versucht, die Dimensionalität der Verbundverteilung für die Klassenvariable durch das Entfernen nicht relevanter Variablen so einzuschränken, dass bereits das dem HNB zugrunde liegende Naive Bayes'sche Netzwerk bestmögliche Schätzergebnisse liefert. Es wird erwartet, dass eine Anwendung des HNB-Ansatzes auf dieses Naive Bayes'sche Netzwerk die vernachlässigten statistischen Abhängigkeiten zwischen den Zufallsvariablen in Form von Latentvariablen aufdeckt. Im letzten Teil des Kapitels wird untersucht, ob sich die Schätzung eines Fahrstreifenwechsels durch eine Zeitreihenanalyse mithilfe eines Dynamischen Bayes'schen Netzwerks verbessern lässt. Das zuvor ermittelte statische Netzwerk dient hierfür als initiales und innerhalb einer Zeitscheibe nicht veränderbares Netzwerk, wohingegen die Struktur des temporären, d. h. zeitscheibenübergreifenden Netzwerks mithilfe genetischer Algorithmen bestimmt wird.

Im letzten Kapitel werden die Ergebnisse der Arbeit zusammengefasst und im Hinblick auf die Anwendbarkeit in einer automatischen Fahrfunktion diskutiert. Die Arbeit schließt mit einem Ausblick auf mögliche Erweiterungen des gezeigten Ansatzes zur Manövervorhersage.

1.3 Automatisches Fahren

Im nachfolgenden Abschnitt wird zunächst die Terminologie für die Bezeichnung automatischer Fahrfunktionen in Abhängigkeit von ihrer Ausprägung erläutert. Es folgt ein kurzer Abriss bisheriger und aktueller Forschungsprojekte zum Thema. Anschließend wird die Zielstellung und Ausprägung des TEMPORARY AUTOPILOT erläutert.

1.3.1 Begriffsklärung

Die Begriffe Autonomes Fahren und Automatisches Fahren prägen seit Jahren die automobilen Forschungsvorhaben für dauerhaft automatisierte, d. h. nicht auf kurzzeitige Eingriffe beschränkte Fahrfunktionen. Obgleich ihre Verwendung oft äquivalent stattfindet, lässt sich dennoch eine Trennung feststellen: Während das Autonome Fahren als führerloses⁵ Fahren, d. h. Fahren ohne Fahrer, bezeichnet wird, ist der Begriff Automatisches Fahren im Bereich der Fahrerassistenzsysteme verbreitet.

Generell unterstützen Fahrerassistenzsysteme den Fahrer bei der Erfüllung seiner Fahraufgabe. Die Unterstützung erfolgt auf unterschiedlichen Ebenen und erstreckt sich von der Information und Warnung über korrigierende Eingriffe in die Fahrdynamik bis hin zu einer graduellen Übernahme der Fahraufgabe. Eine entsprechende Definition der Automatisierungsgrade erfolgt in [Gasser u. a. 2012]. Tabelle 1.1 fasst diese Begriffsdefinitionen unter den Aspekten Ausprägung der Automatisierung, Notwendigkeit und Umfang einer fahrerseitigen Systemüberwachung sowie Übernahmebereitschaft bei Erreichen der Systemgrenzen zusammen.

Der Übergang vom Automatischen zum Autonomen Fahren, besonders im Hinblick auf die in Tabelle 1.1 definierte Vollautomation, ist fließend. Dennoch wird der Begriff Automatisches Fahren auch im weiteren Verlauf übergeordnet verwendet.

1.3.2 Automatisches Fahren - Forschungsarbeiten

Im Folgenden werden, stellvertretend für die in Tabelle 1.1 genannten Automatisierungslevel, Forschungsprojekte aufgeführt, welche assistierende, teil-, hoch- oder vollautomatisierte Fahrsysteme umfassen.

⁵ Beispielsweise [UN/ECE 2006] „...Systeme, bei denen die Anwesenheit eines Fahrzeugführers nicht erforderlich ist, werden als „autonome Lenkanlagen“ bezeichnet.“

Assistierende Systeme sind nahezu herstellerübergreifend und teils bereits in zweiter oder dritter Generation auf dem Markt verfügbar, z. B. in Form einer automatisierten Fahrzeulängsregelung ACC. Aktuelle Generationen zielen auf eine Erweiterung des Wirkungsfeldes hinsichtlich der Domäne, z. B. ACC für urbane Umgebung [To u. a. 2008], oder der vorausschauenden energieeffizienten Fahrzeulängsführung durch karten- und ortungsgestützte Umfeldinformation, vgl. [Dornieden u. a. 2012; Roth u. a. 2011]; [Sanfridson u. a. 2011].

Teilautomatisiert fahrende Systeme stehen seit mehr als drei Jahrzehnten im Fokus der Forschung, beginnend mit der Pionierleistung im Vorfeld, vgl. [Zapp 1988], bzw. im Rahmen des EUREKA Forschungsprojektes PROMETHEUS⁶. Alle im Folgenden vorgestellten Realisierungen nutzen eine auf einem heterogenen Mehrsensormsystem und einer Sensordatenfusion basierende maschinelle Fahrumgebungserfassung.

Im Rahmen von PROMETHEUS wurde erstmals eine automatisierte Fahrzeulängs- und Querführung inklusive automatisch durchgeführter Fahrstreifenwechsel nach Fahrerbestätigung entwickelt und ein Versuchsbetrieb im Realverkehr durchgeführt, vgl. [Ulmer 1994; Dickmanns u. a. 1994].

Im BMBF-geförderten Forschungsprojekt INVENT, vgl. [INVENT-Konsortium 2002], wurde auf Basis der Teilprojekte FAHRUMGEBUNGSERFASSUNG UND INTERPRETATION sowie STAU-ASSISTENT eine teilautomatisierte Längs- und Querführung für Stausituationen entwickelt, vgl. [Zavrel 2002].

In INTELLIGENT CAR, einem internen Forschungsprojekt der Volkswagen AG, wurde eine teilautomatisierte Fahrfunktion entwickelt, vgl. [Weiser u. a. 2009]. Das Ziel von INTELLIGENT CAR war neben der automatischen Längs- und Querführung die automatische Durchführung von Fahrstreifenwechseln nach Fahrerbestätigung, die Möglichkeit der „Freihand“-Fahrt, d. h. der Fahrzeugführung ohne Berührung des Lenkrades durch den Fahrer und der Betrieb im Realverkehr. Durch ein umfangreiches Absicherungskonzept, u. a. durch Risikoanalyse, Komponententest von Hard- und Software sowie Test des Gesamtsystems in Simulationen und realen Erprobungsfahrten konnte ein zuverlässiger Versuchsbetrieb im Realverkehr erreicht werden.

Das Ziel des Teilvorhabens Integrierte Querführung im BMWi-geförderten Forschungsprojekt AKTIV, vgl. [AKTIV-Konsortium 2009], war die Erprobung eines automatischen, fahrerakzeptierten Haltens des Fahrstreifens. In der in [Meinecke u. a. 2011] beschriebenen Realisierung erfolgte die Erfor-

⁶ Programme for a European Traffic of Highest Efficiency and Unprecedented Safety: europäisches Forschungsprojekt 1987 -1995.

schung einer kontinuierlichen Längs- und Querführung in einem Geschwindigkeitsbereich von 0-180 km/h auf gut ausgebauten Landstraßen und Autobahnen sowie in Baustellenbereichen.

Im EU-geförderten Forschungsprojekt HAVEIT, vgl. [HAVEit-Konsortium 2009], wurden die teilautomatisierten Fahrsysteme AUTOMATIC QUEUE ASSISTANCE, CONSTRUCTION SITE ASSISTANCE sowie TEMPORARY AUTOPILOT entwickelt. Das System AUTOMATIC QUEUE ASSISTANCE, vgl. [Grubb u. a. 2009], bietet eine automatisierte Längs- und Querführung im Niedergeschwindigkeitsbereich für Lastkraftwagen an. Das System CONSTRUCTION SITE ASSISTANCE, vgl. [Lüke u. Strauss 2012], bietet eine kontinuierliche Längs- und Querführungsunterstützung auf Autobahnen sowie in Baustellenbereichen an. Die funktionale Ausprägung des TEMPORARY AUTOPILOT, vgl. [To u. Bartels 2010], bietet eine automatische Längs- und Querführung auf Autobahnen und autobahnähnlichen Straßen im Geschwindigkeitsbereich von 0-130km/h. Eine Beschreibung des TEMPORARY AUTOPILOT wird in Unterabschnitt 1.3.3 gegeben. Die vorliegende Arbeit setzt auf diesem System auf.

Seit geraumer Zeit erfolgt die Einführung teilautomatisierter Systeme in den Markt, z. B. in Form einer kontinuierlichen Längs- und Querführung in Stausituationen, vgl. [Audi-AG 2016; VW-AG 2017].

Hochautomatisierte Fahrsysteme wurden in den vergangenen Jahren im Rahmen von Forschungsprojekten in Angriff genommen. Alleinstellungsmerkmal gegenüber den teilautomatisierten Systemen ist ein zulässiges zeitweises Abwenden des Fahrers von der Fahraufgabe.

Im europäische Forschungsprojekt ADAPTIVE werden die hochautomatisierten Fahrsysteme TRAFFIC JAM CHAUFFEUR und HIGHWAY CHAUFFEUR sowie unter der Bezeichnung PARKING GARAGE PILOT ein Fahrsystem zur Realisierung eines vollautomatisierten Parkservice für PKW entwickelt, vgl. [Etemad 2015]. Der TRAFFIC JAM CHAUFFEUR ermöglicht eine hochautomatisierte Fahrt in Stausituationen in einem Geschwindigkeitsbereich von 0-60 km/h. Diese Funktionalität wird durch HIGHWAY CHAUFFEUR auch außerhalb von Stausituationen bis zu einer Geschwindigkeitsgrenze von 130 km/h erweitert und schließt automatische Fahrstreifenwechsel mit ein.

In [Meyer 2015] wird ein System vorgestellt, das eine Strecke von 550 Meilen von Stanford nach Las Vegas hochautomatisch zurücklegt. Das System arbeitet weitgehend auf sensorisch erfassten Umfelddaten und kommt ohne hoch genaue Ortung aus. Nicht hochautomatisch befahrbare Teilstücke sind dem System über annotierte Kartendaten bekannt und erlauben eine für den Fahrer stets beherrschbare Übernahme der Fahrfunktion.

Ein Ziel des 2017 startenden europäischen Förderprojektes L3PILOT, vgl. [L3pilot-Konsortium 2017], ist es, hochautomatische Fahrsysteme in umfangreichen Feldtests zu erproben und zu bewerten. Die Systeme weisen eine hohe Funktionsvielfalt auf, z. B. Parken, Überholen oder das Fahren in urbanen Kreuzungssituationen und sollen mit einer Flotte von 100 Fahrzeugen in elf europäischen Ländern erprobt werden. Die Bewertung der Funktionen erfolgt in Bezug auf deren technische Leistungsfähigkeit, die Nutzerakzeptanz, das Fahrverhalten und den Einfluss auf Verkehr und Gesellschaft.

Vollautomatische Fahrfunktionen für PKW beinhalten im Extremfall die Möglichkeit der fahrerlosen Fahrt. Vollautomatisch fahrende Fahrzeuge beherrschen alle Situationen vom Beginn bis zum Ende einer vollautomatischen Fahrt auf definierten Strecken bzw. in definierten Umgebungen. Von der DARPA⁷ durchgeführte Wettbewerbe für autonom fahrende Landfahrzeuge, vgl. [Darpa 2005, 2007], motivierte dutzende Forschergruppen aus Universitäten, wissenschaftlichen Einrichtungen und Unternehmen die Machbarkeit autonomer Fahrfunktionen im offenen Gelände und Stadtverkehr zu demonstrieren - wenn auch zunächst in künstlichen, nicht öffentlichen Verkehrsumgebungen. Einige der Teilnehmer führen diese Forschungsarbeiten fort und testen diese bereits im öffentlichen Straßenverkehr, vgl. [Thrun u. Urmsen 2011; Saust u. a. 2010; Ziegler u. a. 2014].

Systeme der Kategorie 5 werden nach [VDA 2013] als fahrerlose Systeme bezeichnet. Sie kennzeichnen sich dadurch, dass sie auf beliebigen Strecken alle Verkehrssituationen ohne Einwirkung eines Fahrers meistern können.

Zusammenfassend ist zum Stand der automatischen Fahrfunktionen festzustellen, dass assistierende Systeme bereits seit mehr als einem Jahrzehnt auf dem Markt verfügbar sind und erste teilautomatisierte Systeme in jüngster Zeit im Markt eingeführt wurden. Systeme mit höherem Automatisierungsgrad sind derzeit Gegenstand intensiver Forschungs- und Entwicklungsaktivitäten.

Trotz der technischen Fortschritte gestaltete sich eine mögliche Markteinführung hoch- oder vollautomatisierter Fahrfunktionen unter den geltenden rechtlichen und zulassungstechnischen Rahmenbedingungen bislang als schwierig, vgl. [Gasser u. a. 2012]. Durch eine Ergänzung des hierfür maßgeblichen Wiener Weltabkommen über den Straßenverkehr, vgl. [ECE 2014], wurde die völkerrechtliche Grundlage geschaffen, solche Systeme in Verkehr zu bringen. Jedoch bleibt die grundlegende Voraussetzung, dass diese jederzeit durch den Fahrer übersteuert werden können.

⁷ Defense and Advanced Research Projects Agency - Behörde des US-Verteidigungsministeriums.

1.3.3 HAVEit - Temporary Autopilot

Der TEMPORARY AUTOPILOT ist eine im europäischen Forschungsprojekt HAVEit⁸ entwickelte Funktionsbündelung einer teilautomatisierten Fahrfunktion mit mehreren Fahrerassistenzsystemen. Ihr Ziel besteht darin Unfälle zu vermeiden bzw. Unfallfolgen zu minimieren, welche infolge von Fahrfehlern durch unaufmerksame bzw. abgelenkte Fahrer entstehen können, vgl. [Bartels u. a. 2011].

Das in ein Versuchsfahrzeug integrierte System bietet dem Fahrer in Abhängigkeit von Fahrsituation, Umgebungserfassung, Fahrer und Systemzustand den jeweils passenden Automationsgrad an. Dies beinhaltet:

- Eine automatische Längs- und Querführung auf Autobahnen und autobahnähnlichen Straßen im Geschwindigkeitsbereich von 0-130 km/h. Die Adaption der Längsgeschwindigkeit erfolgt an Geschwindigkeitsgebote, an ein Führungsfahrzeug oder an Kurvenradien zur komfortbegründeten Begrenzung der Querbeschleunigung. Ein automatisches Wiederauffahren wird über eine Nahfeldüberwachung abgesichert und das Rechtsüberholverbote außerhalb von Stausituationen beachtet. Fahrstreifenwechsel werden nicht automatisiert durchgeführt.
- Die Möglichkeit der Freihandfahrt, d. h. der Fahrer kann während der teilautomatisierten Fahrt die Hände vom Lenkrad nehmen, hat aber weiterhin die Verantwortung zur Überwachung der Fahraufgabe. Dies wird durch ein integriertes System zur Fahrerzustandsbeobachtung überwacht. Ein dauerhaftes Abwenden des Fahrers vom Verkehrsgeschehen stellt eine Überschreitung der Systemgrenzen dar.
- Eine zielgerichtete Reaktion bei Erreichen einer Systemgrenze, indem die Fahraufgabe kontrolliert an den Fahrer zurückgegeben bzw. das System durch ein Nothaltemanöver ggf. mit einem Wechsel auf den Standstreifen in einen sicheren Zustand überführt wird.
- Der Fahrer hat jederzeit die Möglichkeit, das System zu übersteuern bzw. zu deaktivieren.

Das Systemstatusdiagramm in Abbildung 1.1 zeigt die Aktivierungsstrategie des TEMPORARY AUTOPILOT.

⁸ Das Projekt HAVEit (Highly Automated VEHicles for Intelligent Transportation) ist ein europäisches Forschungsprojekt, welches durch das 7. Forschungs-Rahmenprogramm der EU gefördert ist, vgl. [HAVEit-Konsortium 2009].

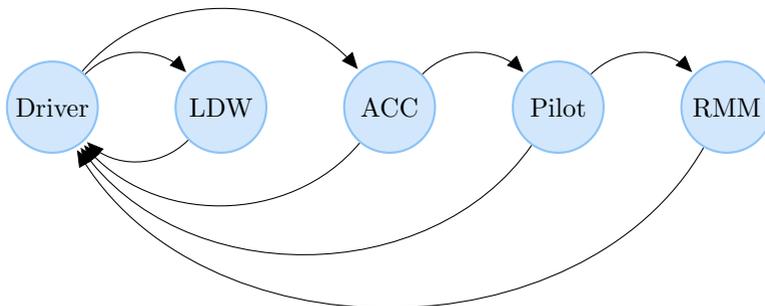


Abbildung 1.1: Systemstatusdiagramm des TEMPORARY AUTOPILOT, angelehnt an [Bartels u. a. 2011]

Das System bietet folgende Betriebsmodi:

Driver Manuelle Längs- und Querführung, der Fahrer erhält keine Unterstützung. In diesen Modus wird bei Deaktivierung aus jedem der anderen Modi zurück gewechselt.

LDW⁹ Warnt den Fahrer vor unbeabsichtigtem Verlassen des Fahrstreifens. Dieser Modus wird passiv geschaltet, sobald die Betriebsmodi Pilot oder RMM aktiv sind. Die Quer- und Längsführung erfolgt manuell durch den Fahrer.

ACC¹⁰ Regelt die Geschwindigkeit auf die vom Fahrer einstellbare Wunschgröße oder adaptiert diese zur Einhaltung eines einstellbaren Abstandes auf die Geschwindigkeit des Vorderfahrzeuges. Im TEMPORARY AUTOPILOT werden in diesem Modus ebenfalls Geschwindigkeitsbegrenzungen durch Geschwindigkeitsgebote, z. B. Verkehrszeichen, oder durch Kurvengrenzgeschwindigkeiten berücksichtigt. Es erfolgt eine automatische Längsregelung, die Querregelung obliegt dem Fahrer.

Pilot Das System übernimmt die Quer- und Längsführung, eine freihändige Fahrt ist zulässig. Dem Fahrer obliegt die Überwachung des Systems. Wird durch die Fahrerzustandsbeobachtung ein dauerhaftes Abwenden des Fahrers vom Verkehrsgeschehen festgestellt und ein Systemhinweis zur Aufmerksamkeitspflicht ignoriert, erfolgt eine Aufforderung zur Übernahme der Fahraufgabe an den Fahrer. Kommt dieser der Aufforderung nicht nach, wird in den Betriebsmodus RMM gewechselt.

RMM¹¹ Bringt das System in einen risikominimalen Zustand. Es wird davon ausgegangen, dass der Fahrer seine Überwachungsfunktion nicht mehr erfüllen kann. In Abhängigkeit der Fahrsituation wird im Rahmen eines eskalierenden Manövers innerhalb des eigenen Fahrstreifens, oder ggf. durch automatisierte Fahrstreifenwechsel auf dem Standstreifen angehalten. Zusätzlich erfolgen weitere Maßnahmen zur Absicherung von Fahrer und Fahrzeug, vgl. [Mirwaldt u. a. 2012]. Die Quer- und Längsführung erfolgt während des gesamten Manövers automatisch, dies kann jederzeit durch den Fahrer unterbrochen werden.

Im Rahmen der entwicklungsbegleitenden Systemerprobung stellte sich insbesondere der Umgang mit Einscherern als herausfordernd dar. Diese werden erst als solche erkannt, sobald sie beginnen in den Fahrstreifen des mit einem TEMPORARY AUTOPILOT ausgestatteten Versuchsfahrzeuges einzutauchen. Gerade bei kleinen Zeitlücken zu den einscherenden Fahrzeugen sind Verzögerungen erforderlich, welche außerhalb des Komfortbereichs liegen und im ungünstigsten Fall eine Überschreitung der Systemgrenze und einen Fahrereingriff zur Folge haben. Eine Fahrstreifenwechselvorhersage für den umgebenden Verkehr soll eine frühzeitige Reaktion des TEMPORARY AUTOPILOT auf Einscherer ermöglichen und zur Steigerung des Fahrkomforts und der Systemverfügbarkeit beitragen. In zukünftigen Weiterentwicklungen des TEMPORARY AUTOPILOT ist zudem die Realisierung von kooperativen Fahrverhalten z. B. durch den Wechsel auf einen freien linken Nachbarfahrstreifen denkbar, um den Fahrstreifenwechsel eines anderen Verkehrsteilnehmers in den Fahrstreifen des TEMPORARY AUTOPILOT zu ermöglichen.

⁹ Fahrstreifenverlassenswarnung, engl. Lane Departure Warning.

¹⁰ Adaptive Geschwindigkeitsregelung, engl. Adaptive Cruise Control.

¹¹ Risikominimales Manöver, engl. Risk Minimum Maneuver.

Tabelle 1.1: Automatisierungsgrade der Fahrzeugführung, vgl. [Casser u. a. 2012; VDA 2013; SAE 2016]

Level	Kategorie BASt/VDA	Kategorie SAE/VDA	Ausprägung der Automatisierung	Überwachung durch Fahrer	Rückfallebene	Beispiel
0	Driver Only	No Automation	keine	permanent	Fahrer, sofort	Einparkhilfe
1	Assistiert	Assisted	dauerhafte Längs- oder Querführung	permanent	Fahrer, sofort	ACC, Fahrstreifen- halte-Assistent
2	Teil- automatisiert	Partial Automation	Längs- und Querführung	permanent	Fahrer, sofort	Stau-Assistent
3	Hoch- automatisiert	Conditional Automation	Längs- und Querführung	nicht permanent	Fahrer, mit Zeitreserve	Stau-Pilot
4	Voll- automatisiert	High Automation	Längs- und Querführung	nicht notwendig	Automation	Garagenpark- Pilot
5	Fahrerlos (autonom)	Full Automation	Längs- und Querführung	nicht notwendig	Automation	Roboter Taxi

2 Modellierung von Wissen und Verhalten

Die Grundlage für eine Modellierung von Wissen und Verhalten ist eine Wissensbasis. Sie enthält eine Menge des problemspezifischen Wissens. Dieses Wissen kann sowohl implizit, d. h. in Form von Daten, Gleichungen, Theorien vorliegen als auch explizit in Form von sprachlich beschreibbaren Wissensinhalten wie Deklarationen und Heuristiken, z. B. Wenn-Dann-Regeln. Für die Modellierung einer Fahrmanövervorhersage stellt die Fahrumgebungs-erfassung eine Menge des problemspezifischen Wissens in Form einer Zustandsbeschreibung des Verkehrsumfeldes implizit zur Verfügung. Werkzeuge und Konzepte zur Erfassung der Fahrumgebung werden im ersten Abschnitt dieses Kapitels erläutert.

Für das Ziehen von Schlussfolgerungen auf Basis dieses Wissens sind Verfahren zu wählen, welche in ihrem Verarbeitungskonzept der Natur des hinterlegten Wissens gerecht werden. So modellieren konventionelle Verfahren, wie die im weiteren Verlauf des Kapitels vorgestellten Standardlogiken und Zustandsautomaten, eine mehr oder weniger ideelle Welt, in der Wissen weder von Ungenauigkeit, Unsicherheit noch Unvollständigkeit behaftet ist. Verfahren, welche die letztgenannten Aspekte berücksichtigen, werden hier mit dem Begriff *intensionale Verfahren* bezeichnet. Dazu wird die Fuzzy Logik und probabilistische Verfahren wie das Bayes'sche Konzept und die Evidenztheorie vorgestellt. Den Schwerpunkt der Vorstellung bilden die Bayes'schen Netzwerke.

Mithilfe der eingeführten Verfahren können Modelle zur Fahrmanövervorhersage erstellt werden. Über die Parametrisierung dieser Modellen lassen sich Muster und Gesetzmäßigkeiten zur Manövervorhersage abbilden. Diese Parameter können über Expertenwissen gegeben sein oder über maschinelle Lernverfahren bestimmt werden. Auf maschinelle Lernverfahren zur Parameter- und Strukturbestimmung für Bayes'sche Netzwerke wird im letzten Abschnitt dieses Kapitels eingegangen.

Eine Diskussion bzgl. der Eignung der vorgestellten Methoden zur Fahrmanövervorhersage ist in Abschnitt 2.4 gegeben.

2.1.1.1 Lokale Umfeldsensorik

Als lokale Umfeldsensoren sind hier bordeigene Messeinrichtungen mit begrenzter Reichweite zur Beobachtung des lokalen Fahrzeugumfeldes bezeichnet. Zu diesen Sensoren zählen nachfolgend aufgeführte Radar-, Lidar- und Ultraschallsensoren sowie videobasierte Umfeldsensoren, wobei letztere unter dem Begriff maschinelles Sehen zusammengefasst werden, vgl. [Winner u. a. 2012].

Radar¹ bezeichnet ein Verfahren zur Erfassung von Objekten durch Ausendung elektromagnetischer Wellen und Empfang sowie Verarbeitung der Reflektionen selbiger. Für den automobilen Bereich werden die Frequenzen 77 GHz und 24 GHz genutzt mit Wellenlängen von 3,9 mm für den hohen und 12,5 mm für den niedrigen Frequenzbereich. Radaranwendungen im 77 GHz-Bereich werden aktuell hauptsächlich für die Erfassung im Fernbereich eingesetzt, während 24 GHz-Radare, welche bei gleicher Bündelung eine größere Antennenapertur benötigen, den Mitten- und Nahbereich erfassen. Vorteil der Radartechnik ist eine weitgehende Unabhängigkeit von äußeren Witterungseinflüssen. Radarstrahlen durchdringen bestimmte Materialien nahezu verlustfrei, so dass die Sensoren „unsichtbar“ hinter Abdeckungen im Fahrzeug verbaut werden können.

Ein **Lidar**-Sensor² arbeitet ähnlich wie Radar ebenfalls mit elektromagnetischen Wellen, jedoch weitaus kleineren Wellenlängen von 780 nm bis 1000 nm. Diese liegen außerhalb des sichtbaren Spektrums im Infrarotbereich. Grundlage für Lidarsensoren bildet die Lasertechnik. Die Vorteile des Lasers sind eine geringe optische Divergenz und eine hohe räumliche und zeitliche Kohärenz. Zudem lässt sich das monochromatische Licht des Lasers auch über weite Entfernungen sehr gut von anderen Lichtquellen trennen. Verfahrens- und bauartbedingt ist das Messergebnis eines Lidarsensors stärker von äußeren Witterungseinflüssen abhängig als dies beim Radar der Fall ist. Durch Streuung an Nebel und an Gischt vorausfahrender Fahrzeuge kann ein Teil des ausgesandten Impulses reflektiert und als scheinbare Objekte wahrgenommen werden. Weiterhin besteht die Möglichkeit, dass die Optik während der Fahrt verschmutzt und somit den Sichtbereich einschränkt.

Zur Erhöhung des Erfassungswinkels wird bei Radarsensoren eine Antennencharakteristik zur Realisierung von Haupt- und Nebenkeulen eingesetzt, bei Lasersensoren finden Mehrstrahl-Laser Anwendung. Alternativ kommen bei Laser- als auch bei Radarsensoren scannende Verfahren zum Einsatz, wobei

¹ Radar - Radio Detection And Ranging.

² Lidar - Light Detection And Ranging.

Sende- und Empfangskomponenten mechanisch bewegt werden und das Umfeld in definierten Winkelschritten abtasten. Laser- und Radarsensoren eignen sich durch ihre direkte radiale Entfernungsmessung zur Detektion von Objekten als auch indirekt zur Freiflächendetektion. Während Radarsensoren durch Ausnutzung des Dopplereffektes direkt die Geschwindigkeit eines Objektes messen, können Laserscanner die sichtbaren Konturen eines Objektes vermessen und diese Merkmale in die Objekthypothesengenerierung einbringen. Lasersensoren verfügen zudem über die Eigenschaft das Reflektivitätsvermögen von Oberflächen zu erkennen. Damit eignen sie sich zudem zur Erkennung von Fahrstreifenmarkierungen und somit zur Bestimmung der Ablage des Fahrzeuges innerhalb des Fahrstreifens, vgl. [Ahlers u. Westhoff 2009].

Ultraschallsensoren senden Schallwellen im Ultraschallbereich aus und empfangen das an einem Hindernis reflektierte Echo. Eine Abstandsmessung erfolgt durch eine Laufzeitmessung des Signals. Als Sendeeinheit dient zumeist ein Piezoelement, das über eine Membran Schallwellen abgibt bzw. durch das Echo angeregt wird. Ultraschallsensoren werden prinzipbedingt vorwiegend zur Freiflächendetektion im Nahbereich bei niedrigen Geschwindigkeiten eingesetzt, z. B. Parkassistenten. Mithilfe einer entsprechenden Signalverarbeitung ist auch ein spezialisierter Einsatz bei höheren Geschwindigkeiten möglich, beispielsweise zur Fahrstreifenwechselunterstützung vgl. [Klee u. Lee 2009].

Ein für den Automobilbereich relativ neues Verfahren bieten **3D Time-of-Flight- (ToF)** bzw. **Photonic Mixer Device (PMD)**-Sensoren als aktive, bildgebende und Abstandsmessende Sensoren, vgl. [Hanser 2007]. Ein PMD-Sensor ist in seiner Grundform ein optoelektronischer Halbleiterchip, der ein elektronisches Referenzsignal mit einem optischen Eingangssignal in Korrelation setzt und durch die Phasenverschiebung die Signallaufzeit und damit die Entfernung schätzen kann. Durch den Einsatz einer modulierten Lichtquelle im Infrarotbereich ist das Verfahren unabhängig von externen Lichtquellen. Eine feldartige Anordnung mehrerer tausend Halbleiterelemente, vergleichbar mit den Bildsensoren einer Kamera, ermöglicht die Gewinnung eines 3D-Bildes der Umgebung in einem Messschritt.

Die Erfassung der Fahrumgebung durch Bildverarbeitungssysteme wird unter dem Begriff **Maschinelles Sehen** zusammengefasst. Die durch CCD³ oder CMOS⁴-Sensoren erfasste Bildinformation kann durch die Extraktion von Merkmalen infolge nachgeschalteter Bildauswerteverfahren nutzbar

³ CCD (Charge-coupled Device), engl. für ladungsgekoppeltes Bauelement.

⁴ CMOS (Complementary Metal Oxide Semiconductor), engl. für komplementärer Metall-Oxid-Halbleiter.

gemacht werden. Bereits aus der zweidimensionalen Abbildung der Verkehrs-umgebung eines (Mono-)Kamerabildes können über Verfahren zur Fahrstreifendetektion die Ablage des Fahrzeuges innerhalb eines Fahrstreifens als auch der weitere geometrische Verlauf des Fahrstreifens und gegebenenfalls der Nachbarfahrstreifen bestimmt werden. Über Klassifikatoren können Verkehrszeichen erkannt und Objekthypothesen, wenn auch verfahrensbedingt mit erhöhter Unsicherheit, aufgestellt werden. Im Falle einer Stereokamera können die zunächst 2-dimensional aufgenommene Daten eines Kamerabildes durch Triangulation mit einem zeitgleich aufgenommenen räumlich versetzten Bildausschnitt der zweiten Kamera dreidimensional zur Objekt- und Freiflächenerkennung ausgewertet werden. Über ein ähnliches Verfahren lässt sich eine statische Szene mithilfe von zwei zeitlich versetzt aufgenommenen Bildern einer Monokamera 3-dimensional erfassen, sofern eine bekannte Bewegung zwischen den Aufnahmezeitpunkten stattgefunden hat, vgl. [Derendarz u. a. 2010].

2.1.1.2 Sensorik zur Eigenbewegungsschätzung

Die Bestimmung der Fahrzeugeigenbewegung kann sowohl durch bordeigene Fahrdynamiksensoren als auch durch eine Positionsbestimmung und Verfolgung über ein globales Navigations-Satelliten-System (GNSS) erfolgen. Zu den Fahrdynamiksensoren zählen Raddrehzahlsensoren, Drehraten- und Beschleunigungssensoren, mit denen die relative Fahrzeugeigenbewegung geschätzt werden kann. Die Verfolgung einer hierüber ermittelten Position ist relativ zum Koordinatenursprung mit einem sich räumlich kumulierenden Fehler behaftet. Dieser Fehler ist bedingt durch Schlupf an den Rädern, Fahrbahnebenenheiten sowie biasbehaftete Sensoren und lässt sich mit entsprechendem technischem Aufwand minimieren, jedoch ohne eine globale Referenzierung nicht abstellen. Eine global referenzierte Position lässt sich über die Nutzung eines GNSS ermitteln und aus der Positionsänderung auf die Fahrzeugeigenbewegung schließen. Durch Störungen des Signals beispielsweise durch Ionosphäreneinflüsse, Mehrwegeausbreitung und Abschattungen ist die Position in Bezug auf Genauigkeit und Integrität ebenfalls fehlerbehaftet. Durch die Nutzung von Mehrfrequenz-GNSS-Empfängern und terrestrischen bzw. satellitengestützten (SBAS⁵) Korrekturdaten lässt sich die Integrität steigern und eine bis auf wenige Zentimeter genaue Position bestimmen. Am Markt verfügbare GNSS-gestützte Inertialsysteme kombinieren die gesamte

⁵ Satellite Based Augmentation System: sendet Korrekturdaten zur Berücksichtigung von Ionosphäreneinflüssen bei der GNSS-gestützten Positionsbestimmung, z.B. WAAS für den nordamerikanischen bzw. EGNOS für den europäischen Raum.

Bandbreite der oben aufgeführten Sensorik über einen Sensordatenfusionsprozess und sind somit in der Lage, eine driftfreie Fahrzeugeigenbewegung auch bei schlechtem GNSS-Empfang zu bestimmen. Zudem existieren Ansätze, die Fahrzeugeigenbewegung mithilfe von Umfeldsensorik zu bestimmen, vgl. [Weiss u. Dietmayer 2008].

2.1.1.3 Straßenkarten- und car2X-basierte Umfelddaten

Umfelddaten außerhalb des Sichtbereiches von bordeigener Sensorik können im einfachsten Fall über digitale Straßenkarten bezogen werden. Dazu gehören z. B. die Fahrbahngeometrie und Konnektivität der Fahrstreifen, Geschwindigkeitsbeschränkungen oder stationäre Gefahrenstellen. Eine bordeigene Kartenbasis unterliegt einem Alterungsprozess, bedingt durch ein sich ständig änderndes Straßennetz. Servergestützte Kartendienste stellen eine aktuelle Kartenbasis zur Verfügung und bieten zudem die Möglichkeit von Echtzeitverkehrsinformation und Gefahrenmeldungen. Eine Herausforderung liegt hier in der Qualitätssicherung dieser Daten, vgl. [Klar u. a. 2012]. Um zielgerichtet Daten bzgl. der vorausliegenden Verkehrsumgebung zur Verfügung stellen zu können, sind insbesondere an Verkehrsknoten, wie z. B. Kreuzungen oder Abfahrten, Kenntnisse über die Fahrtroute vorteilhaft. Zukünftige xFCD⁶- oder Car2x-basierte Systeme bieten das Potential, die bzgl. des Fahrzeugumfeldes zur Verfügung stehende Datenmenge weiter zu erhöhen, vgl. [Kosch u. a. 2012]. So könnten beispielsweise Ampelphasen, die Existenz anderer Verkehrsteilnehmer, detaillierte Zustandsinformationen letzterer oder Routenplanungen berücksichtigt werden. Die Nutzung oben genannter Datenquellen erfordert eine dem Detaillierungsgrad der Datenquelle entsprechend genaue Ortung. Ortungs- und kartenbasierte Fahrerassistenzfunktionen wurden z. B. in [Weiser u. a. 2012; Knap 2012] untersucht.

2.1.2 Verfahren zur Umfeldmodellierung

Eine einzelne Beobachtung eines Sensors ist für eine umfassende und zuverlässige Beschreibung der Verkehrsumgebung in der Regel nicht ausreichend. Die Kombination verschiedener Messungen eines oder mehrerer Sensoren wird als Sensordatenfusion bezeichnet und dient bzgl. der Wahrnehmung des Verkehrsumfeldes u. a. der Erhöhung der Schätzgenauigkeit, der Vergrößerung des Erfassungsbereiches, der Steigerung der Verfügbarkeit oder der

⁶ Extendet Floating Car Data - bezeichnet ein Verfahren zur flottengestützten Sammlung von Verkehrs(umfeld)daten.

Erzeugung neuer Information durch Merkmalskombination verschiedener Sensoren, vgl. [Kirchner u. a. 2001].

Nachfolgend werden mit der objekt-, gitterkarten- und graphenbasierten Umfeldwahrnehmung drei Modellierungskonzepte zur Wahrnehmung, Verfolgung und Abbildung des Verkehrsumfeldes vorgestellt.

2.1.2.1 Objektbasierte Umfeldwahrnehmung

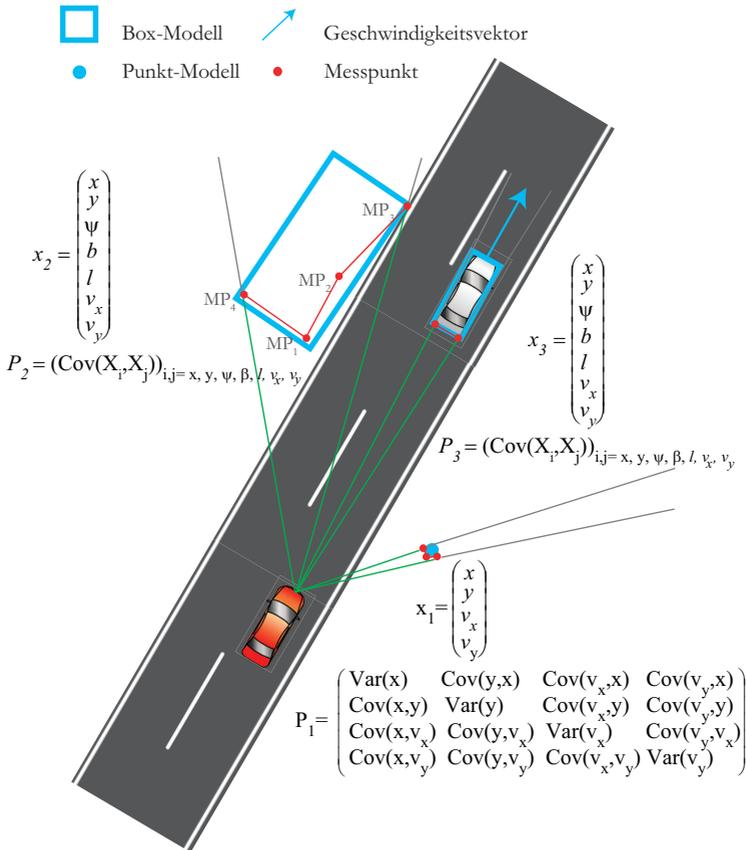


Abbildung 2.2: Objektbasierte Umfeldwahrnehmung, x_n - Zustandsvektor, P_n - Kovarianzmatrix

Bei einer objektbasierten Repräsentation wird das Verkehrsumfeld durch eine Menge von Objekten wie z. B. Fahrzeuge, Fußgänger, Fahrstreifen usw.

beschrieben, vgl. Abbildung 2.2. Hierbei werden die Objekteigenschaften wie Position, Ausdehnung und Dynamik je Objekt durch einen Zustandsvektor modelliert. Die im Zustandsvektor abgebildeten Merkmale müssen durch die Sensorik direkt oder indirekt beobachtbar sein. Die geometrische Abbildung eines Objektes wird daher im einfachsten Fall durch ein Punktmodell abgebildet. Kann die Objektgeometrie beobachtet werden, so kommt häufig ein Box-Modell zum Einsatz, vgl. Abbildung 2.2. Während der Zustand die Schätzung zu einem festen Zeitpunkt wiedergibt, lässt sich über ein Dynamikmodell eine zeitliche Prädiktion des Zustandes durchführen. Werden statistische Filter wie z. B. Kalmanfilter oder Partikelfilter (vgl. [Kalman 1960; Ristic u. a. 2004]) eingesetzt, so sind neben dem Zustandsvektor auch die Unsicherheiten modelliert. Die Unsicherheit über den Zustand lässt sich in einer Kovarianzmatrix angeben. Über Sensordaten werden neue Objekthypothesen generiert und bestehende aktualisiert. Eine ausführliche Beschreibung der objektbasierten Umfeldwahrnehmung und Verfolgung findet sich in Standardwerken wie [Bar-Shalom u. Li 1995; Blackman u. Popoli 1999].

2.1.2.2 Gitterkartenbasierte Umfeldwahrnehmung

Die gitterkartenbasierte Umfeldwahrnehmung zeichnet sich durch eine Repräsentation des Verkehrsumfeldes mittels eines Belegungsgitters (occupancy map) aus. In dieser Rasterstruktur, gezeigt in Abbildung 2.3, wird der Belegungszustand des umgebenden Verkehrsraumes abgebildet, wobei der Detaillierungsgrad von der Rastergröße abhängt. Die Sensordaten werden benutzt, um die Belegungsinformation im Sensorsichtbereich zu aktualisieren. Hierzu werden typischerweise probabilistische Verfahren wie beispielsweise Dempster-Shafer oder Bayesfilter eingesetzt, die die Besonderheiten der Sensorik berücksichtigen. Die Unsicherheit über den Belegungszustand wird demnach über eine Evidenz bzw. Wahrscheinlichkeit ausgedrückt. Auch hier wird für eine detaillierte Darstellung des kartenbasierten Umfeldwahrnehmungsprozesses auf Fachliteratur verwiesen: [Moravec u. Elfes 1984; Hughes u. Murphy 1992; Thrun u. a. 2005]. Eine Realisierung basierend auf dem Dempster-Shafer Ansatz ist beschrieben in [Weiser u. a. 2008; Weiser u. Weiss 2009].

2.1.2.3 Graphenbasierte Umfeldrepräsentation

Zur Verknüpfung von karten- und objektbasierten Umfelddaten mit den Daten einer digitalen Straßenkarte bietet sich eine graphenbasierte Umfeldrepräsentation an, vgl. [Knaup u. Homeier 2010].

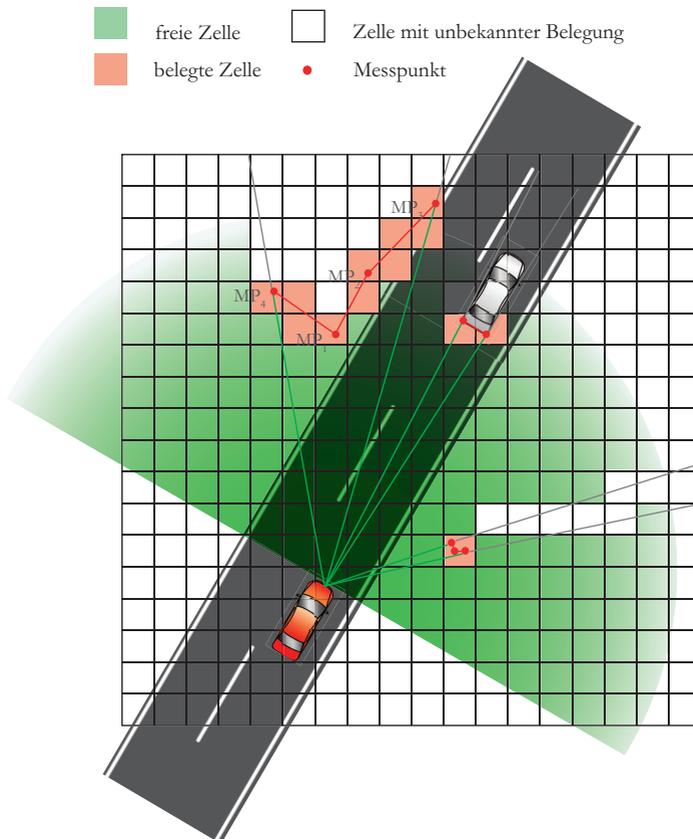


Abbildung 2.3: Gitterkartenbasierte Umfeldwahrnehmung

Ein Graph besteht aus Knoten und Kanten, wobei der Start- und Endpunkt einer Kante durch Knoten beschrieben wird. In [Knaup u. Homeier 2010] repräsentiert jede Kante einen separaten Fahrstreifen, welcher durch weitere Attribute beschrieben wird. Als Basis dient eine digitale Straßenkarte in Kombination mit einem Ortungssystem. Ein Beispiel ist in Abbildung 2.4 gegeben. Zu den in der Straßenkarte hinterlegten Attributen wie Art des Fahrstreifens, Breite, Krümmung, Geschwindigkeitsbeschränkungen oder Verkehrszeichen können u. a. folgende Attribute den Kanten zugeordnet werden:

- Objekte aus der objektbasierten Umfeldwahrnehmung,

- Befahrbarkeitswahrscheinlichkeiten der kartenbasierten Umfeldwahrnehmung,
- Gefahren- und Verkehrsinformation sowie Lichtsignalanlagen und deren Status über server- bzw. infrastrukturbasierte Dienste,
- a priori-Wissen wie beispielsweise die statistische Wahrscheinlichkeit eines Fahrstreifenwechsels in einen Nachbarfahrstreifen.

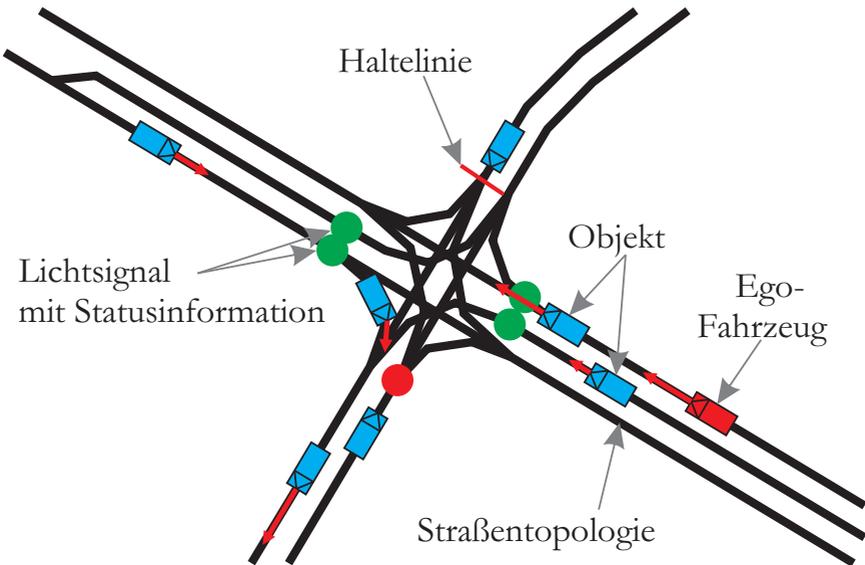


Abbildung 2.4: Graphenbasierte Umfeldrepräsentation nach [Knaup 2012]

2.1.3 Diskussion

Systeme zum hochautomatisierten Fahren stellen hohe Anforderungen an die Wahrnehmung der Verkehrsumgebung. Diese sind insbesondere mit einer homogenen Sensorik schwer zu erfüllen. Der Einsatz heterogener Sensorik und eine Fusion der Sensordaten ermöglicht die Stützung komplexer Umfeldmodelle, vgl. [Stüker 2004]. Ein Umfeldmodell basiert stets auf einem oder einer Kombination der vorgestellten Umfeldmodellierungskonzepte. Entsprechend den Anforderungen der nachgeschalteten Fahrerfunktion sind folgende Eigenschaften der Konzepte ausschlaggebend für die Auswahl: Die objektbasierte

Umfeldwahrnehmung eignet sich gut, um einzelne Verkehrsteilnehmer zu beschreiben, für deren geometrische Beschreibung und dynamisches Verhalten ein geeignetes Modell gefunden werden kann. Es lässt sich jedoch nicht explizit ausdrücken, ob objektfreie Bereiche in der Realität frei sind oder nicht beobachtet wurden. Die kartenbasierte Umfeldwahrnehmung eignet sich gut, um statische und unstrukturierte Umgebungen zu beschreiben. Je nach gewähltem Verfahren lassen sich objektfreie Bereiche explizit von nicht eingesehenen Bereichen unterscheiden. Obwohl das Verfahren für statische Umgebungen ausgelegt ist, ist eine Adaption für dynamische Verkehrsteilnehmer möglich. Die graphenbasierte Umfeldrepräsentation dient der Modellierung des Verkehrsumfeldes im Kontext der Straßengeometrie und Konnektivität unter Einbeziehung von Merkmalen, welche mit der objekt- und kartenbasierten Wahrnehmung extrahiert bzw. über Kommunikationsdienste geliefert werden können. Sie bietet ein sehr hohes Abstraktionsniveau des Verkehrsgeschehens auf eine Vielzahl potentiell relevanter Merkmale. [Knaup u. Homeier 2010] propagieren die graphenbasierte Repräsentation der Verkehrsumgebung daher als zentrale Schnittstelle für nachgelagerte Fahrerassistenzfunktionen. Die vorliegende Arbeit behandelt Fahrmanöver von Kraftfahrzeugen auf Autobahnen. Diese zeichnen sich im Allgemeinen aus durch eine genormte und wohl strukturierte Verkehrsumgebung sowie gerichtete Fahrbewegungen eines auf Kraftfahrzeuge beschränkten Nutzerkreises. Es wird angenommen, dass sich Fahrbahn und Kraftfahrzeuge über ein geometrisches Modell abbilden und mithilfe einer objektbasierten Umfeldwahrnehmung verfolgen lassen, vgl. Abschnitt 4.3.

2.2 Methoden zur Modellierung

Unter dem Oberbegriff *konventionelle* bzw. *extensionale* Verfahren wird in Unterabschnitt 2.2.1 und 2.2.2 ein kurzer Einblick in formale Logiken und Zustandsautomaten gegeben. Unter dem Begriff *intensionale* Verfahren werden Methoden zusammengefasst, welche Schlussfolgerungen aus unsicherem Wissen ziehen können, d. h. aus einer mit Ungenauigkeit, Unsicherheit und Unvollständigkeit behafteten Wissensbasis. Zu diesen Verfahren zählt die vorgestellte Fuzzy-Logik, probabilistische Schlussfolgerungsverfahren wie das Bayes'sche Konzept, die Evidenztheorie und konnektionistische Verfahren wie Künstliche Neuronale Netzwerke (KNN). Abbildung 2.5 zeigt eine Übersicht über alle in diesem Abschnitt diskutierten Konzepte.

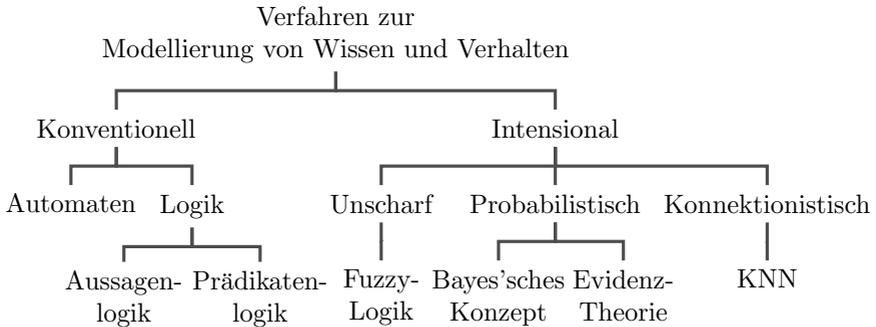


Abbildung 2.5: Übersicht und Einordnung der in diesem Abschnitt diskutierten Verfahren zur Modellierung von Wissen und Verhalten

2.2.1 Logik

Logik ist die Lehre des vernünftigen (Schluss-)Folgerens. Die für das automatisierte Schlussfolgern (automatische Inferenz) mit dem Computer interessanten Logiken untersuchen dabei die Gültigkeit von Argumenten hinsichtlich ihrer Struktur und unabhängig vom konkreten Inhalt der eigentlichen Aussagen. Sie werden deshalb auch *formale Logiken* oder *symbolische Logiken* genannt. Eine einfache und weitverbreitete Form der formalen Logik ist zurückzuführen auf die Boole'sche Algebra, sie trägt den Namen *Aussagenlogik*. Eine Erweiterung der Aussagenlogik um funktionsartige logische Terme stellt die Prädikatenlogik erster Ordnung dar. Neben diesen beiden „Standardlogiken“ existiert eine Vielzahl weiterer formaler Logiken, die vorwiegend für eine effiziente Problembeschreibung in speziellen Anwendungen geschaffen wurden.

Die Aussagenlogik besteht aus atomaren Sätzen, welche mithilfe logischer Operatoren (Junktoren) und Gliederungszeichen zu komplexen Sätzen verknüpft werden, vgl. [Luger 2001]. Atomare Sätze werden als Aussagesymbole bezeichnet. Jedes Symbol steht für eine Aussage, welcher entweder der Wahrheitswert „wahr“ oder „falsch“ zugeordnet werden kann. Häufig genutzte logische Operatoren sind die Negation, Konjunktion, Disjunktion, Antivalenz, Implikation und Bi-Implikation. Die Negation eines Satzes bildet einen neuen Satz, ebenso entsteht durch Konjunktion, Disjunktion, Antivalenz, Implikation und Bi-Implikation zweier Sätze wieder ein Satz. Die Semantik der Aussagenlogik definiert die Wahrheit eines Satzes resul-

tierend aus der Wahrheit seiner atomaren Bestandteile und deren logische Verknüpfungen. Die Regeln für jede logische Verknüpfung können mithilfe einer Wahrheitstabelle repräsentiert werden.

Um zielgerichtete Schlussfolgerungen aus einer Folge von Sätzen ableiten zu können sind Schlussregeln notwendig. Der Prozess des logischen Schließens, d. h. der Ableitung neuer Sätze (Fakten) aus bereits in der Wissensbasis befindlichen Sätzen, wird **Inferenz** genannt.

Die Prädikatenlogik erweitert die Aussagenlogik um funktionsartige logische Terme, sog. *Prädikate* und *Quantoren* sowie um die Möglichkeit der Verwendung unendlicher Mengen (z. B. reelle Zahlen). Sie ist die z. Zt. am weitesten verbreitete Form der Logik und wird auch als Logik erster Ordnung (first-order logic) bezeichnet. Während die Aussagenlogik ausschließlich mit Fakten, d. h. Sätzen mit einer endlichen Anzahl von Wahrheitswerten arbeitet, ist die Prädikatenlogik durch die Verwendung von Variablen in der Lage, allgemeingültige Regeln und Gesetze, d. h. Sätze mit einer unendlichen Zahl von Wahrheitswerten, abzubilden.

Die Prädikatenlogik erster Stufe beschränkt sich in ihrer einfachsten Form auf die Einbeziehung des Allquantors und des Existenzquantors. Ein Modell der Prädikatenlogik beschreibt die Welt durch Objekte, Relationen und Funktionen. Diese logischen Symbole sind atomare, d. h. nicht weiter reduzierbare Bestandteile der Sprache. Einem Funktionssymbol folgt eine in Klammern eingeschlossene Argumentliste. Ist die Stelligkeit der Argumentliste gleich null, so handelt es sich um ein Konstantensymbol. Im Gegensatz zu Prädikaten kann eine Funktion auch Werte außer „wahr“ und „falsch“ ergeben. Das zentrale Konzept der Prädikatenlogik ist somit - neben dem Quantor - das Prädikat. Ein Prädikat in diesem prädikatenlogischen Sinn kann als eine Folge von Wörtern mit klar definierten Leerstellen (Argumenten) verstanden werden, die zu einer - wahren oder falschen - Aussage wird, wenn in jede Leerstelle ein Eigenname eingesetzt wird.

Analog zur Aussagenlogik kann mit der Prädikatenlogik auf Basis einer Menge wahrer Fakten (Sätze) auf neue korrekte Fakten geschlossen werden. Im einfachsten Fall können durch eine Reduzierung auf aussagenlogische Inferenz die bereits genannten Verfahren zur Anwendung kommen. Die drei wichtigsten Verfahren zur logischen Schlussfolgerung in der Prädikatenlogik sind die Vorwärtsverkettung, die Rückwärtsverkettung und die Resolution. Sie bedienen sich alle drei des Unifikationskonzeptes zur Bildung von Inferenzregeln, vgl. [Russell u. a. 2004].

2.2.2 Automaten

Automaten sind in der Informatik eines der wichtigsten Werkzeuge zur Verhaltensgenerierung. Sie finden Verwendung zum Beispiel als sequentielle Algorithmen, als Modell der Ablaufstruktur von Algorithmen, als Formalismus zur Systembeschreibung oder als Formalismus zur Systemspezifikation, vgl. [Thomas 2003].

Ein *Zustandsautomat* (state machine) wird durch seine Zustände, Zustandsübergänge, den Anfangszustand und mögliche Endzustände beschrieben. Ist die Menge der durch den Automaten annehmbaren Zustände endlich, so spricht man von einem *endlichen Automaten*. Zu gewissen Situationen kann eine Ausgabe des Automaten in Form einer Aktion erfolgen.

Ein *Zustand* speichert eine Information über die Vergangenheit, d. h. der aktuelle Zustand bildet die Änderungen der Eingabe seit dem Systemstart bis zum aktuellen Zeitpunkt ab. Einige Zustände sind als Eingangs- oder Endknoten markiert. Typischerweise werden in unterschiedlichen Zuständen unterschiedliche Verhaltensweisen aktiviert. Ein ACC-System beispielsweise wechselt im Wesentlichen zwischen den Zuständen „Fahrzeugfolgefahrt“ und „Freie Fahrt“ und aktiviert entsprechend eine Abstands- oder Geschwindigkeitsregelung.

Der *Zustandsübergang* zeigt eine Änderung des Zustandes des Automaten an. Für den Übergang müssen logische Bedingungen erfüllt sein, die oftmals durch Eingangsgrößen bestimmt werden. Im Beispiel des ACC erfolgt der Übergang in den Zustand „Fahrzeugfolgefahrt“ im Wesentlichen durch ein vom Sensor erkanntes nahes Fahrzeug auf dem eigenen Fahrstreifen und der Übergang in den Zustand „Freie Fahrt“ entsprechend durch Erkennung eines hinreichend freien eigenen Fahrstreifens.

Man unterscheidet *deterministische* und *nichtdeterministische Automaten*. Deterministische Automaten sind dadurch gekennzeichnet, dass es von jedem Zustand einen eindeutigen Zustandsübergang gibt. In nichtdeterministischen Automaten ist die Anzahl der Zustandsübergänge von einem Zustand nicht auf einen eindeutigen Zustandsübergang beschränkt. Es können mehrere Zustandsübergänge parallel oder auch keiner erfolgen.

Über Zustandsautomaten lässt sich ein einfaches Systemverhalten gut beschreiben. Je komplexer dieses Verhalten ist, desto komplexer ist auch der Zustandsautomat, der dieses Verhalten abbilden soll. Je komplexer der Zustandsautomat, desto schwieriger lässt sich dieser formulieren und auf Vollständigkeit prüfen. Damit einhergehend wächst die Fehleranfälligkeit

dieses Verfahrens, weshalb Automaten zur Modellierung eines komplexen Systemverhaltens nur bedingt geeignet sind.

2.2.3 Unscharfe Mengen - Fuzzy-Logik

Die Theorie der unscharfen Menge, auch als Fuzzytheorie bezeichnet, wurde in den 60er Jahren von Lotfi A. Zadeh eingeführt, vgl. [Zadeh 1965]. Die Grundlage bildet der Übergang vom klassischen zweiwertigen Wahrheitsbegriff zum graduellen, mehrwertigen Wahrheitsbegriff für die Gültigkeit einer Aussage, einer Information oder Entscheidung. Nach Zadeh wird der graduelle Wahrheitswert mathematisch durch die Theorie der unscharfen Menge beschrieben. Eine unscharfe Menge stellt die Zusammenfassung von Objekten zu einem Ganzen dar, die einer Eigenschaft bzw. Bedingung mit bestimmten Wahrheitswerten bzw. Zugehörigkeitswerten genügen. Über den Zugehörigkeitswert lässt sich eine Aussage über die Zugehörigkeit eines Wertes zu einer Menge treffen. Zu jeder Menge existiert somit eine Zugehörigkeitsfunktion, welche die Zugehörigkeit eines Elementes aus der Grundmenge zur unscharfen Menge beschreibt. Es existieren mehrere Konzepte für die Beschreibung von Zugehörigkeitsfunktionen, zum Beispiel von: [Zadeh 1965], [Aizerman 1977] und [Bocklisch 1987].

In der Fuzzy-Logik kann die Wissensbasis in eine Daten- und eine Regelbasis unterschieden werden. In der Datenbasis sind die Zugehörigkeitsfunktionen hinterlegt und in der Regelbasis die Verknüpfungsregeln. Solche Verknüpfungsregeln bestehen aus einem Wenn-Teil, in dem die Prämissen enthalten sind, und einem Dann-Teil, in welchem die Konklusion für die Ausgangsgröße festgelegt wird. Der Begriff Prämisse wird hier für die logische Verknüpfung bestimmter Zugehörigkeiten der Eingangsgrößen verwendet. Sie bildet die Voraussetzung aus der auf das Ergebnis (Konklusion) geschlossen wird.

Sind Prämisse und Konklusion mithilfe von linguistischen Variablen definiert, sowie die Teilprämisse „Und“-verknüpft, so spricht man von einem Mamdani-Regler. Möglich wären auch Regler, bei denen sich Prämisse und Konklusion auf scharfe Werte beziehen, bzw. ein anderer Operator für die Verknüpfung der Teilprämissen gewählt wird.

Mit dem Schritt der Fuzzifizierung findet die Transformation von quantitativen scharfen Größen in qualitative unscharfe Größen statt. Dabei wird jedem quantitativen Wert unter Verwendung der jeweiligen Zugehörigkeitsfunktion ein Zugehörigkeitswert zugewiesen.

Das Ziel des Inferenzmechanismus besteht in der Auswertung der Regelbasis durch Zusammenfassung der Teilentscheidung einzelner Regeln zu einer Schlussfolgerungsentscheidung. Es lässt sich in die Teilschritte Prämissenauswertung, Berechnung der Zugehörigkeitsfunktionen (Aktivierung), und Überlagerung der Zugehörigkeitsfunktionen bei mehreren gegebenen Regeln (Aggregation) unterteilen. In der Prämissenauswertung findet die Verknüpfung der in der Prämisse enthaltenen Aussagen unter Verwendung von Fuzzy-Operatoren statt. Wesentliche Operatoren für die Verknüpfung von Fuzzymengen sind die t -Norm (UND-Operator), t -Conorm (ODER-Operator) und die Negation. Die Ermittlung des Wahrheitswertes des Dann-Teils jeder Regel erfolgt im Teilschritt der Aktivierung. Hierzu werden die Fuzzy-Mengen aus dem Bedingungsteil der Regel (Wenn) mit den Mengen des Schlussfolgerungsteils (Dann) in Beziehung gesetzt. Die entstehende Kreuzproduktmenge wird als Fuzzy-Relation bezeichnet. In der Aggregation, dem letzten Teilschritt der Inferenz, werden die durch die Aktivierung festgelegten Zugehörigkeitsfunktionen der Dann-Teile (Fuzzy-Mengen) entsprechend des gewählten Operators überlagert.

Im Zuge der Defuzzifizierung wird anschließend aus der vorliegenden unscharfen Menge von zusammengesetzten Zugehörigkeitsfunktionen eine quantitative (*scharfe*) Größe ermittelt. Es stehen verschiedene Strategien zur Verfügung, die entsprechend der aggregierten unscharfen Menge sinnvoll gewählt werden sollten. Als Beispiel sei hier auf die *Maximum-Methode* und die *Schwerpunktmethode* verwiesen.

Die Fuzzy-Logik ist ein Werkzeug zur Repräsentation vager Information. Die Stärke des Konzeptes liegt darin, auf Basis dieser Informationen Operationen ausführen zu können, welche zu aussagekräftigen und nachvollziehbaren Ergebnissen führen. Für eine Verhaltensgenerierung und Entscheidungsfindung für Fahrerassistenzsysteme findet die Fuzzy-Logik Anwendung z. B. in [Pellkofer 2003] zur Verhaltensmodellierung eines automatisierten Fahrzeuges, in [Schmitt u. Färber 2005] zur Verbesserung eines Bremsassistenten mit Fahrerabsichtserkennung und in [Trabelsi 2005] für ein Fahrbahnzustandserkennungssystem zur Vorkonditionierung von Fahrzeugregelsystemen.

2.2.4 Probabilistische Methoden: Bayes'sches Konzept

Im Folgenden wird die Modellierung von Unsicherheit aufgrund der Zufälligkeit im Auftreten einer bestimmten Konfiguration des Zustandsraumes angelehnt an [Kammel u. a. 2008] beschrieben:

Nimmt eine Größe X bei verschiedenen, unter gleichen Bedingungen durchgeführten Versuchen zufällige Werte \mathbf{x} an, so wird sie als Zufallsgröße bzw. Zufallsvariable bezeichnet. Eine Zufallsgröße ist vollständig charakterisiert, wenn alle Realisationen $\mathbf{x} = (x_1, x_2, \dots, x_n)^T$; $x_i \in \mathbb{R}$, die sie annehmen kann und die Eintrittswahrscheinlichkeit $p : \mathbf{x} \rightarrow [0,1]$ jeder Realisation bekannt sind. Die Unsicherheit bzgl. des Wissens über X , d. h. die Wahrscheinlichkeit, welche Realisation \mathbf{x} die Zufallsgröße X annimmt, wird über die Verteilungsdichtefunktion angegeben:

$$P(X = \mathbf{x}) \quad (2.1)$$

Im Falle einer n -dimensionalen Zufallsvariable $\mathbf{X} = (X_1, X_2, \dots, X_n)^T$ wird Gleichung 2.1 als Verbundverteilungsdichtefunktion bezeichnet. Diese lässt sich nach dem Multiplikationsgesetz der Wahrscheinlichkeitstheorie faktoriisiert darstellen:

$$P(\mathbf{X} = \mathbf{x}) = \prod_i (x_i | x_1, \dots, x_{i-1}) \quad (2.2)$$

Sind von einer n -dimensionalen Zufallsvariable

$$\mathbf{X}_{ij} = (X_i, X_{i+1}, \dots, X_j)^T, \quad 1 \leq i < j \leq n$$

des Zustandsraumes \mathbf{X} die ersten Elemente $\mathbf{X}_{1,k}$ beobachtbar, so kann über den Satz von Bayes die Verteilung aller weiteren Elemente $\mathbf{X}_{k+1,n}$ entsprechend Gleichung 2.3 eingeschränkt werden.

$$P(\mathbf{X}_{k+1,n} | \mathbf{X}_{1,k}) = \frac{P(\mathbf{X})}{P(\mathbf{X}_{1,k})} = \frac{P(\mathbf{X})}{\int \dots \int P(\mathbf{X}) dX_{k+1} \dots dX_n} \quad (2.3)$$

$P(\mathbf{X}_{k+1,n} | \mathbf{X}_{1,k})$ gibt demnach eine (bedingte) Wahrscheinlichkeit für eine Realisation der Elemente $\mathbf{X}_{k+1,n}$ unter der Bedingung an, dass die Elemente $\mathbf{X}_{1,k}$ mit einer bestimmten Wahrscheinlichkeit bereits realisiert sind.

Die Anwendung der Bayes'schen Inferenz führt, obwohl formal stets korrekt, zu einem Komplexitätsproblem bei der Modellierung der Verteilungsfunktion einer n -dimensionalen Zufallsgröße für sehr große n . Im ungünstigsten Fall ist sowohl die Laufzeitkomplexität als auch die notwendige Kapazität zum Speichern der Verteilung mit $O(d^n)$ anzugeben⁷.

Ohne Kenntnis über die Eigenschaften des betrachteten Raumes \mathbf{X} , d. h. der Zusammenhänge zwischen den Zufallsvariablen X_i , lässt sich die Komplexität in der Modellierung der Verteilung nicht einschränken. Sind jedoch

⁷ Die Komplexität $O(d^n)$ gilt für diskrete Zufallsvariablen, d bezeichnet die höchste Stelligkeit einer Zufallsvariable.

Kenntnisse z. B. in Form (bedingter) Unabhängigkeit zwischen Zufallsvariablen vorhanden, so lässt sich dies implizit zur Modellierung von $P(\mathbf{X})$ in Form eines *Markov-Netzwerks* oder *Bayes'schen Netzwerks* nutzen. Die erstgenannten Markov-Netzwerke werden im folgenden Unterabschnitt 2.2.4.1 erläutert, Bayes'sche Netzwerke aufgrund der Relevanz für diese Arbeit detailliert in Abschnitt 2.3.

2.2.4.1 Markov-Netzwerke

Ein Markov-Netzwerk erlaubt die Spezifizierung ungerichteter und lokaler Zusammenhänge innerhalb einer Verbundvariable $\mathbf{X} = (X_1, X_2, \dots, X_n)$ mithilfe eines ungerichteten Graph G und einem Set von Kompatibilitätsfunktionen ϕ_i .

Ist die Wechselwirkung einzelner Zufallsvariablen mit anderen Variablen räumlich begrenzt, d. h. ist die bedingte Verteilung einzelner Zufallsvariablen X_i bei Kenntnis aller weiteren Variablen $X_j, j \neq i$ des Raumes \mathbf{X} nur von einer eingeschränkten Menge benachbarter Variablen \mathcal{N}_i abhängig, so spricht man von einem Markov-Prozess:

$$P(X_i | X_j, \forall j \neq i) = P(X_i | X_j, \forall j \in \mathcal{N}_i). \quad (2.4)$$

Die Nachbarschaften \mathcal{N}_i der Zufallsvariablen $X_{i,i=1,\dots,n}$ sind Teilmengen von \mathbf{X} und müssen folgende Bedingungen erfüllen, um ein gültiges Nachbarschaftssystem zu bilden:

- $X_i \notin \mathcal{N}_i$: Eine Zufallsvariable kann nicht ihr eigener Nachbar sein.
- $X_j \in \mathcal{N}_i \Rightarrow X_i \in \mathcal{N}_j$: Wenn X_i Nachbar von X_j ist, dann ist auch X_j Nachbar von X_i .

Eine Clique c ist eine Menge von Zufallsvariablen des Nachbarschaftsystems, in der jedes beliebige Paar benachbart ist. C bezeichnet die Menge aller Cliquen c . Eine Kompatibilitätsfunktion ϕ_i ist eine reelle Funktion von x_i , welche von den Realisationen der Variablen ihrer korrespondierenden Clique c abhängt. Die Verbundverteilung, welche das Markov-Netzwerk repräsentiert, ist gegeben durch Gleichung 2.5, vgl. [Pearl 1988]. c_i bezeichnet die Realisation der i -ten Clique und K die Zustandssumme:

$$P(X = x) = \frac{1}{K} \prod_i \phi_i(c_i), \quad \text{mit } K = \sum_{X=x} \prod_i \phi_i(c_i) \quad (2.5)$$

Diese gibt das durch K normierte Produkt über alle Cliques des Nachbarschaftssystems an. Falls die Verteilung strikt positiv ist, kann sie als Gibbs-Verteilung in ein logarithmisch-lineares Modell nach Gleichung 2.6 überführt werden, mit $w_j f_j(x) = -\log(\phi_i(c_i))$ als Potentialfunktion von \mathbf{x} :

$$P(\mathbf{X} = \mathbf{x}) = \frac{1}{K} \exp \left(\sum_j w_j f_j(x) \right) \quad (2.6)$$

Mithilfe eines Markov-Netzwerkes kann globales Verhalten durch die Spezifikation lokaler Zusammenhänge innerhalb eines Nachbarschaftsystems modelliert werden. In der Praxis wird zunächst für jede Variable die Menge seiner Nachbarn bestimmt. Anschließend werden niedrigdimensionale Interaktionen zwischen den Zufallsvariablen in Form von Potentialfunktionen $w_j f_j(x)$ formuliert.

2.2.5 Probabilistische Methoden: Evidenztheorie

Die Evidenztheorie bzw. Dempster-Shafer Theorie ist eine probabilistische Datenfusionsmethode zur Kombination von Daten (Hypothesen) unterschiedlicher Glaubwürdigkeit nach [Dempster 1967] und [Shafer 1976]. Es werden Mengen von Hypothesen betrachtet, denen ein Vertrauens-/Plausibilitätsintervall zugewiesen wird. Die betrachteten Mengen können sowohl einzelne Elementarhypothesen als auch eine Disjunktion von Elementarhypothesen sein. Die Disjunktion von Elementarhypothesen eröffnet die Möglichkeit zur Verarbeitung von vager Information, welche sich nicht auf einzelne Elementarhypothesen begrenzen lässt. Dies lässt explizit die Modellierung von Unwissenheit bezüglich der Menge aller (oder der Untermenge einiger) Hypothesen zu.

In einem Raum Θ mit einer endlichen Menge sich gegenseitig ausschließender atomarer Aussagen, d. h. Elementarhypothesen, lassen sich $2^{|\Theta|}$ Teilmengen A_n bilden, vgl. Tabelle 2.1. Jede Teilmenge $A_n \subseteq \Theta$ steht hierbei für eine Aussage.

Tabelle 2.1: Beispiel für die Erzeugung der Potenzmenge aus dem Raum Θ mit zwei und drei Elementarhypothesen.

Raum	Potenzmenge (Teilmengen A_n)
$\Theta = \{\theta_1, \theta_2\}$	$\{\emptyset, \{\theta_1\}, \{\theta_2\}, \Theta\}$
$\Theta = \{\theta_1, \theta_2, \theta_3\}$	$\{\emptyset, \{\theta_1\}, \{\theta_2\}, \{\theta_3\}, \{\theta_1, \theta_2\}, \{\theta_1, \theta_3\}, \{\theta_2, \theta_3\}, \Theta\}$

Für einen Raum mit drei Elementarhypothesen $\Theta = \{\theta_1, \theta_2, \theta_3\}$ unterscheidet man beispielsweise die leere Menge \emptyset , die atomaren Aussagen $\{\theta_1\}, \{\theta_2\}, \{\theta_3\}$, die als vage Aussagen (partiell Unwissen) bezeichneten Kombinationen der atomaren Aussagen $\{\{\theta_1, \theta_2\}, \{\theta_1, \theta_3\}, \{\theta_2, \theta_3\}\}$ und vollständiges Unwissen Θ . Die Verknüpfung von Evidenz mit einer Teilmenge A aus Θ erfolgt über die **Basiswahrscheinlichkeitsverknüpfung** $m(A)$.

$$m : 2^\Theta \rightarrow [0,1], \quad \text{es gilt: } m(\emptyset) = 0 \text{ und } \sum_{A \subseteq \Theta} m(A) = 1 \quad (2.7)$$

Die Funktion $m(A)$ gibt das Maß an Evidenz an, welches der Teilmenge A zugewiesen werden kann. Hierbei kann der leeren Menge keine Evidenzmasse zugewiesen werden. Die Summe der Evidenzmasse, welche auf alle Teilmengen von Θ verteilt wird beträgt eins.

Die **Vertrauensfunktion** Bel ist die Summation aller Evidenzmassen m , die für die Teilmenge $X \subseteq \Theta$ sprechen:

$$Bel(X) = \sum_{\emptyset \neq A \subseteq X} m(A); \quad \text{mit } Bel(\emptyset) = 0 \text{ und } Bel(\Theta) = 1 \quad (2.8)$$

Die **Plausibilitätsfunktion** Pl ist die Summation aller Evidenzmassen m , die A sicher und bei zusätzlicher Information potentiell A zugeordnet werden können:

$$Pl(X) = \sum_{A \cap X \neq \emptyset} m(A); \quad \text{für } \forall X \subseteq \Theta \quad (2.9)$$

Vertrauens- und Plausibilitätsfunktion stehen in folgender Beziehung:

$$Bel(X) \leq Pl(X), Pl(X) = 1 - Bel(\bar{X}); \quad \text{für } \forall X \subseteq \Theta, \bar{X} = \Theta \setminus X \quad (2.10)$$

Für die Verknüpfung der Evidenzen $m(A), m(B)$ zweier Hypothesen A, B kommt die **Kombinationsregel nach Dempster**, Gleichung 2.11 zum Einsatz:

$$m(C) = \frac{\sum_{A \cap B = C_k; C_k \neq \emptyset} m(A)m(B)}{1 - \underbrace{\sum_{A \cap B = \emptyset} m(A)m(B)}_{\kappa}} \quad (2.11)$$

Die Kombination von $m(A)$ und $m(B)$ erfolgt über Orthogonalsummenbildung nach der Kombinationsregel nach Dempster, in deren Ergebnis eine

neue Basiswahrscheinlichkeitsverknüpfung $m(C)$ steht. Die Verknüpfung ist kommutativ und assoziativ. Die Basiswahrscheinlichkeitsverknüpfung m_3 weist der Menge C die skalierte Summation der Produkte der Basiswahrscheinlichkeitsverknüpfungen m_1 und m_2 zu, welche als Schnittmenge C haben. Die Notwendigkeit zur Skalierung resultiert aus einem potentiellen Widerspruch κ zwischen den Verknüpfungen m_1 und m_2 , der sich ergibt, wenn deren Schnittmengenbildung die leere Menge ergibt. Tabelle 2.2 zeigt das Schnittmengendiagramm für A und B mit zwei Elementarhypothesen θ_1, θ_2 für die Bildung von $m(C)$, vgl. Gleichung 2.12 entsprechend Gleichung 2.11. Die Berechnung von $m_3(\theta_1)$ ist in Gleichung 2.13 gegeben, die Berechnung von $m_3(\theta_2)$ und $m_3(\Theta)$ erfolgt analog.

Tabelle 2.2: Schnittmengendiagramm für die Kombination $m(A)$ und $m(B)$ nach Gleichung 2.11.

m	$m_1(\theta_1)$	$m_1(\theta_2)$	$m_1(\Theta)$
$m_2(\theta_1)$	$\theta_1 \cap \theta_1$ $= \theta_1$	$\theta_1 \cap \theta_2$ $= \emptyset$	$\theta_1 \cap \Theta$ $= \theta_1$
$m_2(\theta_2)$	$\theta_2 \cap \theta_1$ $= \emptyset$	$\theta_2 \cap \theta_2$ $= \theta_2$	$\theta_2 \cap \Theta$ $= \theta_2$
$m_2(\Theta)$	$\Theta \cap \theta_1$ $= \theta_1$	$\Theta \cap \theta_2$ $= \theta_2$	$\Theta \cap \Theta$ $= \Theta$

$$m(C) = m_3(\theta_1) + m_3(\theta_2) + m_3(\Theta), \quad \text{mit } m_3(\emptyset) = 0 \quad (2.12)$$

$$m_3(\theta_1) = \frac{m_1(\theta_1) \cdot m_2(\theta_1) + m_1(\theta_1) \cdot m_2(\Theta) + m_1(\Theta) \cdot m_2(\theta_2)}{1 - (m_1(\theta_1) \cdot m_2(\theta_2) + m_1(\theta_2) \cdot m_2(\theta_1))} \quad (2.13)$$

Anwendungspotential und Literaturverweise: Die Evidenztheorie wird vorwiegend für Aufgaben eingesetzt, bei denen unsichere, zum Teil mit Unwissenheit behaftete Information unterschiedlicher Quellen kombiniert werden soll. In der Literatur findet sich ein breites Spektrum von Anwendungen, von denen der vorwiegende Teil auf die Lösung von Klassifikationsproblemen abzielt, vgl. [Bauer 1996; Zeller 1996; Dietmayer 2006; Linzmeier u. Bär 2006]. In der Wahrnehmungsplattform des TEMPORARY AUTOPILOT kommt die Evidenztheorie an unterschiedlichen Stellen zur Anwendung: in der gitterkartenbasierten Umfeldwahrnehmung zur Modellierung des Belegungszustandes einer Gitterzelle, vgl. Unterabschnitt 2.1.2, in der Fahrbahnfusion, vgl. Unterabschnitt 4.3.2.3, zur Modellierung der Fahrstreifenmarkierungsart sowie zur Fahrstreifenzuordnung des Ego-Fahrzeuges über alle verfügbaren Fahrstreifen der befahrenen Richtungsfahrbahn, vgl. Gleichung 4.5.1.

2.2.6 Künstliche Neuronale Netzwerke

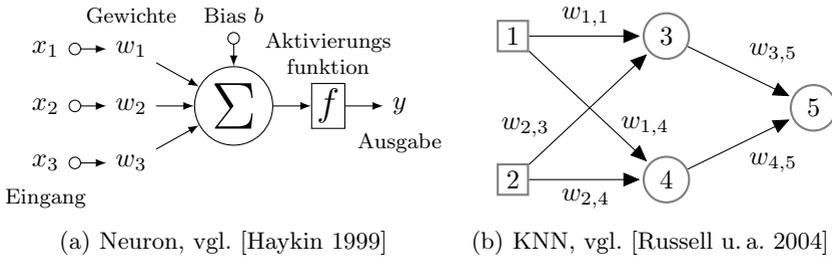


Abbildung 2.6: Beispiel für das Modell eines Neurons (a) und (b) für den Aufbau eines einfachen KNN mit Eingabe-, verborgener und Ausgabeschicht

Ein Künstliches Neuronales Netzwerk (KNN) besteht aus in Schichten angeordneten Neuronen, welche aktiv oder inaktiv sein können und mit anderen Neuronen schichtübergreifend über gewichteten Synapsen verbunden sind. Es existiert mindestens eine Ausgabe- und eine Eingabeschicht, zwischen diesen können je nach Ausprägung des Netzes eine Anzahl von versteckten Schichten, sog. Hidden-Layer existieren. Die Grundidee von KNN ist das Eingangssignal durch eine Sequenz von Schichten zu propagieren, wobei jede Schicht durch eine differenzierbare Funktion eine Menge von Aktivierungen auf die nächste Schicht abbildet, bis schließlich am Ende die Klassengewichte für die finale Ausgabe berechnet werden. In Abbildung 2.6 ist beispielhaft das Modell eines Neurons und ein KNN abgebildet. Ein Neuron besteht aus einer Eingabe-, Aktivierungs- und Ausgabefunktion. Es wird aktiviert, wenn eine Kombination seiner Eingaben einen bestimmten Schwellwert überschreitet.

KNN haben in jüngster Vergangenheit vor allem im Bereich „Deep Learning“ für Convolutional Neuronal Networks (CNN) neue Bedeutung erlangt. Ist bei den bisher genannten Methoden eine expertengestützte Merkmalsauswahl und Aufbereitung üblich, wird dieser Schritt bei Verfahren wie CNN in den maschinellen Lernprozess integriert. Hierbei besteht ein CNN aus einer bestimmten Anzahl an Faltungsschichten (convolutional layers) zur Merkmalsauswahl und einer Anzahl von vollständig verbundenen Schichten zum Zwecke der Klassifikation.

2.3 Bayes'sche Netzwerke

Nachfolgend wird die Wissensmodellierung mithilfe eines Bayes'schen Netzwerks vorgestellt. Dies ist gegeben durch: eine Erläuterung des zugrundeliegenden Konzeptes inkl. der für diese Arbeit relevanten Ausprägungen, eine Beschreibung der Inferenz im Bayes'schen Netzwerk inkl. dem Umgang mit unsicherer Evidenz und abschließend einer Vorstellung von maschinellen Lernverfahren zur Bestimmung eines Bayes'schen Netzwerks.

2.3.1 Konzept des Bayes'schen Netzwerks

Ein Bayes'sches Netzwerk modelliert eine Verbundverteilung in Form eines Graphen. Hierbei werden die Zufallsvariablen durch Knoten in einem gerichteten azyklischen Graphen repräsentiert. Die Kanten zwischen den Knoten beschreiben die bedingte Abhängigkeit zwischen den Zufallsvariablen. Das Konzept der Kausalität ergibt sich durch Vorgabe einer Kantenrichtung zwischen Eltern- und Kindknoten, d. h. in Form einer gerichteten Eltern-Kindbeziehung. Die Menge der Eltern \mathcal{G}_i eines Knotens i wird durch alle Knoten j gebildet, von denen eine Kante zum betrachteten Knoten führt. Die bedingte Wahrscheinlichkeitsverteilung einer Zufallsvariable, bei gegebenen Zufallsvariablen an den Elternknoten j wird in Form einer Wahrscheinlichkeitstabelle angegeben.

Die Verbundverteilung $P(\mathbf{X} = \mathbf{x})$ eines Bayes'schen Netzwerks lässt sich nach Gleichung 2.14 angeben als Produkt der bedingten Wahrscheinlichkeiten über alle Zufallsvariablen X_i bei gegebener Menge der zugehörigen Elternschaft X_j .

$$P(\mathbf{X} = \mathbf{x}) = \prod_{i=1}^n P(X_i | X_j, \forall j \in \mathcal{G}_i). \quad (2.14)$$

Ist eine beliebige Teilmenge von Variablen, z. B. durch Beobachtungen bekannt, so ist die bedingte Verteilung aller anderen Variablen durch Gleichung 2.3 eindeutig bestimmt. Die Vorgehensweise zur Modellierung eines Bayes'schen Netzwerks gestaltet sich nach [Pearl 1988] in den folgenden Schritten:

- 1) Auswahl einer Menge relevanter Variablen Θ , die Domäne beschreibend.
- 2) Festlegen einer Reihenfolge für die Variablen: $\langle X_1, \dots, X_n \rangle$.

3) Solange Variablen in Θ enthalten sind:

- a) Füge die nächste Variable X_i aus Θ dem Netz hinzu.
- b) Füge Kanten von einer Minimalmenge von bereits im Netz befindlichen Elternknoten $Eltern(X_i)$ zu Knoten X_i hinzu, so dass folgender Formel genügt ist, mit X'_1, \dots, X'_m als Bezeichner für die vor X_i gewählten Variablen:

$$P(X_i | X'_1, \dots, X'_m) = P(X_i | Eltern(X_i))$$

- c) Lege die bedingte Wahrscheinlichkeitstabelle für X_i fest.

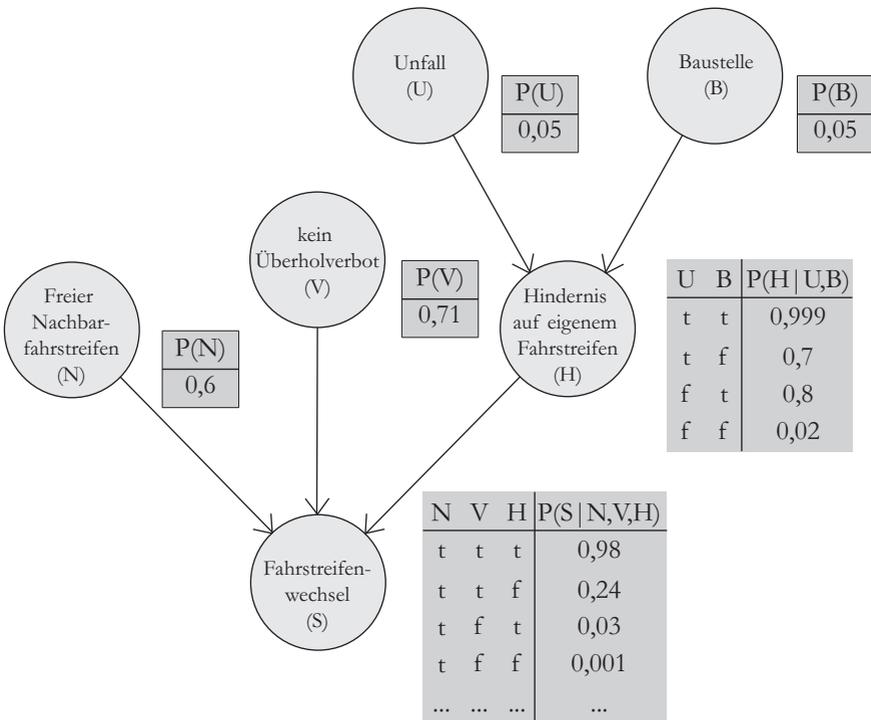


Abbildung 2.7: Aufbau eines Bayes'schen Netzwerks

Abbildung 2.7 zeigt ein Beispiel eines Bayes'schen Netzwerks, das eine Verbundverteilung von sechs Zufallsvariablen eindeutig und konsistent spezifiziert. In dem Beispiel wird die Wahrscheinlichkeit des Ereignisses „Fahrstreifenwechsel“ (S) durch jedes der Ereignisse „Freier Nachbarfahrstreifen“ (N),

„Kein Überholverbot“ (V), „Hindernis auf eigenem Fahrstreifen“ (H), „Unfall“ (U) oder „Baustelle“ (B) begünstigt. Liegt für eine dieser Variablen Evidenz vor, d. h. ein bekanntes Ereignis z. B. aus der Schätzung einer Zustandsgröße, so wird diese als Eingangs- oder Evidenzvariable innerhalb dieser Arbeit bezeichnet.

$$P(N,V,U,B,H,S) = P(U) \cdot P(B|U) \cdot P(H|U,B) \cdot P(V|H,U,B) \cdot P(N|V,H,U,B) \cdot P(S|N,V,H,U,B) \quad (2.15)$$

$$= P(U) \cdot P(B) \cdot P(H|U,B) \cdot P(V) \cdot P(N) \cdot P(S|N,V,H) \quad (2.16)$$

Gleichung 2.15 zeigt die Faktorisierung der im Beispiel verwendeten Verbundverteilung $P(N,V,U,B,H,S)$. Unter Annahme der gegenseitigen Unabhängigkeit von N,V,H und der über H bedingten Abhängigkeit von U und B ergibt sich Gleichung 2.16 welche der in Abbildung 2.7 gezeigten Netzstruktur entspricht.

2.3.1.1 d-Separation

Der Formalismus *d-Separation* dient der Beschreibung von bedingter Unabhängigkeit von Zufallsvariablen ausgedrückt durch die Struktur eines Bayes'schen Netzwerks.

Es seien \mathbf{X} , \mathbf{Y} und \mathbf{Z} paarweise disjunkte Knotenmengen in einem Bayes'schen Netzwerk und es sei jede mögliche ungerichtete Verbindung zwischen einem Knoten $X \in \mathbf{X}$ und einem Knoten $Y \in \mathbf{Y}$ über einen oder mehrere Knoten aus \mathbf{Z} als Pfad bezeichnet. Jeder Pfad lässt sich in Dreiergruppen unterteilen, welche jeweils einem der folgenden Verbindungstypen zugeordnet werden können: *seriell*, *divergent* und *konvergent*. Eine Dreiergruppe über die Knoten X, Z, Y gilt als

- (a) *seriell* für eine von X bzw. Y zu Z und eine von Z zu Y bzw. X weg gerichtete Kante, vgl. Abbildungen 2.8(a), 2.8(e), als
- (b) *divergent* für je eine von Z zu X und Z zu Y gerichtete Kante, vgl. Abbildungen 2.8(b), 2.8(f) oder als
- (c) *konvergent* wenn, beide Kanten von X und Y nach Z gerichtet sind, vgl. Abbildungen 2.8(c), 2.8(g), 2.8(d), 2.8(h).

Von einer d-Separation der Mengen \mathbf{X}, \mathbf{Y} durch \mathbf{Z} spricht man genau dann, wenn alle Pfade in einem Bayes'schen Netzwerk zwischen einem Knoten

$X \in \mathbf{X}$ und einem Knoten $Y \in \mathbf{Y}$ durch einen oder mehrere Knoten aus \mathbf{Z} blockiert sind. Ein Pfad gilt als blockiert, wenn eine Dreiergruppe an Knoten vom Typ *seriell* oder *divergent* ist und Evidenz für Z vorliegt. Ist der Verbindungstyp *konvergent*, so gilt der zugehörige Pfad als blockiert, wenn weder Evidenz für Z noch für Kindknoten A von Z vorliegt. Ist ein Pfad nicht blockiert, so gilt er als aktiv, d. h. die entsprechenden Knoten können sich gegenseitig beeinflussen. Werden die Knoten X, Y durch einen Knoten Z d-separiert, gilt $P(X|YZ) = P(X|Z)$.

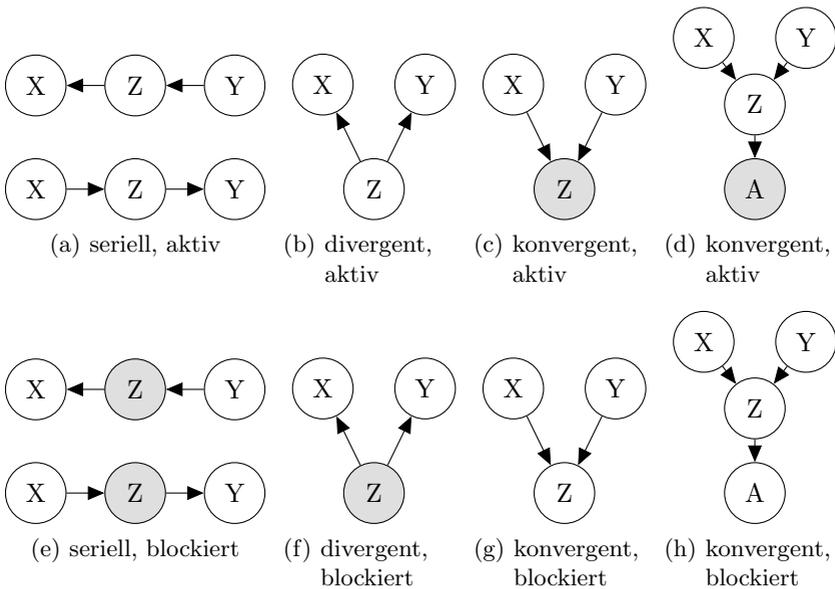


Abbildung 2.8: Typen von Kausalstrukturen in Bayes'schen Netzwerken, grau eingefärbte Knoten sind beobachtet

Zur Verdeutlichung sei im Folgenden die Abhängigkeit zwischen den Knoten N, B des in Abbildung 2.7 auf Seite 38 gegebenen Bayes'schen Netzwerks betrachtet: Zwischen den Knoten N, B existiert im gegebenen Netzwerk ein einziger Pfad über die Knoten S und H mit den Dreiergruppen $\langle N \rightarrow S \leftarrow H \rangle$ und $\langle S \leftarrow H \leftarrow B \rangle$, wobei in ersterer die Knoten konvergent und in letzterer seriell verbunden sind.

Es gilt $N \perp\!\!\!\perp B$, d. h. N, B sind garantiert unabhängig, wenn für keinen Knoten des Netzwerks eine Evidenz beobachtet wird, da $\langle N \rightarrow S \leftarrow H \rangle$ den Pfad blockiert. Ebenso gilt $N \perp\!\!\!\perp B|H$, d. h. N, B sind garantiert unabhängig,

wenn für H eine Evidenz beobachtet wird, da $\langle S \leftarrow H \leftarrow B \rangle$ den Pfad blockiert. Kann eine Evidenz für S beobachtet werden, so ist N, B nicht d-separiert, da weder $\langle N \rightarrow S \leftarrow H \rangle$ noch $\langle S \leftarrow H \leftarrow B \rangle$ den Pfad blockieren. Es gilt $N \not\perp\!\!\!\perp B|S$, d. h. N, B sind nicht garantiert unabhängig⁸.

2.3.1.2 Naives Bayes'sches Netzwerk

Ein Naives Bayes'sches Netzwerk ist ein Spezialfall. Es zeichnet sich dadurch aus, dass alle Knoten, d. h. Zufallsvariablen X_i in direkter kausaler Beziehung zur Klassenvariable C stehen und untereinander keine direkten Abhängigkeiten aufweisen:

$$P(X_1, \dots, X_n|C) = \prod_i P(X_i|C) \quad (2.17)$$

Die Kanten sind von der Klassenvariable zu den Attributvariablen gerichtet. In der Praxis hat dies den Vorteil, dass im Vergleich zu einem konventionellen Bayes'schen Netzwerk weniger Parameter benötigt werden um das Netz zu bestimmen. Das heißt, dass viele kompakte Übergangswahrscheinlichkeitstabellen in ihrem zugehörigen Knoten verortet sind, statt in einer komplexen Tabelle für die Klassenvariable bei umgekehrter Kausalitätsrichtung, vgl. Abbildung 2.7 mit 2.9. In der Folge werden weniger Daten benötigt um die Übergangswahrscheinlichkeiten zu bestimmen, was gegenüber anderen Modellen einen schnelleren Lernprozess für das Naive Bayes'sche Netzwerk verspricht. Naive Bayes'sche Netzwerke werden z. B. als Naive Bayes Klassifikatoren eingesetzt. Hierbei wird der oft vorhandene statistische Zusammenhang zwischen den Eingangsknoten durch die *naive* Annahme einer gegebenen Unabhängigkeit vernachlässigt, was ggf. die Vorhersagegenauigkeit reduziert.

2.3.1.3 Dynamisches Bayes'sches Netzwerk

Ein Dynamisches Bayes'sches Netzwerk erweitert das Konzept der Bayes'schen Netzwerke um die Modellierung stochastischer temporaler Prozesse. Es besteht aus einem Prior- und einem temporalen Netz. Während das Prior-Netz analog zu einem klassischen Bayes'schen Netzwerk die Abhängigkeiten zwischen den Zufallsvariablen X einer Zeitscheibe modelliert, beschreibt das temporale Netz die Abhängigkeiten der Zufallsvariablen X^{t_n}

⁸ Eine Unabhängigkeit zwischen N, B könnte dennoch über eine entsprechende bedingte Wahrscheinlichkeitstabelle für den Knoten H realisiert werden. Dies ist jedoch im gegebenen Beispiel nicht der Fall.

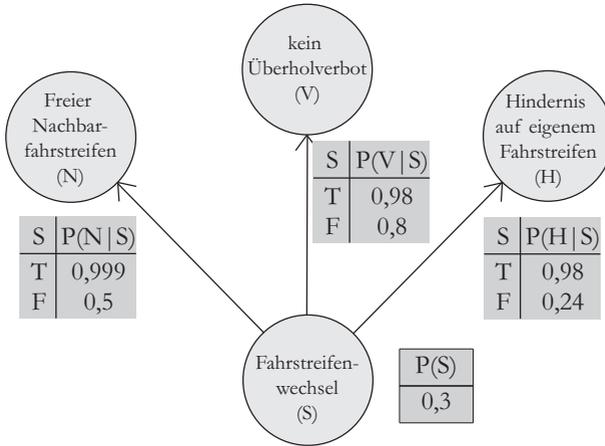


Abbildung 2.9: Aufbau eines Naive Bayes'schen Netzwerks

zwischen den Zeitscheiben: $x_i^{t_n} \rightarrow x_j^{t_m}$, mit $n < m, i = j$ oder auch $i \neq j$. Theoretisch können alle Variablen einer Zeitscheibe die Variablen in allen folgenden Zeitscheiben beeinflussen, was jedoch hinsichtlich der damit verbundenen Komplexität nicht anzustreben ist.

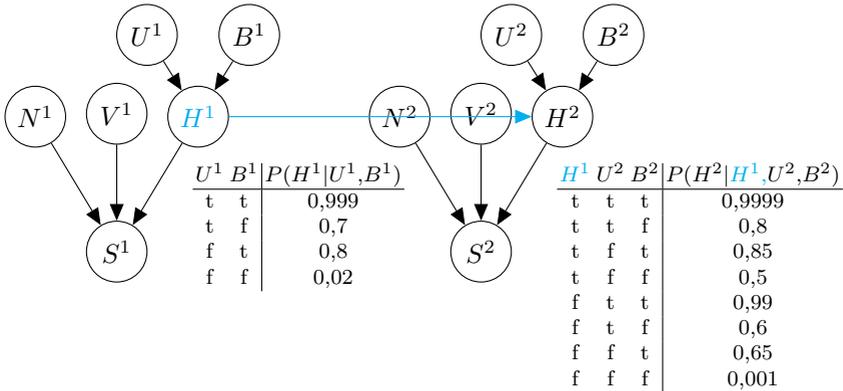


Abbildung 2.10: Dynamisches Bayes'sches Netzwerk 1. Ordnung: zeitliche Abhängigkeit mindestens einer Variable X^2 von mindestens einer Variable X^1 der vorhergehenden Zeitscheibe

In der Praxis kann mit jeder Zeitscheibe eine Beobachtung modelliert werden, d. h. mit jeder Beobachtung wird eine Zeitscheibe hinzugefügt. Für

komplexe Dynamische Bayes'sche Netzwerke, d. h. in welche fortlaufend Beobachtungen eingebracht werden, können in einem sog. *sliding window*- bzw. *rollup*-Verfahren zurückliegende Zeitscheiben unter Beibehaltung ihres statistischen Einflusses abgeschnitten werden. Abbildung 2.10 zeigt die Erweiterung des in Abbildung 2.7 eingeführten Beispiels um eine zusätzliche temporale Abhängigkeit der Zufallsvariable H , gegeben durch $H^1 \rightarrow H^2$ und der angepassten Wahrscheinlichkeitstabelle für H^2 . Eine Übersicht über Inferenz- und Lernverfahren für Dynamische Bayes'sche Netzwerke ist in [Mihajlovic u. Petkovic 2001] gegeben.

2.3.2 Inferenz und Schlussfolgern

In einem Bayes'schen Netzwerk kann das Schlussfolgern sowohl in als auch entgegen der Kausalrichtung erfolgen. Abbildung 2.11 illustriert diesen Umstand für das diagnostische Schlussfolgern entgegen der Kausalrichtung und das prädiktive Schlussfolgern in Kausalrichtung.

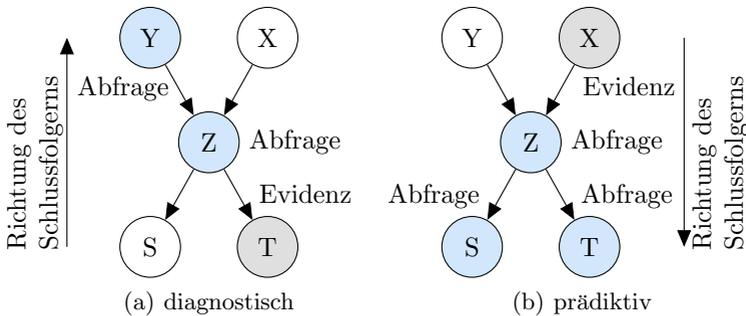


Abbildung 2.11: Arten des Schlussfolgerns, nach [Korb u. Nicholson 2010]

Ist die Evidenz, d. h. die Realisierung einer Variable bekannt, werden mithilfe des Formalismus der d-Separation alle betroffenen, d. h. abhängigen Variablen des Netzes ermittelt und für diese die posteriori-Wahrscheinlichkeit berechnet. Die Evidenz kann in jede Variable eingebracht werden. Die Inferenz in einfachen Baumstrukturen erfolgt durch die lokale Anwendung des Bayes-Theorem für jeden Knoten und einer Weitergabe über die bedingten Wahrscheinlichkeitstabellen zwischen den Knoten. Letztgenannter Vorgang wird *message passing* genannt, vgl. [Pearl 1988].

Wenn Knoten über mehr als einen Pfad erreicht werden können ist ein Clusteringverfahren notwendig, z. B. mithilfe des Junction Tree Algorithmus.

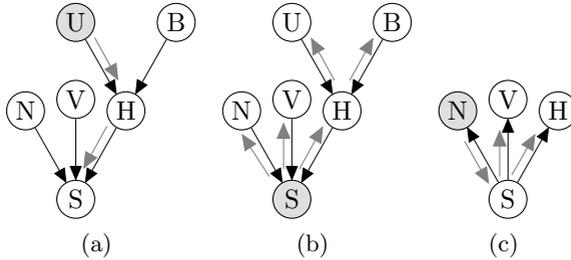


Abbildung 2.12: Weitergabe von Evidenz (graue Knoten) in Bayes'schen Netzwerken anhand von drei unterschiedlichen Beispielen

Für komplexe Netzstrukturen ist die Bestimmung einer exakten Inferenz ggf. rechnerisch unmöglich. In diesem Fall kann die Inferenz näherungsweise berechnet werden, vgl. [Korb u. Nicholson 2010]. Abbildung 2.12 zeigt an drei unterschiedlichen Netzwerkkonfigurationen beispielhaft die schrittweise Weitergabe von Evidenz für eine Beobachtung, d. h. jeweils gegebene Evidenz für die Variable U , S oder N .

2.3.2.1 Anwendung weicher Evidenz in Bayes'schen Netzwerken

Die Evidenzen für Eingangsvariablen sollen innerhalb dieser Arbeit aus der Erfassung des Verkehrsumfeldes, vgl. Abschnitt 4.3, abgeleitet werden und sind somit prozessbedingt potentiell unsicherheitsbehaftet: Sei x eine Realisation der Eingangsvariable X mit

$$x = \{(x_1, p_1), \dots, (x_m, p_m)\}, \text{ und } \sum_{j=1}^m p_j = 1, p_j (j = 1, \dots, m) \quad (2.18)$$

der Wahrscheinlichkeit von x den Zustand x_j einzunehmen. Wird nun die gesamte Evidenzmasse auf mehr als einen Zustand verteilt, so spricht man von weicher oder auch unsicherer Evidenz, andernfalls von harter Evidenz. Verdeutlicht sei dies an einer beispielhaften Beobachtung für die Eingangsvariable *Freier Nachbarfahrstreifen* (N) aus dem in Abbildung 2.7 gegebenen Beispiel: Eine Realisierung n in einer Form als weiche Evidenz wäre gegeben durch $n = \{(n_1; 0,9), (n_2; 0,1)\}$ und eine Realisierung als harte Evidenz durch $n = \{(n_1; 1,0), (n_2; 0,0)\}$.

Während das Setzen von harter Evidenz in Bayes'schen Netzwerken gebräuchlich ist, ist dem Autor kein Verfahren bekannt, welches das direkte Setzen von unsicherer Evidenz ermöglicht.

Eine Umgehungslösung bieten [Chan u. Darwiche 2005] unter Nutzung des Konzeptes der virtuellen Evidenz nach [Pearl 1988] an: Grundidee ist die von [Chan u. Darwiche 2005] gezeigte Transformation der unsicheren Evidenz aus der zugrunde liegenden Beobachtung in eine virtuelle Evidenz η , welche auf die Variable X einwirkt. Die Unsicherheit der Evidenz wird durch die Wahrscheinlichkeitsquotienten $\lambda_1, \dots, \lambda_m$ quantifiziert.

Eine virtuelle Evidenz wird in einem Bayes'schen Netzwerk durch das Hinzufügen einer Kindvariable Z zu X und einer gerichteten Kante $X \rightarrow Z$ repräsentiert, wobei eine Realisation z von Z mit dem virtuellen Ereignis η korrespondiert. Die bedingten Wahrscheinlichkeiten $P(z|x_j)$ von Z entsprechen in ihrem Verhältnis zueinander den Wahrscheinlichkeitsquotienten λ_j :

$$P(z|x_1) : \dots : P(z|x_m) = \lambda_1 : \dots : \lambda_m \quad (2.19)$$

Über die Inferenz mit einer harten Evidenz $Z = z$ wird schließlich eine der unsicheren Evidenz entsprechende Verteilung in X realisiert. Schlussendlich läuft es somit für jede unsicherheitsbehaftete Beobachtung von X auf die Bestimmung der Wahrscheinlichkeitstabelle für Z hinaus:

$$P'(x_j) = q_j, \text{ mit } j = 1, \dots, m \quad (2.20a)$$

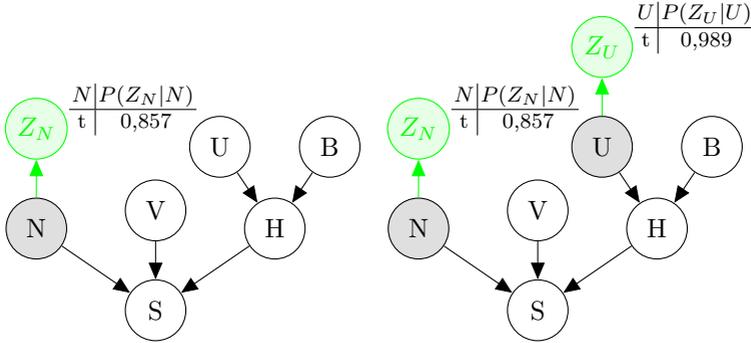
$$\lambda_1 : \dots : \lambda_m = \frac{q_1}{P(x_1)} : \dots : \frac{q_m}{P(x_m)} \quad (2.20b)$$

$$P(z|x_j) = \frac{\lambda_j}{\sum_{i=1}^m \lambda_i} \quad (2.20c)$$

Sei P die A-priori-Verteilung für X und P' die aus einer Beobachtung resultierende Verteilung, so lässt sich die virtuelle Evidenz η in Form der Wahrscheinlichkeitsquotienten λ_j nach Gleichung 2.20b berechnen und die bedingten Übergangswahrscheinlichkeiten für Z nach Gleichung 2.20c. Abbildung 2.13(a) zeigt die Erweiterung des Bayes'schen Netzwerks aus dem in Abbildung 2.7 gegebenen Beispiel um virtuelle Variablen $Z_{(\cdot)}$.

Sei beispielhaft aus einer Beobachtung von N eine unsichere Evidenz $P'(N=n) = 0,9; P'(N=\bar{n}) = 0,1$ gegeben, so ergibt sich unter Berücksichtigung der Priorwahrscheinlichkeit $P(n) = 0,6$ eine bedingte Übergangswahrscheinlichkeit von $P(z|n) = 0,857$.

Für das Setzen von multipler weicher Evidenz über mehrere Variablen in einem Zeitschritt muss der Formalismus der d-Separation Berücksichtigung finden. Während im gegebenen Beispiel in Abbildung 2.13(b) beide Evidenzvariablen durch S und H d-separiert sind, trifft dies auf die Variablen N



(a) einfache weiche Evidenz mit $P'(N=n) = 0,9$ (b) multiple weiche Evidenz mit $P'(N=n)=0,9; P'(U=u)=0,83$

Abbildung 2.13: Virtuelle Variablen $Z_{(\cdot)}$ und zugehörige Übergangswahrscheinlichkeiten für das in Abbildung 2.7 gegebene Beispiel

und H im zweiten, in Abbildung 2.14(b) gegebenen Beispiel nicht zu. Eine voneinander unabhängige Berechnung der virtuellen Evidenz für Z_N und Z_H führt entsprechend nicht zwangsläufig zu einer Realisierung der beobachteten Verteilung $P'(N)$ und $P'(H)$ als Randverteilung für N und H . Wird die aus 2.14(a) bekannte virtuelle Evidenz für Variable N in 2.14(b) gesetzt, gibt es keine Möglichkeit die Randverteilung von N zu halten, sobald eine weitere Evidenz, beispielsweise für H , gesetzt wird. Eine Lösung, welche die aus P' resultierenden virtuelle Evidenz so bestimmt, dass die beobachteten Randverteilungen für die entsprechenden Variablen eingehalten werden, findet sich in [Valtorta u. a. 2002; Peng u. a. 2010; Mrad u. a. 2015] und wird durch Anwendung des Iterative Proportional Fitting Algorithmus (IPF) erreicht.

[Peng u. a. 2010] stellen mit *BN-IPFP-1* und *BN-IPFP-2* zwei Algorithmen mit einem jeweils unterschiedlichen Konzept bzgl. der Anwendung der virtuellen Evidenz vor. Aus einer Beobachtung sei eine Menge von s weichen Evidenzen $P'(X^j)$ für die Variablen X^j , mit $j = 1 \dots s$ eines Bayes'schen Netzwerks gegeben. Während in *BN-IPFP-1* für jede von weicher Evidenz betroffene Variable X^j eine virtuelle Variable Z_{X^j} mit entsprechend angepasster bedingter Übergangswahrscheinlichkeit $P(Z_{X^j}|X^j)$ angelegt wird, kommt in *BN-IPFP-2* eine einzige virtuelle Variable für alle X^j zur Anwendung mit $P(Z|X^1, \dots, X^s)$. Entsprechend wird in *BN-IPFP-1* iterativ $P(Z_{X^j}|X^j)$ für jede Variable bestimmt und in *BN-IPFP-2* $P(Z|X^1, \dots, X^s)$ mit Z als gemeinsame Kindvariable für alle betroffenen Variablen X^j . In

Abbildung 2.14 wird die weiche Evidenz nach dem Verfahren *BN-IPFP-1* realisiert. Der Pseudocode zu *BN-IPFP-1* ist in Abschnitt A.5 gegeben.

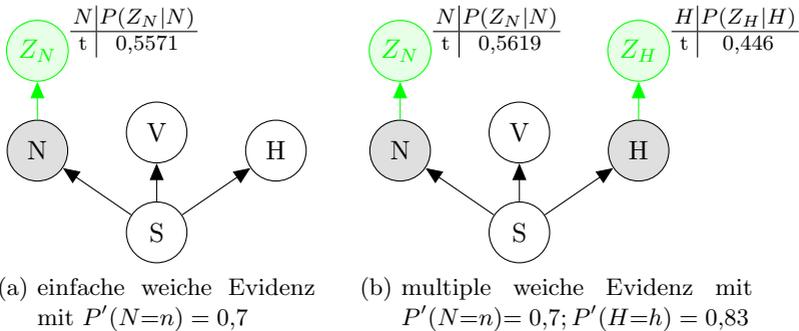


Abbildung 2.14: Virtuelle Variablen $Z_{(\cdot)}$ und zugehörige Übergangswahrscheinlichkeiten für das in Abbildung 2.9 gegebene Beispiel. Für 2.14(b) werden $P(Z_N|N)$ und $P(Z_H|H)$ mit *BN-IPFP-1* modelliert, $P'(N=n)$ und $P'(V=v)$ werden bereits nach zweimaliger Iteration realisiert

[Peng u. a. 2010] argumentieren, dass die Komplexität von *BN-IPFP-1* maßgeblich durch die Größe des Bayes'schen Netzwerks und der damit verbundenen Ausführdauer des Inferenzprozesses bestimmt wird, welcher zur Ermittlung der Posteriori-Verteilungen je Iterationsschritt durchgeführt wird. Die Komplexität von *BN-IPFP-2* wird bestimmt durch die Dimensionalität der zu ermittelnden bedingten Übergangswahrscheinlichkeiten und damit durch die Anzahl der betroffenen Variablen, für die während einer Beobachtung eine weiche Evidenz vorliegt.

Für diese Arbeit wird davon ausgegangen, dass die Art der Evidenz für alle Eingangsvariablen potentiell weich ist und dass von einer Beobachtung ein Großteil der Eingangsvariablen betroffen sein wird. Relevant ist hiernach *BN-IPFP-1*, eine detaillierte Beschreibung findet sich in [Mrad u. a. 2015].

2.3.3 Maschinelle Lernverfahren

Mithilfe eines Bayes'schen Netzwerks lässt sich eine hochdimensionale Verteilung unter Kenntnis der statistischen Abhängigkeiten in niedrigdimensionale Verteilungen überführen. Das heißt, eine hochdimensionale Zufallsvariable wird in mehrere niedrigdimensionale Zufallsvariablen zerlegt. Diese Zufallsvariablen bilden die Knoten in einer azyklisch gerichteten Graphenstruktur. Für

jeden Knoten existiert eine lokale Wahrscheinlichkeitsverteilung z. B. in Form einer bedingten Wahrscheinlichkeitstabelle, welche die Übergangswahrscheinlichkeit des Knotenzustandes in Abhängigkeit der Elternknoten angibt.

Das notwendige Wissen zur Erstellung der Graphenstruktur nebst der bedingten Wahrscheinlichkeiten kann entweder explizit vorliegen, so dass es z. B. über einen Experten in ein Bayes'sches Netzwerk überführt werden kann, oder implizit in Form von Daten, welche das notwendige Wissen z. B. in Form von gelabelten Messdaten aus einer Fahrumgebungserfassung enthalten. Im letztgenannten Fall muss dieses Wissen über maschinelle Lernfähigkeiten extrahiert werden. Während für das Lernen der Übergangswahrscheinlichkeiten bei gegebener Netzstruktur etablierte Methoden existieren, z. B. via Expectation-Maximization (EM) Algorithmus, vgl. [Dempster u. a. 1977], gestaltet sich das Erstellen einer geeigneten Graphenstruktur deutlich komplexer und erfolgt daher häufig manuell durch einen Experten.

Maschinelle Strukturlernmethoden ermitteln Graphenstrukturen durch die Variation einer initialen Netzstruktur auf Basis gegebener Ground-Truth Daten. Es lassen sich zwei verschiedene Ansätze unterscheiden. Bei den *Score Based*-Methoden wird eine Punktezahl maximiert. Bei den *Constrained Based*-Methoden wird hingegen die bestmögliche Einhaltung vorgegebener Bedingungen angestrebt, z. B. statistische Unabhängigkeit. Eine Übersicht ist in [Margaritis 2003] gegeben.

Übliche maschinelle Strukturlernmethoden gehen von einem vollständig definierten Set an Netzknoten aus. Dies schränkt die Anwendbarkeit der Methoden insbesondere dann ein, wenn unbekannte Knoten existieren und / oder gegebene Netzknoten eine starke statistische Abhängigkeit aufweisen, die nur über Zwischenknoten aufzulösen sind. Ein Verfahren, welches diese Einschränkungen umgeht, ist das auf einem *Hierarchical Naive Bayes* (HNB) Modell basierende Verfahren von [Zhang u. a. 2004].

Eine große Herausforderung der maschinellen Strukturbestimmung für Dynamische Bayes'sche Netzwerke ist die Explosion des Konfigurationsraumes mit einer zunehmenden Anzahl an Zeitscheiben. Eine Möglichkeit diesen zumindest z. T. zu beherrschen stellt die Anwendung Genetischer Algorithmen dar, vgl. [Tucker u. a. 2001; Ross u. Zuviria 2007; Dai u. Ren 2015]. Alle genannten Autoren schränken zudem den Suchraum ein, z. B. durch eine lokale Stabilität des Netzwerkes, d. h. keine Änderung innerhalb einer Zeitscheibe oder durch eine Beschränkung der Konnektivität und oder der Anzahl der betrachteten Zeitscheiben.

Nachfolgend erfolgt eine kurze Einführung in *Score Base* und *Constrained Based* Strukturlernverfahren sowie in das HNB-Modell, vgl. [Ghassemi 2015],

und in die Struktursuche mithilfe eines Genetischen Algorithmus. Im Anschluss erfolgt eine kurze Einführung in den EM-Algorithmus.

2.3.3.1 Score Based Lernverfahren

Score Based Learning bezeichnet Punktezahl-basierte Lernverfahren, welche aus einer Suchprozedur zum gezielten Durchschreiten des Konfigurationsraumes und einer Bewertungsmetrik zur Bewertung der jeweiligen Netzkonfiguration bestehen.

Eine gebräuchliche Bewertungsmetrik ist der *log-likelihood*-Wert. Ein solcher zeigt, wie gut ein (Ground-Truth) Datensatz durch eine Netzstruktur und zugehörige bedingte Wahrscheinlichkeitsverteilungen repräsentiert wird. $\log P(D|G, \theta_G)$ stellt die *log-likelihood*-Funktion eines Bayes'schen Netzwerks, bestehend aus der Struktur G und dem Parametersatz Θ_G gegeben dem Datensatz D , als die Wahrscheinlichkeit des Datensatzes D bei gegebenen Bayes'schen Netzwerk dar. Die *log-likelihood*-Funktion ist gegeben in Gleichung 2.21, mit M_{ijk} als Bezeichner für die Anzahl der Ereignisse $X_i = x_{ir}$, $\text{Eltern}(X_i) = j$, i der Nummer der Variablen im Netz, j der Kombination des Elternsatzes und r als der Ausprägung der Variable X_i .

$$\log P(D|G, \Theta_G) = \sum_{ijr} M_{ijr} \log \theta_{ijr} \quad (2.21)$$

$$\text{BICscore}(G, D) = \log P(D|G, \Theta_G) - \frac{d}{2} \log N \quad (2.22)$$

$$\text{mit } d = \sum_{i=1}^n (R_i - 1) Q_i \quad (2.23)$$

Der in Gleichung 2.22 definierte *BICscore* kombiniert die *log-likelihood*-Funktion mit einem Strafterm zur Verminderung von Überanpassung aufgrund zu komplexer Netzstrukturen, vgl. [Schwarz 1978; Carvalho 2009]. Dabei bezeichnet N die Anzahl an Tupel im Datensatz D , n die Anzahl an Netzvariablen, R_i die Anzahl an Zuständen der Variablen i und Q_i die Anzahl an möglichen Zustandskombinationen der Elternvariablen.

Über eine Suchprozedur erfolgt die Ermittlung der Netzstruktur innerhalb des Konfigurationsraumes, welche die höchste Bewertung in Bezug auf die Score-Metrik hat. Ein bekanntes heuristisches Suchverfahren ist das *Hill-Climbing*-Verfahren, beispielhaft dargestellt in Abbildung 2.15. Ausgangspunkt der Suche kann ein leeres Netz, d. h. ein Netz ohne Kanten, ein Netz mit zufälligen Kanten oder ein auf Basis von Vorinformation mit Kanten

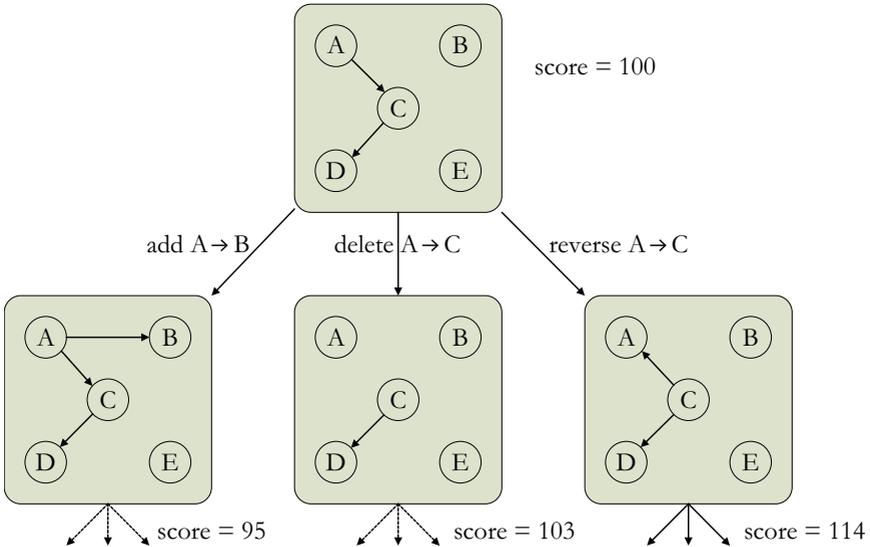


Abbildung 2.15: Darstellung eines *Hill-Climbing*-Verfahrens zur Strukturbestimmung eines Bayes'schen Netzes, angelehnt an [Margaritis 2003]

gefülltes Netz sein. In jedem Suchschritt werden sukzessiv die Kanten des Netzes geändert und ein *Score*-Wert, beispielsweise nach Gleichung 2.22 bestimmt. Hierbei können nicht existente Kanten eingefügt, existierende gelöscht oder in ihrer Kausalitätsrichtung geändert werden, soweit keine gerichteten Zyklen entstehen. Wie beispielhaft in Abbildung 2.15 dargestellt, erfolgt im nächsten Suchschritt die Änderung der Netzstruktur auf Basis der Netzkonfiguration, welche den höchsten *Score*-Wert erzielt hat. Die Suche ist beendet, sofern durch Änderung der bestehenden Konfiguration keine weitere Netzkonfiguration erzeugbar ist, welche eine bessere Bewertung aufweist.

2.3.3.2 Constraint-Based Lernverfahren

Constraint-Based Learning bezeichnet Lernverfahren, welche durch Manipulation der Netzkonfiguration versuchen eine Struktur zu bestimmen, welche vorgegebenen Bedingungen bzw. Beschränkungen (constraints) bestmöglich genügt. Eine den Bayes'schen Netzwerken zugrunde liegende Beschränkung ist die bedingte Unabhängigkeitsannahme zwischen zwei nicht direkt verbundenen Knoten. Die Verfahren bestehen aus folgenden Schritten:

- Bestimmung der ungerichteten Graphenstruktur
- Bestimmung der Kausalitäten zur Ermittlung der gerichteten Graphenstruktur

Ein Vertreter der *Constraint-Based* Lernverfahren ist der in [Spirtes u. a. 1993] vorgestellte *SGS algorithm*: Im ersten Schritt des Verfahrens wird über alle Variablen ein komplett verbundener ungerichteter Graph erstellt. Paarweise werden Variablen-Sets gebildet und jeweils über den χ^2 -Test auf bedingte Unabhängigkeit getestet. Falls der Unabhängigkeitstest zwischen zwei Variablen fehlschlägt, wird die Kante zwischen beiden Knoten beibehalten, andernfalls gelöscht. Falls keine Kante existiert, muss ein Subset existieren, welches beide Variablen d-separiert, vgl. Unterabschnitt 2.3.1. Zu Beginn des zweiten Schrittes werden Variablen-Tripel X, Y, Z gesucht, so dass eine Kante zwischen X, Z und eine Kante zwischen Y, Z aber keine Kante zwischen X, Y existiert. Wenn kein Subset existiert, welches Z enthält und X, Y d-separiert, wird jeweils eine gerichtete Kante von X zu Z und Y zu Z gesetzt. Das Verfahren prüft iterativ, ob eine gerichtete Kante von X zu Y , eine ungerichtete Kante Y, Z , keine ungerichtete Kante X, Z besteht. Existiert weiterhin keine weitere Variable W mit einer gerichteten Kante W nach Y , so wird die ungerichtete Kante Y, Z durch eine gerichtete Kante von Y nach Z ersetzt. Weiterhin wird geprüft, ob es einen, gegebenenfalls über mehrere Variablen verlaufenden, gerichteten Pfad von X nach Y und eine ungerichtete Kante zwischen beiden Variablen gibt. Im positiven Fall wird die ungerichtete durch eine gerichtete Kante ersetzt. Das Verfahren ist beendet, wenn keine der oben genannten Regeln mehr anwendbar sind. Hierbei ist nicht sichergestellt, dass jeder verbliebenen ungerichteten Kante eine Kausalitätsrichtung zugewiesen wurde. Gewöhnlich werden diese Kanten in einem nachgelagert Schritt so orientiert, dass ein azyklischer gerichteter Graph entsteht.

2.3.3.3 HNB-Model

HNB-Model ist ein *score-based* Strukturlernverfahren nach [Zhang u. a. 2004]. Ausgehend von einem initialen naiven Bayes'schen Netzwerk wird dessen Struktur über die Anwendung von Operatoren so manipuliert, dass der *BIC-Score*, vgl. Gleichung 2.22, der zu bestimmenden Netzstruktur maximal ist. Diese Operatoren erlauben das Einfügen von Latentvariablen, wodurch gegebenenfalls ein Hierarchisches Naive Bayes'sches Netzwerk (HNB) entsteht. Als latent werden Variablen bezeichnet, für welche im Lerndatensatz keine direkte Beobachtung vorliegt. Auf Basis von Lerndaten wird

ein *Hill-Climbing*-Algorithmus ausgeführt, welcher sich iterativ der finalen Struktur nähert:

1. Nutze eine gegebene Netzkonfiguration als Startpunkt, d. h. *Seed* für die Suche, und errechne deren Wertung mithilfe des *BIC-Score*.
2. Unter Anwendung der Operatoren *Parent Introduction* und *Parent Alliteration*: Berechne alle möglichen Netzkonfigurationen, welche mit genau einer Veränderung des *Seed* erreichbar sind.
3. Bestimme den *BIC-Score* für alle in Schritt 2 gefundenen Netzkonfigurationen und wähle die Konfiguration mit der höchsten Bewertung aus.
4. Ist die Bewertung der gefundenen Netzkonfiguration höher als der *BIC-Score* des *Seed*, wird diese zum neuen *Seed* bestimmt und mit Schritt 2 fortgefahren. Andernfalls weist keine neue Konfiguration eine bessere Bewertung als die Konfiguration des *Seed* auf, womit letztgenannte Konfiguration als finale Struktur bestimmt und das Verfahren beendet ist.

[Zhang u. a. 2004] weisen nach, dass die Menge der möglichen HNB-Modelle bei einer gegebenen Menge an Klassen- und Merkmalsvariablen endlich ist, wenn die HNB sparsam und regulär sind:

- Sei $M = (m, \theta)$ ein HNB mit der Struktur m und den Parametern θ sowie der Klassenvariable C und den Merkmalsvariablen A . M gilt als *sparsam* falls kein anderes HNB $M' = (m', \theta')$ mit C und A existiert, welches weniger Parameter als M aufweist, sofern die Wahrscheinlichkeitsverteilungen über Klassen- und Merkmalsvariablen identisch sind.
- Ein HNB ist *regulär*, falls für jede beliebig Latente Variable Z mit den als Kind- oder Elternknoten auftretenden Nachbarvariablen $X_1 \dots X_n$ gilt:

$$|Z| \leq \frac{\prod_{i=1}^n |X_i|}{\max_{i=1}^n |X_i|} \quad (2.24)$$

$|Z|$ bzw. $|X_i|$ bezeichnet die Kardinalität von Z bzw. X .

Jede Anwendung der Operatoren in Schritt 2 der Iteration zieht die Bestimmung der Kardinalität der betreffenden Latente Variable nach sich. Entsprechend definiert jede mögliche Kardinalität der Latente Variable eine neue Netzkonfiguration. Die maximale Kardinalität bestimmt sich aus Gleichung 2.24, die minimale Kardinalität beträgt zwei, bzw. drei sofern eine Latente Variable nur zwei Kindvariablen hat, welche ebenfalls Latente Variablen sind.

Für die Bewertung der jeweiligen Netzkonfigurationen in Schritt 3 müssen die Netzparameter, d. h. die bedingten Wahrscheinlichkeitstabellen, angeleitet werden. Diese werden mithilfe des EM-Algorithmus, vgl. Unterabschnitt 2.3.3.5, auf Basis eines Lerndatensatzes bestimmt.

2.3.3.3.1 Parent Introduction Operator Mithilfe des *Parent Introduction* Operators werden Latentvariablen eingefügt, wenn ein Knoten des Netzes mindestens drei Kindknoten hat.

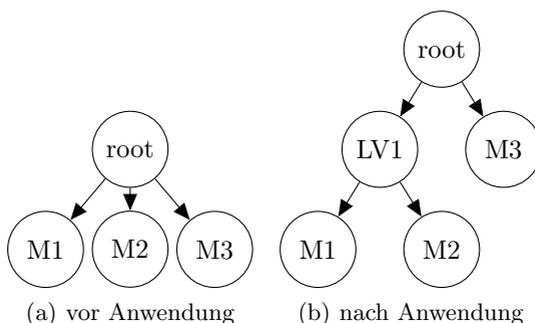


Abbildung 2.16: Anwendung des *Parent Introduction* Operators

Abbildung 2.16 zeigt beispielhaft die Anwendung des Operators in dem die direkte Abhängigkeit der Variablen $M1$, $M2$ von der Variable $root$ durch das Einfügen einer Latentvariable $LV1$ als Kind von $root$ und Elternvariable von $M1$, $M2$ aufgelöst wird. Die Variablen $M1$, $M2$, $M3$, $root$ können sich weiter gegenseitig beeinflussen, solange keine Evidenz für $LV1$ beobachtet wird. Weitere mögliche Konfigurationen wären das Einfügen der Latentvariable $LV1$ als Elternvariable für $M1$, $M3$ oder $M2$, $M3$.

2.3.3.3.2 Parent Alliteration Operator Mithilfe des im vorhergehenden Abschnitt erläuterten *Parent Introduction* Operators werden immer genau zwei Variablen separiert. Erst über die Anwendung des *Parent Alliteration* Operators lässt sich im nächsten Iterationsschritt ein weitere Variable hinzufügen. *Parent Alliteration* ist möglich, wenn eine Latentvariable mehr als eine Geschwistervariable hat. Abbildung 2.17 zeigt beispielhaft die Manipulation einer Netzstruktur über den Operator in der die Variable $M3$ zum Kindknoten der Latentvariable $LV1$ mutiert. Alternativ hätte über den Operator auch $M4$ zum Kindknoten von $LV1$ mutieren können.

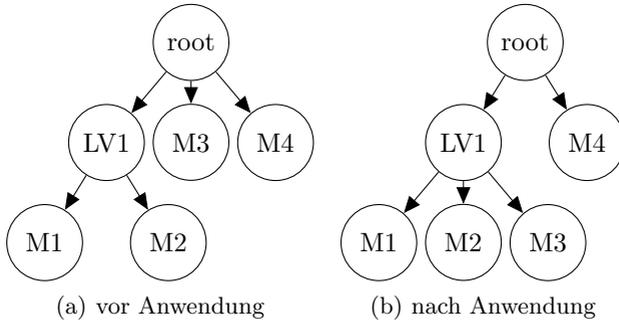


Abbildung 2.17: Anwendung des *Parent Alliteration Operator*s

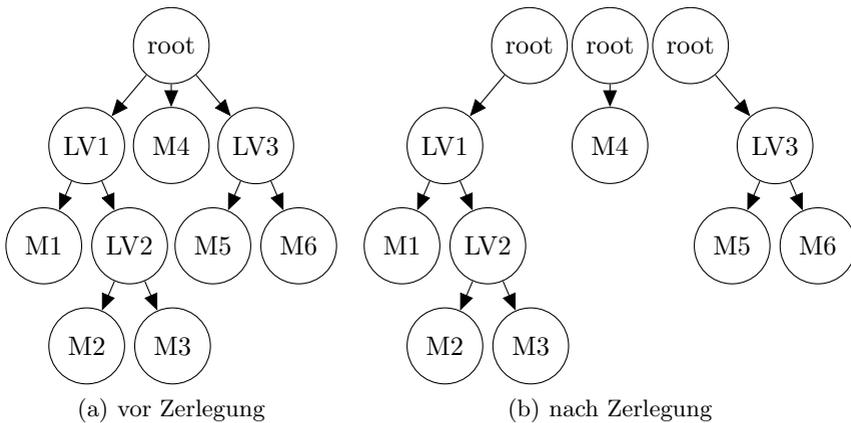


Abbildung 2.18: Zerlegung eines Bayes'schen Netzwerks nach [Zhang u. a. 2004]

2.3.3.3.3 Subnetze [Zhang u. a. 2004] zeigen, dass sich ein Bayes'sches Netzwerk unterhalb seiner Klassenvariable in Subnetze zerlegen lässt, vgl. Abbildung 2.18, und die Summation des *BIC-Scores* der Teilnetze den *BIC-Score* des Gesamtnetzes ergibt. Wird zu Beginn des Bewertungsverfahrens jedes Netz in seine Subnetze zerlegt und separat bewertet, steigert sich die Effizienz des Verfahrens, da pro Netzkonfiguration nur jeweils ein Subnetz manipuliert wird und die zwischengespeicherten *BIC-Scores* der unveränderten Subnetze wieder verwendet werden können.

2.3.3.4 Struktursuche per Genetischem Algorithmus

Ein Genetischer Algorithmus ist ein stochastisches Optimierungsverfahren, welches in stark vereinfachter Form den evolutionsbiologischen Entwicklungsprozess nachahmt. Nachfolgend wird die Anwendung zur Strukturbestimmung eines Dynamischen Bayes'schen Netzwerks angelehnt an [Dai u. Ren 2015] beschrieben.

Wie in Unterabschnitt 2.3.1.3 beschrieben, definiert sich ein Dynamisches Bayes'sches Netzwerk über die Parameter eines initialen und eines temporalen Netzwerkes. Jede Variation dieser Netzwerke bildet ein Individuum aus dem möglichen Konfigurationsraum. Dessen Netzwerkstruktur wird im Folgenden als Genotyp bezeichnet. Jedes Individuum ist Teil einer Population, welche in jedem Suchschritt von einer Generation in die nächste überführt wird. Die Überführung der Individuen erfolgt durch Operatoren wie *Mutation*, *Kreuzung* und *Selektion*. Die Zielfunktion eines genetischen Algorithmus wird Fitnessfunktion genannt und wird maximiert bzw. minimiert, bis ein Terminierungskriterium erreicht ist. Über diese wird bestimmt, wie gut ein Individuum das zugrunde liegende Optimierungsproblem löst. [Dai u. Ren 2015] nutzen den BIC-Score als Fitnessfunktion, s. Gleichung 2.22. Zur Initialisierung der ersten Population bestimmen die Autoren die Transinformation, s. Abschnitt A.1 zwischen den Zufallsvariablen und ermitteln hierüber für jede Variable ein Kante zu der Variable, zu der die höchste Abhängigkeit besteht. Aus den gefundenen Kanten werden anschließend Individuen, d. h. Netzstrukturen, gebildet. Nachfolgend ist die von den Autoren vorgeschlagene Abbildung der Struktur eines Dynamischen Bayes'schen Netzwerks auf einen Genotyp und eine Erläuterung der Operatoren gegeben.

Abbildung der Struktur als Genotyp [Dai u. Ren 2015] bilden die Struktur eines Dynamischen Bayes'schen Netzwerks ersten Grades durch folgendes aus drei Teilen bestehendes Schema ab:

$$\begin{aligned}
 & (i_1, i_2, \dots, a_{11}, a_{12}, a_{22}, \dots, a_{2n}, a_{n1}, \dots, a_{nn}, \\
 & e_{12}, e_{13}, e_{23}, e_{14}, e_{24}, e_{34}, \dots, e_{1n}, e_{2n}, \dots, e_{(n-1)n})
 \end{aligned} \tag{2.25}$$

n bezeichnet die Anzahl an Variablen innerhalb eines Zeitslots, i_k die nach der Kausalitätsfolge $1 \dots k$ geordneten Variablen des Zeitslots $X_k[t]$, a_{jk} die Abhängigkeit zwischen zwei Zeitscheiben, d. h. der Existenz $a_{jk} = 1$ oder Nichtexistenz $a_{jk} = 0$ einer gerichteten Kante von $X_j[t-1]$ nach $X_k[t]$, und e_{jk} die Abhängigkeit innerhalb eines Zeitslots, d. h. der Existenz einer gerichteten Kante von X_j zu X_k . Die Anwendung dieser Codierung auf ein Minimalbeispiel ist in Abbildung 2.19 dargestellt.

Operator Mutation Die Mutation überführt ein Individuum aus einer Elterngeneration in eine neue Generation, indem Teile des Genotyps zufälligen Änderungen unterliegen, vgl. Abbildung 2.20(a).

Operator Kreuzung Der Kreuzungsoperator erzeugt ein Individuum einer neuen Generation durch Vereinen von verschiedenen Genotypen der Elterngeneration, vgl. Abbildung 2.20(b).

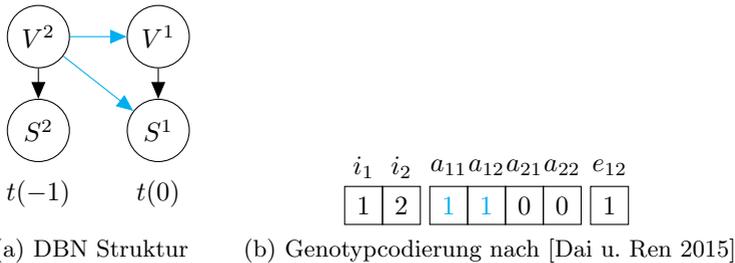


Abbildung 2.19: Minimalbeispiel zur Codierung eines DBN

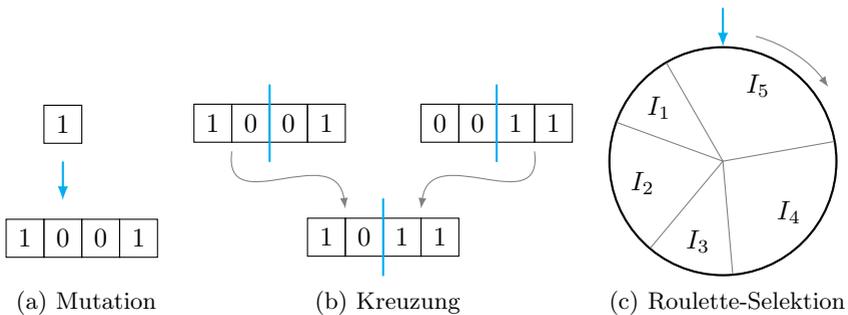


Abbildung 2.20: Beispielhafte Anwendung der Operatoren des Genetischen Algorithmus

Operator Selektion Während der Kreuzungs- und Mutationsoperator ein Individuum d. h. eine Konfiguration eines Dynamischen Bayes'schen Netzwerks durch Variation direkt in die Folgegeneration überführt, wählt der Selektionsoperator Individuen nach bestimmten Kriterien aus, welche in die nächste Generation ohne Variation überführt werden. Kriterien können z. B.

die *Elitismus* genannte Auswahl der nach Fitnessfunktion besten Elemente oder zufällig ausgewählte Elemente via *Roulette Selektion* sein. In Abbildung 2.20(c) ist das Funktionsprinzip des Rouletteselektors für fünf Individuen I grafisch dargestellt. Die Auswahl erfolgt durch virtuelles Drehen des Rades. Die jeweilige Kreisbogenlänge entspricht dem relativen Fitnesswert eines Individuums gegenüber den anderen Individuen.

2.3.3.5 Expectation-Maximization Algorithmus

Der Expectation-Maximization Algorithmus ist ein Verfahren zur Parameterschätzung in probabilistischen Modellen bei unvollständigen Lerndaten. Im Falle eines Bayes'schen Netzwerks gelten die bedingten Wahrscheinlichkeitstabellen (CPTs), in denen die Übergangswahrscheinlichkeiten zwischen den Variablen des Netzes abgebildet sind, als Parameter. Unvollständige Lerndaten zeichnen sich unter anderem durch fehlende Beobachtungen von Latentvariablen aus. Als Standardreferenz zum EM-Algorithmus und seinem Konvergenzverhalten gilt die Veröffentlichung von [Dempster u. a. 1977]. Eine kurze Beschreibung des Algorithmus ist nachfolgend gegeben.

Seien X und Z zwei statistisch abhängige Zufallsvariablen und Θ ein Parametersatz, d. h. die CPTs der Variablen, welcher die statistische Abhängigkeit beschreibt. Während die möglichen Realisationen von X und Z bekannt sind, existieren ausschließlich Beobachtungen von X innerhalb eines unvollständigen Datensatzes D' . Die Variable Z ist latent. Die Schätzung von $\hat{\Theta}$ bei latenten Variablen erfolgt iterativ, vgl. [Sucar 2015]:

- 1.) Bestimme mithilfe der Maximum-Likelihood Methode aus Θ alle CPTs für Variablen, deren Messwerte vollständig in D' vorliegen. Das heißt, die Werte der Variablen und all ihrer Eltern sind in der Datenbank enthalten.
- 2.) Initialisiere $\hat{\Theta}^{t=0}$ mit den Werten aus Schritt 1 sowie mit zufälligen Werten für alle unbekanntes CPTs.
- 3.) **Expectation-Schritt:** Schätze die unbekanntes Realisationen der Latentvariablen durch probabilistische Inferenz basierend auf den bekannten Realisationen der Variablen aus D' und vervollständige den Datensatz zu D^t , vgl. Gleichung 2.26 bis 2.29.
- 4.) **Maximization-Schritt:** Schätze $\hat{\Theta}^{t+1}$ basierend auf dem vervollständigten Datensatz D^t , vgl. Gleichung 2.30.

5.) Wiederhole die Schritte 3 und 4 bis sich Konvergenz einstellt.

$$D = (d_{ij})_{Nn}, \text{ mit } N \text{ der Anzahl an Tupel und } n \text{ der} \quad (2.26)$$

Anzahl an Variablen im Datensatz D

$$V = (v_{ij})_{Nn}, \text{ mit } v_{ij} = \begin{cases} 1 & : \text{ falls } d_{ij} \in D, \\ 0 & : \text{ falls } d_{ij} \notin D \end{cases} \quad (2.27)$$

$$D^t = (d_{ij}^t)_{Nn}, \text{ mit } d_{ij}^t = \begin{cases} E(d_{ij}^t | D', \hat{\Theta}^t) & : \text{ falls } v_{ij} = 0, \\ d_{ij}^0 & : \text{ falls } v_{ij} = 1 \end{cases} \quad (2.28)$$

$$E(d_{ij}^t | D', \hat{\Theta}^t) = \operatorname{argmax}_{R_i} P(r_{ij} | X_i), \text{ mit } R_i \text{ der Anzahl mög-} \quad (2.29)$$

licher Realisationen von Z_i und r_{ij} der Realisation von Z_i

$$\hat{\Theta}^{t+1} = \operatorname{argmax}_{\Theta} \sum_Z P(Z | X, \hat{\Theta}^t) \log P(X, Z, \Theta) \quad (2.30)$$

Es ist nicht sichergestellt, dass der Algorithmus zu einem globalen Maximum von $\log P(X, Z; \Theta)$ konvergiert. Ein mehrmaliges Ausführen unter geänderten Startparametern $\hat{\Theta}^0$ ist daher sinnvoll, um die Gefahr lokaler Maxima zu reduzieren.

2.4 Diskussion

Die vorgestellten Verfahren werden nachfolgend auf ihre voraussichtliche Anwendbarkeit für eine Fahrstreifenwechselvorhersage betrachtet:

Konventionelle bzw. extensionale Systeme, wie etwa Zustandsautomaten sind sehr gut geeignet zur Abbildung von Kausalitäten, z. B. $A \xrightarrow{m} B$: Wenn A gegeben, dann aktualisiere B über Regel m . Andererseits müssen hierfür Kenntnisse über die Modellstruktur gegeben sein, z. B. basierend auf dem Systemwissen eines Experten. Weiterhin ist keine direkte Verarbeitung von unsicherem Wissen bzgl. der Eingangsdaten als auch der Modellparameter vorgesehen. Zusätzlich ergeben sich semantische Schwierigkeiten bei einer gleichzeitigen Behandlung prädiktiver und diagnostischer Information. Hierfür sind oft Regeln mit vielen Ausnahmen notwendig, welche wiederum die Modularität der zugrunde liegenden Systeme einschränken und deren Anwendung unpraktikabel werden lassen. Konventionelle Verfahren sind daher nur bedingt anwendbar, da sich mit ihnen auf Basis einer mit Unsicherheit behafteten Datengrundlage, wie sie aus dem Kalman-Filter-Schätzprozessen der TAP-Umfeldwahrnehmung zu erwarten ist, kaum ein praktikables Vorhersagemodell erstellen lassen wird.



(a) Messunsicherheit
11.01.2011, www.miamiherald.com



(b) Vagheit (10.10.2009
comocyclo.blogspot.jp)

Abbildung 2.21: Beispiele für Messunsicherheit und Vagheit: 2.21(a): unscharfes Wissen durch unsichere Messungen, es könnte ein Fahrrad sein, oder aber mit geringerer Wahrscheinlichkeit Bestandteil eines im Hintergrund fahrenden PKWs; (2.21(b): unscharfes Wissen durch unscharfe Mengen, d. h. vagen Begrifflichkeiten: das dargestellte Fahrzeug gehört nur mit einem gewissen Prozentsatz zur Kategorie Fahrrad.

In der Fahrumgebungserfassung, vgl. Abschnitt 2.1, ist unsicheres Wissen typisch. Probabilistische Methoden und Fuzzy Methoden bieten unterschiedliche Ansätze, um diese Eigenschaft explizit abzubilden.

Unschärfe und stochastische Unsicherheit sind hierbei grundverschiedene Ausprägungen von Unsicherheit. Während die stochastische Unsicherheit das Eintreten bestimmter Ereignisse durch Wahrscheinlichkeiten quantifiziert, entzieht sich Unschärfe dieser Form der Modellierung. Unschärfe beschreibt die mangelnde Präzision und undefiniertheit in der Beschreibung von Ereignissen oder Elementen. Abbildung 2.21 gibt ein Beispiel für diese Unterscheidung. Im Hinblick auf die intensionalen Verfahren werden Fuzzy-Logik-Systeme nicht favorisiert, da das Ereignis Fahrstreifenwechsel recht gut beschreib- und abgrenzbar scheint, vgl. Abschnitt 3.1, und somit das Konzept der Modellierung von unscharfen Mengen keine Anwendung findet.

Mithilfe probabilistischer Methoden können Zusammenhänge beispielsweise als Verbundverteilung, abgebildet über ein probabilistisches Netzwerk, modelliert werden: $P(B|A) = p$: Für eine Realisation von A , z. B. A ist wahr, können wir B eine Wahrscheinlichkeit p zuordnen. Vorausgesetzt werden muss hier, dass keine anderen Abhängigkeiten, z. B. zu einem zusätzlichen Wissen z : $P(B|A,Z)$, bestehen oder dies vernachlässigt werden kann.

Die Modellierung von Systemen basierend auf der Dempster-Shafer Theorie erlaubt zwar die Abbildung von Unsicherheiten und explizitem bzw. partiellem Unwissen, dem Autor ist allerdings kein Konzept zur Modellierung von Kausalitäten bekannt. Schließlich kommt auch das mit den Bayes'schen Netzwerk eng verwandten Markov-Netzwerk nicht zur Anwendung, da hierüber nur lokale Nachbarschaftsbeziehungen abgebildet werden können und keine direkte Kausalität.

Eine weitere Methode stellen die Künstlichen Neuronale Netze (KNN) dar. Wissen wird hier durch maschinelle Lernverfahren aus Beispielen zumeist in einer hoch parallelen und mehrschichtigen Netzwerkstruktur abgebildet. Eine manuelle expertengestützte Modellierung ist nicht praktikabel. Das Verfahren erlaubt die Verarbeitung von unsicherem und unvollständigem Wissen und eignet sich grundsätzlich für eine Fahrstreifenwechselvorhersage. Eine hohe Netzkomplexität gestaltet jedoch die Nachvollziehbarkeit der Entscheidungsfindung für den menschlichen Betrachter schwierig.

Letztlich verspricht die Verwendung eines Bayes'schen Netzwerks eine durchgehend probabilistische Datenverarbeitung ausgehend vom Kalman-Filter basierten Wahrnehmungsprozess bis zur Modellierung der Fahrstreifenwechselvorhersage. Die Möglichkeit einer manuellen expertengestützten Modellierung kausaler Zusammenhänge in Form eines gerichteten Graphen, als auch die direkte Interpretierbarkeit zuvor unbekannter Kausalitäten aus einer maschinell bestimmten Netzstruktur sprechen für die Flexibilität der Methode. Aus diesen Gründen wird für die vorliegende Arbeit eine Wissensmodellierung mit einem Bayes'schen Netzwerk favorisiert.

3 Stand der Technik

Der Stand der Technik zur Erkennung und Vorhersage von Fahrstreifenwechseln soll in Kapitel 3 als Ergebnis einer Literaturrecherche dargestellt werden. Grundsätzlich sollen folgende Fragestellungen betrachtet werden:

- Was kennzeichnet ein Fahrstreifenwechselmanöver?
- Welche Lösungen zur Vorhersage existieren bereits und
- über welche Parameter lässt sich ein Fahrstreifenwechsel vorhersagen?

Das Kapitel widmet sich der Analyse des Fahrstreifenwechsels und stellt bekannte Lösungen zu dessen Vorhersage vor. Dem vorausgehend erfolgt eine Einordnung in die Fahraufgabe, eine Kategorisierung, eine Unterteilung in Manöverabschnitte und die Identifikation wesentlicher Einflussgrößen. Bekannte Verfahren zur Vorhersage lassen die Kategorisierung in eine makroskopische und eine mikroskopische Sichtweise zu. Während die makroskopische Sichtweise zurzeit im Bereich der Verkehrssimulation angesiedelt ist, und bei der Verhaltensentscheidung eines Fahrzeuges auch das Verhalten der angrenzenden Fahrzeuge innerhalb eines Ausschnittes berücksichtigt, bezieht sich die mikroskopische Sichtweise meist nur auf ein Fahrzeug und dessen unmittelbare Verkehrsumgebung. Im letztgenannten Fall kann weiterhin in die Manövervorhersage für das eigene Fahrzeug sowie in die Manövervorhersage von sensorisch wahrgenommenen Fremdfahrzeugen unterschieden werden. Aus der Literatur bekannte Verfahren werden vorgestellt. Das Kapitel schließt mit einer Diskussion der vorgestellten Ansätze sowie einer Übersicht an Einflussfaktoren auf einen Fahrstreifenwechsel.

3.1 Das Fahrstreifenwechselmanöver

Ein Fahrstreifenwechsel lässt sich beschreiben als ein Manöver eines Fahrzeuges auf einer Straße mit mindestens zwei Fahrstreifen (FS), in dessen Verlauf von einem Ausgangs- auf einen Zielfahrstreifen gewechselt wird. Dieser Wechsel kann prinzipiell sowohl nach links als auch nach rechts erfolgen, vgl. Abbildung 3.1. In diesem Abschnitt sollen, nach einer Einordnung des Fahrstreifenwechsels in die Fahraufgabe, wesentliche Zusammenhänge und Einflussgrößen basierend auf einer Literaturrecherche im Bereich der

Unfallursachen-, Fahrverhaltens- und Fahrerassistenzforschung herausgearbeitet werden. Ein Schwerpunkt bildet hierbei die Beschreibung des Vorganges an sich, d. h. die Umstände und letztendlich die Art und Weise wie ein Fahrstreifenwechsel ausgeführt wird.

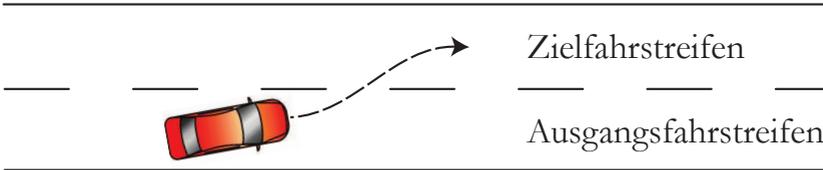


Abbildung 3.1: Fahrstreifenwechsel von rechts nach links

Abschließend soll erwähnt werden, dass der in dieser Arbeit verwendete Begriff Fahrstreifenwechsel gleichbedeutend mit dem im allgemeinen Sprachgebrauch etablierten, aber technisch in dieser Hinsicht nicht korrekten Begriff Spurwechsel¹ ist. Abbildung 3.2 illustriert diesen Umstand im übertragenen Sinn.



(a) Spurwechsel [MDR 2014]



(b) Fahrstreifenwechsel [Meyer 2015]

Abbildung 3.2: Spurwechsel 3.2(a) eines Eisenbahnwaggon vom westeuropäischen auf das russische Schienennetz an der polnisch-weißrussischen Grenze in Brest gegenüber dem Fahrstreifenwechsel eines PKWs 3.2(b)

3.1.1 Einordnung in die Fahraufgabe

Die Durchführung eines Fahrstreifenwechselmanövers ist Bestandteil der Fahraufgabe durch den Fahrer, der in einem Mensch-Maschine-System mit

¹ Der Begriff Spur beschreibt in der Kraftfahrzeug-Technik den Winkel eines Rades zur Längsachse des Fahrzeuges.

dem Fahrzeug und dem Verkehrsumfeld interagiert. Ein Modell zur Beschreibung menschlichen Verhaltens in Mensch-Maschine Systemen liefert [Rasmussen 1983]. Er unterteilt die menschliche Verhaltensweise und Handlung in drei Ebenen:

- Das *wissensbasierte Verhalten* repräsentiert die bewusst gesteuerte Verhaltensweise.
- Das *regelbasierte Verhalten* repräsentiert die Anwendung gelernter Regeln.
- Das *fähigkeitsbasierte Verhalten* repräsentiert die hochgeübte automatisierte Verhaltensweise.

Das Drei-Ebenen Modell der Fahrzeugführung (vgl. [Bernotat 1970; Michon 1985; Erke 1993]) fokussiert das Modell von [Rasmussen 1983] auf die Fahraufgabe und teilt diese ein in:

- die *Navigationsebene*, d. h. Festlegung der Route unter Berücksichtigung von Randbedingungen wie Verkehrsaufkommen, Gefahren, Fahrtdauer und Uhrzeit;
- die *Führungsebene*, d. h. die Umsetzung der gewünschten Fahrtroute unter Berücksichtigung anderer Verkehrsteilnehmer, z. B. durch Folgen bzw. Halten des Fahrstreifens, Fahrstreifenwechsel, Abbiegen usw.;
- und die *Stabilisierungsebene*, welche die Quer- und Längsführung, d. h. Beschleunigen, Lenken und Schalten betrifft.

Das Manöver Fahrstreifenwechsel ist entsprechend in der Führungsebene der Fahraufgabe einzuordnen und dient der Umsetzung der gewünschten Route, bzw. der Umsetzung von Vorgaben der Navigationsebene durch regelbasiertes Verhalten. Hieraus folgt gemäß [Rasmussen 1983] die Möglichkeit einer Abbildung des Manövers in einem Modell.

3.1.2 Empirische Analysen des Fahrstreifenwechsels

Zur Rekonstruktion von Unfällen wurden bereits in den 60er Jahren Modelle zur geometrischen Beschreibung von Fahrstreifenwechseln aufgestellt: Im Rahmen seiner Dissertation führte [Spindler 1963] empirische Untersuchungen durch, in deren Ergebnis ein Fahrstreifenwechsel am besten mit

einer Wendeklothoide² zu beschreiben ist. Zur näherungsweise Berechnung schlägt er die Methode der schrägen Sinuslinie vor. [Runkel 1969] verwendet in seiner Dissertation ein Kreisbogenverfahren zur Beschreibung des Fahrstreifenwechsels, wobei sich dieser aus zwei zueinander entgegen gesetzten Kreisbögen zusammensetzt.

Tabelle 3.1: Fahrstreifenwechselkategorisierung nach [Sporrer u. a. 1998]

Kategorie	zeitliche oder örtliche Beschränkung	Zeitraumen & Geometrie
Freier Fahrstreifenwechsel	keine	> 6,5 s asymmetrisch
Freier Fahrstreifenwechsel ohne zwingende Beschränkungen	Verkehrsaufkommen auf Ziel-FS gering	4,7 - 6,5 s asymmetrisch
	Verkehrsaufkommen auf Ziel-FS hoch	3,5 - 4,7 s asymmetrisch
Fahrstreifenwechsel zum Einleiten oder Abschließen eines Überholvorgangs	Überholvorgang auf FS des Gegenverkehrs	3,1 - 4,7 s symmetrisch bis asymmetrisch
Notausweichen	plötzlich auftretende Notsituation	2 s symmetrisch

[Sporrer u. a. 1998] beziehen sich auf die oben genannten Arbeiten und führten Untersuchungen von Fahrstreifenwechseln in Stadt-, Landstraßen- und Autobahnsituationen durch. Auf Basis von ca. 100 analysierten Fahrstreifenwechseln bestätigten sie die bereits von [Spindler 1963; Runkel 1969] konstatierte Unabhängigkeit der Fahrstreifenwechseldauer von der gefahrenen Geschwindigkeit v , mit Ausnahme von Notfallmanövern, ebenso wie die Unabhängigkeit der untersuchten Bestimmungsgrößen Gierwinkel φ , Lenkwinkel δ und der Querschleunigung a_{quer} von v . Sie stellten einen asymmetrischen Verlauf der Bestimmungsgrößen bei normal ausgeführten Manövern fest, wobei sie einen Anstieg der Symmetrie bei einer Zunahme der Intensität der gefahrenen Manöver, d. h. insbesondere bei Notfallmanövern beobachteten. Bezüglich der Dauer des Fahrstreifenwechsels beobachteten

² Ein Folge von zwei Klothoiden mit jeweils entgegengesetzter Krümmung, welche an ihrem Nullpunkt aneinandergereiht sind.

sie dessen Abhängigkeit von der Wechselabsicht des Fahrers, d. h. freies Wechseln bzw. Überholen, und der Verkehrsdichte insbesondere auf dem Zielfahstreifen. Auf Basis ihrer Beobachtungen kategorisieren [Sporrer u. a. 1998] Fahrstreifenwechsel wie in Tabelle 3.1 dargestellt.

Um Fahrstreifenwechselsituationen bei der Auslegung eines ACC-Systems für PKWs zu berücksichtigen, untersuchte [Freyer 2008] Trajektorien (zeitabhängige Bewegungspfade) von PKWs in Fahrstreifenwechselmanövern. Diese wurden in Probandenstudien in Form realer Fahrversuche aufgezeichnet. Er stellt fest, dass die Querbeschleunigung weder von der Fahrgeschwindigkeit noch von der Verkehrssituation auf dem Zielfahstreifen abhängt und dass die Dauer des Manövers als konstant angenommen werden kann. In den von ihm durchgeführten Studien betrug die durchschnittliche Manöverdauer 7,4 s. Ebenfalls konnte er einen sinusförmigen Verlauf der lateralen Position in Abhängigkeit von der Zeit feststellen, welcher, wie bereits in [Sporrer u. a. 1998] beschrieben, eine asymmetrische Geometrie aufweist. Entsprechend propagiert [Freyer 2008] Gleichung 3.1 zur Abbildung des zeitabhängigen Kurvenverlaufs, mit den Konstanten $n = 0,0504$ und $z = 6,88$:

$$y(t) = -\frac{1}{2} \cdot \left(\cos \left(\frac{\pi}{\sqrt{n \cdot T_{FSW} + z}} \cdot t \right) - 1 \right); [y] = m, [t] = s \quad (3.1)$$

Weiterführend bestimmt [Freyer 2008] die situationsabhängige Fahrer-motivation zur Durchführung eines Fahrstreifenwechselmanövers, vgl. Unterabschnitt 3.2.1.

Den Fahrstreifenwechsellvorgang von motorisierten Zweirädern untersucht [Rauscher 2007]. Er kommt zu dem Schluss, dass der Fahrstreifenwechsel von einspurigen Fahrzeugen deutlicher von Flieh- und Gewichtskräften geprägt ist und daher nicht ausreichend realitätsgetreu durch die Formeln von [Spindler 1963; Runkel 1969] beschrieben werden kann. [Rauscher 2007] stellt einen geringen Einfluss von Querbeschleunigung und Ablage auf den Fahrstreifenwechsellvorgang fest und bemerkt, dass im Gegensatz zu zweispurigen Fahrzeugen der Zeitverlauf nicht völlig geschwindigkeitsunabhängig ist. Er nennt eine Zeitdauer von 2,8 – 3,4 s von Beginn bis Ende des Vorganges.

Das Fahrstreifenwechselverhalten auf Bundesautobahnen (BAB) mit je zwei Richtungsfahstreifen untersucht [Sparmann 1978], ebenfalls auf Basis empirischer Untersuchungen.

Um die Unsicherheit bei der Bestimmung von Wechselanfang und Ende zu umgehen, definiert er den erstmaligen Schnitt des Fahrzeuggrundrisses mit der zu überfahrenden Fahrstreifenmarkierungslinie als den Beginn des Vorgangs sowie den letztmaligen Schnitt als dessen Ende. Der Beginn und das

Ende des Fahrstreifenwechsels kennzeichnen den Bereich in dem das Fahrzeug beide Fahrstreifen beansprucht. Sparmann unterscheidet die in Abbildung 3.3 aufgeführten Typen des Fahrstreifenwechsels. Unter einer differenzierteren Betrachtung nach PKW, LKW und deren kombinierte Beteiligung am Manöver führt er letztlich insgesamt vierundzwanzig unterschiedliche Typen auf. Für seine Untersuchungen betrachtet er die Geschwindigkeiten der beteiligten Fahrzeuge, ihre Zeitlücken und teilweise auch Abstände der beteiligten Fahrzeuge zueinander.

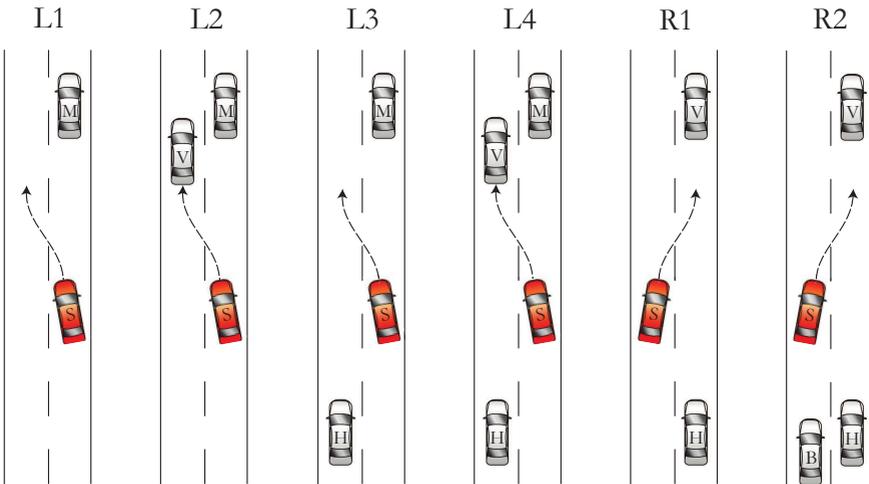


Abbildung 3.3: Typisierung des Fahrstreifenwechsellvorgangs (links L1 - L4 und rechts R1, R2) auf BAB mit zwei Fahrstreifen nach [Sparmann 1978]

Im Ergebnis seiner Untersuchungen stellt Sparmann für die Fahrstreifenwechsellmanöver nach links (vgl. Abbildung 3.3 L1 - L4) eine Abhängigkeit der Zeitlücke („Reaktionsabstand“) von der Geschwindigkeitsdifferenz zum Vorderfahrzeug (M), als auch einen Einfluss der Verkehrsdichte fest. Die Zeitlücke wird mit wachsender Verkehrsstärke von makroskopischen Umfeldbedingungen beeinflusst. Durch das wechselnde Fahrzeug (S) werden Behinderungen des nachfolgenden Verkehrs (H) auf dem Zielfahrstreifen in Kauf genommen. Zu den auf dem Zielfahrstreifen vorausfahrenden Fahrzeugen (V) wird eine sehr kurze Zeitlücke in Kauf genommen, wenn dieses deutlich schneller als das wechselnde Fahrzeug fährt. Die Zeitdauer, die ein Fahrstreifenwechsellvorgang nach links beansprucht, ist signifikant größer als für einen Fahrstreifenwechsellvorgang nach rechts, beide sind jedoch weitestgehend unabhängig von der gefahrenen Geschwindigkeit.

Bei einem Fahrstreifenwechsel nach rechts (vgl. Abbildung 3.3 R1, R2) stellt er für die Zeitlücken zu den vorausfahrenden Fahrzeugen (V) auf dem Zielfahrstreifen keinen Einfluss anderer Kenngrößen fest, mit einer Ausnahme: Ein auf dem Ausgangsfahrstreifen folgendes Fahrzeug (B) mit wenig Abstand reduziert die Zeitlücken des wechselnden Fahrzeuges zu den umgebenden Fahrzeugen (V, H) auf dem Zielfahrstreifen deutlich, vgl. Abbildung 3.3 R2.

Generell stellt Sparmann eine Abhängigkeit der Fahrstreifenwechsellhäufigkeit von der Verkehrsdichte fest. Diese erreicht ein Maximum von ca. 600 Wechsel/h bei einer Verkehrsdichte von 2000 Fahrzeugen/h pro betrachteten Kilometer.

In [Fastenmeier u. a. 2001] erfolgt eine Analyse des Fahrstreifenwechsels aus der psychologischen Sicht des Fahrers. Dabei werden die mentalen Abläufe und Ursachen bei der Entscheidung für oder gegen einen Wechsel analysiert und dessen Umsetzung beschrieben. Der Fahrstreifenwechsellvorgang wird hierbei in die folgenden vier Phasen unterteilt:

- (1) *Entscheidung für den Fahrstreifenwechsel fällen*: Es werden die Motivatoren, d. h. Reize, die einen Fahrstreifenwechsel veranlassen, und die Inhibitoren, d. h. Reize, die einen Fahrstreifenwechsel verhindern, abgewogen und eine Entscheidung für oder gegen den Wechsel getroffen. Motivatoren können z. B. navigatorische Erfordernisse, ein langsames Vorderfahrzeug, Hindernisse auf dem eigenen Fahrstreifen bzw. Sperrung des Fahrstreifens oder ein durch den Fahrer präferierter Fahrstreifen sein. Inhibitoren können Überholverbote oder eine Belegung des Zielfahrstreifens sein.
- (2) *Fahrstreifenwechsel vorbereiten*: Wird in Phase eins eine Entscheidung für einen Fahrstreifenwechsel getroffen, so wird dieser in Phase zwei vorbereitet, durch z. B. Setzen des Fahrtrichtungsanzeigers und Beginn einer Geschwindigkeitsangleichung an die Geschwindigkeit des Zielfahrstreifens.
- (3) *Fahrstreifenwechsel einleiten*: Nach einer erneuten Überprüfung der Durchführbarkeit wird das Lenkrad in Richtung des Zielfahrstreifens eingeschlagen und die Angleichung der Geschwindigkeit an den Zielfahrstreifen abgeschlossen.
- (4) *Fahrstreifenwechsel abschließen*: Das wechselnde Fahrzeug wird in der Mitte des Zielfahrstreifens positioniert und der Fahrstreifenwechselanzeiger wird abgeschaltet.

[Langer 2016] stellt, zur Anwendung für eine Fahrerabsichtserkennung, eine Beschreibungsmethode des Fahrerverhaltens für Fahrstreifenwechsellvorgänge vor. Das Verhalten wird hierbei auf Basis einzelner Aktivitäten beschrieben, welche katalogisiert sind nach visueller Informationsaufnahme, Querführung, Längsführung, Signalgebung, Schaltvorgängen und sonstigen Aktivitäten. Auf der Grundlage einer Probandenstudie wurden 167 Fahrstreifenwechsellmanöver untersucht. Es konnten spezifische Blickzuwendungen sowie Fixationen als auch ein spezifischer Lenkbeginn und die Betätigung des Fahrtrichtungsanzeigers als charakteristische Fahreraktivitäten im Zusammenhang mit einem Fahrstreifenwechsel bestätigt und eine zeitliche Verteilung der Aktivitäten ermittelt werden.

3.1.3 Fahrstreifenwechselmodelle für simulative Anwendungen

Das taktische Fahrerverhalten bei Fahrstreifenwechseln untersucht [Ehmanns 2002] zum Zweck der Abbildung in ein Simulationsmodell. Hierfür wertet er Fahrstreifenwechsellvorgänge in Fahr Simulatorstudien und realen Fahrversuchen aus und führt statistische Untersuchungen durch. Er weist nach, dass die Kollisionszeiten TTC und Zeitlücken t_L zum umgebenden Verkehr wesentliche Einflussfaktoren für eine Fahrstreifenwechselentscheidung sind. Abbildung 3.4 zeigt Bereiche, in denen ein Einschervorgang in eine Lücke möglich ist, wobei sich die Bereiche H1 und H2 auf den Folgeverkehr und V1 und V2 auf den vorausfahrenden Verkehr im Zielfahrstreifen beziehen. Generell wird bei Zeitlücken größer 3 s zum Folgefahrzeug (B) durch den Einscherer (E) in die Lücke gewechselt, vgl. Bereich H2. Bezüglich der Distanz d zum Führungsfahrzeug (A) erfolgt ein Wechsel, wenn ein unterer Mindestfolgeabstand d_{UF} eingehalten werden kann, vgl. Bereich V2. Bei Kollisionszeiten des Einscherers zum umgebenden Verkehr von größer 5 s wird auch bei sehr geringen Zeitlücken von bis zu $0,3\text{ s}$ zum Folge- bzw. Führungsfahrzeug in die Lücke gewechselt, vgl. Bereiche H1 und V1.

Ein Überholwunsch aufgrund eines langsamer vorausfahrenden Fahrzeuges wird jedoch auch bei einer Kollisionszeit von weniger als 5 s gebildet. Um einen Fahrstreifenwechsel mit Folgefahrzeug zu vermeiden und stattdessen ein Fahrstreifenwechsel mit Führungsfahrzeug auszuführen, wird häufig ein auf dem Zielfahrstreifen von hinten näherkommendes Fahrzeug zunächst passieren gelassen, um anschließend einen Fahrstreifenwechsel durchzuführen. Als weiteres Indiz für einen bevorstehenden Fahrstreifenwechsel stellte

[Ehmanns 2002] eine Erhöhung der Geschwindigkeit des einschерenden Fahrzeuges zum Erreichen einer Lücke fest.

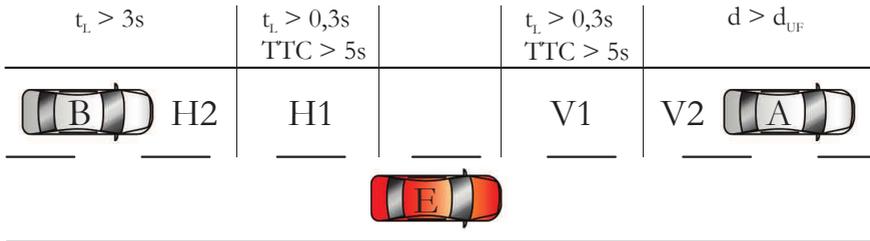


Abbildung 3.4: Relevante Bereiche (H2, H1, V1, V2) für das Einscheren in eine Lücke und deren Charakterisierung durch Kollisionszeit TTC , Zeitlücke t_L und unteren Mindestfolgeabstand d_{UF} , vgl. [Ehmanns 2002; Chen 2009]

[Ehmanns 2002] weißt weiterhin insbesondere für dichten Verkehr nach, dass die Kooperationsbereitschaft des umgebenden Verkehrs ein fundamentaler Bestandteil der Modellierung sein muss. Das Kooperationsverhalten äußert sich nach einem angezeigten Wechselwunsch des Einschererers in Form einer Geschwindigkeitsanpassung des Nachfolgeverkehrs auf dem Zielfahrsstreifen. Der Betrag der akzeptierten Verzögerung a_{Grenz} bei der Geschwindigkeitsanpassung richtet sich nach der Verkehrssituation:

- $a_{Grenz} \geq -0,5 m/s^2$: Fahrstreifenwechsel ohne für andere ersichtliche Motivation,
- $a_{Grenz} \geq -1,5 m/s^2$: verkehrsbedingter Fahrstreifenwechsel zum Überholen langsamer Fahrzeuge,
- $a_{Grenz} \geq -2,5 m/s^2$: Hindernisse auf dem Fahrstreifen, inkl. Fahrstreifenende
- Keine Kooperation zeigen Fahrer auf dem Zielfahrsstreifen, wenn für diese selbst kein Folgefahrzeug vorhanden ist.

Für die Realisierung eines Fahrerassistenzsystems zum autonomen Fahrstreifenwechsel knüpft [Chen 2009] an die Arbeit von [Ehmanns 2002] an. Das System soll dabei alle notwendigen Aufgaben zur Herbei- und Durchführung eines Fahrstreifenwechsels übernehmen, dazu gehört die Bildung des Wechselwunsches, die Überprüfung der Durchführbarkeit und die Durchführung des Fahrstreifenwechsels. Interessant ist hier die Bildung des Wechselwunsches durch eine Analyse der lokalen Verkehrssituation auf dem jeweiligen

Ausgangs- und Zielfahrstreifen, welche sich mithilfe der Durchschnittsgeschwindigkeit und der Verkehrsdichte³ charakterisieren lässt.

Weitere Arbeiten zur Beschreibung des Fahrstreifenwechsels im Bereich der Verkehrssimulation sind u. a. in [Treiber u. Helbing 2002; Panwai u. Dia 2007] zu finden.

3.2 Fahrstreifenwechsellvorhersage

In diesem Abschnitt werden aus der Literatur bekannte Lösungen zur Vorhersage von Fahrstreifenwechselmanövern aufgeführt und diskutiert. Grundsätzlich kann in die Manöर्वorhersage für das eigene Fahrzeug und die Vorhersage für Fremdfahrzeuge, d. h. Fahrzeuge aus dem umgebenden Verkehr des eigenen Fahrzeuges, unterschieden werden. Ziel der Eigenfahrzeugvorhersage ist häufig die Erkennung der Fahrerabsicht zur Anpassung des Verhaltens von Fahrerassistenzsystemen, z. B. für ein ACC-System Minimierung der Zeitlücke auf das aktuelle Zielfahrzeug bei einem erkannten Überholwunsch des Fahrers. Die Vorhersage von Fahrstreifenwechselmanövern des umgebenden Verkehrs findet Anwendung zur Erkennung von Einscherern in den Fahrschlauch⁴ eines ACC-Systems. Ziel ist hier die frühzeitige Reaktion auf einscherende Fahrzeuge, um starke Verzögerungen oder gar das Erreichen der Systemgrenzen eines ACC-Systems zu verhindern.

3.2.1 Eigenfahrzeugvorhersage

Bei der Erkennung von Fahrmanövern sieht [Gerdes 2006] die Motivation des Fahrers zur Auswahl eines Manövers von folgenden zueinander konkurrierenden Zielen abhängig: *Unfallfreies Fahren*, *Ziel erreichen*, *Befolgen der Verkehrsregeln*, *Optimieren der Geschwindigkeit* und *Verbleib im aktuellen Manöver* (Trägheit). Die Manöverauswahl, als Element der Führungsebene des Drei-Ebenenmodells, vgl. Unterabschnitt 3.1.1, wird unter Berücksichtigung der genannten Ziele von der Navigationsebene durch die Wahrnehmung der Fahrumgebung beeinflusst. Sie hat nach einer getroffenen Manöverentscheidung in Form von Fahrereingaben und Zustandsänderungen des Fahrzeugs direkten Einfluss auf die Stabilisierungsebene. Zur Erkennung der Manöver *Fahrstreifenwechsel nach links*, *Fahrstreifenwechsel nach rechts*, *Halten des Fahrstreifens* und *dem Führungsfahrzeug folgen*, verwendet [Gerdes

³ Aus der Verkehrsdichte kann auf den durchschnittlichen Abstand zwischen den Fahrzeugen geschlossen werden.

⁴ Bezeichnet den Bereich in dem die vom ACC-System verfolgten Fahrzeuge zur Abstandsregelung Verwendung finden.

2006] ein Bayes'sches Netzwerk mit einer kombinierten Top-Down Inferenz. Das heißt, die Evidenz aus der Navigationsebene und die Evidenz aus der Stabilisierungsebene werden für die Schätzung der Manöverentscheidung herangezogen. Die Erkennungswahrscheinlichkeit wird mit 86,5 %, bei 12,7 % fehlerhaft erkannten und 0,8 % nicht erkannten Manövern angegeben.

[Schroven u. Giebel 2008] greifen den Ansatz von [Gerdes 2006] mit einer kombinierten Top-Down Inferenz in einem Bayes'sches Netzwerk zur Detektion von Fahrmanövern auf, vgl. Abbildung 3.5. Sie ordnen beobachtbare Einflussgrößen den Begriffen *Inhibitoren* und *Motivatoren* zu, vgl. [Fastenmeier u. a. 2001]. Zusätzlich führen sie den Begriff *Indikatoren* ein. Über diesen werden Einflussgrößen bezeichnet, welche die Evidenz für eine Manöverentscheidung aus der Stabilisierungsebene repräsentieren, d. h. *Indikatoren* stellen Fahrereingaben und Zustandsänderungen des Fahrzeuges dar.

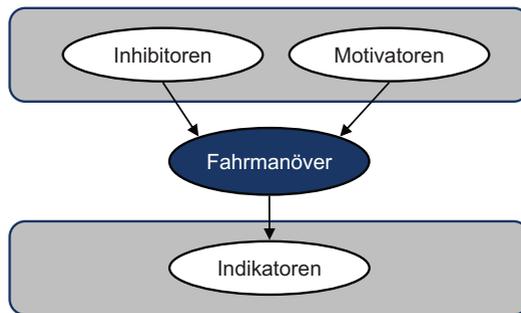


Abbildung 3.5: 3-Ebenenmodell zur Fahrmanövererkennung nach [Schroven u. Giebel 2008]

Als Einflussgrößen verwenden [Schroven u. Giebel 2008] u. a. die Ablage zu den Fahrstreifenmarkierungen und deren Art, den Zustand des Führungsfahrzeuges, die Fahrgeschwindigkeit, den Lenkradwinkel und die Lenkradwinkelgeschwindigkeit sowie die Betätigung des Fahrtrichtungsanzeigers des eigenen Fahrzeuges. Belastbare Angaben zu Treffer- und Fehlerraten werden nicht gegeben, da sich das System zum Zeitpunkt der Veröffentlichung noch in Entwicklung befand.

Für ein situationsadaptives ACC-System berechnet [Freyer 2008] die Fahrmotivation für einen Fahrstreifenwechsel. Ziel ist es, ein frühzeitiges Abbremsen auf ein langsameres Vorderfahrzeug hinauszuzögern, wenn die Möglichkeit für einen Fahrstreifenwechsel besteht. Zunächst erfolgt eine Prüfung der Geschwindigkeitsverhältnisse anhand einer Entscheidungstabelle unter Berücksichtigung der im ACC-System eingestellten Wunschgeschwindigkeit,

der tatsächlich gefahrenen Geschwindigkeit und der Geschwindigkeit des ACC-Zielobjektes. Sollte sich durch einen Fahrstreifenwechsel für das ACC-Fahrzeug keine vorteilhaftere Situation ergeben, wird keine Motivation für einen Fahrstreifenwechsel angenommen und keiner der weiteren Motivatoren geprüft. Andernfalls wird mithilfe von Kennlinien, welche die Motivation für einen Fahrstreifenwechsel in Abhängigkeit von den folgenden Parametern abbilden, die Fahrstreifenwechsellmotivation bestimmt:

- *Differenz der ACC-Wunschgeschwindigkeit und der tatsächlich gefahrenen Geschwindigkeit,*
- *Differenzgeschwindigkeit zum langsameren Vorderfahrzeug,*
- *Eintauchstärke und Änderung der Zeitlücke zum Vorderfahrzeug.*

Die Kennlinien wurden im Rahmen von Probandenstudien durch Fahrversuche bestimmt. Ist eine Fahrstreifenwechsellmotivation erkennbar, wird in einem nachgelagerten Modul die Durchführbarkeit des Manövers geprüft. Hierfür erfolgt eine Trajektoriengenerierung, vgl. Gleichung 3.1, und anschließend eine Bewertung der Kritikalität der Trajektorie zu allen umgebenden relevanten Fahrzeugen durch eine Betrachtung von Kollisionszeiten und Zeitlücken. Ein Modul zur Erkennung des Manöverbeginns wird verwendet, um eine Fahrerreaktion zu identifizieren. Dieses stützt sich auf die Indikatoren: Fahrrichtungsanzeiger, Zeit bis Queren der Markierung, Quergeschwindigkeit und ein um Kurven bereinigter Lenkradwinkel.

Ein System zur Vorhersage von Überholvorgängen auf Basis von Fuzzy-Logik stellen [Blaschke u. a. 2008] vor. Als Eingangsdaten werden ausschließlich die auf dem Controller Area Network (CAN)-Bus verfügbare Daten eines mit ACC ausgerüsteten Fahrzeugs verwendet. Diese Indikatoren sind der *Abstand* und die *Differenzgeschwindigkeit* zwischen Ego- und Führungsfahrzeug sowie der *Bremsdruck*, der *Fahrpedalwert* und die *Fahrpedalgeschwindigkeit* des Ego-Fahrzeugs. Verwendung fand der Mamdani-Controller. Zur Beschreibung des Fuzzy-Systems wurde eine Regelbasis von 100 gleichberechtigten Regeln aufgestellt und anhand von naturalistischen Fahrdaten die Zugehörigkeitsfunktionen aus den Häufigkeitsverteilungen der Indikatoren erstellt. Die Validierung des Systems fand mit einem zweiten Datensatz statt, welcher eine Gesamtstreckenlänge von 71 km mit Stadt- und Landstraßen sowie Autobahnanteil repräsentierte und 172 Überholmanöver enthielt. Basierend auf diesem Validierungsdatensatz wurde eine Trefferquote von 71 %, d. h. 147 erkannte Manöver bei neun nicht und 16 falsch erkannten Manövern, erzielt. Für die Auswertung wurden nur Manöver bei einer Geschwindigkeit größer

60 km/h berücksichtigt. Die Vorhersagezeit lag im Durchschnitt 2,1 s vor Verlassen des Fahrstreifens, in 70,7 % der erkannten Manöver betrug die Vorhersagezeit mehr als 1 s.

Ein System zur wahrscheinlichkeitsbasierten Entscheidungsmodellierung für die Durchführung von automatischen Fahrstreifenwechseln auf Fahrbahnen mit mehreren Richtungsfahrstreifen stellen [Schubert u. Wanielik 2010] vor. Ziel ist somit nicht die Manövervorhersage, sondern das Treffen einer Manöverentscheidung *Fahrstreifenwechsel rechts*, *Fahrstreifenwechsel links* oder *Fahrstreifen halten* entsprechend dem aktuellen Zustand der Verkehrsumgebung. Aufgrund der probabilistischen Natur der Eingangsdaten und des damit einhergehenden stochastischen Schätzprozesses zur Beobachtung des Verkehrsumfeldes propagieren [Schubert u. Wanielik 2010] ein Bayes'sches Netzwerk zur Modellierung der Manöverentscheidung, vgl. Abbildung 3.6. Hierfür schlagen sie einen Eingangsdatensatz mit minimaler Redundanz, bestehend aus den Parametern bzgl. der linken und rechten Fahrstreifenmarkierung mit der Ausprägung *durchgezogen* und *unterbrochen* und den Status des eigenen und der benachbarten Fahrstreifen *LeftLane*, *OwnLane*, *RightLane* mit den Ausprägungen *gefährlich*, *belegt* und *frei* vor. Die Fahrstreifenbegrenzungsinformation wird via Bildverarbeitung aus einem Kamerabild extrahiert und klassifiziert. Das Klassifikationsergebnis, als Eingangsverteilung der Knoten *ObservationBorderLeft* und *ObservationBorderRight* wird über eine bedingte Wahrscheinlichkeitsfunktion den darunter liegenden Knoten *BorderLeft* und *BorderRight* aufgeprägt. Der Status der Fahrstreifen wird über ein Abstandsmaß zum nächsten Objekt auf dem jeweiligen Fahrstreifen berechnet. Die Wahrscheinlichkeitsverteilungen der Markierungsart und der Fahrstreifenstatus werden über einen stochastischen Schätzprozess ermittelt und den Eingangsknoten des Bayes'schen Netzwerks als diskretisierte Eingangsverteilungen aufgeprägt. Über die Entscheidungsknoten *LaneChangeLeft* und *LaneChangeRight* mit den Ausprägungen *sicher*, *möglich* und *unmöglich* wird die Durchführbarkeit eines Fahrstreifenwechsels nach links, bzw. rechts bewertet und mit dem Knoten *LateralSafety* der Nutzen der Manöver. Der Knoten *LateralManoeuvre* gibt die Wahrscheinlichkeit für die eingangs genannten Manöver an. Die bedingten Wahrscheinlichkeitsverteilungen der Knoten *LaneChangeLeft*, *LaneChangeRight* und *LateralSafety* sowie *BorderLeft* und *BorderRight* werden durch Expertenwissen vorgegeben, die Inferenz innerhalb des Bayes'schen Netzwerks erfolgt nach den Verfahren von [Lauritzen u. Spiegelhalter 1988]. [Schubert u. Wanielik 2010] demonstrieren die Funktionsweise ihres Ansatzes an einem naturalistischen Messdatensatz.

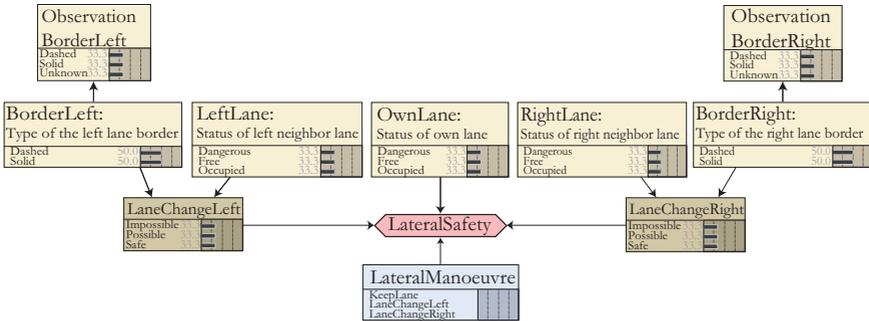


Abbildung 3.6: Bayes'sches Netzwerk zur Ableitung von lateralen Manöverentscheidungen nach [Schubert u. Wanielik 2010]

Die Identifikation und Beschreibung kognitiver Prozesse zur Entwicklung von Algorithmen zur Fahrstreifenwechselabsichtserkennung ist Inhalt der Arbeit von [Henning 2010]. In einer Feldstudie mit 194 aufgezeichneten Fahrstreifenwechseln werden Indikatoren untersucht, die auf die Vorbereitung eines Fahrstreifenwechsels hindeuten, d. h. Indikatoren, mit denen sich ein Fahrstreifenwechsel vor Beginn der lateralen Bewegung in der sog. Vorbereitungsphase vorhersagen lässt. Insbesondere bei Fahrstreifenwechseln mit rückwärtigem Verkehr kristallisierte sich neben Indikatoren der Längsführung wie Gas- und Bremspedalbetätigung und Varianz der Geschwindigkeit das Blickverhalten der Fahrer in den Außenspiegel als geeigneter sehr früher Indikator heraus. Gegenstand der Untersuchung sind diesbezüglich die Häufigkeit als auch die maximale Dauer der Blickzuwendung. [Henning 2010] stellt allerdings eine Beeinflussung des kognitiven Prozesses zur Wahrnehmung der Verkehrsumgebung bei der aktiven Bearbeitung von Zweitaufgaben durch den Fahrer fest, die sich in einer starken Reduzierung der Blickzuwendungshäufigkeit bemerkbar macht. Als ungeeignete Indikatoren zur Vorhersage des Fahrstreifenwechsels in der Vorbereitungsphase erscheint dem Autor das Signal des Fahrstreifenwechselanzeigers und die Erkennung des Schulterblicks des Fahrers, welche beide teils gar nicht oder teils sehr spät gesetzt bzw. durchgeführt werden.

Im Rahmen einer tabellarischen Auflistung über Untersuchungen zur Vorhersage des Eigenfahrstreifenwechsels findet sich in [Henning 2010] ein Überblick über den aktuellen Stand der Forschung, dem er seine Arbeiten gegenüber stellt. Er betrachtet hierbei Modellierungsmethode, Gegenstand der Vorhersage und Zeitpunkt, Datengrundlage und verwendete Indikatoren sowie Erkennungs- und Fehlalarmraten. Er stellt fest, dass in Studien, deren Daten-

basis auf Simulatordaten beruhen, überwiegend gute Resultate hinsichtlich der Vorhersage von Fahrstreifenwechseln erzielt werden. Studien mit naturalistischen Fahrdaten erzielen teils gute Resultate, wenn diese mit nur wenigen Probanden durchgeführt wurden, vgl. [McCall u. a. 2007; Kuge u. a. 2000; Salvucci u. a. 2007], während bei vielen Probanden deutlich schlechtere Ergebnisse erzielt werden, vgl. [Oliver u. Pentland 2000]. Weiterhin bemerkt er, dass nur in solchen Studien der Vorhersagezeitpunkt vor Beginn der lateralen Bewegung liegt, bei denen das Blickverhalten des Fahrers in den Erkennungsalgorithmus integriert ist.

Eine weitere detaillierte Übersicht zu Untersuchungen zur Vorhersage von Eigenfahrstreifenwechseln findet sich in [Deml u. Neumann 2010]. Eine vereinfachte Darstellung von [Deml u. Neumann 2010] zeigt Tabelle 3.2. Es wird eine unkommentierte Auflistung gegeben, unter Angabe des Modellierungsansatzes, des Zeitpunktes der Klassifikation, der Klassifikationsgüte, der Datenerhebung und der verwendeten Eingangsgrößen, kategorisiert nach den Verfahren:

- *Hidden Markov Modelle (HMM)*
- *Bayes'sche Netzwerke (BN)*
- *Support Vector Machines (SVM)*
- *Sparse Bayesian Learning (SBL)*
- *Modell Tracing (MT)*
- *Neuronale Netzwerke (NN)*

Angegeben ist: das Verfahren, die Art des Fahrstreifenwechsels (FSW), d. h. normaler (St) oder Notfallfahrstreifenwechsel (No), die verwendete Datenbasis (DB) unterschieden nach simulativen (Si) und naturalistischen (Na) Fahrdaten, der Vorhersagezeitpunkt t_p , die Erkennungsrate (EKR) des Ansatzes mit Treffer- (T) und Fehlerquote (F), sowie die zugehörige Quellenangabe. Der Vorhersagezeitpunkt t_p bezieht sich auf den Manöverbeginn, d. h. bei einer negativen Vorhersagezeit wird das Manöver erst nach dessen Beginn erkannt, bei einer positiven Vorhersagezeit entsprechend vor Manöverbeginn.

3.2.2 Fremdfahrzeugvorhersage

Eine Einschererererkennung von Fremdfahrzeugen zur Erweiterung eines ACC-Systems wird in [Dagli 2005] vorgestellt. Durch eine frühzeitige Reaktion

Tabelle 3.2: Übersicht über Modellierungsansätze zum Eigenfahrstreifenwechsel entnommen aus [Deml u. Neumann 2010]: [-] keine Angabe, [+] durchgeführt, [o] nicht betrachtet

Verfahren	FSW		DB		t_p [s]	EKR [%]		Quelle
	St	No	Si	Na		T	F	
HMM		+	+	o	-1,1	98,3	0,29	[Kuge u. a. 2000]
	+		+	o	-	-	-	
	+	-	o	+	> -2	>74	22	[Berndt u. Dietmayer 2009; Berndt u. a. 2008]
	+	-	o	+	0,1	29,4	-	[Oliver u. Pentland 2000]
	+	-	o	-	-3	95	20	[Polling u. a. 2005]
	+	+	+	o	-0,48	33	67	[Tezuka u. a. 2006]
BN	+		+	o	-0,5	78	56	[Tezuka u. a. 2006]
		+	+	o	-0,58	89		
SVM	+	-	o	+	-0,3	87	5	[Salvucci u. Mandalia 2005]
	+	-	o	+	-1,2	97,9		
	+	-	+	o	<2,06	>97	>2	[Dogan u. a. 2008]
SBL	+	-	o	+	2,5	95	5	[McCall u. a. 2007]
	+	-	o	+	2	87,3	0,39	[Doshi u. Trivedi 2009]
MT	+	-	+		>	82	5	[Salvucci u. a. 2007]
	+	-		+	-0,5	61		
	+	-	+			93		
	+	-		+	> -1	77		
NN	+	-	+	o	<1,79	<100	>3	[Dogan u. a. 2008]

auf einscherende Fahrzeuge soll das Abschalten eines ACC-Systems, bedingt durch das Erreichen der Systemgrenzen in Form einer Unterschreitung einer minimalen Sollbeschleunigung und/oder einer minimalen Zeitlücke, vermieden werden. Für potentielle Einscherer in den Fahrstreifen des ACC-Fahrzeuges soll eine Einscherwahrscheinlichkeit berechnet werden, anhand derer ein ACC-System eine frühzeitige Zielauswahl bezüglich des relevanten Führungsfahrzeuges treffen kann. Hierfür definiert [Dagli 2005] das in Abbildung 3.7 dargestellte Aktionsmodell, in dem er den Aktionsraum in die lateralen Aktionen *Fahrstreifenwechsel links*, *Fahrstreifenwechsel rechts*, *Quer bleiben* und die longitudinalen Aktionen *Beschleunigen*, *Verzögern*, *Längs bleiben* einteilt. Aktionen innerhalb der lateralen oder longitudinalen Gruppe sind jeweils disjunkt, d. h. es kann zeitgleich nur eine laterale und longitudinale Aktion durchgeführt werden. Die Modellierung der Einschererererkennung erfolgt über ein durchgehend probabilistisches Datenverarbeitungskonzept. Die Berechnung der Einscherwahrscheinlichkeit erfolgt durch ein Bayes'sches Netzwerk, vgl. Unterabschnitt 2.3.1. Die Eingangsmerkmale werden durch ein Kalman-Filter geschätzt und die resultierenden Verteilungen den Eingangsknoten des Bayes'schen Netzwerks aufgeprägt, womit eine durchgehenden Berücksichtigung der Unsicherheiten des Wahrnehmungs- und Schätzprozesses gewährleistet ist.

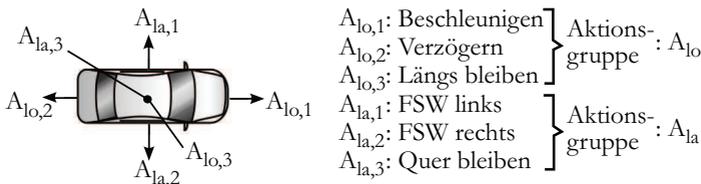


Abbildung 3.7: Aktionsmodell nach [Dagli 2005]

Im Fokus der weiteren Untersuchung lag die Integration der Einschererererkennung in ein reales ACC-System. Hierfür wurde das in Abbildung 3.8 abgebildete Bayes'sche Netzwerk entworfen, um Einschersituationen, wie die in Abbildung 3.3 dargestellten Situationen R1 bzw. L4 (ohne Berücksichtigung des Vorderfahrzeuges M), zu erkennen. Dargestellt sind die Eingangsknoten, vgl. Tabelle 3.4, die Zwischenknoten *Trajektorie TR*, *laterale Evidenz LE* und *Orientierung zur Lücke*⁵ *OL* sowie der Zielknoten *Einscherer*.

⁵ Um die Berechnung der Zeitintervalle des potentiellen Einscherers zu den auf dem Zielfahrstreifen vorausfahrenden Fahrzeug V und nachfolgenden Fahrzeug H zu vermeiden, wird zwischen diesen eine Lücke definiert, vgl. Abbildung 3.3 R1, L4.

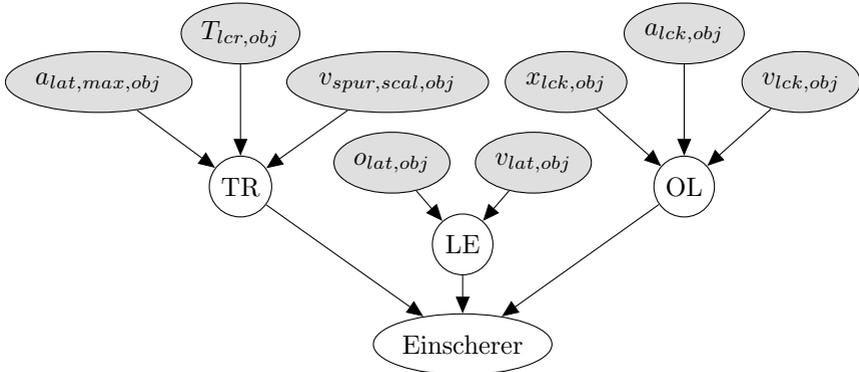


Abbildung 3.8: Reduziertes Bayes'sches Netzwerk zur Einschereerkennung, vgl. [Dagli 2005]. Graue/weiße Symbole: beobachtete/latente Variablen

Tabelle 3.4: Eingangsmerkmale bezogen auf das potentiell einscherende Fahrzeug, welche als Eingangsknoten für das in Abbildung 3.8 dargestellte Bayes'sche Netzwerk dienen

Notation	Beschreibung
Trajektorie TR	
$a_{lat,max,obj}$	maximal ausgenutzte laterale Beschleunigung
$T_{lcr,obj}$	Zeit bis Überquerung der Fahrstreifenmarkierung
$v_{spur,scal,obj}$	Kurswinkel (skaliert)
Laterale Evidenz LE	
$o_{lat,obj}$	Ablage zur Fahrstreifenmitte
$v_{lat,obj}$	laterale Geschwindigkeit
Orientierung zur Lücke OL	
$x_{lck,obj}$	Abstand zur Position der Lücke
$a_{lck,obj}$	Relativgeschwindigkeit zur Lückengeschwindigkeit
$v_{lck,obj}$	Relativbeschleunigung zur Lückenbeschleunigung

Während die Eingangsknoten zur Abbildung der diskretisierten Verteilungen mehrere Zustände aufweisen, haben die Zwischen- und der Zielknoten

jeweils zwei Zustände: *wahr* - Einschervorgang liegt vor, *falsch* - Einschervorgang liegt nicht vor. Untersuchungen zur statistischen Abhängigkeit der Eingangs- und Zwischenknoten werden in [Dagli 2005] nicht aufgeführt. Die Validierung des Systems erfolgte auf Basis naturalistischer Fahrdaten. Aus einem 1000 km Fahrstrecke umfassenden Messdatensatz mit 206 enthaltenen Einschervorgängen wurden 194 Einscherer im Mittel 1 s vor dem Queren der Fahrstreifenmarkierung in den Fahrstreifen des ACC-Fahrzeuges, erkannt. Der Bezugspunkt für das Queren der Fahrstreifenmarkierung lag hierbei auf der Mitte des Fahrzeughecks. Berücksichtigt wurden Einscherer im Bereich von 0 bis 60 m vor dem ACC-Fahrzeug. 58 Einschervorgänge wurden fehlerhaft klassifiziert und 12 Einschervorgänge nicht erkannt. Der Autor gibt an, dass alle nicht rechtzeitig erkannten Einschervorgänge durch Einscherer mit einer sehr geringen Einscherdistanz sowie einer hohen positiven Relativgeschwindigkeit zum ACC-Fahrzeug verursacht wurden. Zudem befanden sie sich, während des Einschierens in den Fahrstreifen des ACC-Fahrzeuges, außerhalb des ACC-Sensorsichtbereiches. Im Ergebnis konnte das um eine Einschererererkennung erweiterte ACC-System deutlich früher auf Einscherer reagieren. Eine Abschaltung des ACC-Systems verursacht durch Einscherer konnte, bezogen auf den untersuchten Messdatensatz, vermieden werden.

Basierend auf den Arbeiten von [Dagli 2005] entwickelt [Kasper 2013] ein System zur „Erkennung von Fahrmanövern mit objektorientierten Bayes-Netzen in Autobahnscenarien“. Fokus ist hier ebenfalls die Erkennung von Einschermanövern für ein ACC-System. Im Gegensatz zu [Dagli 2005] erfolgt der Aufbau des Bayes’schen Netzwerks hierarchisch mithilfe generischer Bayes’scher Netzwerk-Objekte bzw. Fragmente in vier Schichten. Ein Fragment wird als Klasse bezeichnet, deren Instanziierung als ein Objekt der entsprechenden Klasse.

Schicht 1: Die erste Schicht dient der Modellierung von Unsicherheiten in den beobachteten Eingangssignalen. Der Messwert eines Signals s_{mess} setzt sich aus dem realen Wert s_{erw} und dem Messfehler s_{err} zusammen. Unter der Annahme einer mittelwertfreien und normalverteilten Varianz σ^2 wird die bedingte Wahrscheinlichkeitsverteilung für das gemessene Signal wie folgt angegeben:

$$p(s_{mess}|s_{erw},\sigma) = \mathcal{N}(s_{erw},\sigma^2) \quad (3.2)$$

Die Modellierung des realen Messwertes s_{erw} erfolgt entsprechend Abbildung 3.9(a) mithilfe der diagnostischen Inferenz über die beobachtbaren Werte des Messfehlers s_{err} und des gemessenen Signals s_{mess} .

Schicht 2: In dieser Schicht wird das Fahrstreifenwechselverhalten in Form der Grundhypothesen *Laterale Evidenz* (LE-H), *Trajektorie* (TR-H) und *Freiraum* (FR-H) modelliert. Die Modellierung einer Grundhypothese erfolgt als Subnetz entsprechend Abbildung 3.9(b) unter Verwendung der in Schicht 1 objektorientierten Modellierung des realen Signalwertes aus Messung und Messfehler. Während die Eingangsmerkmale für die Hypothesen LE-H und TR-H im wesentlichen denen von [Dagli 2005], vgl. Tabelle 3.4 entsprechen, ersetzt Kasper die bei Dagli verwendete *Orientierung zur Lücke* mit der Hypothese *Freiraum*. Hierfür spannt Kasper ein virtuelles Belegungsgrid mit 3x3 Zellen mit dem Bezugsobjekt als Zentrum auf. Das Grid wird mit der Bewegung des Bezugsobjektes mitgeführt, die Zellbreite entspricht der Fahrstreifenbreite, die Länge der Zellen entspricht der Länge des Bezugsfahrzeuges. Über die in Tabelle 3.5 aufgeführten Merkmale wird die Freiraumhypothese für jede Zelle modelliert.

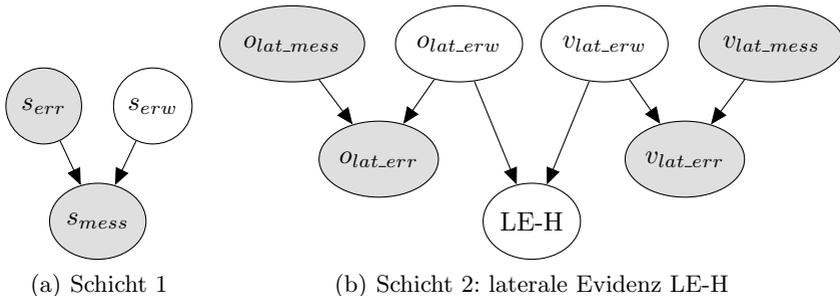


Abbildung 3.9: Elemente eines objektorientierten Bayes'schen Netzwerks nach [Kasper 2013] mit 3.9(a) der diagnostischen Inferenz in Schicht 1 und der lateralen Evidenz als Beispiel für Schicht 2 in 3.9(b). Beobachtete Variablen sind grau, latente Variablen weiß.

Schicht 3: Die Modellierung von Fahrstreifenwechselmanövern, d. h. der Beziehung des beobachteten Fahrzeugs zum Fahrstreifen, erfolgt in Schicht 3. Wie in Abbildung 3.10(b) dargestellt, setzt sich die Hypothese *Fahrstreifenwechsel* (SW-H) aus zwei Objekten der in Abbildung 3.10(a) dargestellten Klasse *Überschreitung einer Fahrstreifenmarkierung* (ÜSPM-H) jeweils für die linke und rechte Markierung zusammen. Für ÜSPM-H werden die Objekte der Grundhypothesen Trajektorie (TR-H), Laterale Evidenz (LE-H) und die Hypothese Fahrstreifenwechsellmöglichkeit (FSWM) zur Modellierung verwendet. Für die Hypothese FSWM finden zwei Instanzen der Klasse *Freiraum* Anwendung, um Fälle abdecken zu können, in denen eine durch ein Objekt freigegebene Zelle bereits im Anschluss durch ein weiteres Objekt

belegt sein könnte. Die Hypothese *Fahrstreifenwechsel* (SW-H) erlaubt die Abschätzung bzgl. des Fahrstreifenwechselverhaltens nach rechts (R), links (L) oder Fahrstreifen halten (F).

Tabelle 3.5: Eingangsmerkmale der Freiraumhypothese nach [Kasper 2013]

Notation	Beschreibung
T_{TE}	Zeitreserve bis Eintritt in Zelle
T_{TD}	Zeitreserve bis Austritt aus Zelle
S_{TE}	Distanz bis Eintritt in Zelle
S_{TD}	Distanz bis Austritt aus Zelle

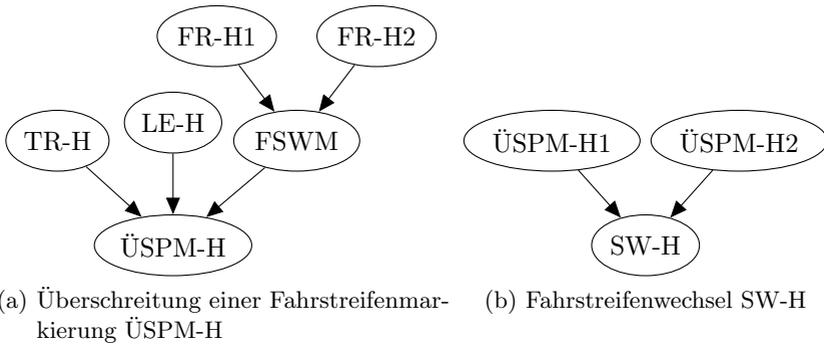


Abbildung 3.10: Elemente eines objektorientierten Bayes'schen Netzwerks der Schicht 3 nach [Kasper 2013]

Schicht 4: Die vierte Schicht dient schließlich der Modellierung von Fahrmanövern unter Berücksichtigung des Fahrzeugumfeldes in Form von Fahrzeug-Fahrzeug- bzw. Fahrzeug-Objekt-Beziehungen entsprechend Abbildung 3.11. Die relative Bewegung zweier Objekte zueinander wird über zwei Hypothesen SW-H1 und SW-H2 bzgl. des Fahrstreifenwechselverhaltens über den Knoten *Beziehungsklassen* modelliert. Aus den drei möglichen Hypothesen der Klasse Fahrstreifenwechsel [L,R,F] ergeben sich neun unterschiedliche Beziehungsmöglichkeiten zweier Objekte zueinander (LL,LR,...,RF,FF). Die fahrstreifenbezogene Position des Bezugsobjektes auf der Fahrbahn wird über den Knoten *Positionsklasse* modelliert mit den möglichen Positionen *links*, *rechts* und *voraus*. Über den Knoten Fahrmanöver lassen sich schließlich 27 mögliche Fahrmanöver aus den Zustandskombinationen der Knoten

Beziehungsklassen und Positionsklassen schätzen. Abbildung 3.12 zeigt beispielhaft eines der 27 Fahrmanöver. Dargestellt ist eine Einschersituation für die Beziehung zwischen zwei Fahrzeugen, wobei Fahrzeug 1 (Fzg_1) die Bewegungsklassen Folgefahrt (F) und Fahrzeug 2 (Fzg_2) auf Position links (Pos^{links}) von Fzg_1 die Bewegungsklasse Fahrstreifenwechsel rechts (R) inne hat.

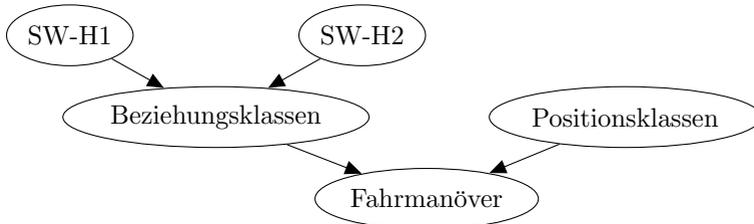


Abbildung 3.11: Objektorientiertes Bayes'sches Netzwerk, [Kasper 2013]

Die Auswahl der beobachtbaren Evidenzvariablen, der Latentvariablen, die Bestimmung der Graphenstruktur und Parameter des Bayes'schen Netzwerks erfolgt manuell über Expertenwissen. Die Validierung des vorgestellten Bayes'schen Netzwerks erfolgt rein über die Bewertung des Klassifikationsergebnisses. Hierfür wurde das System an realen Daten getestet: 1191 Einschermanöver wurden korrekt, 229 falsch klassifiziert. Der Zeitgewinn gegenüber der Zielobjektaufschaltung eines ACC-Systems während der Einschersituation ist mit 0,155 s bis 1,189 s angegeben. Eine Besonderheit des vorgestellten Ansatzes ist die Verwendung eines objektorientierten Bayes'schen Netzwerks: Die Modellierung generischer Subnetzwerke bzw. Fragmente ist möglich, wenn diese eine identische Struktur, identische bedingte Wahrscheinlichkeitstabellen und die gleiche Anzahl von Zuständen je Variable aufweisen. [Kasper 2013] wendet die Objektorientierung insbesondere auf Schicht 1 seines Netzes an, d. h. auf die Modellierung der Eingangsdaten. Der Autor zielt mit der Verwendung eines objektorientierten Bayes'schen Netzwerks auf die Reduktion bzw. Beherrschbarkeit der Komplexität großer Klassifikationsmodelle.

Eine Situationsbewertung des Fahrverhaltens auf mehrstreifigen Fahrbahnen für automatisierte Fahrzeuge ist Inhalt eines Artikels von [Althoff u. a. 2009]. Hierfür wird ein System zur Bestimmung einer Wahrscheinlichkeit für einen Fahrstreifenwechsel über eine stochastische Erreichbarkeitsanalyse vorgestellt. In einem gegebenen Zeitintervall wird die Aufenthaltswahrscheinlichkeit eines Einscherer auf einer in äquidistante Quadrate diskretisierten Verkehrsfläche bestimmt. Die kontinuierliche Dynamik der Verkehrsteilnehmer wird

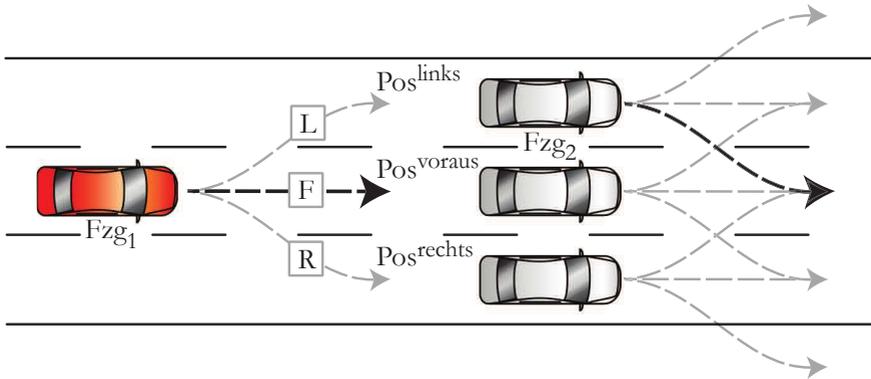


Abbildung 3.12: Bildung der Fahrmanöver aus Bewegungsklassen (L,F,R), Beziehungsklassen (LL,...,FF) und Fahrzeug-Fahrzeug-Beziehung mit den Positionsklassen (Pos^P , mit $P \in [links, voraus, rechts]$) nach [Kasper 2013]. Das Fahrmanöver Einscherer für Fzg_2 bezogen auf Fzg_1 ist beispielhaft über die schwarz hervorgehobenen Pfeilmarkierungen dargestellt.

über Markov-Ketten, vgl. Unterabschnitt 2.2.4.1, abstrahiert. Für jedes mögliche Eingangsintervall wird anhand von Übergangswahrscheinlichkeiten die Aufenthaltswahrscheinlichkeit des Einscherers auf der diskretisierten Verkehrsfläche, d. h. einer Menge von Zellen, geschätzt. Die Schätzung der Aufenthaltswahrscheinlichkeit erfolgt sowohl für den Einscherer, als auch für dessen potentiell folgefahrendes Fahrzeug nach dem Einschervorgang. Infolge dessen kann die zukünftig zu befahrene Verkehrsfläche des automatisierten Fahrzeugs innerhalb des gegebenen Zeitintervalls auf Konfliktfreiheit geprüft werden. [Althoff u. a. 2009] demonstrieren die prinzipielle Anwendbarkeit des Verfahrens an einem numerischen Beispiel. Die Modellierung der Übergangswahrscheinlichkeiten, d. h. des Fahrverhaltens, erfolgt über Heuristiken. Die Autoren weisen allerdings im Ausblick auf die Möglichkeit des Erlernens dieser Parameter aus naturalistischen Fahrdaten hin. Detaillierte Angaben zur Behandlung der systemimmanenten Unsicherheit bei der Verwendung von Umfelddaten werden nicht gegeben.

[Graf u. a. 2013] verwenden die Methode des Fallbasierten Schließens zur Vorhersage von Einschermanövern anderer Fahrzeuge in den Fahrstreifen des Ego-Fahrzeugs. Das Szenenbild wird hierbei kategorisiert durch die Relation des beobachteten Fahrzeuges zum Ego-Fahrzeug und den potentiell umgebenden Fahrzeugen, vorausfahrend auf dem eigenen und seitlich auf dem benachbarten vom Ego-Fahrzeug befahrenen Fahrstreifen. Die Relationen

werden in Form von Level- und Trendintervallen für die Zeitreihen der Zustandsgrößen Abstand und Relativgeschwindigkeit zu den jeweiligen Fahrzeugen charakterisiert. Zur Konstruktion der Lösung wird das Szenenabbild mit bekannten ähnlichen Fällen aus der Falldatenbank verglichen. Als mögliche Lösung kann *Fahrstreifenwechsel*, *kein Fahrstreifenwechsel*, oder bei mehrdeutigen Fällen auch keine Lösung ausgegeben werden. Szenenabbilder von fehlerhaft ausgegebenen oder mehrdeutigen Lösungen können nach der Beobachtung des tatsächlichen Manövers korrigiert in der Falldatenbank abgespeichert werden. Die Autoren geben am Beispiel einer Autobahnscene und einer Datenbasis von 21 bekannten Situationen eine Trefferchance von 73 % mit einer durchschnittlichen Vorhersagezeit von 2,1 s an. Bei einer weiteren Autobahnscene und einer Datenbasis von 47 bekannten Situationen erhöht sich die Trefferchance auf 79 % bei einer durchschnittlichen Vorhersagezeit von 2,3 s. Angaben zu fehlerhaft erkannten Situationen oder zum Bezugspunkt der Vorhersagezeit werden nicht gemacht. Ebenso werden keine Angaben zum Umgang mit den inhärenten Unsicherheiten der verwendeten Zustandsgrößen gegeben.

3.3 Zusammenfassung & Diskussion

Ein Fahrstreifenwechselmanöver ist gekennzeichnet durch einen Wechsel eines Fahrzeuges von einem Ausgangs- in einen Zielfahrstreifen und ist im Allgemeinen mit der Querung einer Fahrstreifenmarkierung verbunden. Die Manöverentscheidung kann als kognitiver Prozess auf der Führungsebene im Drei-Ebenenmodell der Fahrzeugführung angesehen werden. Beeinflusst durch die Navigationsebene wird ein Fahrstreifenwechsel motiviert oder eingeschränkt, z. B. durch navigatorische Erfordernisse, ein zu langsames Vorderfahrzeug oder durch Überholverbote. Zudem hat er direkte Auswirkungen auf die Stabilisierungsebene in Form von Beschleunigungs- und Lenkvorhängen. Die Trajektorie hängt hierbei von zeitlichen und örtlichen Beschränkungen des makroskopischen Verkehrsumfeldes ab, ebenso von der Art des Fahrzeuges, z. B. PKW oder Motorrad. [Fastenmeier u. a. 2001] unterteilt das Fahrstreifenwechselmanöver in vier Phasen *FSW entscheiden*, *FSW vorbereiten*, *FSW einleiten* und *FSW abschließen*.

Im zweiten Teil des Kapitels werden Lösungen zur Vorhersage von Fahrstreifenwechseln aufgeführt. Diese nutzen unterschiedliche charakteristische Situationsmerkmale der ersten drei Manöverphasen für eine möglichst frühzeitige Vorhersage. Der Umfang der verwendeten Merkmale variiert von einer Beschränkung auf reine Fahrzustandsdaten des betrachteten Fahrzeuges, z. B. Beschleunigung, Quergeschwindigkeit, über die Verwendung zusätzlicher

Umfeldinformation, wie die Querablage des Fahrzeuges im Fahrstreifen, bis zur Betrachtung einer komplexen Verkehrsszene. Die Ergebnisse zeigen, dass mit der Verwendung komplexer Eingangsdaten bessere Ergebnisse gewonnen werden als bei einer auf wenige Merkmale reduzierten Merkmalsmenge, vgl. [Salvucci u. Mandalia 2005; Dogan u. a. 2008; McCall u. a. 2007; Doshi u. Trivedi 2009] zu [Tezuka u. a. 2006; Berndt u. Dietmayer 2009; Berndt u. a. 2008]. Ansätze zur Vorhersage von Fahrstreifenwechseln anderer Fahrzeuge nutzen generell komplexere Eingangsdaten, ggf. inkl. der infolge des Wahrnehmungsprozesses auftretenden Unsicherheiten der Eingangsmerkmale, vgl. [Dagli 2005; Kasper 2013]. Eine Eigenfahrzeugvorhersage scheint hingegen auch mit weniger Merkmalen realisierbar, vgl. [Freyer 2008; Blaschke u. a. 2008]. Eine Übersicht über Situationsmerkmale, die den bisher genannten Literaturquellen entnommen und um persönliche Überlegungen des Autors ergänzt sind, wird mit Abbildung 3.13 gegeben. Über eine erweiterte Umfeldwahrnehmung können zusätzliche Merkmale zur Verbesserung der Fahrstreifenwechselvorhersage erfasst werden.

Die genannten Ansätze zur Vorhersage der Manöverentscheidung spiegeln ein breites Spektrum möglicher Verfahren wider. Diese beinhalten u. a. Support-Vector Machines, Hidden Markov Modelle, Fuzzy-Logik Systeme, Bayes'sche Netzwerke bis hin Neuronalen Netzwerken. Eine detaillierte Bewertung der verwendeten Verfahren anhand der erzielten Resultate ist nicht möglich. So liegt weder eine gemeinsame Datenbasis vor, auf deren Grundlage verglichen werden kann, noch ist der Manöverbeginn einheitlich definiert. Insbesondere für die Fremdfahrzeugvorhersage von Fahrstreifenwechseln beinhalten alle vorgestellten Ansätze ein expertengestützt parametrisiertes Vorhersagemodell. Eine datengetriebene maschinelle Entwicklung des Vorhersagemodells bietet daher Forschungspotential. Ebenso existiert in allen Ansätzen kein direkter Zeitbezug zwischen der Schätzung einer Fahrstreifenwechselhypothese und der Zeit bis zum Manöverbeginn. Entsprechend hat ein Zeitbezug der Fahrstreifenwechselvorhersage Neuheitswert.



Abbildung 3.13: Situationsmerkmale des Fahrstreifenwechsels

4 Konzept der Fahrstreifenwechselvorhersage

Die Konzeption einer Fahrstreifenwechselvorhersage bestimmt den Inhalt von Kapitel 4. Auf Basis der Definition des Vorhersageziels werden Anforderungen an eine Methode zur Fahrstreifenwechselvorhersage abgeleitet. Die Anforderungen ergeben sich zum einen aus der Applikation und zum anderen aus den Eigenschaften der Datenbasis, d. h. der potentiell zur Verfügung stehenden Daten der Umfeldwahrnehmung. Es wird gezeigt, dass ein Bayes'sches Netzwerk die identifizierten Anforderungen am besten erfüllt und somit das favorisierte Modellierungswerkzeug darstellt. Im Anschluss wird die Einbettung des Moduls zur Fahrstreifenwechselvorhersage in die modulare Softwarearchitektur der Umfeldwahrnehmungsplattform des TEMPORARY AUTOPILOT und das Vorgehen zur Schätzung einer Fahrstreifenwechselwahrscheinlichkeit beschrieben, gefolgt von einer Vorstellung der letztgenannten Plattform. Im letzten Abschnitt werden die Klassenvariable sowie die Evidenzvariablen definiert und deren Berechnung innerhalb der Umfeldwahrnehmungsplattform angegeben.

4.1 Anforderungen

Methoden zur Modellierung von Wissen und Verhalten sind in Kapitel 2 beschrieben. Die Auswahl der Methode wird maßgeblich durch das zu modellierende Ereignis, die problemspezifische Wissensbasis, d. h. die Datengrundlage über das Ereignis, als auch durch den Einsatzzweck bestimmt. In diesem Abschnitt wird das Vorhersageziel spezifiziert und die Anwendung Bayes'scher Netzwerke als favorisierte Methode zur Vorhersage von Fahrstreifenwechselmanövern diskutiert.

4.1.1 Anforderungen aus der Applikation

Die Vorhersage von Fahrstreifenwechselmanövern bezieht sich auf detektierte Fahrzeuge im Wirkungsbereich der automatischen Fahrfunktion TAP, vgl. Unterabschnitt 1.3.3. Hierzu zählen insbesondere Fahrzeuge auf den unmittelbaren Nachbarfahrstreifen. Applikationsspezifisch relevant sind Fahrzeuge, sobald sie in den vom TAP genutzten Fahrstreifen einscheren. Ziel

der Vorhersage ist folglich der Zeitpunkt t_0 dieses Einschermanövers. Nach der Definition in Abbildung 4.1 tritt dieser ein, wenn der Abstand y zwischen einer Fahrbahnmarkierungslinie und der ihr zugewandten Seite des potentiellen Einschersers zu null wird, und das betreffende Fahrzeug folgend tatsächlich in den Fahrstreifen einschert.

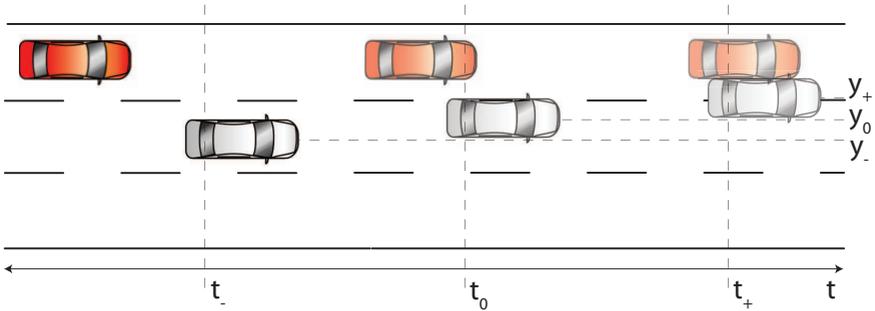


Abbildung 4.1: Ziel der Vorhersage

Hierbei soll die Zeit bis zum prädierten Fahrstreifenwechsel unter Angabe eines Unsicherheitsmaßes bestimmt werden. Die gewählte Methodik muss algorithmisch verfügbar sein und sich in die Umfeldwahrnehmungsplattform des TAP integrieren lassen. Dabei sollte sie den Anforderungen der Applikation an Determinismus und Verarbeitungsgeschwindigkeit Rechnung tragen sowie eine durchgehende Nachvollziehbarkeit des Prädiktionsergebnisses gewährleisten.

4.1.2 Anforderungen aus der Beschaffenheit der Eingangsdaten/Datenbasis

Das Fahrstreifenwechselmanöver mit Modellen und potentiellen Merkmalen zu dessen Beschreibung sind in Abschnitt 3.1 aufgeführt.

Über die Umfeldwahrnehmungsplattform des TAP ist eine Schnittmenge der aufgeführten Merkmale als Eingangsmerkmale verfügbar, welche über den Prozess einer Sensordatenfusion (vgl. Abschnitt 2.1) geschätzt werden. Charakteristisch für diese Datenbasis ist ihre unsicherheitsbehaftete und teils unvollständige Natur. So wird für jedes Merkmal, d. h. für jede Zustandsgröße eine Verteilung geschätzt. Mangels genauer Kenntnis findet größtenteils die Gaußverteilung Anwendung. Unvollständig bedeutet, dass temporär Daten über bestimmte Merkmale, z. B. durch Verdeckung eines

Sensorsichtbereiches oder einer streckenweise unvollständigen Attribuierung der digitalen Straßenkarte, nicht zur Verfügung stehen können.

Schlussfolgerungen auf einen Fahrstreifenwechsel sollen auf Basis der Änderung von Eingangsmerkmalen getroffen werden. Diesbezüglich muss das Wissen über logische Zusammenhänge explizit oder implizit modelliert und gegebenenfalls erlernt werden können.

4.1.3 Diskussion

Die in Unterabschnitt 4.1.1 und 4.1.2 dargelegten Anforderungen können wie folgt zusammengefasst werden: Es soll für potentielle Einscherer unter Angabe eines Unsicherheitsmaßes die Zeit bis zu einem Fahrstreifenwechsel geschätzt werden. Maßgeblich ist die Zeit bis zum Erreichen der Markierungslinie, wenn danach ein Wechsel in den Fahrstreifen des TAP erfolgt. Die für die Umsetzung notwendige Methode soll den nachstehenden Anforderungen genügen:

- Verarbeitung von unsicheren und unvollständigen Daten
- Abbildung logischer Zusammenhänge zur Schlussfolgerung
- Anwendbarkeit von maschinellen Lernverfahren
- Verfügbarkeit von Bibliotheken und Algorithmen
- deterministisches und nachvollziehbares Ergebnis

Unter den gegebenen Bedingungen scheint eine probabilistische Modellierung des Fahrstreifenwechsels als am besten geeignet, vgl. Abschnitt 2.4. Hierbei wird der Fahrstreifenwechsel zunächst als Realisation eines hochdimensionalen Zufallsvektors $\mathbf{X} = (X_1, X_2, \dots, X_n)^T$ mit den Zufallsvariablen $X_i, i = 1, \dots, n$ aufgefasst. Über die Verbundverteilungsdichtefunktion $P(\mathbf{X} = \mathbf{x})$ kann nun die Wahrscheinlichkeit modelliert werden, mit welcher der Fahrstreifenwechsel eine bestimmte Konfiguration annimmt. Von der Menge Zufallsvariablen \mathbf{X} stellt die Schnittmenge $\mathbf{E} = (E_1, E_2, \dots, E_m)^T$ den über die Umfeldwahrnehmungsplattform beobachtbaren Teil dar. Hierbei werden auch diese Zufallsvariablen als Verteilungsdichtefunktionen modelliert und lassen folglich die Verarbeitung von unsicherem Wissen zu. Unvollständige Daten können durch eine Marginalisierung der Verteilung abgebildet werden.

Durch eine Modellierung als Bayes'sches Netzwerk lassen sich kausale Zusammenhänge, d. h. stochastische Abhängigkeiten, in Form eines gerichteten azyklischen Graphen abbilden, in dem die Knoten Zufallsvariablen und die Kanten bedingte Abhängigkeiten zwischen den Variablen beschreiben, vgl. Unterabschnitt 2.3.1. Ziel ist es, die hochdimensionale Verbundverteilungsdichtefunktion $P(\mathbf{X} = \mathbf{x})$ in eine Vielzahl von niedrigdimensionalen Verteilungen zu überführen, welche über die explizite Vorgabe von stochastischen Abhängigkeiten in einem Graphen gekoppelt sind. Die Angabe der bedingten Wahrscheinlichkeitsverteilung des Knotens, d. h. der durch ihn repräsentierten Zufallsvariable bei gegebenem Elternknoten, charakterisiert diese Abhängigkeit. Für die Eingangsknoten, d. h. Knoten ohne Elternknoten, wird die Wahrscheinlichkeitsverteilung über die Umfeldwahrnehmungsplattform geschätzt. Ist eine Teilmenge der Knoten durch Beobachtung bekannt, so ist über die in Unterabschnitt 2.3.1 gegebene Gleichung 2.3 die bedingte Verteilung aller verbliebenen Variablen eindeutig bestimmt. Sowohl die Struktur des Graphen als auch die bedingten Wahrscheinlichkeiten der Knoten können über Lernverfahren ermittelt werden, vgl. Unterabschnitt 2.3.3.

Obwohl die Methode die Verarbeitung von kontinuierlichen Daten erlaubt, als hybrides Bayes'sches Netzwerk sogar in Kombination mit diskreten Daten, ist die Technologie der Bayes'schen Netzwerke primär dafür gedacht, diskrete Zustandsdaten zu verarbeiten, vgl. [Korb u. Nicholson 2010]. Kontinuierliche Daten sind im Vorfeld zu diskretisieren. Zum Zwecke der Modellierung eines Bayes'schen Netzwerkes, der Inferenz und dem Erlernen von Struktur und Parametern existiert eine Vielzahl von Algorithmen und Softwarepaketen. Eine Übersicht findet sich in [Murphy 2005]. In Abschnitt A.2 wird auf das in dieser Arbeit angewendete Softwarepaket eingegangen.

4.2 Architektur und Arbeitsweise des Prädiktionsmoduls

Innerhalb dieses Abschnittes wird die Architektur und das Vorgehen zur Fahrstreifenwechselforhersage erläutert. Dies beinhaltet eine Vorstellung der Softwarearchitektur der Umfeldwahrnehmungsplattform mit der Einordnung und Anbindung des Moduls zur Manöर्वorhersage. Es werden die Arbeitsschritte für den Online-Prozess einer Fahrstreifenwechselforhersage beschrieben. Eine Beschreibung der zugrunde liegenden Hard- und Softwareumgebung, des Laufzeitverhaltens sowie GeNIe/SMILE als Softwarepaket zur Modellierung Bayes'scher Netzwerke ist in Abschnitt A.2 gegeben.

4.2.1 Architektur

Abbildung 4.2 stellt das Schichtenmodell der Umfeldwahrnehmung des TEMPORARY AUTOPILOT inklusive der wichtigsten Verschaltungen dar, vgl. Unterabschnitt 4.3.2. Generell werden Sensordaten in der Eingabeschicht über das Fahrzeug-CAN-Netzwerk bezogen, in der Decodierungsschicht in generische Datenformate konvertiert und in der Fusionsschicht aggregiert. Weiter erfolgt in der Kodierungsschicht eine Zusammenstellung, Konvertierung und Filterung entsprechend der vereinbarten Ausgabeschnittstellen und im Anschluss in der Ausgabeschicht die Ausgabe an das Fahrzeug-Netzwerk. Die Manövervorhersage ist als Modul *Maneuver-Prediction* innerhalb der Fusionsschicht den Fusions-Modulen nachgeschaltet und mit diesen gekoppelt.

Als zentrale Eingangsdaten stehen alle geschätzten Objekte in Form einer zyklisch gesendeten Objektliste zur Verfügung. Die Objektdaten aus dem Modul *Object-Fusion* werden im *ObjectDataCollector* in die notwendige Relation zur Fahrbahn gesetzt und von dort an die Manövervorhersage übertragen. Die geschätzten Fahrbahndaten und die um Verkehrszeichen angereicherten elektronischen Kartendaten werden über je eine Dienstschnittstelle der Module *Lane-Fusion* und *ePSD/TSR-Fusion* abgefragt. Die globale Fahrstreifenzuordnung auf dem aktuellen Fahrbahnsegment wird über das Modul *EgoLaneAssignment* bezogen. Die Ausgabeschnittstelle des Moduls *Ego-Fusion* wird innerhalb einer allen übrigen Modulen zugrunde liegenden Basisklasse zur Verfügung gestellt und ist daher in der Abbildung nur rudimentär verschaltet.

Die im Modul *Maneuver-Prediction* um eine Manövervorhersage ergänzten Objekte werden als Objektliste über einen Ausgabeselektor in der Codierungsschicht nach festgelegten Kriterien gefiltert und über die Ausgabeschicht an das Fahrzeugnetzwerk übertragen. Die Struktur des Moduls ist in Abbildung 4.3 gegeben. Um eine Austauschbarkeit der Prädiktionsmethode zu gewährleisten wird diese über einen Wrapper mit definierten Schnittstellen gekapselt.

4.2.2 Vorgehen

Innerhalb des Moduls *Maneuver-Prediction* wird für jedes Objekt die Wahrscheinlichkeitsverteilung für einen Fahrstreifenwechsel über die in Tabelle 4.5 in Unterabschnitt 4.4.1 beschriebenen Zeitintervalle geschätzt. Diese Information wird anschließend dem Objekt hinzugefügt.

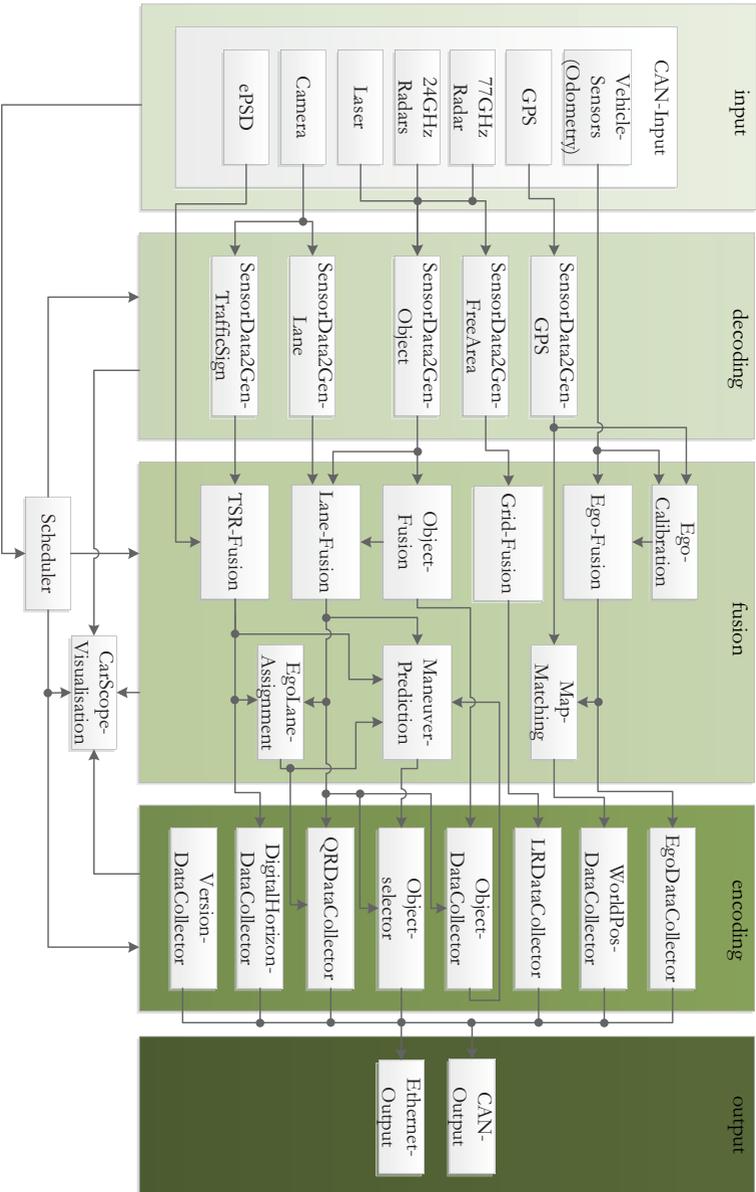


Abbildung 4.2: Strukturdiagramm Umfeldwahrnehmung; vgl. [Weiser u. a. 2012]

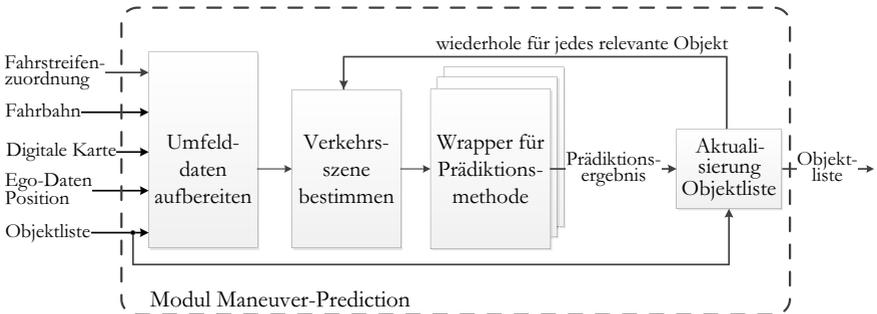


Abbildung 4.3: Struktur & Ablauf im Modul *Maneuver-Prediction*

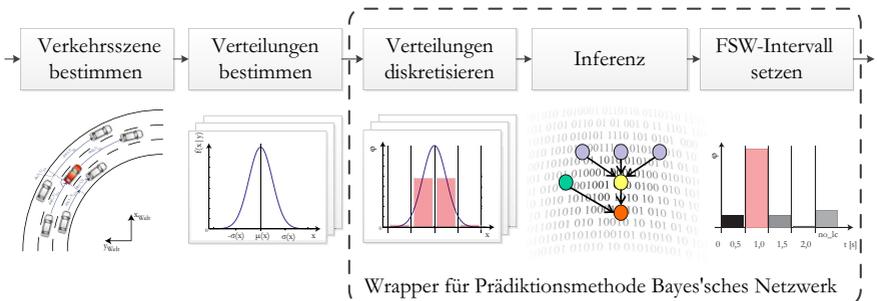


Abbildung 4.4: Ablauf Schätzung Fahrstreifenwechsel im Wrapper für die Prädiktionmethode Bayes'sches Netzwerk

Das gewählte Vorgehen ist in Abbildung 4.3 und 4.4 dargestellt, die Arbeitsschritte werden nachfolgend erläutert.

Umfelddaten aufbereiten: Es erfolgt eine Abfrage der Dienstschnittstelle für Fahrbahn, elektronische Straßenkarte und Ego-Zustand zur Bestimmung der derzeit gültigen Fahrbahnsituation inklusive der Verkehrsregeln. Anschließend erfolgt eine Vorfilterung der Objektliste auf relevante Objekte im Wirkungsbereich des TAP. Die folgenden Arbeitsschritte werden für jedes relevante Objekt ausgeführt:

Verkehrsszene bestimmen: Für jedes Objekt der Objektmatrize wird eine Beschreibung der Verkehrsszene ermittelt. Hierzu werden der Zustand des betreffenden Objektes, des relevanten Fahrbahnabschnittes und der benachbarten Objekte entsprechend der in Unterabschnitt 4.5.2 beschriebenen Umgebungsmaske herangezogen. Es erfolgt eine Berechnung der Eingangsdaten wie in Abschnitt 4.5 beschrieben. Aus Objektbeziehungen ermittelte

Eingangsdaten werden zwischengespeichert, um ggf. eine Mehrfachberechnung bei der Betrachtung des unmittelbaren Nachbarobjektes zu vermeiden.

Bestimmung der Eingangsverteilungen: Die Verteilungen der Eingangsdaten werden entsprechend Abschnitt 4.5 bestimmt.

Diskretisierung der Eingangsverteilungen: Alle kontinuierlichen Eingangsverteilungen werden diskretisiert, vgl. Abschnitt 5.2. Die diskreten Verteilungen werden auf weiche Evidenz geprüft und entsprechend Unterabschnitt 2.3.2.1 in virtuelle Evidenz transformiert.

Setzen der Eingangsverteilungen und Inferenz: Die Evidenzvariablen des Bayes'schen Netzwerks werden mit den diskretisierten Eingangsverteilungen aktualisiert und der Inferenzprozess wird angestoßen, vgl. Unterabschnitt 2.3.2 u. [Klass 2009].

FSW-Intervall setzen: Infolge des Inferenzprozesses im Bayes'schen Netzwerk wird in der Variable *lane change* die Verteilung über die Zeitintervalle für einen Fahrstreifenwechsel nach links und rechts geschätzt. Das betreffende Objekt wird um diese Information ergänzt.

Aktualisierung Objektliste: Die Objektliste wird um das Objekt, für das eine Fahrstreifenwechselvorhersage erfolgt ist, aktualisiert.

4.3 Umfeldwahrnehmungsplattform

Die Bestimmung der Eingangsgrößen für eine Fahrstreifenwechselvorhersage soll auf Basis der in Abbildung 4.5 vorgestellten Sensorplattform des TEMPORARY AUTOPILOT erfolgen. Über diese werden Daten des Verkehrsumfeldes inklusive des eigenen Fahrzeuges erfasst und über den Prozess einer Sensordatenfusion in einem Umfeldmodell abgebildet. Dieses Umfeldmodell stellt die rechnerinterne Repräsentation der Umgebung dar. Der folgende Abschnitt beschreibt die Umfeldwahrnehmungsplattform des TEMPORARY AUTOPILOT bestehend aus Versuchsfahrzeug, Sensorik und Umfeldwahrnehmungsprozess.

4.3.1 Sensorik und Versuchsfahrzeug

Die Umfeldwahrnehmungsplattform dient der Erfassung und Verfolgung des Fahrzeugumfeldes. Sie besteht physisch aus einem Versuchsfahrzeug, einem Sensorfusionsrechner und den per CAN-Bus angeschlossenen Umfeldsensoren.

Basis der Umfeldwahrnehmungsplattform ist ein Volkswagen Passat Variant, Baujahr 2009, 2.0l (125 KW) TDI-Motor mit Direktschaltgetriebe. Über

modifizierte Schnittstellen ist die Aktorik des Fahrzeuges sowohl longitudinal als auch lateral elektronisch ansteuerbar.

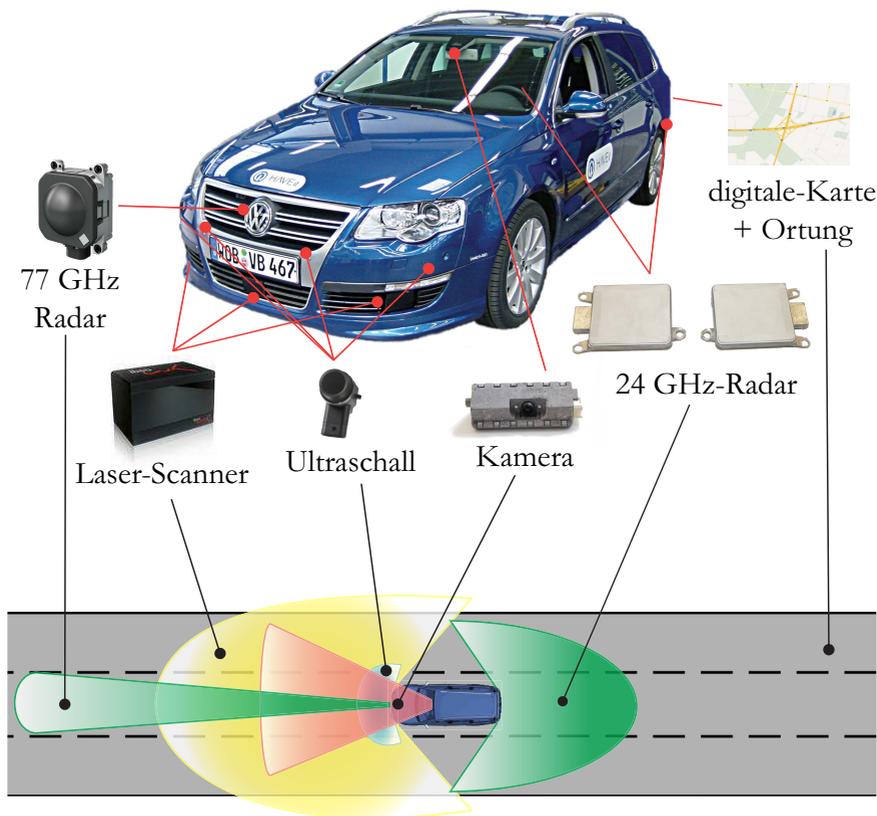


Abbildung 4.5: Versuchsfahrzeug, Umfellsensoren u. Sichtbereiche (nicht maßstäblich) des Temporary Autopilot, angelehnt an [Bartels u. a. 2011]

Das Fahrzeug ist bereits ab Werk mit einer Mono-Kamera des Spurhalteassistenten und einem Ultraschallsystem zur Einparkunterstützung ausgestattet. Die Kamera liefert Fahrstreifendaten mit einer Reichweite von circa 30 m, die Ultraschallsensoren liefern radiale Abstandsinformation bis zu einer Reichweite von circa 3 m. Die Signale werden über eine Schnittstelle gemeinsam mit den Daten der Fahrdynamiksensoren des Fahrzeuges zur Verfügung gestellt. Zusätzlich ist das Fahrzeug im Front- und Heckbereich mit Sensorik

zur Objekt- und Freiflächendetektion ausgestattet: Zum Einsatz kommen ein 77 GHz-Fernbereichsradar mit einem Öffnungswinkel von 8° und einer Reichweite von circa 150 m und drei Stück in der Frontschürze verbauten Laserscannern mit einer Reichweite von 150 m und einem Öffnungswinkel von jeweils 85° . Die äußeren Laserscanner sind jeweils um 30° nach außen geneigt. Im Heckbereich ist auf der Fahrer- und Beifahrerseite jeweils ein 24 GHz-Radar mit einer Reichweite von circa 70 m verbaut. Die Verbaupositionen der Sensoren sowie deren Sichtbereiche sind in Abbildung 4.5 skizziert.

4.3.2 Umfeldmodell und Sensordatenfusionsprozess

Innerhalb dieses Unterabschnittes werden die Bestandteile des Umfeldmodells und Sensordatenfusionsprozesses vorgestellt und ihre Funktion umrissen. Für eine detaillierte Architekturbeschreibung des Wahrnehmungsprozesses des TEMPORARY AUTOPILOT sei auf [Steinmeyer u. a. 2010] verwiesen.

Das Umfeldmodell beschreibt den Zustand des eigenen Fahrzeuges, den Zustand von Umfeldobjekten sowie den Verlauf und die Befahrbarkeit der Straße. Die Schätzung und Aktualisierung der Teilmodelle erfolgt über jeweils separate Fusionskomponenten, die über definierte Schnittstellen miteinander agieren. Als Eingangsdaten für die Vorhersage von Fahrstreifenwechselmanövern sollen insbesondere die Schätzergebnisse der Egofusions-, der Objektfusions- und der Fahrbahnfusionskomponente dienen. Deren Funktionsweise wird daher in den folgenden Unterabschnitten umrissen. Weitere hier nicht näher beschriebene Teilfusionen des TAP sind die Gridfusion zur Schätzung der Befahrbarkeit des unmittelbaren Umfeldes und die Fahrerzustandsfusion, über die ein Maß zur Beurteilung der Aufmerksamkeit des Fahrzeugführers ermittelt wird.

4.3.2.1 Egozustandsfusion

Die Egozustandsfusion schätzt den Dynamikzustand des eigenen Fahrzeuges über ein Kalman-Filter aus den Daten der Fahrzeugodometrie (Raddrehzahlsensoren). Der geschätzte Zustand ist in Tabelle 4.1 gegeben. Eine Änderung des Radumfangs zur Laufzeit wird durch einen Radumfangsschätzer berücksichtigt. Die Position des Fahrzeuges wird in einem ortsfesten kartesischen Koordinatensystem geschätzt. Die Positionsangaben sind sprungfrei, finden jedoch nur im unmittelbaren Wirkungsraum des TAP Anwendung, da prinzipbedingte Odometriefehler mit Zunahme der gefahrenen Wegstrecke einen

wachsenden Positionierungsfehler nach sich ziehen, vgl. Abbildung 4.6. Der Versatz des Ego-Koordinatensystems zu einem globalen Koordinatensystem wird über ein Mapmatching-Modul bestimmt.

Tabelle 4.1: Geschätzter Zustandsvektor des Ego-Fahrzeuges

x	globale x -Position bzgl. Koordinatenursprung [m]
y	globale y -Position bzgl. Koordinatenursprung [m]
s	gefahrte Wegstrecke vom Koordinatenursprung [m]
v_C	Kursgeschwindigkeit [m/s]
a_C	Kursbeschleunigung [m/s ²]
ψ	Kurswinkel [°]
$\dot{\psi}$	Gierrate [°/s]



Abbildung 4.6: Trajektorie des Ego-Fahrzeuges auf einer Kreisbahn (Ausdehnung: 800 m längs, 400 m quer): rot - GPS-Trajektorie, blau - geschätzte Trajektorie aus der Ego-fusion

4.3.2.2 Objektfusion

Sensoren zur Erfassung von Objekten beschreiben das Verkehrsumfeld als eine Menge detektierter Objekte. Hierbei werden die Objekteigenschaften wie Position, Abmessungen und Dynamik durch einen Zustandsvektor und die

zugehörigen Unsicherheiten über eine Kovarianzmatrix modelliert. Mithilfe des Kalmanfilterverfahrens werden die Sensormessungen aggregiert und die Objekteigenschaften geschätzt. Sofern Messdaten zur Verfügung stehen, welche die geometrischen Eigenschaften eines Objektes beschreiben, erfolgt die Verfolgung per Boxmodell, andernfalls per Punktmodell. Die geschätzten Objekteigenschaften sind in Tabelle 4.2 aufgeführt. Abbildung 4.7 zeigt die geschätzte Position und die geometrischen Eigenschaften eines Objektes aus den Beobachtungen zweier Sensoren sowie der Objekthistorie (nicht abgebildet).

Tabelle 4.2: Geschätzter Zustandsvektor für Umfeldobjekte

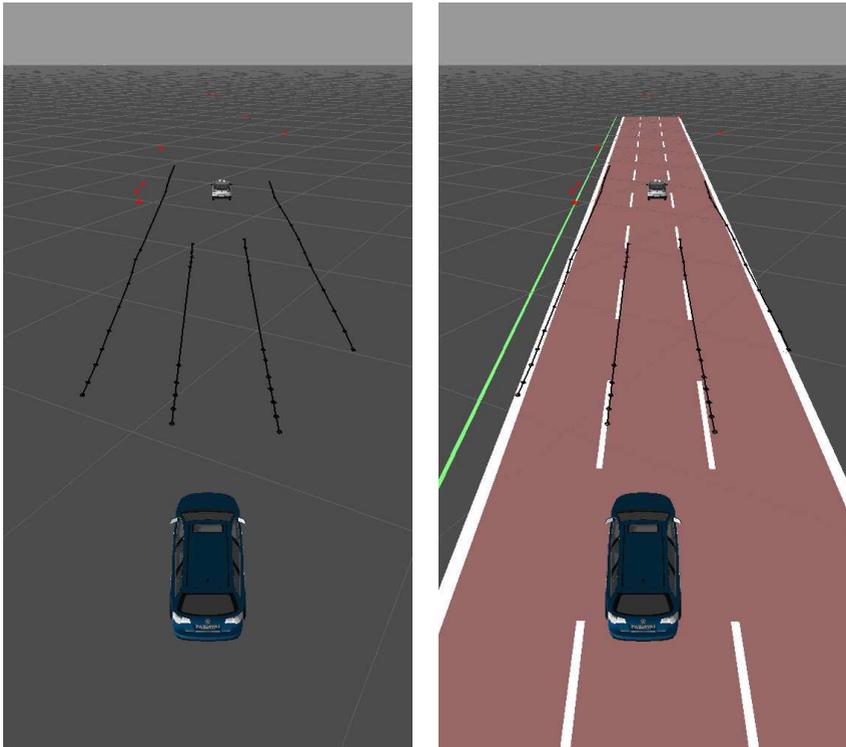
x	x-Abstand zum Ego-Fahrzeug [m]
y	y-Abstand zum Ego-Fahrzeug [m]
v_x	Relativgeschwindigkeit in x-Richtung [m/s]
v_y	Relativgeschwindigkeit in y-Richtung [m/s]
a_x	Relativbeschleunigung in x-Richtung [m/s^2]
a_y	Relativbeschleunigung in y-Richtung [m/s^2]
w	Objektbreite [m]
l	Objektlänge [m]



Abbildung 4.7: Objektfusion: *rot* - Beobachtung Sensor 1, *grün* - Beobachtung Sensor 2, *weiß* - fusioniertes Objekt, (*blau* - Ego-Fahrzeug)

4.3.2.3 Fahrbahnfusion

Die Fahrbahnfusion schätzt den exakten Fahrbahnverlauf im unmittelbaren Wirkungsraum des TAP. Mithilfe eines Kalmanfilters wird ein 2-Segmentmodell als Referenzlinie geschätzt, das jeweils aus einem Polynom 3. Grades besteht. Der geschätzte Zustandsvektor ist in Tabelle 4.3 gegeben, die zugehörige Kovarianzmatrix ist hier nicht aufgeführt. Weiterhin wird die Ablage jeder Fahrstreifenmarkierung zur Fahrbahnreferenzlinie geschätzt.



(a) Eingangsdaten

(b) Fahrbahnmodell

Abbildung 4.8: 4.8(a) Eingangsdaten der Fahrbahnfusion: Markierungsstützpunkte der Kamera (schwarze Linien), Randobjekte Radar (rote Sterne), Umfeldobjekt (weißes Fahrzeug); 4.8(b) Fahrbahnmodell: Fahrbahn (graurote Fläche), Fahrbahnmarkierung (weiße Linien), Fahrbahnbegrenzungsschätzung (grüne Linie), Ego-Fahrzeug (blaues Fahrzeug)

Das Fahrbahnmodell bildet nur die über die Sensorik beobachteten Fahrstreifen ab, d. h. gegebenenfalls nur einen Teil der tatsächlich vorhandenen Fahrstreifen. Über eine Ausgabeschnittstelle lassen sich die Parameter der Fahrbahn in einer definierten Entfernung zum Ego-Fahrzeug oder die Position von Objekten relativ zur Fahrbahn abfragen. Die Ausgabe erfolgt im Fahrbahnkoordinatensystem.

Als Eingangsdaten dienen der beobachtete Verlauf der Fahrbahnmarkierungen in Form von segmentierten Stützpunkten aus der Kamera, Randobjekte aus dem Radarsensor, die den Fahrbahnverlauf beschreiben, sowie Trajektorien von vorausfahrenden Fahrzeugen aus der Objektfusion. Zur Initialisierung der Krümmung eines neuen Segmentes werden die Daten einer mit einem Ortungsmodul gekoppelten digitalen Straßenkarte genutzt. Die Visualisierung der Eingangsdaten und des Fahrbahnmodells ist in Abbildung 4.8 dargestellt, den geschätzten Zustandsvektor der Fahrbahn zeigt Tabelle 4.3. Die Schätzung des Fahrbahnmodells beruht auf der Grundannahme, dass die beobachteten Markierungen parallel verlaufen, stationär, d. h. ortsfest sind und sich das Ego-Fahrzeug relativ zu diesen bewegt. Auf Basis der Bewegung des Ego-Fahrzeuges wird der Zustand des Fahrbahnmodells unter Anwendung von Prozessrauschen bewegungsentsprechend vorhergesagt. Die Assoziation von gemessenen Fahrbahnmerkmalen, z. B. Markierungen, mit dem Modell aktualisiert dieses ebenso und reduziert die Zustandsunsicherheit. Abhängig von der Filterparametrisierung führt somit ein kurzzeitiges Fehlen von gemessenen Fahrbahnmerkmalen, unter Inkaufnahme einer erhöhten Zustandsunsicherheit, nicht zum Ausfall der Fahrbahnfusion.

Tabelle 4.3: Geschätzter Zustandsvektor der Fahrbahn

y_0	lateraler Versatz zum Straßenreferenzpunkt [m]
ψ_0	Ausrichtung der Fahrbahn bei $s = 0$ [rad]
κ_0	Krümmung der Fahrbahn bei $s = 0$ [rad/m^2]
$\dot{\kappa}$	Krümmungsänderung entlang des 1. Segment [rad/m^2]
$\Delta\dot{\kappa}$	Δ Krümmungsänderung zu Beginn des 2. Segmentes [rad/m^2]

Zusätzlich zu den geometrischen Eigenschaften der Fahrbahn wird die Ausprägung jeder Markierung auf der Höhe des Ego-Fahrzeuges per Dempster-Shafer-Verfahren (vgl. Unterabschnitt 2.2.5) geschätzt. Hierbei spannen die Art und die Breite der Markierung jeweils einen separaten Wahrnehmungsrahmen auf. Das gewählte Verfahren erlaubt für jedes Merkmal die Modellierung

des Zustandes *unbekannt* in Form von *unterbrochen oder durchgezogen* ($\theta_{utbr} \cup \theta_{dgez}$) für die Markierungsart und *Schmalstrich oder Dickstrich* ($\theta_{schm} \cup \theta_{dick}$) für die Markierungsbreite, (vgl. Tabelle 4.4). Über diesen Zustand wird eine wegstreckenabhängige Vergessensrate modelliert, um eine dynamische Änderung des Merkmalszustandes zu ermöglichen.

Tabelle 4.4: Geschätzte Merkmale einer Fahrbahnmarkierung nach Dempster-Shafer; Bezeichnung der Teilevidenzen: θ_{utbr} - unterbrochen, θ_{dgez} - durchgezogen, θ_{schm} - Schmalstrich, θ_{dick} - Dickstrich, \emptyset - leere Menge

Merkmal	Wahrnehmungsrahmen	Teilmengen (hyperpowerset)
Art	$\Theta_{Art} = \{\theta_{utbr}, \theta_{dgez}\}$	$\{\emptyset, \{\theta_{utbr}\}, \{\theta_{dgez}\}, \{\theta_{utbr} \cup \theta_{dgez}\}\}$
Breite	$\Theta_{Breite} = \{\theta_{schm}, \theta_{dick}\}$	$\{\emptyset, \{\theta_{schm}\}, \{\theta_{dick}\}, \{\theta_{schm} \cup \theta_{dick}\}\}$

4.3.2.4 Ausgabeschnittstelle des Umfeldmodells

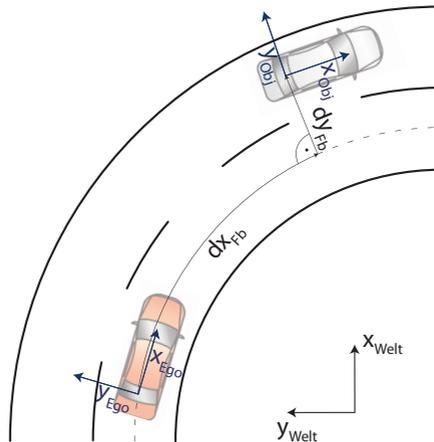


Abbildung 4.9: Angewandte Umfeldkoordinatensysteme: fahrbahnrelatives Koordinatensystem (*Fb*), absolutes Koordinatensystem (*Welt*), fahrzeugrelative Koordinatensysteme *Ego*, *Obj*

Das Umfeldmodell des TAP kann über Ausgabeschnittstellen abgefragt werden. Der Zustand des Umfeldmodells wird hierfür auf den Ausgabezeitpunkt

vorhergesagt. Die Eigenschaften der Fahrbahn und des Ego-Fahrzeuges können über eine Dienste-Schnittstelle abgerufen werden, vgl. [Steinmeyer u. a. 2010]. Verfolgte Umgebungsobjekte werden zur detektierten Fahrbahn in Relation gesetzt und mit Merkmalen wie einer relativen Fahrstreifenzuordnung (zum Ego-Fahrzeug) und der Ablage auf der Fahrbahn ergänzt. Sie werden als Objektliste zur Verfügung gestellt. Die Positionsangaben der Objekte werden hierbei in ein fahrbahnrelatives Koordinatensystem (Fb) transformiert: dx_{Fb} gibt den longitudinalen Abstand des betrachteten Objektes zum Ego-Fahrzeug entlang der Fahrstreifenmitte des Egofahrstreifens an. dy_{Fb} gibt den lateralen Versatz des Objektes zur Fahrbahnmitte des Egofahrstreifens entlang der positiv orientierten Orthogonalen an der Stelle x an. Abbildung 4.9 verdeutlicht diesen Zusammenhang.

Über einen weiteren Dienst können Informationen zur Fahrbahn aus einer digitalen Straßenkarte abgerufen werden, hierzu zählen beispielsweise die Anzahl der zur Verfügung stehenden Fahrstreifen, Geschwindigkeitsbeschränkungen und Überholverbote.

4.4 Klassen- und Evidenzvariablen

Mithilfe eines Bayes'schen Netzwerks kann eine hochdimensionale Verbundverteilung einer Menge von Zufallsvariablen zur Schätzung eines Fahrstreifenwechsels als strukturierte Zerlegung in niedrigdimensionale Verteilungen über einen gerichteten Graphen abgebildet werden, vgl. Unterabschnitt 2.2.4. Die Dimensionalität wird aus der Vielzahl der gegebenen Einflussfaktoren in Abbildung 3.13 auf Seite 86 ersichtlich. Die Graphenstruktur beinhaltet sowohl Variablen, im Folgenden als Evidenzvariablen bezeichnet, welche direkt über die Wahrnehmungsplattform beobachtet werden können, als auch indirekt beobachtbare Variablen. Letztere sind zunächst ausschließlich latent und sollen im Zuge der Bestimmung der Graphenstruktur über maschinelle Lernverfahren identifiziert werden, vgl. Kapitel 5. Innerhalb dieser Arbeit soll die Identifizierung solcher latenten Variablen zur Modellierung von gegebenenfalls vorhandenen Abhängigkeiten zwischen den direkt beobachtbaren Variablen eingesetzt werden.

In diesem Abschnitt erfolgt zunächst die Definition der Klassenvariable ausgehend von den in Abschnitt 4.1 definierten Anforderungen. Im Anschluss erfolgt eine Zusammenstellung möglicher Evidenzvariablen auf Basis der in Kapitel 3 erarbeiteten Grundlagen sowie der Spezifikation der eingesetzten Umfeldwahrnehmungsplattform (vgl. Abschnitt 4.3).

4.4.1 Definition der Klassenvariable

Basierend auf einer aktuellen Konfiguration an Eingangsdaten soll der wahrscheinlichste Zeitpunkt eines innerhalb des Zeitintervalls $(0,2] s$ bevorstehenden Fahrstreifenwechsels vorhergesagt werden.

Es verbietet sich die Schätzung der Wahrscheinlichkeit für einen exakten Zeitpunkt t_0 , da dies unendlich viele Realisationen der stetigen Zufallsgröße Zeit t im genannten Zeitintervall impliziert, deren Eintrittswahrscheinlichkeit jeweils null beträgt: $\{t \in \mathbb{R} | 0 < t \leq 2\} \Rightarrow P(LC = t_0) = 0$.

Entsprechend wird das Ereignis Fahrstreifenwechsel im Folgenden als zeitdiskrete Zufallsvariable $LC = lane_change$ mit äquidistanten Zeitintervallen definiert, vgl. [Weiser 2010]. Für einen Vorhersagezeitraum von $2 s$ mit einer Schrittweite von $0,5 s$ ergeben sich neun Zeitintervalle als Realisationen lc_i , vgl. Tabelle 4.5 sowie Gleichungen 4.1 und 4.2.

$$lc_i = (lc_1, lc_2, \dots, lc_9)^T \quad (4.1)$$

$$= (no_lc, lc_left_0.5, lc_left_1.0, lc_left_1.5, lc_left_2.0, \\ lc_right_0.5, lc_right_1.0, lc_right_1.5, lc_right_2.0)^T \quad (4.2)$$

Tabelle 4.5: Zeitintervalle und deren Nomenklatur innerhalb dieser Arbeit. Das Intervall $(2; \infty) s$ steht für *kein Wechsel*, alle weiteren für *Wechsel*.

Zeitintervall	lc_i	Zeitintervall	lc_i	Zeitintervall	lc_i
kein FSW		FSW links		FSW rechts	
$(2; \infty) s$	no_lc	$(0,0; 0,5] s$	$lc_left_0.5$	$(0,0; 0,5] s$	$lc_right_0.5$
		$(0,5; 1,0] s$	$lc_left_1.0$	$(0,5; 1,0] s$	$lc_right_1.0$
		$(1,0; 1,5] s$	$lc_left_1.5$	$(1,0; 1,5] s$	$lc_right_1.5$
		$(1,5; 2,0] s$	$lc_left_2.0$	$(1,5; 2,0] s$	$lc_right_2.0$

Die Zufallsvariable LC bildet folglich innerhalb des Bayes'schen Netzwerks die Klassenvariable, welche von n Zufallsvariablen abhängig einen *Fahrstreifenwechsel* modelliert. Ziel ist die Bestimmung der Wahrscheinlichkeit

$$P(LC = lc_i | X)$$

für jede Realisation lc_i , d. h. der Verteilung der Zufallsvariablen für jede gegebene Konfiguration X an Eingangsdaten.

4.4.2 Definition Evidenzvariablen

Die folgende Zusammenstellung potentieller Eingangsmerkmale, d. h. Evidenzvariablen, erfolgt unter Berücksichtigung der in Abbildung 3.13 aufgeführten Einflussmerkmale und der in Abschnitt 4.1 gegebenen Anforderung auf Basis der Spezifikation der eingesetzten Umfeldwahrnehmungsplattform (vgl. Abschnitt 4.3). Diese beinhaltet beispielsweise weder die Berücksichtigung fahrzeugklassenspezifischer Beschränkungen wie z. B. Geschwindigkeitsbeschränkungen für LKW noch spezielle Ein- und Ausfädel Situationen an Autobahnein- und ausfahrten, da diese zum Zeitpunkt der Datenerfassung noch nicht modelliert waren.

Alle Merkmale beziehen sich auf das Bezugsobjekt, d. h. ein potentiell fahrstreifenwechselndes Fahrzeug, vgl. Abbildung 4.10. Gegeben sind nachfolgend: eine Beschreibung des Eingangsmerkmals, eine Knotenbezeichnung und zugehörige ID zur eindeutigen Identifikation des Merkmals im weiteren Verlauf der Arbeit. Für eine Herleitung der Merkmale wird auf Abschnitt 4.5 verwiesen.

4.4.2.1 Laterale Indikation

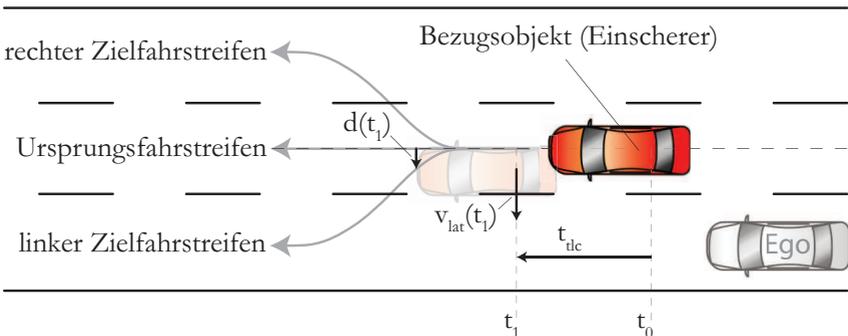


Abbildung 4.10: Eingangsmerkmale der lateralen Indikation: Ablage $d(t)$, Quergeschwindigkeit v_{lat} und Zeit bis zum Queren der Markierung t_{tlc}

Die laterale Indikation beinhaltet Merkmale, welche aus einem bereits initiierten bzw. unmittelbar bevorstehenden Fahrstreifenwechsel und der daraus resultierenden Querbewegung folgen. Hierzu gehören die Ablage des Fahrzeuges innerhalb des Fahrstreifens (deviation), die Quergeschwindigkeit (v_{lat}) und die Zeit bis zum Queren der Markierungslinie (t_{tlc}), vgl. Tabelle 4.6. Nicht aufgeführte interessante Eingangsmerkmale sind der Gierwinkel bzw.

die Gierrate des Fahrzeuges und die Fahrtrichtungsanzeiger. Diese Merkmale werden nicht betrachtet, da sie zum Stand der Datenerhebung von der Umfeldwahrnehmungsplattform für Umfeldobjekte z. T. nicht beobachtet werden konnten und dementsprechend nur für das Ego-Fahrzeug zur Verfügung stünden.

Tabelle 4.6: laterale Indikation

Merkmalsbeschreibung	Knotenbezeichnung	ID
Zeit bis zum Queren der linken Markierung (Wert positiv) bzw. der rechten Markierung (Wert negativ) des Ursprungs-FS durch das einscherende Fzg.	ttlC	1
laterale Ablage des einscherenden Fzgs. im Ursprungs-FS	deviation	2
laterale Geschwindigkeit des einscherenden Fzgs.	vLat	3

4.4.2.2 Fahrbahn

Tabelle 4.7: Fahrbahn

Merkmalsbeschreibung	Knotenbezeichnung	ID	
Distanz bis Befahrbarkeitsende des	Ursprungs-FS	distance2LaneEnd-Center	5
	linken Ziel-FS	distance2LaneEndLeft	8
	rechten Ziel-FS	distance2LaneEndRight	16
Überholverbot (FS-Markierung oder Verkehrszeichen) zur	linken Seite	noPassingLeft	28
	rechten Seite	noPassingRight	29
Anzahl Fahrstreifen bis zum äußerst rechten Fahrstreifen	lanes2mostRightLane	30	

Es wird angenommen, dass das Befahrbarkeitsende eines Fahrstreifens einen Fahrstreifenwechsel beeinflusst, ebenso Überholverbote und das

Rechtsfahrgebot. Entsprechend wird die Distanz bis Befahrbarkeitsende des Ursprungs- und angrenzender Fahrstreifen, als auch ein Überhol- bzw. Wechselverbot in angrenzende Fahrstreifen als Eingangsmerkmal verwendet, vgl. Tabelle 4.7. Um den potentiellen Einfluss des Rechtsfahrgebotes auf einen Fahrstreifenwechsel abzubilden, wird die Anzahl der Fahrstreifen bis zum äußerst rechten regulären Fahrstreifen bestimmt.

4.4.2.3 Verkehrsgeschwindigkeit

Fahrstreifenwechselforgänge sind häufig Reaktionserscheinungen auf Behinderungen, z. B. bzgl. der Wunschgeschwindigkeit des Fahrers. Da die Wunschgeschwindigkeit des Fahrers nicht bekannt ist, finden die in Tabelle 4.8 gegebenen Situationsmerkmale Anwendung. Diese geben die Differenz der fahrstreifenbezogenen räumlich gemittelten Verkehrsgeschwindigkeit zu der für den Streckenabschnitt erlaubten Höchstgeschwindigkeit bzw. der Geschwindigkeit des Bezugsobjektes an.

Tabelle 4.8: Verkehrsgeschwindigkeit

Merkmalsbeschreibung		Knotenbezeichnung	ID
Differenz der Geschwindigkeitsbegrenzung zur aktuellen Durchschnittsgeschwindigkeit auf dem	Ursprungs-FS	vMax2vActCenter	4
	linken Ziel-FS	vMax2vActLeft	9
	rechten Ziel-FS	vMax2vActRight	17
Differenz der Geschwindigkeit des einscherenden Fzgs. zur aktuellen Durchschnittsgeschwindigkeit auf dem	linken Ziel-FS	vActRefObj2vAct-LaneLeft	10
	rechten Ziel-FS	vActRefObj2vAct-LaneRight	18

4.4.2.4 Beziehung zu Umfeldobjekten

Im Folgenden sind Situationsmerkmale zusammengefasst, welche auf Grund der Einwirkung der unmittelbar das Bezugsobjekt umgebenden Verkehrsteilnehmer einen Fahrstreifenwechsel motivieren bzw. hemmen, d. h. potentielle Kosten für den Fahrzeugführer als auch für andere beteiligte Verkehrsteilnehmer infolge eines Fahrstreifenwechsels darstellen. Diese möglichen Objekt-Objekt Beziehungen sind in Abbildung 4.12 auf Seite 115 abgebildet. Es

wird angenommen, dass geringe Zeitlücken, hohe Geschwindigkeitsdifferenzen oder geringe Abstände zwischen einem herannahenden Fahrzeug und einem potentiellen Einscherer einen Einschervorgang hemmen, d. h. für den Einscherer bzw. das herannahende Fahrzeuge zu hohen Kosten hinsichtlich des Stellaufwandes in Form positiver bzw. negativer Beschleunigungsvorgänge führt. Entsprechend werden die in Tabelle 4.9 gegebenen Situationsmerkmale wie die Zeitlücke, der Längsabstand und die Geschwindigkeitsdifferenz (modelliert als Lückenausdehnungsgeschwindigkeit) zwischen zwei Fahrzeugen angewendet.

Tabelle 4.9: Beziehung zu Umfeldobjekten

Merkmalsbeschreibung		Knotenbezeichnung	ID
Zeitlücke zu einem unmittelbar vorausfahrendem Fzg. auf dem	Ursprungs-FS	timeGapFrontCenter	22
	linken Ziel-FS	timeGapFrontLeft	11
	rechten Ziel-FS	timeGapFrontRight	19
Zeitlücke zu einem unmittelbar folgendem Fzg. auf dem	Ursprungs-FS	timeGapBackCenter	25
	linken Ziel-FS	timeGapBackLeft	6
	rechten Ziel-FS	timeGapBackRight	14
zeitliche Änderung des Abstandes zu einem unmittelbar vorausfahrendem Fzg. auf dem	Ursprungs-FS	expRateGapFrontCenter	24
	linken Ziel-FS	expRateGapFrontLeft	11
	rechten Ziel-FS	expRateGapFrontRight	19
zeitliche Änderung des Abstandes zu einem unmittelbar folgendem Fzg. auf dem	Ursprungs-FS	expRateGapBackCenter	27
	linken Ziel-FS	expRateGapBackLeft	7
	rechten Ziel-FS	expRateGapBackRight	15
longitudinaler Abstand zu einem unmittelbar vorausfahrendem Fzg. auf dem	Ursprungs-FS	lengthGapFrontCenter	23
	linken Ziel-FS	lengthGapFrontLeft	12
	rechten Ziel-FS	lengthGapFrontRight	20
longitudinaler Abstand zu einem unmittelbar folgenden Fzg. auf dem	Ursprungs-FS	lengthGapBackCenter	26

4.5 Eingangsdatenberechnung

Die in Abschnitt 4.4 aufgeführten Eingangsgrößen definieren die Verkehrsszene für jedes betrachtete Objekt und sind über die sensorische Wahrnehmung und Verarbeitung von Daten des Verkehrsumfeldes zu bestimmen. Dieser Abschnitt beschreibt die Vorgehensweise zur Bestimmung der Eingangsgrößen. Grundlage zur Extraktion der Verkehrsszene ist das in Abschnitt 4.3 beschriebene Umfeldmodell. Die nachfolgend bestimmten Werte liegen größtenteils in einer kontinuierlichen Form vor, d. h. sie werden beschrieben durch Zustand und Unsicherheit, und sind vor dem Einbringen als Evidenz in ein diskretes Bayes'sches Netzwerk in geeigneter Form zu diskretisieren, vgl. Abschnitt 5.2.

4.5.1 Fahrbahn und Verkehrsfluss

Für die Eingangsknoten *vlat* und *deviation* aus Tabelle 4.6 können Zustand und Unsicherheit direkt aus dem Umfeldmodell entnommen werden. Für die Knoten *noPassingLeft* und *noPassingRight* aus Tabelle 4.7 wird eine binäre Verteilung aus der in Unterabschnitt 4.3.2.3 bestimmten Dempster-Shafer Verteilung approximiert. Zweckmäßig geschieht dies durch eine Normierung der Evidenz auf eins für die Zustände der jeweiligen Fahrbahnmarkierungen rechts und links vom betrachteten Fahrzeug. Diese Zustände sind *unterbrochen* (θ_{utbr}) und *durchgezogen* (θ_{dgez}) bei $m(utbr \cup dgez) > 0$ bzw. unter der Annahme einer Gleichverteilung bei vollständigem Unwissen, d. h. $m(utbr \cup dgez) = 0$.

Zeit bis zum Queren der Markierung: Die Berechnung des Eingangsknotens t_{tlc} erfolgt nach Gleichung 4.3b unter der Annahme, dass sich die Quergeschwindigkeit unmittelbar vor einem Fahrstreifenwechsel annähernd linear verhält, d. h. die Querbeschleunigung konstant ist.

Auf Basis der zur Verfügung stehenden Messdaten lassen sich für Fahrstreifenwechsel nach links und rechts die Querbeschleunigungskonstanten $a_{latL} = 0,38$ und $a_{latR} = -0,33$ experimentell bestimmen. Eine im Rahmen der experimentellen Bestimmung von a_{latL}, a_{latR} durchgeführte Analyse zeigt, dass sich die Quergeschwindigkeit nur innerhalb des Zeitraumes von 0..1,5 s vor Berührung der Fahrbahnmarkierung annähernd linear verändert und diese Änderung ab einer $t_{tlc} > 1,5$ s zunehmend nichtlinear wird. Für das hier betrachtete Zeitintervall von 0..2 s scheint die Linearitätsannahme gerade noch anwendbar.

Um die Annäherung an die linke oder an die rechte Markierung in einem Knoten zu codieren wird der Wert für t_{tlc} entsprechend Formel 4.3a positiv für eine Annäherung an die Markierung links vom Fahrzeug und negativ für die Annäherung an die Markierung zur rechten Seite definiert. Der Wert wird zu null, d. h. ungültig, sobald das Fahrzeug mit einer Fahrzeugaußenseite jeweils die linke oder rechte Markierung überquert oder die Quergeschwindigkeit v_{lat} genau null beträgt. t_{tlc} wird nach Gleichung 4.3b bestimmt. Die Herleitung findet sich in Abschnitt A.3.

$$t_{tlc} \begin{cases} > 0 & : v_{lat} > 0, \frac{w-w_o}{2} > |d|, \\ < 0 & : v_{lat} < 0, \frac{w-w_o}{2} > |d|, \\ = 0 & : \text{sonst,} \end{cases} \quad (4.3a)$$

$$t_{tlc} = \begin{cases} -\frac{1}{a_{latL}} \cdot (v_{lat} - \sqrt{m}) & : v_{lat} > 0, \frac{w-w_o}{2} > |d|, \\ \frac{1}{a_{latR}} \cdot (v_{lat} + \sqrt{n}) & : v_{lat} < 0, \frac{w-w_o}{2} > |d|, \\ 0 & : \text{sonst.} \end{cases} \quad (4.3b)$$

mit der Quergeschwindigkeit v_{lat} , Fahrstreifenbreite w , Objektbreite w_o , Ablage zur Fahrstreifenmitte d und

$$\begin{aligned} m &= v_{lat}^2 - a_{latL} \cdot (2d + w - w_o), \\ n &= v_{lat}^2 - a_{latR} \cdot (2d - w + w_o). \end{aligned}$$

Die Unsicherheit bzgl. t_{tlc} berechnet sich in Form der Varianz $\sigma_{t_{tlc}}^2$ nach Gleichung 4.4a bis 4.4c unter der Annahme, dass die Funktionsparameter v_{lat}, w, w_o, d voneinander unabhängig sind, sowie a_{latL} bzw. a_{latR} bekannte Konstanten sind:

$$\sigma_{t_{tlc}}^2 = \sum_{i=1}^n \left(\frac{\partial t_{tlc}}{\partial x_i} \right)^2 \sigma_{x_i}^2 \quad \text{mit } t_{tlc} = f(x_1, \dots, x_n), x \in [v_{lat}, d, w, w_o] \quad (4.4a)$$

$$\sigma_{t_{tlc}}^2 = \left(\frac{\partial t_{tlc}}{\partial v_{lat}} \right)^2 \sigma_{v_{lat}}^2 + \left(\frac{\partial t_{tlc}}{\partial d} \right)^2 \sigma_d^2 + \left(\frac{\partial t_{tlc}}{\partial w} \right)^2 \sigma_w^2 + \left(\frac{\partial t_{tlc}}{\partial w_o} \right)^2 \sigma_{w_o}^2 \quad (4.4b)$$

$$\sigma_{t_{tlc}}^2 = \begin{cases} \frac{1}{a_{latL}^2} \left(-1 + \frac{v_{lat}}{\sqrt{l}} \right)^2 \sigma_{v_{lat}}^2 + \frac{1}{m} p & : v_{lat} > 0, \frac{w-w_o}{2} < |d|, \\ \frac{1}{a_{latR}^2} \left(1 + \frac{v_{lat}}{\sqrt{r}} \right)^2 \sigma_{v_{lat}}^2 + \frac{1}{n} p & : v_{lat} < 0, \frac{w-w_o}{2} < |d|, \\ 0 & : \text{sonst,} \end{cases} \quad (4.4c)$$

$$\text{mit } p = \sigma_d^2 + \frac{1}{4} (\sigma_w^2 + \sigma_{w_o}^2).$$

Differenzgeschwindigkeiten: Die Bestimmung der Evidenzvariablen $vMax2vActCenter$, $vMax2vActLeft$ und $vMax2vActRight$ erfolgt nach Gleichung 4.5. Die Werte der Variablen $vActRefObj2vActLaneLeft$ und $vActRefObj2vActLaneRight$ werden nach Gleichung 4.6 bestimmt. Es werden folgende Bezeichner verwendet: v_{max} für die zulässigen Höchstgeschwindigkeit, \bar{v}_{lane} für die Durchschnittsgeschwindigkeit im Fahrstreifen und v_{refObj} für die Geschwindigkeit des betrachteten Objektes.

$$v_{\Delta v_{max} \bar{v}_{lane}} = v_{max} - \bar{v}_{lane} \quad (4.5a)$$

$$\sigma_{v_{\Delta v_{max} \bar{v}_{lane}}}^2 = \sigma_{v_{max}}^2 + \sigma_{\bar{v}_{lane}}^2 \quad (4.5b)$$

$$v_{\Delta v_{refObj} \bar{v}_{lane}} = v_{refObj} - \bar{v}_{lane} \quad (4.6a)$$

$$\sigma_{v_{\Delta v_{refObj} \bar{v}_{lane}}}^2 = \sigma_{v_{refObj}}^2 + \sigma_{\bar{v}_{lane}}^2 \quad (4.6b)$$

Die Berechnung von \bar{v}_{lane} erfolgt für jeden Fahrstreifen über den nach der Varianz gewichtete Durchschnitt der Längsgeschwindigkeiten der beobachteten Umfeldobjekte. Die Formeln 4.7a bis 4.7c beschreiben den iterativen Prozess der Berechnung unter der Annahme, dass alle Objekte auf einem Fahrstreifen eine nahezu identische Geschwindigkeit aufweisen. $\bar{v}_{lane}(n)$ beschreibt die geschätzte Durchschnittsgeschwindigkeit nach dem n -ten Filterschritt, mit $n \in N, [1 < n \leq AnzahlUmfeldobjekte_{FS}]$. $v_{mess}(n)$ beschreibt die gemessene Längsgeschwindigkeit des n -ten Umfeldobjektes, $\sigma_{v_{mess}}^2$ bzw. σ_v^2 die Varianz der Messung bzw. Schätzung und k den Gewichtungsfaktor.

$$\bar{v}_{lane}(n) = \bar{v}_{lane}(n-1) + k(n) \cdot (v_{mess}(n) - \bar{v}_{lane}(n-1)) \quad (4.7a)$$

$$k(n) = \frac{\sigma_{\bar{v}_{lane}}^2(n-1)}{\sigma_{\bar{v}_{lane}}^2(n-1) + \sigma_{v_{mess}}^2(n)} \quad (4.7b)$$

$$\sigma_{\bar{v}_{lane}}^2(n) = \sigma_{\bar{v}_{lane}}^2(n-1) - k(n) \cdot \sigma_{v_{mess}}^2(n) \quad (4.7c)$$

Distanz bis Befahrbarkeitsende des Fahrstreifens Für die in Tabelle 4.7 aufgeführten Knoten $distance2LaneEndCenter$, $distance2LaneEndLeft$ und $distance2LaneEndRight$ wird die Distanz bis zum Ende der Befahrbarkeit des jeweiligen Fahrstreifens durch eine Abfrage der Gridfusion, vgl. [Steinmeyer 2009], und der digitalen Straßenkarte ermittelt. Die Auswahl erfolgt durch eine Minimumbildung über beide Distanzwerte. Ein Betrag von *null* charakterisiert die Nichtexistenz des Fahrstreifens.

Über einen Dienst der Gridfusion lässt sich für jeden Fahrstreifen die Distanz entlang der Fahrbahn von der x-Position des Referenzfahrzeuges bis zur nächsten Gitterzelle in Fahrtrichtung mit relevanter statischer Belegung ermitteln. Die Unsicherheit bzgl. der Wegstrecke folgt aus der Positionsunsicherheit des Referenzfahrzeuges im Fahrbahnkoordinatensystem und der Positionsungenauigkeit des Ego-Fahrzeuges im Belegungsgitter. Letztere ist durch eine genügend hoch gewählte Auflösung des Belegungsgitters vernachlässigbar.

Über die digitale Straßenkarte lässt sich die Distanz bis zum Ende des betreffenden Fahrstreifens bzw. der Auf-/Abfahrt ermitteln. Die Unsicherheit bzgl. der Wegstrecke folgt aus der Positionsunsicherheit des Referenzfahrzeuges im globalen Weltkoordinatensystem (durch Ortungs- und Kartenfehler) und - unter Berücksichtigung der Fehlerfortpflanzung - aus der Positionsunsicherheit im Fahrbahnkoordinatensystem.

Anzahl Fahrstreifen bis zum äußerst rechten Fahrstreifen Der in Tabelle 4.7 aufgeführte Knoten beschreibt die Anzahl der Fahrstreifenwechsel nach rechts, welche durchgeführt werden müssen, um den äußerst rechten Fahrstreifen der Hauptfahrbahn zu befahren. Der Knoten ist ausgeprägt als diskrete Wahrscheinlichkeitsverteilung bzgl. der Zuordnung des potentiellen Einscherrers über alle Fahrstreifen. Gleichung 4.8 beschreibt die Wahrscheinlichkeitsfunktion der diskreten Zufallsvariable LANES2MOSTRIGHT für eine beliebige Schätzung S der Fahrstreifenzuordnung als Summe der Einzelwahrscheinlichkeiten aller Realisationen $lanes2MostRight$.

$$P(\text{LANES2MOSTRIGHT} \in S) = \sum_{lanes2MostRight_j \in S} p(lanes2MostRight_j) \quad (4.8)$$

Als Realisationen S sind vorgesehen:

- (> 2) mehr als zwei Fahrstreifenwechsel nach rechts,
- (2) zwei Fahrstreifenwechsel nach rechts,
- (1) ein Fahrstreifenwechsel nach rechts,
- (0) kein Fahrstreifenwechsel und
- (< 0) mindestens ein Fahrstreifenwechsel nach links

um den rechten Fahrstreifen der Hauptfahrbahn zu erreichen. Die Bestimmung von *lanes2MostRight* basiert auf der Bestimmung des vom Bezugsobjekt belegten Fahrstreifens aufgrund seiner Position relativ zum Ego-Fahrzeug und der globalen Fahrstreifenzuordnung des Ego-Fahrzeuges über alle verfügbaren Fahrstreifen der Richtungsfahrbahn.

Die laterale Position (Ablage) des potentiellen Einscherers auf der Fahrbahn relativ zum Ego-Fahrzeug ist eine Zufallsvariable Y_{Fb} mit stetiger Verteilung. Bei Annahme einer Normalverteilung \mathcal{N} lässt sich die Wahrscheinlichkeitsfunktion $P(Y_{Fb})$ durch den Erwartungswert der Ablage $\mu_{y_{Fb}}$ und die zugehörige Varianz $\sigma_{y_{Fb}}^2$ beschreiben. $P(a \leq Y_{Fb} \leq b)$ als die Zuordnungswahrscheinlichkeit zu einem Fahrstreifen ergibt sich demnach durch eine Integration über die Wahrscheinlichkeitsdichtefunktion $f_{y_{Fb}}$ innerhalb der Fahrstreifenbegrenzung (Intervallgrenzen) $[a \leq b]$, vgl. Gleichung 4.9. Hierbei entspricht a der Ablage der linken und b der Ablage der rechten Markierung bzw. Begrenzung des jeweiligen Fahrstreifens.

$$P(a \leq Y_{Fb} \leq b) = \frac{1}{\sigma_{y_{Fb}} \sqrt{2\pi}} \cdot \int_a^b \left(e^{-\frac{1}{2} \left(\frac{y - \mu_{y_{Fb}}}{\sigma_{y_{Fb}}} \right)^2} \right) dy \quad (4.9)$$

Über Gleichung 4.9 lässt sich eine Fahrstreifenzuordnung des potentiellen Einscherers relativ zum Ego-Fahrzeug vornehmen, nicht jedoch zur Fahrbahn. Das heißt, es kann die Evidenz bestimmt werden, mit welcher das beobachtete Fahrzeug dem Fahrstreifen des Ego-Fahrzeuges bzw. den Fahrstreifen links oder rechts vom Ego-Fahrzeug zugeordnet werden kann.

Zur Bestimmung von $P(\text{LANES2MOSTRIGHT} \in S)$ ist eine fahrstreifengenaue Positionierung bzw. Zuordnung des beobachteten Fahrzeuges auf der Fahrbahn über alle verfügbaren Fahrstreifen notwendig. Im Vordergrund steht hier nicht die möglichst genaue Positionierung des Fahrzeuges im Weltkoordinatensystem, sondern die Zuordnung zu einem Fahrstreifen der tatsächlichen Fahrbahn. Derzeitige rein GNSS-basierte Ortungslösungen scheinen für diesen Zweck nicht ausreichend, vgl. [Haak u. a. 2010], da die Genauigkeit der Ortung und die zugrunde liegenden digitalen Straßenkarten keine fahrstreifengenaue Aussage bzgl. der Position eines Fahrzeuges auf der Fahrbahn zulassen. Technisch aufwendige, hoch genaue Ortungslösungen bieten zwar Abhilfe, setzen aber weiterhin die Verfügbarkeit einer hoch genauen Karte voraus. Sie gestalten sich in Abhängigkeit der Ausführung deutlich kostenintensiver und weisen teilweise eine unzureichende Verfügbarkeit auf, vgl. [Weiser u. a. 2009; Macht u. a. 2009].

Die Schätzung des befahrenen Fahrstreifens erfolgt daher über ein Verfahren, welches das Muster der wahrgenommenen Fahrbahnmarkierungen mit den für jede Fahrstreifenzuordnung zu erwartendem Muster vergleicht und hieraus Zuordnungshypothesen generiert. Grundlage ist die Schätzung des Fahrbahnmodells über die Fahrbahnfusion. Die Ausgabeschnittstelle der Fahrbahnfusion stellt das Markierungsmuster des beobachteten Fahrbahnabschnittes auf Höhe des Ego-Fahrzeuges zur Verfügung, vgl. Abbildung 4.11. Die zu erwartenden Muster werden anhand der Straßenbauvorschriften, vgl. [Rohloff 2002; Seliger 1998], und den in der digitalen Straßenkarte hinterlegten Eigenschaften für den aktuell befahrenen Fahrbahnabschnitt erstellt. Entsprechend wird die Fahrstreifenzuordnung zunächst für das Ego-Fahrzeug geschätzt und unter Berücksichtigung der relativen Position anderer Fahrzeuge zum Ego-Fahrzeug auf diese übertragen.

$$P(FZ \in S_{Fz}) = \sum_{fz_k \in S_{Fz}}^n p(fz_k) \quad (4.10)$$

Gleichung 4.10 beschreibt die Wahrscheinlichkeitsfunktion der diskreten Zufallsvariablen FZ für eine beliebige Schätzung S_{Fz} der Fahrstreifenzuordnung nach [Weiser u. To 2009], [Liensdorf 2009], als Summe der Einzelwahrscheinlichkeiten aller Realisationen fz . Als Realisationen (Hypothesen) sind die Fahrstreifen der Fahrbahn vorgesehen. Die Zuordnungswahrscheinlichkeit zu einem Fahrstreifen und damit die Evidenz für eine bestimmte Anzahl an Fahrstreifenwechsel für das Erreichen des äußerst rechten Fahrstreifens bestimmt sich für jede der oben genannten Realisationen von LANES2MOSTRIGHT nach Gleichung 4.11. Hierbei steht j für die jeweilige Realisation und n für die Anzahl der betrachteten Menge der Fahrstreifen FS mit ihren jeweiligen Begrenzungen $[a_i, b_i]$.

$$p(\text{lanes2MostRight})_j = \sum_{k \in S_{Fz}; [a_i, b_i] \in FS}^n p(fz)_k \cdot P(a_i \leq Y_{Fb} \leq b_i) \quad (4.11)$$

Abbildung 4.11 stellt die Vorgehensweise zur Bestimmung von $P(\text{LANES2MOSTRIGHT})$ auf einer Fahrbahn mit drei Fahrstreifen beispielhaft dar. Grundlage ist die globale Fahrstreifenzuordnung des Ego-Fahrzeuges und die ego-relative Position des beobachteten Bezugsobjektes. $p(\text{lanes2MostRight})_j$ ergibt sich durch eine Summation des über die Zuordnungshypothese $p(fz)_k$ gewichteten Integrals $P(a_i \leq Y_{Fb} \leq b_i)$ über den Fahrstreifen j .

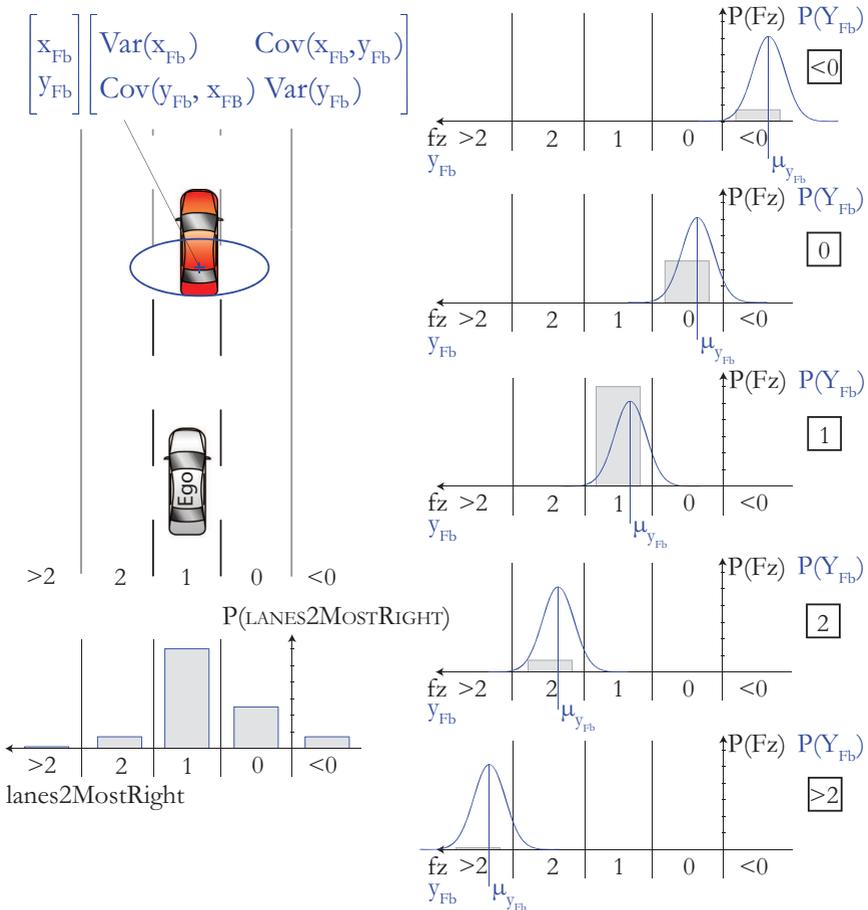


Abbildung 4.11: Beispiel für eine Fahrstreifenzuordnung auf einer Fahrbahn mit $n = 3$ Fahrstreifen. $P(\text{LANES2MOSTRIGHT})$ ergibt sich aus $P(FZ)$ und $P(Y_{Fb})$ nach Gleichung 4.8 und Gleichung 4.11. Für eine übersichtliche Darstellung wird $\sigma_{x_{Fb}}\sigma_{y_{Fb}} = \sigma_{y_{Fb}}\sigma_{x_{Fb}} = 0$ angenommen.

4.5.2 Bezug zum umgebenden Verkehr

Für die Bestimmung der Fahrstreifenwechselwahrscheinlichkeit wird der umgebende Verkehr des potentiellen Einscherers, d. h. des Bezugsobjektes, berücksichtigt. Die entsprechenden Eingangsknoten des Bayes'schen Netzwerks sind in Tabelle 4.9 aufgeführt. Betrachtet werden die räumlichen und

zeitlichen Abstände, d. h. die Lücken zwischen dem Bezugsobjekt und den nächsten Umfeldobjekten bzw. Fahrzeugen auf dessen Fahrstreifen oder dessen unmittelbaren Nachbarfahrstreifen. Charakteristisch für eine Lücke ist ein vorausfahrendes Fahrzeug (VF) und ein unmittelbar nachfolgendes Fahrzeug (FF), die Eigenschaften der Lücke lassen sich aus den Zustandsvektoren der betroffenen Fahrzeuge ableiten. Die Auswahl der relevanten Umgebungsfahrzeuge aus der Menge der verfolgten Umfeldobjekte erfolgt über eine Umgebungsmaske, wie in Abbildung 4.12 dargestellt.

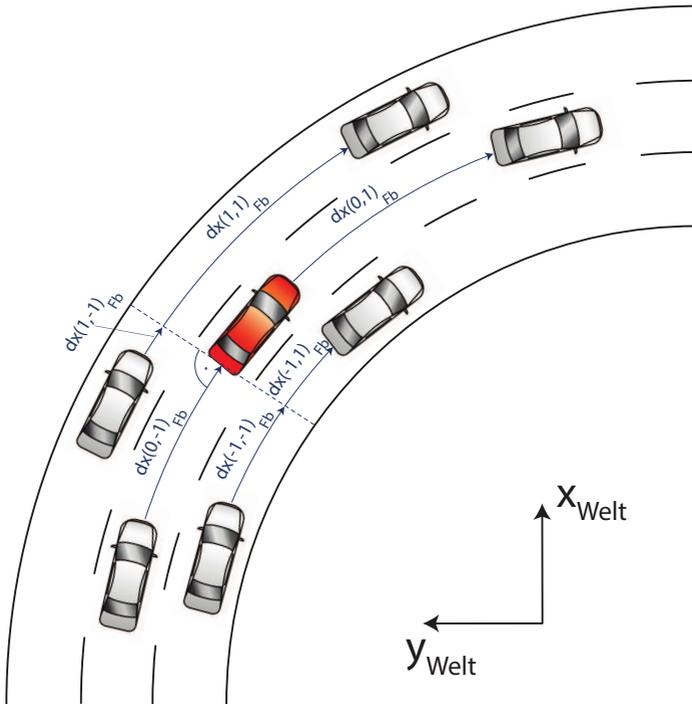


Abbildung 4.12: Umgebungsmaske

Alle unmittelbar um das Bezugsobjekt befindlichen Lücken weisen einen festen Bezugspunkt zu diesem auf: Auf dessen eigenen Fahrstreifen begrenzt die Front bzw. das Heck des Bezugsobjektes zu jeweils einer Seite die Lücke. Die unmittelbaren Lücken auf den Nachbarfahrstreifen beginnen bzw. enden auf Höhe des Hecks des Bezugsobjektes. Alle weiteren Grenzen werden auf den entsprechenden Fahrstreifen durch die jeweils in Fahrtrichtung nächsten Fahrzeuge vor dem Bezugsobjekt bzw. entgegen der Fahrtrichtung hinter

diesem gebildet. Für alle möglichen Lücken ist das Bezugsfahrzeug, unabhängig vom Fahrstreifen, entweder das Folgefahrzeug oder das vorausfahrenden Fahrzeug. Eine Lücke ist für den Fahrstreifen des Bezugsobjektes definiert über den räumlichen Abstand dx_{Fb} entlang der Fahrbahn zwischen Heckstoßfänger des vorausfahrenden (VF) und Frontstoßfänger des folgenden Fahrzeuges (FF). Für die dem Bezugsobjekt benachbarten Fahrstreifen gilt jeweils die x_{Fb} -Position des Heckstoßfängers vom Bezugsfahrzeug als Referenzwert bzgl. x_{Fb} über alle Fahrstreifen. Abbildung 4.13 illustriert diesen Zusammenhang. Ein Grenzfall stellt Abbildung 4.13(c) dar: Hier wird das links vom Bezugsobjekt befindliche Objekt als voraus fahrendes Fahrzeug (VF) gewertet, solange es mit der Fahrzeugfront bzgl. x_{Fb} vor dem Referenzwert des Bezugsobjektes liegt. Die Länge der betreffenden Lücke wird in diesem Fall negativ.

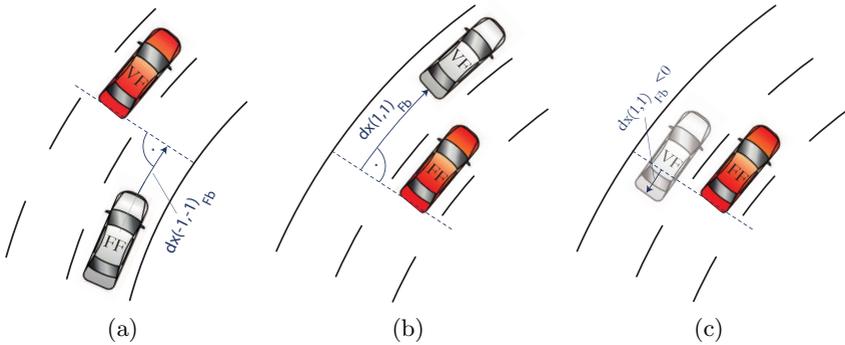


Abbildung 4.13: Definition der Lücken auf den Nachbarfahrstreifen des Bezugsfahrzeuges (rot) durch umgebenden Verkehr (weiß), 4.13(a) hinter und 4.13(b) sowie 4.13(c) vor dem Bezugsfahrzeug

Über die Auswertung der Geschwindigkeitsvektoren lassen sich neben der Längsausdehnung d_x einer Lücke zudem die Zeitlücke t des nachfolgenden Fahrzeuges zum Vorausfahrenden und die Ausdehnungsgeschwindigkeit $v_{\Delta x}$, d. h. das Wachstum der Lücke berechnen:

$$d_{x(FF,VF)} = x_{(VF)} - x_{(FF)} \quad (4.12a)$$

$$\sigma_{d_{x(FF,VF)}}^2 = \sigma_{x_{(VF)}}^2 + \sigma_{x_{(FF)}}^2 \quad (4.12b)$$

$$t_{(FF \rightarrow VF)} = \frac{d_{x(VF,FF)}}{v_{x(FF)}} \quad (4.13a)$$

$$\sigma_{t_{(FF \rightarrow VF)}}^2 = \frac{\sigma_{d_x(VF, FF)}^2}{v_{x(FF)}^2} + \left(\frac{d_x(VF, FF)}{v_{x(FF)}} \right)^2 \cdot \sigma_{v_x(FF)}^2 \quad (4.13b)$$

$$v_{\Delta x(FF, VF)} = v_{x(VF)} - v_{x(FF)} \quad (4.14a)$$

$$\sigma_{v_{\Delta x(FF, VF)}}^2 = \sigma_{v_x(VF)}^2 + \sigma_{v_x(FF)}^2 \quad (4.14b)$$

Sind die Dimensionen eines erfassten Fahrzeuges bzw. Umfeldobjektes nicht bekannt, so werden Standardwerte für einen PKW angenommen. Können Lücken durch das Fehlen entsprechender Umfeldobjekte und/oder Fahrstreifen nicht gebildet werden, so werden abhängige Eingangsmerkmale als ungültig markiert.

4.6 Diskussion

Im vorliegenden Kapitel wird aus den Anforderungen an eine Fahrstreifenwechselvorhersage das Vorhersageziel und ein Architekturkonzept abgeleitet sowie die gewählte Methode eines Bayes'schen Netzwerks bestätigt. Es erfolgt eine Festlegung der Klassen- und Evidenzvariablen und eine ausführliche Erläuterung zur Ermittlung der Evidenz über die Wahrnehmungsplattform des TEMPORARY AUTOPILOT.

Für die Bewertung der gewählten Methodik anhand realer Fahrdaten steht die Ermittlung geeigneter Parameter für ein Bayes'sches Netzwerk aus. Dies beinhaltet die Bestimmung einer Graphenstruktur, die Ermittlung von latenten Variablen, die Festlegung geeigneter Zustandsräume für die einzelnen Variablen (mit Ausnahme der bereits spezifizierten Klassenvariable) und die Bestimmung der bedingten Übergangswahrscheinlichkeiten zwischen den Variablen. Die Ermittlung der Netzwerkparameter kann manuell, d. h. auf Basis von Expertenwissen oder datengetrieben über maschinelle Lernverfahren erfolgen. Das folgende Kapitel 5 widmet sich der datengetriebenen Bestimmung geeigneter Netzwerkparameter.

5 Datengetriebene Ermittlung von Netzwerkparametern

Kapitel 5 beschreibt die datengetriebene Bestimmung der Parameter eines Bayes'schen Netzwerks zur Fahrstreifenwechselvorhersage mithilfe des maschinellen Lernens. Das Vorgehen ist exemplarisch in Abbildung 5.1 dargestellt.

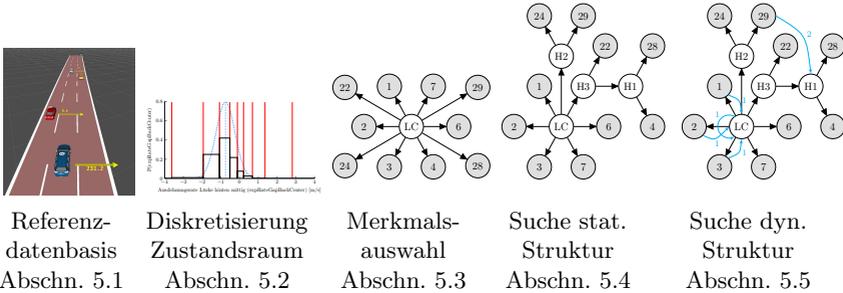


Abbildung 5.1: Schritte und Kapitelverweise für das Vorgehen zur Bestimmung eines Bayes'schen Netzwerks zur Fahrmanövriervorhersage

In Abschnitt 5.1 wird die automatisiert retrospektive Erzeugung von Referenzdatendaten auf Basis naturalistischer Fahrdaten einer Probandenstudie vorgestellt. Ein Großteil der hierbei erzeugten Daten liegt in kontinuierlicher Form vor, beschrieben durch eine Verteilung. Im Abschnitt 5.2 erfolgt daher die informationstheoretische Bestimmung des diskreten Zustandsraumes für die Evidenzvariablen. Die Auswahl relevanter Evidenzvariablen für eine Fahrstreifenwechselvorsage erfolgt in Abschnitt 5.3. Über Merkmalsauswahlverfahren werden verschiedene Teilmengen an Evidenzvariablen erzeugt und jeweils in Form eines Naive Bayes'schen Netzwerks bewertet. Das hierbei erzeugte Naive Bayes'sche Netzwerk dient im weiteren Verlauf als Ausgangspunkt einer Struktursuche. Mithilfe des HNB-Verfahrens werden in Abschnitt 5.4 latente Variablen und deren Zustandsraum innerhalb der Netzwerkstruktur identifiziert und ein Hierarchisches Naive Bayes'sches Netzwerk gebildet. Die gefundene Netzwerkstruktur dient als Ausgangsbasis für ein Dynamisches Bayes'sches Netzwerk, für das in Abschnitt 5.5 das temporale Netzwerk mithilfe eines Genetischen Algorithmus identifiziert wird.

5.1 Datenbasis

Das Thema des vorliegenden Abschnittes ist die Bereitstellung von Daten in einer Datenbasis für die in Abschnitt 4.4 vorgeschlagenen Knoten zur Modellierung eines Bayes'schen Netzwerks. Als Datenbasis findet die Schätzung des Umfeldmodells über die Umfeldwahrnehmungsplattform Verwendung, vgl. Abschnitt 4.3. Diese Schätzung wird für jeden Zeitpunkt aus aufgezeichneten Daten von Messfahrten ermittelt. Auf dieser Basis werden Referenzdaten erzeugt, die für jedes Umfeldobjekt eine tatsächliche zeitliche Vorhersage der anstehenden Fahrstreifenwechselforgänge erlauben. Die hierfür notwendigen Daten werden in Realfahrten aufgezeichnet und in einem nachgelagerten Schritt retrospektiv referenziert. Die kleinste Einheit der Datenbasis wird als Situationsmerkmal bzw. Variable bezeichnet, welche jeweils den Wert der in Unterabschnitt 4.4.2 spezifizierten Evidenzvariablen und der in Tabelle 4.5 auf Seite 103 spezifizierten Klassenvariable Fahrstreifenwechsel enthält. Die geordnete Wertesammlung aller genannter Variablen zu einem Zeitschritt wird als Instanz bzw. Tupel bezeichnet, diese beschreibt die zu extrahierende Verkehrsszene.

5.1.1 Messdatenaufnahme

Die Versuchsstrecke umfasst circa 30 km auf der Bundesautobahn (BAB) 39 ab Anschlussstelle Weyhausen über das Kreuz Königslutter bis zur Anschlussstelle Rennau auf der BAB 2, vgl. Abbildung 5.2, mit zwei bzw. drei Fahrstreifen. Zur Variation des Fahrerverhaltens im Ego-Fahrzeug und der damit einhergehenden Beeinflussung des umgebenden Verkehrs, werden die Messfahrten im Rahmen einer 20 Personen umfassenden Probandenstudie, d. h. mit wechselnden Fahrern, im realen Verkehr aufgezeichnet. Um eine repräsentative Auswahl der Probanden in Bezug auf alle Verkehrsteilnehmer zu erzielen, orientiert sich die gewählte Stichprobe an einer Unfallstatistik, welche die Verteilung der Nichtunfallverursacher an einem Unfall nach Altersgruppe und Geschlecht widerspiegelt. Die Bezugsstatistik, vgl. [Tenzer 2004], ist in Tabelle 5.1 gegeben, die Stichprobe in Tabelle 5.2. Die Probanden befahren nach einer Einweisung die Versuchsstrecke jeweils zweimal in beide Richtungen. Während der Fahrt wurden die CAN-Daten der Eingabeschicht, vgl. Abbildung 4.2, sowie das Videobild der Frontkamera aufgezeichnet. Im Anschluss wurde die Fahrerfahrung und der Fahrstil per Fragebogen erfragt. Sondersituationen wie Baustellen, Stausituationen, Verpflechtungsbereiche werden nicht betrachtet.

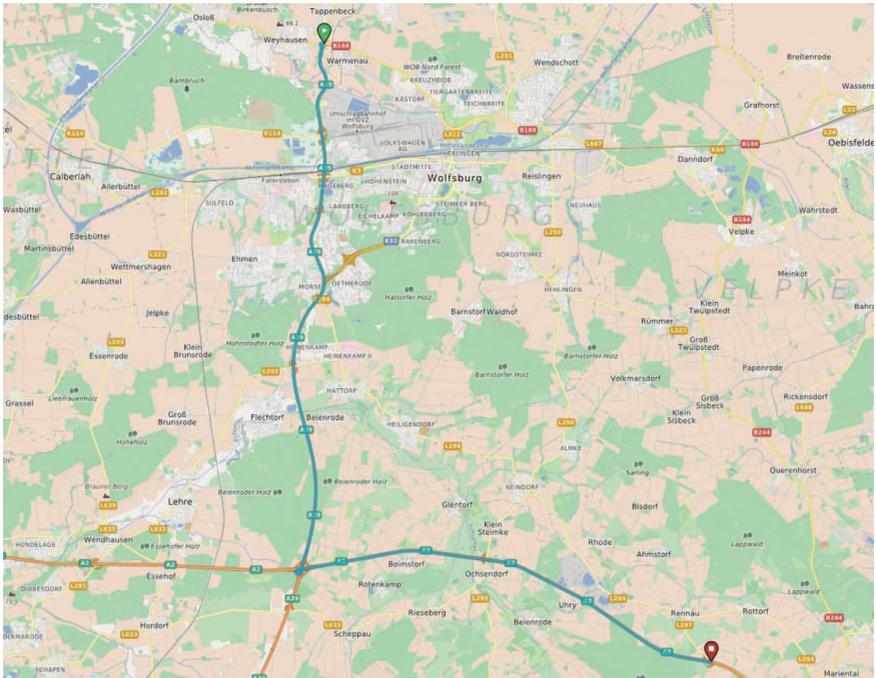


Abbildung 5.2: Versuchsstrecke auf BAB 39/BAB 2,
(Quelle <http://www.openstreetmap.org>)

Tabelle 5.1: Bezugsstatistik

Altersgruppe (in Jahren)	männlich	weiblich
bis 18	0 %	0 %
18 bis 25	11 %	8 %
25 bis 35	14 %	10 %
35 bis 45	15 %	10 %
45 bis 55	10 %	6 %
55 bis 65	7 %	3 %
über 65	4 %	1 %

Tabelle 5.2: Stichprobe

Altersgruppe (in Jahren)	männlich	weiblich
bis 18	0 %	0 %
18 bis 25	5 %	10 %
25 bis 35	10 %	15 %
35 bis 45	25 %	15 %
45 bis 55	5 %	0 %
55 bis 65	10 %	5 %
über 65	0 %	0 %

5.1.2 Erzeugung von Referenzdaten

Als Ergebnis der Messdatenaufnahme stehen Daten aus 80 Messfahrten auf der beschriebenen Strecke zur Verfügung. In diesen Daten sollen die Fahrstreifenwechsel aller auf der Fahrbahn beobachteten Objekte mindestens im gewählten Zeitintervall, vgl. Tabelle 4.5 auf Seite 103, referenzierbar sein. Es gilt bzgl. der Vorhersagezeit die in Unterabschnitt 4.1.1 festgelegte Referenz für den Vorhersagezeitpunkt. Das heißt, zu jedem Objekt soll zu jedem Zeitpunkt eine Aussage getroffen werden können, ob und in welche Richtung innerhalb der nächsten zwei Sekunden ein Fahrstreifenwechsel erfolgt. Aufgrund der hohen Datenmenge und der geforderten Vorhersageintervalle wird eine automatisierte retrospektive Referenzdatenerzeugung realisiert, vgl. [Grewe 2010; Montemayor Ayala 2011].

5.1.2.1 Retrospektive Referenzdatenerzeugung

Grundgedanke der retrospektiven Referenzdatenerzeugung ist die Annahme, dass bei Vorliegen aller Messdaten einer Versuchsfahrt die durchgeführten Fahrstreifenwechsel der beobachteten Fahrzeuge innerhalb des Beobachtungszeitraumes bekannt sind, d. h. der genaue Zeitpunkt jedes beobachteten Fahrstreifenwechsels für jeden davor liegenden Zeitschritt exakt bestimmt werden kann. Um die bestehende Architektur der Umfeldwahrnehmungsplattform des TAP, vgl. Unterabschnitt 4.2.1, mit minimalen Anpassungen beibehalten zu können, erfolgt die Umsetzung in einem Prozess mit einem zweimaligen Durchlaufen aller Messdaten.

Während des ersten Durchlaufs erfolgt *a)* die Abfrage der Fahrbahnschnittstelle und Aufzeichnung des gesamten wahrgenommenen Fahrbahnaufbaus in einer Datenbank und *b)* die Aufzeichnung der Ausgabe des Moduls Objektfusion. Es werden die IDs und Objektzustände aller beobachteten Objekte und des Ego-Fahrzeuges in einer Datenbank aufgezeichnet. Als Schlüssel dient der jeweilige Zeitstempel.

Während des zweiten Durchlaufs stehen die Datenbanken mit den aufgezeichneten Objektzuständen und dem gesamten Fahrbahnverlauf zur Verfügung. Zu jedem Ausgabezeitpunkt wird für jedes Objekt die Zeitdauer bis zu einem möglichen folgenden Fahrstreifenwechsel exakt ermittelt, indem die Position des Objektes in der Objektdatenbank nachverfolgt und auf den zukünftigen Fahrbahnverlauf projiziert wird. Der zukünftige Fahrbahnverlauf ist über die Fahrbahndatenbank abrufbar. Wird ein Fahrstreifenwechsel festgestellt, so erfolgt eine Konsistenzprüfung, d. h. das betreffende Objekt

muss komplett in den neuen Fahrstreifen gewechselt sein und dort eine Mindestverweilzeit von 2 s aufweisen. Die Zeit bis zum Fahrstreifenwechsel sowie die Wechselrichtung werden dem betreffenden Ausgabe-Objekt in Form der in Tabelle 4.5 gegebenen Zeitintervalle als zusätzliches Attribut Fahrstreifenwechsel hinzugefügt.

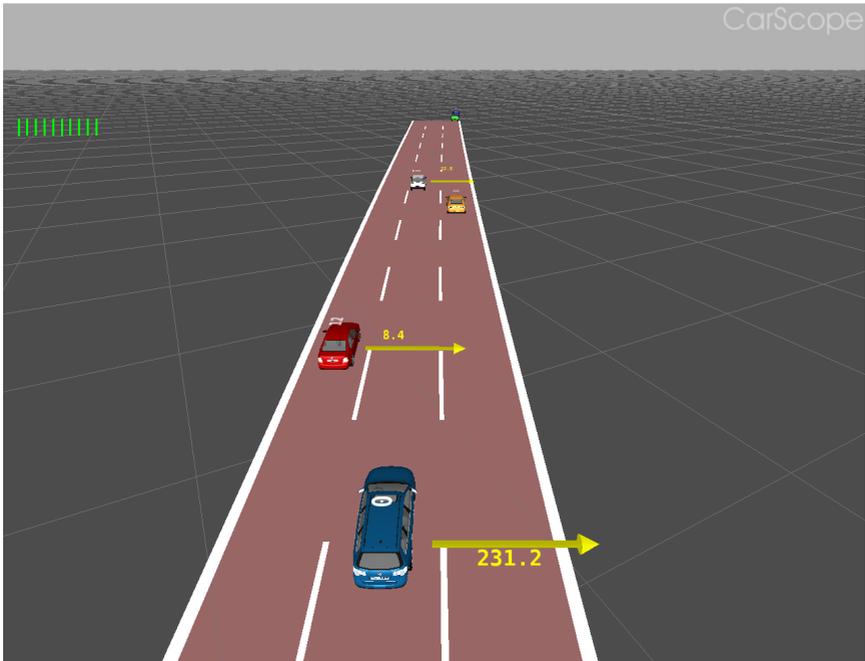


Abbildung 5.3: Fahrscene mit Referenzdaten: Visualisierung der Zeiten bis Fahrstreifenwechsel für Umfeldobjekte (blaues Fahrzeug im Vordergrund ist das Ego-Fahrzeug)

Durch das beschriebene Verfahren kann für jedes Objekt, inklusive des Ego-Fahrzeuges, zu jedem Messzeitpunkt des Datensatzes die Zeit bis zum nächsten Fahrstreifenwechsel bestimmt werden, wenn: *a)* das Objekt im verbliebenen Beobachtungszeitraum einen Fahrstreifenwechsel durchführt und *b)* der Fahrstreifenwechsel den oben genannten Kriterien entspricht.

Abbildung 5.3 zeigt die Visualisierung einer Fahrscene mit den zugehörigen Referenzdaten. Dargestellt ist die Wechselrichtung und die Zeitdauer bis zum Beginn des nächsten Fahrstreifenwechsels des jeweiligen Objektes. Wie in Abbildung 5.3 erkennbar, sind mit dem beschriebenen Verfahren für

den Referenzdatensatz Vorhersagezeiten darstellbar, welche die geforderte Zeitspanne von 2 s deutlich übertreffen.

5.1.3 Eigenschaften der Datenbasis

Während der Datenerhebung legte das Messfahrzeug, d. h. das Ego-Fahrzeug, eine Strecke von 1 894,6 km zurück. Diese werden ausgewertet und in die Datenbasis überführt. 82,6 % der Aufnahmen wurden bei Tageslicht und 17,4 % bei Nacht bzw. Dämmerung durchgeführt. Für das Ego-Fahrzeug und jedes Objekt im Beobachtungshorizont wird ein Datentupel mit einer Frequenz von 10 Hz extrahiert, welches die in Abschnitt 4.5 definierte Verkehrsszene beschreibt. Der Beobachtungshorizont für die Szenenextraktion wurde beschränkt auf das Ego-Fahrzeug und Objekte mit einer Fahrstreifenzuordnung im Fahrstreifen des Ego-Fahrzeuges sowie dessen unmittelbare Nachbarfahrstreifen. Der maximale longitudinale Abstand der Objekte zum Ego-Fahrzeug wurde auf 100 m, der minimale auf -30 m festgelegt. Im Ergebnis stehen 1 446 034 Tupel an kontinuierlichen und teils bereits diskreten Werten der Evidenzvariablen und Klassenvariable mit insgesamt 2 545 beobachteten Fahrstreifenwechsellvorgängen für die nachfolgende Datenanalyse zur Verfügung. Die Klasseninformation stellt das Merkmal Fahrstreifenwechsel. Dieses hat in 45 144 der Tupel die Ausprägung *Fahrstreifenwechsel links* bzw. *rechts* nach den in Tabelle 4.5 definierten Zeitintervallen. In allen anderen Tupeln hat das Merkmal Fahrstreifenwechsel die Ausprägung *kein Fahrstreifenwechsel*.

Tabelle 5.3: Übersicht über die Anzahl der Tupel, die Fahrstrecke sowie die beobachteten Fahrstreifenwechsel je Datensatz. Bei einer Abtastfrequenz von 10 Hz ist ein Fahrstreifenwechsellvorgang in maximal 20 Tupel abgebildet.

Datensatz	Tupel	Strecke [m]	Fahrstreifenwechsellvorgänge			
			alle Objekte		Ego-Fahrzeug	
			links	rechts	links	rechts
Gesamt	1446034	1894634	1115	1430	500	578
Lerndaten	757245	1005432	597	755	283	319
Testdaten	688789	889201	518	675	217	259

Die erzeugte Datenbasis wird verhältnismäßig in einen Lern- und in einen Testdatensatz aufgeteilt. Hierbei erfolgt die Auswahl zufällig über die einzelnen Fahrten der Probanden. Die Aufteilung der Datenbasis ermöglicht eine Bewertung der erstellten Bayes'schen Netzwerke zur Fahrstreifenwechsellvorhersage auf Basis unabhängiger Validierungsdaten. Tabelle 5.3 gibt

eine Übersicht über die Anzahl der Tupel, die Länge der Fahrstrecke sowie die beobachteten Fahrstreifenwechsel je Datensatz. Die Anzahl der Fahrstreifenwechsel für alle Objekte enthält die separat aufgeführten Wechsel für das Ego-Fahrzeug.

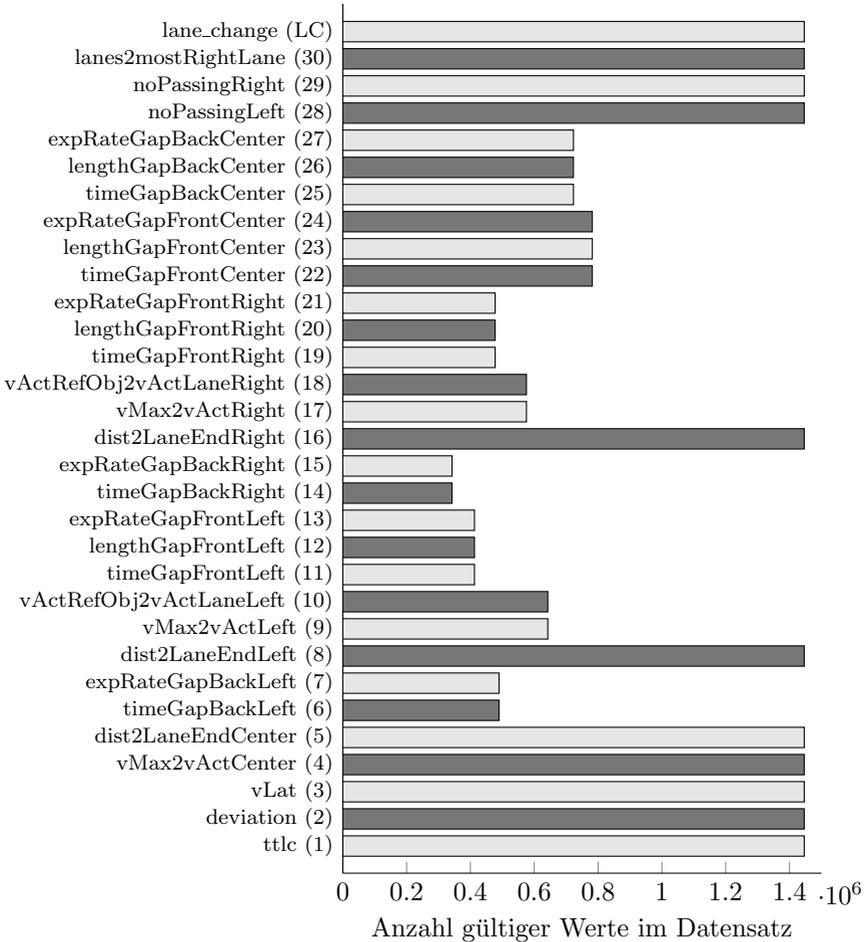


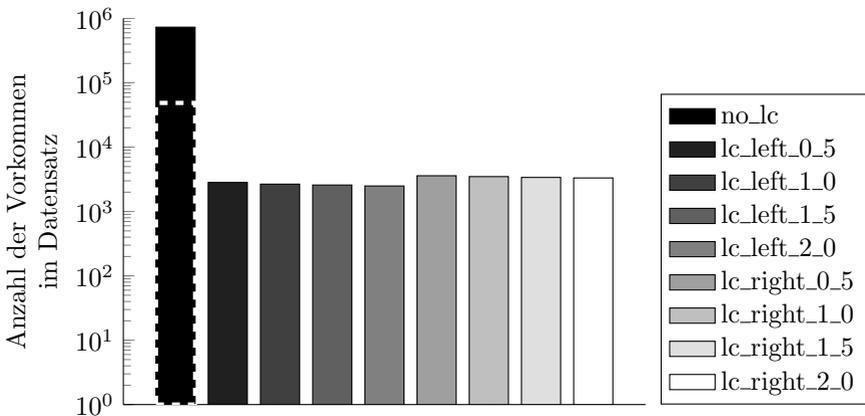
Abbildung 5.4: Anzahl der gültigen Messwerte je Situationsmerkmal bezogen auf den Gesamtdatensatz

Ein aus einer Verkehrsszene extrahiertes vollständiges Tupel bedingt die Verfügbarkeit aller der in Abbildung 4.12 auf Seite 115 dargestellten Fahrstreifen und Umgebungsobjekte. Dies ist tatsächlich nur in 2 834, d. h. 0,19 %, der

betrachteten Tupel der gesamten Datenbasis der Fall. So ist beispielsweise auf einer Autobahn mit zwei Richtungsfahrstreifen im Normalfall entweder ein linker oder ein rechter Nachbarfahrstreifen existent. Situationsmerkmale, welche sich auf den nicht existenten Fahrstreifen beziehen, sind entsprechend ungültig. Abbildung 5.4 gibt eine Übersicht über die Anzahl der gültigen Werte pro Situationsmerkmal bezogen auf die gesamte Datenbasis. Die Gültigkeit von Merkmalen eines Tupel muss bei der Fahrstreifenwechselforhersage berücksichtigt werden. Auf diesen Aspekt wird in Unterabschnitt 5.2.4 genauer eingegangen.

5.1.3.1 Balancierung des Lerndatensatzes

Für das Merkmal Fahrstreifenwechsel zeigt sich entsprechend den definierten Zeitintervallen eine sehr starke Übergewichtung von Tupeln mit der Ausprägung *kein Wechsel* (*no_lc*). Lediglich 3,3% (24380 Tupel) der Daten entfallen auf die übrigen Zeitintervalle.



Ausprägung Variable Fahrstreifenwechsel, siehe Legende

Abbildung 5.5: Histogramm der Variable Fahrstreifenwechsel über den unbalancierten Lerndatensatz. Der weiß unterbrochen umrandete Bereich zeigt die Häufigkeit von *no_lc* im balancierten Datensatz.

Um die Gefahr einer Überanpassung infolge der Übergewichtung der Merkmalsausprägungen *kein Wechsel* für die nachfolgenden Verfahren des maschinellen Lernens zu reduzieren, wird der Lerndatensatz im Verhältnis eins zu

drei balanciert. Das heißt, die Anzahl der im Datensatz enthaltenen Tupel, in denen das Merkmal Fahrstreifenwechsel die Ausprägung *kein Wechsel* enthält, wird durch einen zufälligen Ausschluss derselben soweit reduziert, dass bezogen auf das Merkmal Fahrstreifenwechsel Tupel mit der Ausprägung *Fahrstreifenwechsel links* bzw. *rechts* ein Drittel der Datenmenge stellen. Abbildung 5.5 zeigt das Histogramm über das Merkmal Fahrstreifenwechsel vor und nach der Balancierung des Datensatzes. Die Balancierung reduziert den Lerndatensatz auf 73 140 Tupel und betrifft ebenso alle weiteren Eingangsmerkmale wie beispielhaft das Histogramm des Merkmals *Zeit bis zum Queren der Markierung (ttlc)*, vgl. Unterabschnitt 4.5.1, das in Abbildung 5.6 dargestellt ist.

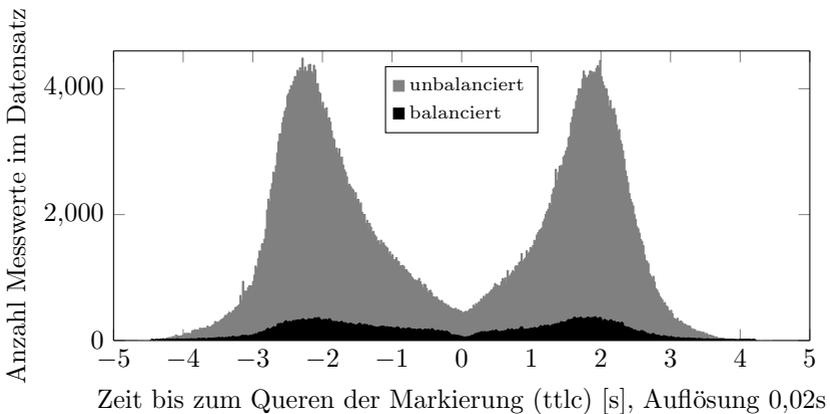


Abbildung 5.6: Histogramme des Eingangsmerkmals *Zeit bis zum Queren der Markierung (ttlc)* über den unbalancierten und balancierten Lerndatensatz

5.1.3.2 Statistische Abhängigkeit der Zufallsvariablen innerhalb der Datenbasis

Abbildung 5.7 stellt die statistische Abhängigkeit der in der Datenbasis *balancierter Lerndatensatz* zur Verfügung stehenden Zufallsvariablen in Form einer Transinformationsmatrix dar. Auffällig ist die häufig auftretende hohe Korrelation der Merkmalsvariablen (ID 1-30) untereinander im Gegensatz zu den Transinformationswerten zwischen Merkmalsvariablen und Klassenvariable (ID 31).

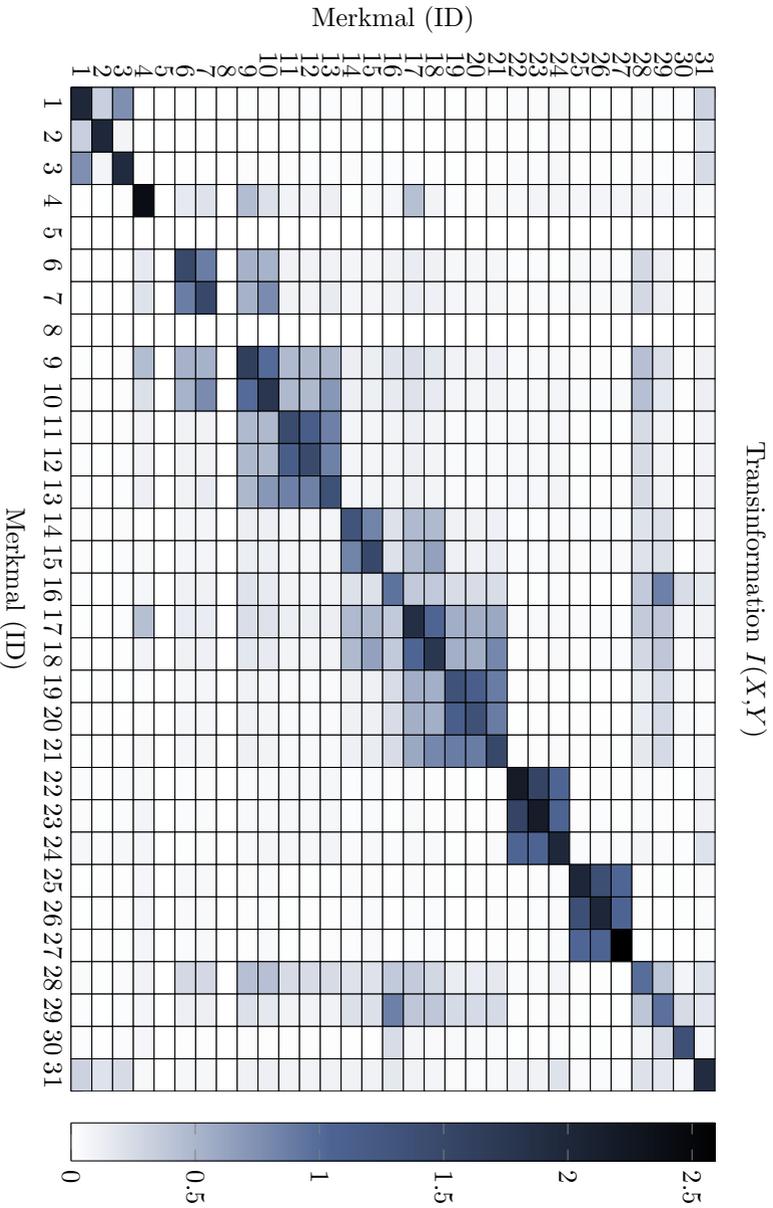


Abbildung 5.7: Stellt die Transformation zwischen den Merkmalsvariablen (ID 1-30) sowie den Merkmalsvariablen und der Klassenvariable (ID 31) dar; Daten: balancierter Lern Datensatz, vgl. Unterabschnitt 5.1.3.

Die Variablen sind in Abschnitt 4.4 ab Seite 103 erläutert, eine Übersicht findet sich in Abbildung 5.4 auf Seite 125. Auf Basis der Transinformativswerte sind folgende Gruppierungen von Merkmalsvariablen erkennbar:

1. Merkmale zur lateralen Ablage im Fahrstreifen: ID 1-3.
2. Merkmale bezogen auf die in Abbildung 4.12 dargestellten Lücken um das Bezugsfahrzeug:
 - hinten links ID 6,7,9,10,
 - vorne links ID 9-13,
 - hinten rechts ID 14-18,
 - vorne rechts ID 17-21,
 - vorne mittig ID 22-24,
 - hinten mittig ID 25-27.
3. Merkmale mit Information bzgl. der Überfahrbarkeit der linken und rechten Fahrstreifenmarkierung um das Bezugsfahrzeug: ID 28, 29. Die genannten Merkmale weisen zudem eine nicht zu vernachlässigende Abhängigkeit zu den Merkmalen auf, welche sich auf die Lücken des linken und rechten Fahrstreifens beziehen.

Die gefundenen Abhängigkeiten lassen sich darüber erklären, dass insbesondere für die Bestimmung der Merkmalswerte in den Gruppen 1 und 2 z. T. ähnliche Basiswerte des Umfeldmodells zur Berechnung herangezogen werden, vgl. Abschnitt 4.5. Die Transinformativswerte der Variablen mit der ID 5, 8, 16, d. h. jeweils der Distanz bis Fahrstreifenende mittig, links und rechts, sind insbesondere für den linken und mittigen Fahrstreifen nahezu durchgängig bei null. Zum Aufnahmezeitpunkt der Datenbasis stand diese Information nicht durchgängig zur Verfügung, so dass über diese Merkmale lediglich die Existenz des betreffenden Fahrstreifens binär codiert abgebildet ist.

5.1.3.3 Statistische Abhängigkeit der Klassenvariable über Zeitreihen

Der bisher betrachtete Lern- und Testdatensatz bezieht sich auf das Ego-Fahrzeug und alle Objekte in dessen Beobachtungshorizont. Um eine kontinuierliche Zugehörigkeit der Datentupel zu einem Objekt zu gewährleisten, finden im Folgenden nur Tupel Verwendung, welche dem Ego-Fahrzeug zuzuordnen sind. Für diesen Datensatz ist in Abbildung 5.8 die Transinformation

$I(X, LC)$ zwischen den Evidenzvariablen $X(t = n)$ und der Klassenvariable $LC(t = 0)$ für die Zeitscheiben $n = 0 \dots -3,8 s$ gegeben.

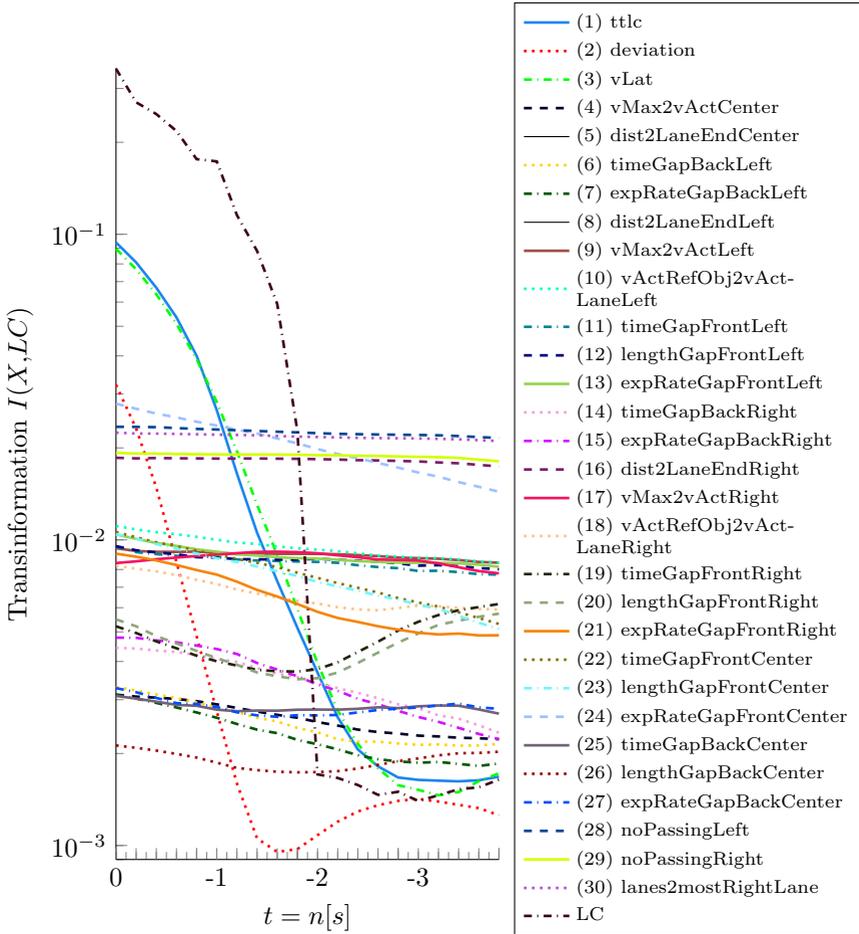


Abbildung 5.8: Transinformation I (logarithm. Skalierung) zwischen Klassenvariable $LC(t = 0)$ und Evidenzvariablen $X(t = n)$ sowie $LC(t = n)$ mit $n = 0 \dots -3,8 s$. Der verwendete Datensatz berücksichtigt nur das Ego-Fzg.

Die Abnahme der statistischen Abhängigkeit zwischen der Klassenvariable zum Zeitpunkt $t = 0$ und den Variablen der lateralen Evidenz *ttl*, *deviation* und *vlat* über die Zeitscheiben $t = 0 \dots -2 s$ ist besonders ausgeprägt, während die auf die Fahrbahn bezogenen Evidenzvariablen wie

z. B. *noPassingLeft*, *noPassingRight* oder *lanes2MostRightLane* nahezu keine Änderung der Abhängigkeit aufweisen. Für alle übrigen Evidenzvariablen kann eine geringe, meist abnehmende Änderung der Transinformation zur Klassenvariable über die betrachteten Zeitscheiben festgestellt werden. Weiterhin abgebildet ist die Transinformation $I(LC(t = n), LC(t = 0))$ zwischen der Klassenvariable $LC(t = 0)$ und $LC(t = n)$. Der starke Abfall bis $t = -2s$ und der danach nahezu gleichbleibende Verlauf ist in der Definition der Klassenvariable begründet, vgl. Unterabschnitt 4.4.1. Die für $I(LC(t = n), LC(t = 0))$ ermittelten vergleichsweise hohen Werte beziehen sich auf die wahren Werte von LC aus den Referenzdaten und sind ggf. nicht vollständig auf die durch einen Klassifikator prädierten Werte für LC übertragbar.

5.2 Diskretisierung

Wie in Unterabschnitt 4.2.2 und Abbildung 4.4 beschrieben müssen die kontinuierlichen Situationsmerkmale für die Evidenzvariablen des Bayes'schen Netzwerks diskretisiert werden. Dieser Abschnitt beschäftigt sich mit der Bestimmung der notwendigen Diskretisierungsschwellen. Ausgehend von einer Erläuterung der eingesetzten Diskretisierungsverfahren wird eine Zielstellung formuliert und die entsprechende Vorgehensweise beschrieben. Im Anschluss werden die bestimmten Diskretisierungsschwellen für alle Merkmale aufgeführt und das Ergebnis diskutiert, vgl. [Vogel 2014].

5.2.1 Verfahren zur Diskretisierung

Verfahren zur Abbildung kontinuierlicher Daten auf diskrete Teilmengen lassen sich beispielsweise über die hierarchische Struktur für Diskretisierungsmethoden nach [Liu u. a. 2002] kategorisieren. Diese strukturiert zunächst nach der grundsätzlichen Herangehensweise: dem Teilen oder dem Zusammenfügen von Mengen des Lerndatensatzes. Im ersteren Fall wird das Gesamtintervall des Datensatzes in Teilintervalle heruntergebrochen, bis ein Stop-Kriterium erfüllt ist. Im entgegengesetzten Fall wird die Gesamtmenge der Daten bereits zu Beginn in kleinere Teilintervalle unterteilt und diese werden im weiteren Verlauf zu geeigneten Teilintervallen zusammengefügt. Das zweite genannte Unterscheidungsmerkmal für Diskretisierungsverfahren ist die Nutzung von Klasseninformation der Klassenvariable zur Bestimmung der Intervallgrenzen. Es wird zwischen überwachten Verfahren, d. h. Verfahren, in denen Klasseninformation genutzt wird, und unüberwachten Verfahren

ohne Nutzung von Klasseninformationen unterschieden. Schließlich gruppieren [Liu u. a. 2002] Verfahren mit ähnlichen Maßen zur Bestimmung der Intervallgrenzen, z. B. Abhängigkeit, Entropie oder Binning.

Im Rahmen dieser Arbeit werden nachfolgend jeweils drei überwachte und unüberwachte Diskretisierungsverfahren auf ihre Eignung untersucht. Abbildung 5.9 zeigt die Kategorisierung dieser Verfahren nach der oben genannten Struktur.

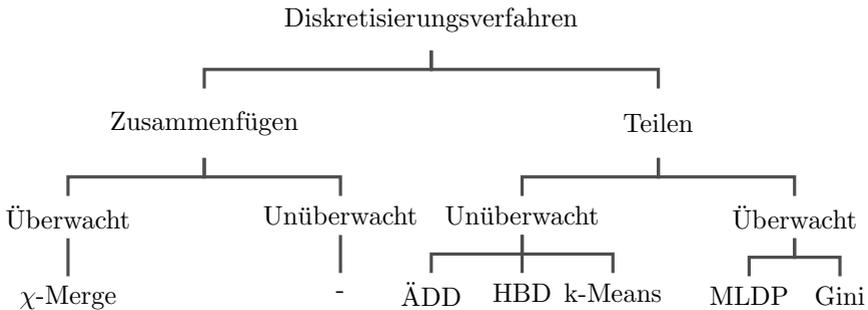


Abbildung 5.9: Einordnung der angewandten Diskretisierungsverfahren in Anlehnung an die hierarchische Struktur für Diskretisierungsmethoden nach [Liu u. a. 2002]. Die Verfahren sind in Unterabschnitt 5.2.1.2 und 5.2.1.1 erläutert.

Die nachfolgenden Abschnitte geben einen kurzen Überblick über die in dieser Arbeit angewandten Vertreter der nicht überwachten (unsupervised) und überwachten (supervised) Diskretisierungsmethoden. Im Anschluss werden die jeweils mit beiden Methoden ermittelten Diskretisierungsintervalle für beispielhaft ausgewählte Eingangsknoten gegenübergestellt und diskutiert.

5.2.1.1 Überwachte Diskretisierungsalgorithmen

Überwachte Diskretisierungsalgorithmen nutzen zur Bestimmung der Diskretisierungsintervalle die Beziehung zwischen der Konfiguration der Situationsmerkmale¹ und der Klassenvariable Fahrstreifenwechsel mit ihren Ausprägungen. Unter der Voraussetzung einer vollständigen Ground-Truth Datenbasis wird der Algorithmus, welcher die genaueste Abbildung der kontinuierlichen Daten auf die diskretisierten Daten liefert, gleichzeitig der Algorithmus sein, bei dem die gegenseitige Abhängigkeit zwischen den Eingangsdaten und der

¹ Das heißt, der Ausprägung der wahrgenommenen Verkehrsszene.

Vorhersage der Fahrstreifenwechsel unter allen Abbildungen maximal ist. Vertreter dieser Verfahren sind:

- MDLP (Minimum Description Length Principle): Ist ein Entropieminimierungsverfahren nach [Fayyad u. Irani 1993]. Es basiert auf der rekursiven Teilung definierter Wertebereiche in je zwei Teilintervalle auf Basis der minimalen Klassenentropie zwischen den Teilintervallen, vgl. Unterabschnitt A.4.1.
- Gini: Ist ein Diskretisierungsverfahren nach [Zhang u. a. 2007] und besitzt eine ähnliche Funktionsweise wie das MDLP-Verfahren. Statt der Klassenentropie wird das Gini-Kriterium zur Bestimmung der Intervallgrenzen eingesetzt, vgl. Unterabschnitt A.4.2.
- χ -Merge: Ist ein Verfahren nach [Kerber 1992], in dem jeder kontinuierliche Wert des Datensatzes zunächst als eigenes Intervall aufgefasst wird. Über den χ^2 -Test als Bewertungskriterium werden benachbarte Intervalle zusammengefügt bis das Abbruchkriterium erreicht ist, vgl. Unterabschnitt A.4.3.

5.2.1.2 Unüberwachte Diskretisierungsalgorithmen

Nicht überwachte Diskretisierungsalgorithmen zeichnen sich dadurch aus, dass sie keine Klasseninformation zur Bestimmung der Intervalle nutzen. Vorteile der Verfahren sind ihre vergleichsweise geringe Komplexität und damit verbunden ein geringer Speicher- und Rechenaufwand.

Einfache Verfahren sind die Diskretisierung nach gleicher Schrittweite, d. h. äquidistante Diskretisierung ÄDD, oder die Diskretisierung nach gleicher Frequenz, d. h. häufigkeitsbasierte Diskretisierung HBD. Ein weiterer Vertreter der nicht überwachten Diskretisierungsalgorithmen ist der k-Means Clusteralgorithmus.

- ÄDD: Bei der Diskretisierung nach gleicher Schrittweite werden die Diskretisierungsintervalle zwischen den Maximum und Minimum einer gegebenen Verteilung bei einer gegebenen Intervallanzahl in gleichem numerischen Abstand gewählt, vgl. Unterabschnitt A.4.4. Für nicht annähernd gleichverteilte Daten besteht die Gefahr, dass einige Intervalle deutlich mehr Daten² repräsentieren als andere.
- HBD: Die Diskretisierung nach gleicher Frequenz versucht die genannte Beschränkung des ÄDD-Verfahrens aufzuheben, indem die

Intervallgrenzen so gesetzt werden, dass die Datenmenge gleichmäßig auf die gegebenen Anzahl von Intervallen aufgeteilt wird, vgl. Unterabschnitt A.4.5.

- k-Means, vgl. Unterabschnitt A.4.6: Ist ein nichtdeterministisches Diskretisierungsverfahren das auf Ideen von [Steinhaus 1957] und [Lloyd 1982] zurück geht. Der Algorithmus basiert auf dem Finden von Clustern. Dazu sucht er nach ähnlichen Datenpunkten und gruppiert diese so zu Clustern, dass die Distanz zwischen den Punkten eines Clusters minimal und die Distanz der Clustermitten zueinander maximal ist. Die Cluster entsprechen hierbei den Diskretisierungsintervallen.

5.2.1.3 Diskussion

Abbildung 5.10 zeigt die Ergebnisse der vorgestellten Diskretisierungsmethoden am Beispiel des Merkmals *vMax2vActRight*, d. h. der Differenz zwischen zulässiger Geschwindigkeit und aktueller Geschwindigkeit auf dem Fahrstreifen in Fahrtrichtung rechts vom Bezugsfahrzeug. Dargestellt sind jeweils sechs Diskretisierungsintervalle.

Jedes der genannten Verfahren hat Vor- und Nachteile, welche entsprechend der Datenbeschaffenheit individuell berücksichtigt bzw. vernachlässigt werden können. Die Histogramme der Merkmale, d. h. der Evidenzvariablen des Bayes'schen Netzwerks, unterscheiden sich z. T. stark, vgl. Abbildung 5.6 und 5.10, so dass pauschal keine Präferenz für eines der genannten Diskretisierungsverfahren gegeben werden kann. Vielmehr muss für jedes Merkmal individuell das Verfahren ermittelt werden, welches den Informationsverlust minimal hält. Weiterhin muss die im folgenden Abschnitt formulierte Zielstellung bei der Auswahl des Diskretisierungsverfahrens Berücksichtigung finden.

5.2.2 Vorbetrachtung und Ziel der Diskretisierung

In dieser Arbeit werden Bayes'sche Netzwerke mit diskreten Zufallsvariablen zur Modellierung einer Fahrstreifenwechselvorhersage untersucht. Diese diskreten Zufallsvariablen zeichnen sich durch eine endliche Stelligkeit, d. h. eine endliche Anzahl von Werteintervallen³, aus.

² Anzahl von Tupeln.

³ Werteintervalle, engl. bins.

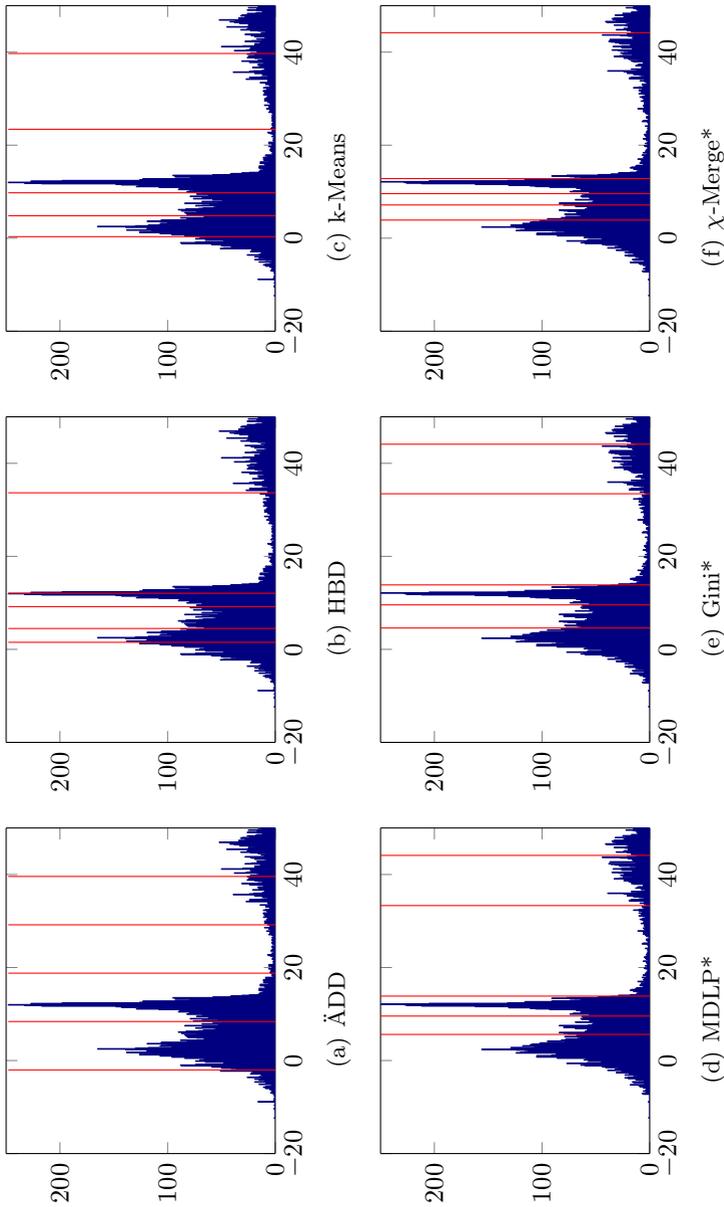


Abbildung 5.10: Ermittelte Diskretisierungsschwellen je Verfahren über dem Histogramm des Merkmals $v_{Max2vActRight}$, x-Achse in [m/s] (Auflösung 0.12 m/s), y-Achse: Anzahl Messwerte. * Für die überwachten Verfahren sind die Intervalle mit dem geringsten Informationsverlust dargestellt, vgl. Unterabschnitt 5.2.3.

Je mehr Wertintervalle jeweils die einzelnen Zufallsvariablen eines Netzes charakterisieren, desto mehr Elemente enthalten die bedingten Wahrscheinlichkeitstabellen⁴, vgl. Unterabschnitt 2.3.1, welche die bedingte Wahrscheinlichkeitsverteilung der repräsentierten Zufallsvariable bei gegebenen Zufallsvariablen an den Elternknoten angeben. Für ein effizientes und möglichst vollständiges Erlernen der bedingten Verteilungen sowie eine effiziente Inferenz im Bayes'schen Netzwerk ist eine möglichst geringe Stelligkeit der Zufallsvariablen anzustreben.

Ein Großteil der Situationsmerkmale aus der Beschreibung der Verkehrsszene, welche dem Bayes'schen Netzwerk über die Eingangsknoten aufgeprägt werden, liegen als kontinuierliche unsicherheitsbehaftete Größen⁵ in Form einer Normalverteilung $N(\mu; \sigma^2)$ mit Erwartungswert μ und Varianz σ^2 vor, vgl. Abschnitt 4.5. Diese Merkmale sollen so auf eine endliche Anzahl von Wertintervallen diskretisiert werden, dass sich jeweils eine diskrete Abbildung der Verteilung $N(\mu; \sigma^2)$ auf eben diese Wertintervalle ergibt. Abbildung 5.11 veranschaulicht diesen Vorgang unter Vorwegnahme der in Tabelle 5.6 ermittelten Diskretisierungsschwellen für das Merkmal *expRateGapBackCenter*.

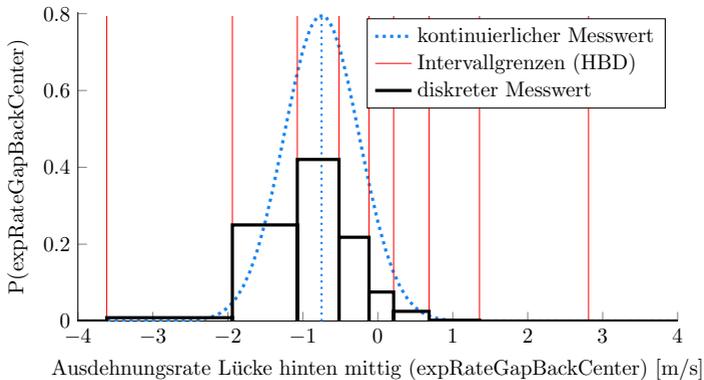


Abbildung 5.11: Diskretisierung eines fiktiven kontinuierlichen Messwertes $N(-0,75 \frac{m}{s}; 0,5 \frac{m}{s}^2)$ anhand der mithilfe des HBD-Verfahrens ermittelten Diskretisierungsschwellen für das Merkmal *expRateGapBackCenter*

Der Informationsgehalt einer Zufallsvariable bzw. zweier Zufallsvariablen zueinander lässt sich über die in Abschnitt A.1 gegebenen Gleichungen

⁴ Die Anzahl der Elemente n einer bedingten Wahrscheinlichkeitstabelle bestimmt sich aus dem Produkt aus der Stelligkeit k_{Eltern} der m Elternknoten mit der Stelligkeit k_{Kind} des Kindknoten: $n = (k_{Eltern_0} \cdot k_{Eltern_1} \cdot \dots \cdot k_{Eltern_m}) \cdot k_{Kind}$.

⁵ Infolge des vorausgegangenen Kalmanfilterprozesses.

A.1 und A.2 beschreiben. Bei einer Diskretisierung besteht die Gefahr von Informationsverlust infolge der Abbildung kontinuierlicher Werte auf diskrete Werteintervalle. Über eine Grenzwertbetrachtung der Gleichung A.1 zur Entropie zeigt sich in Gleichung 5.1, dass im Extremfall eines einzigen Intervalls $n \rightarrow 1$ und damit auch $p(x) \rightarrow 1$ der vollständige Informationsverlust droht:

$$\Rightarrow \lim_{n \rightarrow 1} H(x) = -1 \cdot \log_2 = 0 \quad (5.1)$$

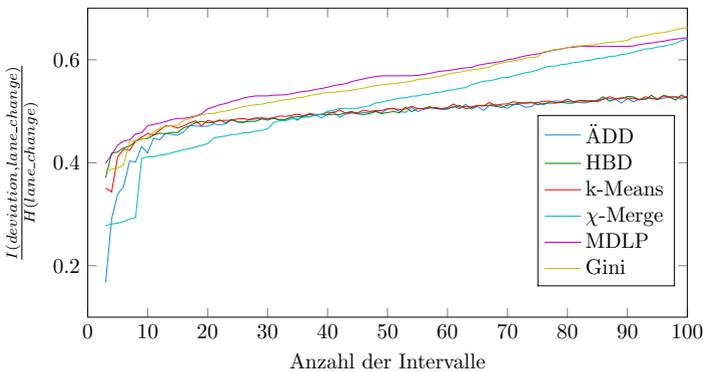


Abbildung 5.12: Verlauf der relativen Transinformation von Merkmal Ablage zur Klassenvariable Fahrstreifenwechsel $\frac{I(\text{deviation/lane_change})}{H(\text{lane_change})}$ über alle in Unterabschnitt 5.2.1 vorgestellten Verfahren zwischen 3 und 100 Intervallen, mit $H(\text{deviation}) \approx 0,631$, vgl. [Vogel 2014]

Einen Überblick über den Verlauf des Informationsgehaltes in Abhängigkeit von der Anzahl an Diskretisierungsintervallen gibt Abbildung 5.12. Dargestellt ist der Verlauf der relativen Transinformation von Merkmal Ablage zur Klassenvariable Fahrstreifenwechsel zwischen drei und hundert Intervallen über alle in Unterabschnitt 5.2.1 vorgestellten Verfahren. Deutlich erkennbar ist der starke Anstieg der Transinformation im Intervall [3; 10], während diese im weiteren Verlauf über alle Verfahren schwächer ansteigt und im Fall einer gegen unendlich strebenden Anzahl von Intervallen ihr Maximum findet. Das gezeigte Verhalten kann in ähnlicher Form ebenfalls bei allen anderen Situationsmerkmalen beobachtet werden.

Ziel der Diskretisierung ist es für jedes Situationsmerkmal die Intervallgrenzen so festzulegen, dass der Informationsgehalt weitgehend erhalten und die Stelligkeit der Zufallsvariablen möglichst gering bleibt. Aufgrund

der oben genannten Erkenntnisse scheint dies im Bereich von minimal drei und maximal zehn Intervallen gewährleistet zu sein. Die weitere Untersuchung zur Bestimmung geeigneter Intervallgrenzen beschränkt sich daher auf diesen Bereich.

5.2.3 Bewertung der Diskretisierungsintervalle

Das Kriterium zur Bewertung der für alle Merkmale und Verfahren bestimmten Intervallgrenzen stellt die Transinformation zwischen der diskretisierten Evidenzvariablen und der Klassenvariable *Fahrstreifenwechsel* dar. Da die überwachten Verfahren bereits die Klasseninformation der Klassenvariable zur Bestimmung der Intervallgrenzen nutzen, wird der in Unterabschnitt 5.1.3.1 genannte Trainingsdatensatz nochmals geteilt, in einen Datensatz für die Bestimmung der Intervallgrenzen und einen für deren Bewertung. Anschließend werden die folgenden drei Schritte ausgeführt:

- Für jedes kontinuierliche Situationsmerkmal wird über alle in Unterabschnitt 5.2.1 genannten Verfahren je ein Satz von zwei bis achtzehn Diskretisierungsschwellen auf Basis des Trainingsdatensatzes bestimmt.
- Mit jedem merkmalspezifischem Satz an Diskretisierungsschwellen werden auf Basis des Testdatensatzes diskrete Daten der bisher kontinuierlichen Situationsmerkmale erzeugt.
- Schließlich kann die Transinformation zwischen jeder diskreten Evidenzvariablen und der Klassenvariable in Abhängigkeit von der Intervallanzahl bestimmt werden, vgl. Abbildung 5.13.

Abbildung 5.13 stellt die Transinformation der Variablen *TimeGapFrontCenter* und *lane_change* unter Verwendung von zwei bis achtzehn Diskretisierungsschwellen über alle Diskretisierungsverfahren dar. Es zeigt sich, dass für die überwachten Verfahren erwartungsgemäß eine Zunahme der Intervallanzahl in einer monotonen Zunahme der Transinformation zwischen Eingangs- und Klassenvariablen resultiert. Dies ist bei den unüberwachten Verfahren nicht der Fall. Auffallend ist, dass die überwachten Verfahren in einigen Intervallen, z. B. [7:11] einen geringen Anstieg der Transinformation aufweisen. Diese Eigenschaft ist abhängig von der Verteilung der Eingangsdaten und von der Wahl des verfahrensspezifischen Abbruchkriteriums. Dieses Verhalten lässt sich in ähnlicher Form auch bei anderen Evidenzvariablen als der hier diskutierten *TimeGapFrontCenter* beobachten. Grund hierfür ist, dass die jeweils nächsten ermittelten Diskretisierungsschwellen teilweise

in sehr geringem Abstand zu bereits bestehenden Schwellen gesetzt werden. Tabelle 5.4 zeigt diesen Sachverhalt für die betrachtete Variable bei 12 und 19 über das χ -Merge Verfahren ermittelten Intervallgrenzen. Grenzen mit geringem Abstand zu einer benachbarten Grenze sind grau hinterlegt dargestellt.

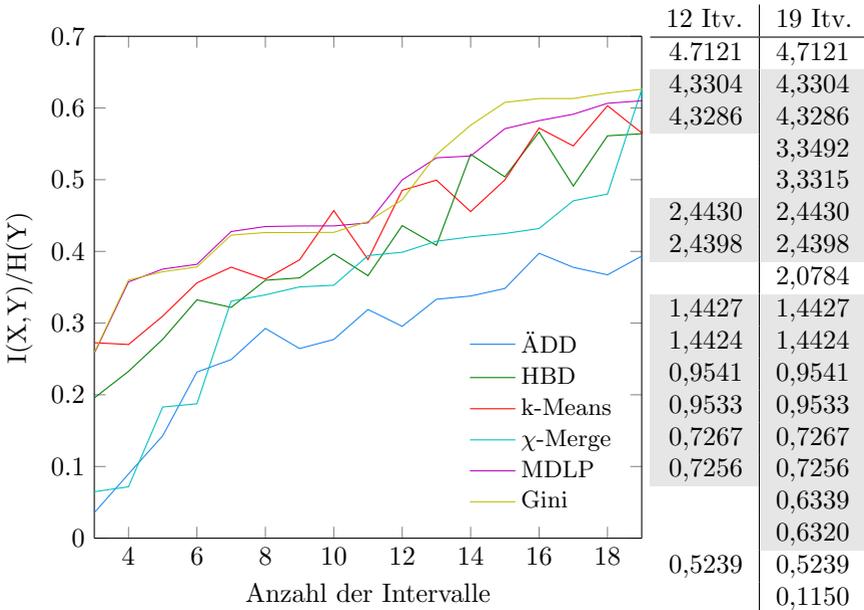


Abbildung 5.13: Verlauf der relativen Transinformation von Variable *TimeGapFrontCenter X* zu *lane_change Y*, mit $H(Y) = 3,08031 \cdot 10^{-2}$

Tabelle 5.4: χ -Merge Intervallgrenzen 12 und 19

Eine Lösung besteht in einem nachgelagerten iterativen Prozess, bei dem die Intervallgrenzen auf Basis des Zugewinns an Transinformation ausgewählt werden:

- Aus der Menge der bestimmten Intervallgrenzen wird zunächst die Grenze ausgewählt, auf deren Basis die höchste Transinformation erzielt wird. Diese Diskretisierungsschwelle bildet das erste Element in einem sortierten Satz an Diskretisierungsschwellen.
- Dieser Prozess wird iterativ wiederholt, indem der sortierte Satz an Intervallgrenzen um genau die Diskretisierungsschwelle erweitert

wird, mit der der erweiterte sortierte Satz die höchste Transinformation zwischen Eingangs- und Klassenvariable erzielt. Der Prozess wird abgebrochen, wenn neun Intervallgrenzen ausgewählt und damit die nach Unterabschnitt 5.2.2 empfohlenen maximal 10 Intervalle bestimmt sind.

Tabelle 5.5 zeigt die Auswahl der ersten 9 Intervallgrenzen für das Verfahren χ -Merge beginnend mit der ersten Schwelle 2,4398 und die zugehörige Entwicklung der relativen Transinformation unter Hinzunahme weiterer Diskretisierungsschwellen. Das heißt, $\frac{I(X,Y)}{H(Y)} = 0,2945$ basiert auf 3 Intervallen, definiert durch die Diskretisierungsschwellen bei 2,4398 und 4,7121. Das vorgeschlagene Verfahren garantiert keine monotone Abnahme des Informationszugewinns pro zusätzlicher Diskretisierungsschwelle, führt jedoch zu einem steileren Anstieg der Transinformation bei zunehmender Intervallanzahl für die überwachten Verfahren, vgl. Abbildung 5.14 gegenüber Abbildung 5.13.

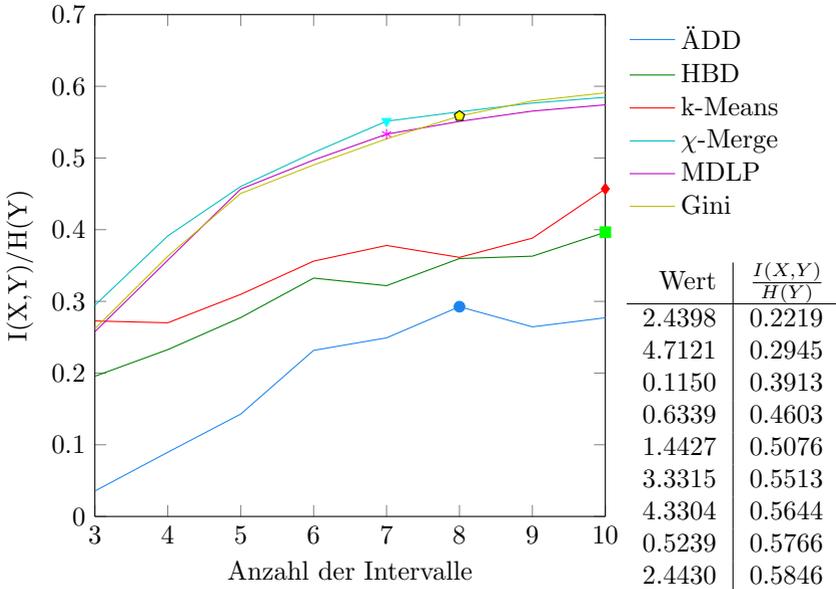


Abbildung 5.14: Verlauf der relativen Transinformation von Variable *TimeGapFrontCenter* X zu *lane_change* Y nach der Evaluierung, mit $H(Y) = 3,08031 \cdot 10^{-2}$

Tabelle 5.5: Intervallgrenzen χ -Merge und relative Transinformation

$$\Delta GI = \frac{\Delta I(X,Y)}{I_n(X,Y)}, \text{ mit } \Delta I(X,Y) = I_{n+1}(X,Y) - I_n(X,Y) \quad (5.2)$$

Gleichung 5.2 definiert den Transinformationsgewinn ΔGI pro zusätzlicher Diskretisierungsschwelle, n bezeichnet die Anzahl an gewählten Schwellen. Über den Transinformationsgewinn lässt sich für die überwachten Verfahren anhand eines Schwellwertes eine automatisierte Auswahl der Intervallanzahl realisieren: Unterschreitet der durch die Hinzunahme einer weiteren Diskretisierungsschwelle erzielte Transinformationsgewinn den definierten Schwellwert, werden die bisher ausgewählten Diskretisierungsschwellen unter Ausschluss der letztgewählten Schwelle als geeignet betrachtet. Unter Beachtung der nicht monotonen Abnahme des Transinformationsgewinns wird zur Vermeidung lokaler Minima bei Unterschreitung des Schwellwertes eine weitere Diskretisierungsschwelle geprüft. Der Schwellwert wurde auf 0,05 festgelegt. Für die unüberwachten Verfahren erfolgt die Auswahl der Intervallanzahl über das Maximum der relativen Transinformation.

Abbildung 5.14 zeigt die durch Marker gekennzeichnete Auswahl an Intervallgrenzen für das jeweilige Diskretisierungsverfahren.

5.2.4 Diskussion der Diskretisierungsergebnisse

Der vorgestellte informationstheoretische Ansatz zur Bestimmung der Diskretisierungsschwellen zeigt die Lösung des Zielkonfliktes zwischen einer möglichst geringen Intervallanzahl pro Situationsmerkmal bei geringstmöglichem Informationsverlust infolge der Diskretisierung auf.

Die Ergebnisse des beschriebenen Vorgehens für die Bestimmung geeigneter Diskretisierungsintervalle werden beispielhaft anhand der Situationsmerkmale *expRateGapBackCenter* und *ttlc* in Abbildung 5.15 dargestellt. In Abbildung 5.15(a) ist zu erkennen, dass das nicht überwachte HBD-Verfahren die höchste relative Transinformation über alle Verfahren bei einer Diskretisierung des Merkmalwertebereichs in zehn Intervallen aufweist. Demgegenüber wird für das Merkmal *ttlc* die Diskretisierung nach dem überwachten Gini-Verfahren bei bereits vier Intervallen gewählt, vgl. Abbildung 5.15(b). Grundsätzlich ist festzustellen, dass es für den hier verwendeten Datensatz nicht das eine richtige Verfahren oder die eine passende Intervallanzahl gibt, welche allgemeingültig für alle in dieser Arbeit verwendeten Situationsmerkmale vorteilhaft sind. Es ist für jedes Merkmal entsprechend der Eigenschaften der Datenbasis über alle Verfahren und jede Anzahl an Intervallen das jeweils geeignete Verfahren mit einer geeigneten Intervallanzahl zu bestimmen.

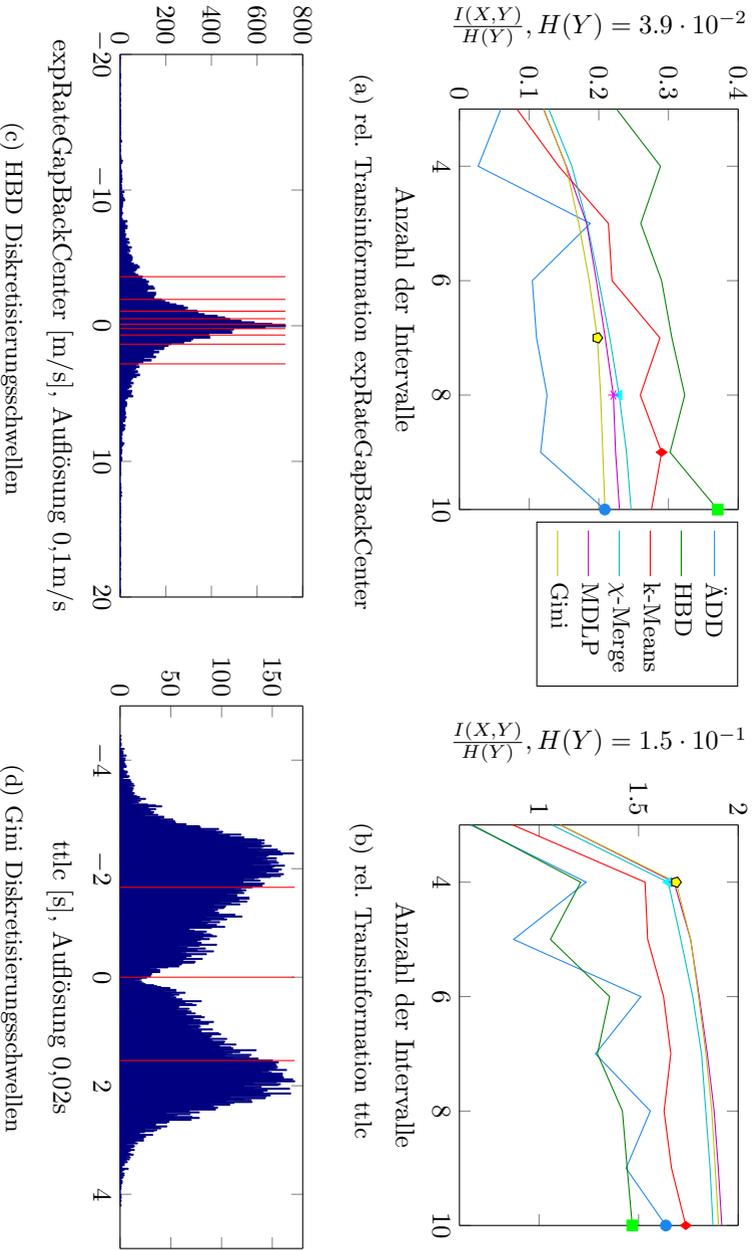


Abbildung 5.15: Auswahl des Diskretisierungsverfahrens und der Intervallanzahl anhand der relativen Transinformation für die Merkmale *expRateGapBackCenter* und *ttle*. Die aus dem gewählten Verfahren resultierenden Intervalle sind für beide Merkmale in einem Histogramm dargestellt.

Entsprechend werden in dieser Arbeit die Schwellen zur Diskretisierung der kontinuierlichen Situationsmerkmale wie in Tabelle 5.6 aufgelistet festgelegt. Die im Ergebnis der Voruntersuchung in Unterabschnitt 5.2.2 bestimmte Maximalanzahl von zehn Intervallen wird nur für ein Merkmal benötigt. Alle weiteren Situationsmerkmale lassen sich mit z. T. deutlich weniger Intervallen abbilden.

Wie in Unterabschnitt 5.1.3 diskutiert, sollten fehlende Messwerte, d. h. Tupel mit ungültigen, weil nicht gemessenen Merkmalen, behandelt werden. Dieser Umstand kann durch Marginalisierung des entsprechenden Merkmalswertes, d. h. Annahme einer Gleichverteilung, oder durch Einführung eines zusätzlichen „ungültig“-Zustandes gelöst werden. Im Rahmen des Diskretisierungsprozesses in dieser Arbeit wird auf die letztgenannte Methode zurückgegriffen, da über eine Marginalisierung des Merkmalswertes die Information verloren geht, ob das Merkmal nicht gemessen wurde oder ob es während der Messung mit einer hohen Unsicherheit behaftet war. Es werden alle Merkmale, welche einen ungültigen, weil nicht messbaren Zustand einnehmen können, um ein zusätzliches Intervall erweitert. Entsprechende Merkmale sind Abbildung 5.4 auf Seite 125 zu entnehmen. Sie sind dadurch gekennzeichnet, dass sie bzgl. ihrer Anzahl an gültigen Werten nicht die mögliche Maximalanzahl aufweisen.

5.3 Reduktion des Merkmalsraumes

Es soll ein Bayes'sches Netzwerk bestimmt werden, welches geeignet ist die Datenbasis bestmöglich zu erklären, um damit ein bestmögliches Vorhersageergebnis für die Klassenvariable Fahrstreifenwechsel zu erzielen. Über das in Kapitel 3 erarbeitete Domänenwissen und die Darstellbarkeit möglicher Zusammenhänge in Form von Variablen über die Umfeldwahrnehmungsplattform ist entsprechend Abschnitt 4.4 eine Menge von 30 spezifischen Variablen verfügbar. Das heißt aus dem Raum aller möglichen Merkmale \mathbf{X} zur Vorhersage eines Fahrstreifenwechsels steht eine Teilmenge \mathbf{X}' zur Verfügung.

Ein lokaler Ansatz um Kausalitäten zu entdecken basiert auf der Bestimmung der Markov-Decke für eine Zufallsvariable, d. h. der Menge an Variablen welche die betreffende Variable unabhängig gegenüber dem übrigen Graphen macht. Dies sind die Eltern- und Kindervariablen der Klassenvariable sowie die weiteren Elternvariablen der Kinder, vgl. [Pearl 1988]. Die Variablen der Markov-Decke tragen die vollständige Information zur Bestimmung der Klassenvariable Fahrstreifenwechsel. Alle anderen Variablen sind mindestens

bedingt unabhängig. Ist die Markov-Decke für die Klassenvariable vollständig bestimmt, so lässt sich aus der Menge der zur Markov-Decke gehörenden Zufallsvariablen die Klassenvariable vorhersagen.

Da der Raum \mathbf{X} zur vollständigen Bestimmung der Markov-Decke unbekannt ist, muss mit fehlenden Variablen gerechnet werden. Dies betrifft Variablen, welche zusätzlich beobachtet werden müssten um das Vorhersageergebnis zu verbessern, sowie nicht beobachtbare Variablen, über die sich eine potentielle Abhängigkeit zwischen den in \mathbf{X}' enthaltenen Variablen beschreiben lässt. Während die erstgenannte Gruppierung von Variablen nur über eine Anpassung der Datenbasis gewonnen werden kann, ist die letztgenannte Gruppierung über maschinelle Lernverfahren zu bestimmen, vgl. Abschnitt 2.3.3.3.

Die Bestimmung der Markov-Decke erfolgt über Merkmalsauswahlverfahren. Auch wenn diese zunächst nur unvollständig bestimmt werden kann, soll das Konzept im weiteren Verlauf angewendet werden.

Die gegebene Merkmalsmenge kann irrelevante und redundante Merkmale enthalten. Dies birgt die Gefahr von erhöhtem Berechnungsaufwand, möglicher Überanpassung und steht der Erstellung eines möglichst kompakten Vorhersagemodells entgegen. Die gezielte Dimensionalitätsreduktion der Zufallsvariable ist daher essentiell für das weitere Vorgehen. Merkmalsauswahlverfahren helfen die oben genannten Gefahren durch eine gezielte Auswahl relevanter und den Ausschluss redundanter Merkmale zu reduzieren. Im folgenden Abschnitt findet eine knappe Beschreibung und Einordnung der in dieser Arbeit angewandten Verfahren zur Merkmalsauswahl statt.

5.3.1 Angewandte Verfahren zur Merkmalsauswahl

Zur Merkmalsauswahl existieren sowohl überwachte als auch unüberwachte Verfahren. Erstere nutzen die Korrelation zwischen den Ausprägungen der Merkmale und den Referenzwerten der Klassenvariable. Letztere hingegen nutzen die Datenvarianz und Separierbarkeit. Es gibt univariate Verfahren, welche jeweils die Merkmale einer Merkmalsmenge unabhängig von einander untersuchen und multivariate Verfahren die die Gesamtheit der Merkmalsmenge untersuchen. Die Ergebnisse können als Merkmalsset und / oder als Gewichtung der Merkmale nach ihrer Relevanz und Redundanz vorliegen.

Grundsätzlich lassen sich Merkmalsauswahlverfahren nach ihrer Arbeitsweise charakterisieren in:

- **Filter-Methoden:** Die Auswahl von Merkmalen erfolgt durch eine Analyse des Merkmalsraumes. Beispielsweise erzeugt die Anwendung statistischer Maße auf jedes Merkmal für dieses eine individuelle Wertung. Anhand der Wertung ergibt sich eine Rangfolge auf deren Basis die Merkmalsauswahl erfolgt. Die Auswahl der Merkmalsmenge erfolgt daher ohne Kenntnisse über die ggf. später verwendete Vorhersagemethode.
- **Wrapper-Methoden:** Variationen eines definierten Vorhersagemodells werden auf Basis verschiedener Merkmalskombinationen erstellt, angelehrt und evaluiert. Die beste Merkmalskombination wird anschließend über einen Vergleich der Modellvorhersagegüte, d. h. der Evaluationsergebnisse, ermittelt. Die Variation des Modells über das Durchsuchen der Potenzmenge einer Merkmalsmenge wird im Folgenden *Wrapper-Methode mit Brute-Force* genannt. Hierbei ist es möglich genau die Teilmenge an Merkmalen zu bestimmen, welche optimal bzgl. der Klassifikationsgüte ist. Die Variation des Vorhersagemodells mithilfe einer gerichteten Suche über die Menge der Merkmale wird im Folgenden *Wrapper-Methode mit gerichteter Suche* genannt. Das Finden der optimalen Merkmalsmenge kann hierbei nicht garantiert werden.

Vertiefende Literatur zu Verfahren und Anwendung der Merkmalsauswahl findet sich in [Guyon u. Elisseeff 2003; Liu u. Motoda 2007]; [Stanczyk u. Jain 2015].

In der vorliegenden Arbeit finden die in [Zhao u. a. 2015] vorgestellten Verfahren Anwendung. Zusätzlich wird eine eigene Wrapper-Methode basierend auf dem Naive-Bayes-Klassifikator implementiert. Im Folgenden werden die angewendeten Verfahren erläutert:

- (1) Überwachte univariate Filter mit Ausgabe einer gewichteten Merkmalsliste:
 - **FISHER SCORE:** Ist ein Filterverfahren, welches für jedes Merkmal einen Fisher-Score bestimmt, d. h. unter Nutzung diskriminierender Methoden und generativer statistischer Modelle die relevanten Merkmale bestimmt, vgl. [Duda u. a. 2007];
 - **RELIEF-F:** Ist eine Erweiterung des Relief-Verfahrens von [Kira u. Rendell 1992] um Mehrklassenfähigkeit und den Umgang mit verrauschten und unvollständigen Daten. Relief ist ein statistisches Filterverfahren zur Merkmalsauswahl. Es wählt zufällige Instanzen des Datensatzes aus und versucht ihre nächsten Nachbarn zu finden. Es ändert die Gewichte der Merkmalsrelevanz so ab, dass

das Merkmal, welches die meisten Merkmale aus anderen Klassen als nächsten Nachbar hat, die höchste Gewichtung erzielt, vgl. [Kononenko 1994; Liu u. Motoda 2007];

- T-TEST: Ist ein Test auf eine statistische Hypothese, basierend auf der Student-Verteilung. Die t-Statistik hat ihren Ursprung bei William Sealy Gosset [Student 1908; Fisher 1925];
 - χ^2 : Ist ein Verfahren basierend auf der χ^2 -Verteilung, vgl. [Liu u. Setiono 1995];
 - KRUSKAL-WALLIS: Das Verfahren gibt eine Liste mit auszuschließenden Merkmalen aus. Es testet auf Widerlegung der Nullhypothese bzgl. eines Zusammenhangs zwischen Merkmal und Klassenvariable. Ist die Nullhypothese widerlegt, kann das Merkmal aus der Merkmalsmenge ausgeschlossen werden, vgl. [Kruskal u. Wallis 1952; Wei 1981];
 - GINI INDEX: Das Verfahren basiert auf dem Gini Index, einem statistischen Maß der Streuung, vgl. [Gini 1912];
 - INFORMATION GAIN: Die Merkmalsauswahl erfolgt auf Basis der Entropie. Das Verfahren berechnet die statistische Abhängigkeit einer Teilmenge von Merkmalen bzgl. einer bestimmten Klasse, vgl. [Cover u. Thomas 1991] und Abschnitt A.1;
- (2) Überwachte multivariate Filter mit Ausgabe einer gewichteten Merkmalsliste:
- mRMR (*minimum redundancy maximum relevance selection*): Verfahren auf Basis der Transinformation zur Auswahl von Merkmalen mit maximaler Relevanz bzgl. der Klassenvariable und minimaler Redundanz bzgl. der Menge der Situationsmerkmale, vgl. [Peng u. a. 2005];
- (3) Überwachte multivariate Filter mit Ausgabe eines Merkmalssets:
- FCBF (*fast correlation based filter*): Ein korrelationsbasierter Filteralgorithmus für hochdimensionale Daten, vgl. [Yu u. Liu 2003]. Der Filter ist geeignet, redundante und irrelevante Merkmale zu entfernen. Mit zunehmender gegenseitiger Abhängigkeit der Merkmale steigt die Gefahr, dass zu viele Merkmale aussortiert werden, vgl. [Senliol u. a. 2008];
 - CFS (*correlation-based feature selection*): Ist ein korrelationsbasiertes Merkmalsauswahlverfahren. Merkmale, welche mit einer Klasse

in Beziehung stehen oder diese vorhersagen, werden als relevant eingestuft, alle anderen als irrelevant, vgl. [Hall u. Smith 1999];

- (4) Überwachte Embedded-Methode mit Ausgabe eines Merkmalssets:
- **BLOGREG** (*Bayesian logistic regression*): Univariates Bayes'sches logistisches Regressionsverfahren, vgl. [Shevade u. Keerthi 2003; Cawley u. Talbot 2006];
 - **SBMLR** (*sparse multinomial logistic regression via Bayesian L1 regularisation*): Multivariate Methode zur Erkennung von Mehrklassenmustern, vgl. [Cawley u. a. 2007];
- (5) Unüberwachte univariate Filter mit Ausgabe einer gewichteten Merkmalsliste:
- **SPEC** (*spectral feature selection*): Ist ein auf der spektralen Graphentheorie basierendes Gerüst nach [Zheng u. Liu 2007], mit dem sich bestimmte überwachte und nicht überwachte Methoden zur Merkmalsauswahl als Spezialfall herleiten lassen. Hier findet das Filterverfahren Laplacian Score Anwendung, vgl. [He u. a. 2005].
- (6) Überwachte Wrappermethode mit Ausgabe einer gewichteten Merkmalsliste:
- **WRAPPER-METHODE MIT BRUTE-FORCE**: In dieser Methode wird für alle möglichen Merkmalskombinationen, d. h. der Potenzmenge der Merkmale, ein Naive-Bayes-Klassifikator gebildet, dessen Parameter mit einem Lerndatensatz angelernt und mit einem Testdatensatz bewertet werden. Somit kann aus der Menge aller Kombinationen die Merkmalskombination mit dem besten Klassifikationsergebnis gewählt werden. Der Pseudocode findet sich in Listing A.2.
 - **WRAPPER-METHODE MIT GERICHTETER SUCHE**: Im Gegensatz zum Brute-Force-Ansatz werden die Merkmalmengen beginnend mit einem Merkmal schrittweise aufgebaut. Zu Beginn ist die Anzahl der Merkmalssets gleich der Anzahl der Merkmale. Für jedes Merkmalsset wird ein Naive-Bayes-Klassifikator gebildet und analog zum Brute-Force-Ansatz angelernt und getestet. Auf Basis des Merkmalssets mit dem besten Klassifikationsergebnis werden jeweils durch Hinzufügen eines weiteren bisher nicht verwendeten Merkmals neue Sets gebildet und darüber ein Naive-Bayes-Klassifikator angelernt und bewertet. Dieser Vorgang wird wiederholt, bis alle Merkmale Verwendung finden. Die Anzahl möglicher Sets reduziert

sich daher mit jedem Iterationsschritt um eins, wobei sich gleichzeitig die Anzahl der Merkmale im Set um eins erhöht. Final wird das Merkmalsset mit dem besten Klassifikationsergebnis gewählt. Die Methode wird in zwei Ausprägungen implementiert:

- (a) WRAPPER (HART): Mit der Anwendung von harter Evidenz bei der Bestimmung der Übergangswahrscheinlichkeiten und Durchführung der Inferenz. Der zugehörige Pseudocode findet sich in Listing A.3.
- (b) WRAPPER (WEICH): Mit der Anwendung von weicher Evidenz. Die Bestimmung der Übergangswahrscheinlichkeiten erfolgt nach [Xiao u. a. 2009], die Bestimmung der Inferenz erfolgt wie in Unterabschnitt 2.3.2.1 beschrieben.

Dieses Verfahren garantiert nicht das Finden des besten Merkmalssets, oft wird nur ein lokales Maximum bzgl. der Klassifikationsgüte gefunden.

Es ist davon auszugehen, dass eine Anwendung der Brute-Force-Methode die Menge an Evidenzvariablen findet, mit der ein darauf aufbauendes Naives Bayes'sches Netzwerk die höchste Klassifikationsgüte erzielt. Entsprechend wäre eine Anwendung der weiteren hier aufgeführten Verfahren obsolet. Allerdings erfordert das Verfahren einen sehr hohen Rechenaufwand. Für die Anwendung der Wrapper-Methoden ist in Abschnitt A.6 eine Abschätzung der Laufzeitkomplexität gegeben. Bei einer gegebenen Menge von 30 Evidenzvariablen existieren rund $4 * 10^{21}$ mögliche Teilmengen, welche durch die Brute-Force Methode zu bewerten wären. Es wird daher von einem Einsatz der Wrapper-Methode mit Brute-Force Abstand genommen.

Die in [Zhao u. a. 2015] durchgeführte Bewertung anhand verschiedener Testdatensätze und Klassifikatoren schließt grundsätzlich keines der weiter genannten Merkmalsauswahlverfahren für eine Anwendung auf die hier gegebene Problemstellung aus. Im folgenden Unterabschnitt 5.3.2 kommen daher alle in [Zhao u. a. 2015] aufgeführten Verfahren und die eigene Implementierung der Wrapper-Methode WRAPPER (HART) und WRAPPER (SOFT) mit gerichteter Suche zur Anwendung. Bis auf das letztgenannte Verfahren arbeiten alle Methoden mit harter Evidenz. Diese wird aus dem zugrunde liegenden Datensatz mit weicher Evidenz ermittelt.

5.3.2 Vorgehen zur Merkmalsauswahl

Die genannten Verfahren zur Merkmalsauswahl werden auf den balancierten Lerndatensatz angewandt, vgl. Unterabschnitt 5.1.3.1. Unter Anwendung der in Abschnitt 5.2 bestimmten Diskretisierungsschwellen liegen die Daten im Datensatz für alle Merkmale in diskreter Form vor. Die Auswahl der Evidenzvariablen erfolgt in zwei Schritten:

- 1.) Anwendung der im vorhergehenden Abschnitt 5.3.1 aufgeführten Verfahren zur Bestimmung von Merkmalssets.
- 2.) Bestimmung der Klassifikationsgüte für jedes Merkmalsset auf Basis eines Naive Bayes-Klassifikators.

Zu Schritt 1:

Die Ergebnisse der angewandten Verfahren zur Merkmalsauswahl sind in Tabelle 5.7 entsprechend ihrer Gewichtung oder als ungewichtetes Merkmalsset aufgelistet. Die Verfahren BlogReg, CFS, FCBF, mRMR, und SBMLR geben eine Empfehlung über die zu verwendenden Variablen und schließen ungeeignete Variablen aus der Merkmalsmenge aus. Die ausgeschlossenen Variablen sind in Tabelle 5.7 durchgestrichen und in grauer Textfarbe dargestellt. Die Verfahren CFS und FCBF geben keine Gewichtung und somit keine Rangfolge für die gewählten Merkmale vor. Kruskal-Wallis schließt eine Teilmenge aus der Gesamtmenge aller Merkmale aus. Die verbleibenden grau gekennzeichneten Merkmale sind ungewichtet und können einen Zusammenhang zur Klassenvariable haben, müssen aber nicht. Die Anwendung der Verfahren Relief-F und SPEC auf den genannten Datensatz führt zum speicherbedingten Abbruch der Verfahren, es kommt daher ein auf ein Viertel der ursprünglichen Größe reduzierter Datensatz zur Anwendung.

Die in Tabelle 5.7 dargestellten Ergebnisse sind teilweise stark diversitär und erlauben nicht die gewünschte Festlegung auf ein kompaktes Merkmalsset. Diese erfolgt über eine Bewertung der Klassifikationsgüte für jedes Set an Evidenzvariablen im folgenden Schritt.

Zu Schritt 2:

Die Ergebnisbewertung der Merkmalsauswahlverfahren erfolgt über einen Leistungsvergleich. Ziel ist die Ermittlung des Merkmalssets mit der voraussichtlich höchsten Vorhersagegenauigkeit. Hierfür wird mit dem jeweilige Set von Merkmalen ein Vorhersagemodell angelernt und dessen Vorhersagegüte

bewertet. Die Vorgehensweise ist an das in [Zhao u. a. 2015] geschilderte Verfahren angelehnt, jedoch zweckmäßig auf den Einsatz eines Naive Bayes'schen Netzwerks als Klassifikator reduziert.

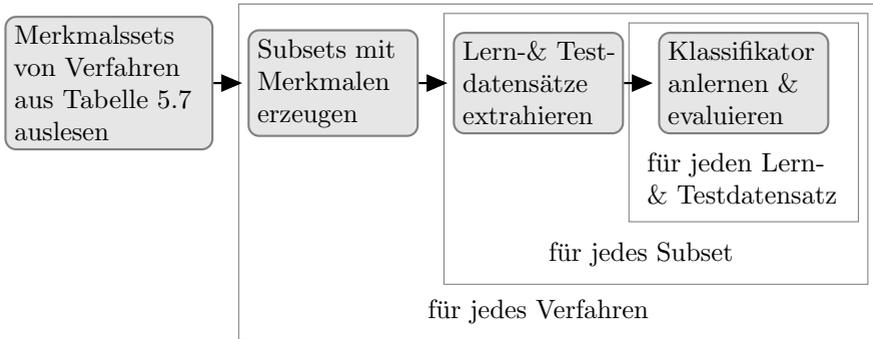


Abbildung 5.16: Ablauf zur Bestimmung der Klassifikationsgüte für jede Menge an Evidenzvariablen

Die Ergebnisse der Methoden WRAPPER (HART) und WRAPPER (SOFT), angewendet auf das gesamte Merkmalsset, entsprechen bereits dem geschilderten Verfahren und können daher direkt in die Auswertung übernommen werden. Da das Verfahren KRUSKAL-WALLIS nur Merkmale ausgeschlossen hat, wird auf die dabei verbliebene Menge an Merkmalen das in WRAPPER (HART) implementierte Verfahren angewendet. Auch hier können die Ergebnisse direkt in die Auswertung übernommen werden.

Die Vorgehensweise für alle weiteren Verfahren ist in Abbildung 5.16 dargestellt und gliedert sich in folgende Schritte:

- (1) Für jedes Verfahren wird das entsprechende Merkmalsset aus Tabelle 5.7 ausgelesen.
- (2) Aus dem verfahrensspezifischen Merkmalsset werden Subsets erzeugt, wenn das Merkmalsauswahlverfahren eine gewichtete Rangfolge von Merkmalen liefert. Es gilt folgendes Vorgehen: Aus der Rangfolge von n Merkmalen werden n Merkmalssets gebildet, beginnend mit dem Set bestehend aus dem ranghöchsten Merkmal. Jedes weitere Set ergibt sich aus dem Vorgängerset erweitert um das nächst rangniedere Merkmal. Das n -te Set umfasst folglich n Merkmale. Für Verfahren ohne gewichtete Merkmalsliste wird nur das gegebene Set berücksichtigt.

Tabelle 5.7: Ergebnisse der Merkmalsauswahlverfahren als Variablensets z. B. {28}, {28,24}, {28,24,3}, ... mit Gewichtung (ohne Kennzeichnung), ohne Gewichtung (*) u. Ausschlussmenge (!); Variablenauswahl: \mathbb{H} / \mathbb{H} : implizit / explizit ausgeschlossen, ID / \mathbb{ID} explizit / implizit eingeschlossen

Methode	Rangfolge der Variablen [Abnahme der Relevanz \rightarrow]																																																										
	ID	Variable	ID	Variable	ID	Variable	ID	Variable	ID	Variable	ID	Variable	ID	Variable	ID	Variable	ID	Variable	ID	Variable	ID	Variable	ID	Variable																																			
Fisher Score	28	24	3	29	2	16	13	14	22	11	18	9	12	30	17	10	15	23	1	6	7	25	20	27	19	21	4	26	5	8																													
Relief-F	28	3	24	29	2	16	14	1	18	13	17	22	30	11	15	9	12	23	25	10	27	8	5	4	26	21	6	19	20	7																													
T-test	2	3	18	14	15	1	17	20	19	29	27	25	26	7	21	6	10	4	9	30	16	12	23	11	13	22	24	28	8	5																													
χ^2	1	3	24	28	2	29	16	10	14	13	15	9	11	22	12	17	23	18	30	21	7	6	4	25	19	20	26	27	5	8																													
Kruskal-Wallis \dagger	46	28	4	40	11	24	2	3	29	22	23	14	21	6	7	9	30	25	12	17	19	26	4	13	20	8	5	27	18	15																													
Gini	24	3	28	29	16	1	7	6	14	2	15	21	10	9	20	19	4	13	23	22	12	11	18	30	17	25	26	27	5	8																													
Information Gain	1	3	28	24	2	29	16	10	9	14	13	15	17	11	22	12	23	18	30	7	6	21	4	25	20	19	26	27	5	8																													
mRMR	1	29	30	28	16	17	18	21	20	19	15	14	24	23	22	9	10	13	11	12	25	26	7	6	4	3	2	5	8	27																													
FGBF*	1	28	24	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20	21	22	23	25	26	27	29	30																													
CFS*	1	2	3	24	28	29	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20	21	22	23	25	26	27	29	30																												
BlogReg	24	16	22	6	9	21	20	10	18	7	29	14	15	23	13	28	3	30	4	1	17	27	25	11	2	5	8	12	19	26																													
SBMLR	28	29	2	5	16	3	24	21	1	30	20	6	10	13	18	14	9	25	15	19	11	4	7	27	22	23	26	12	17	8																													
SPEC	4	2	1	3	17	18	22	27	6	20	19	29	28	24	25	9	7	10	12	11	21	16	14	23	15	26	13	30	8	5																													
Wrapper (hart)	1	3	2	24	28	6	7	4	29	22	15	16	21	26	20	10	18	19	25	12	27	5	8	9	14	30	17	13	23	11																													
Wrapper (weich)	1	3	2	7	14	24	28	6	10	29	16	21	22	19	20	25	4	18	8	5	27	30	15	9	17	23	12	26	13	11																													
ID	Variable	ID	Variable	ID	Variable	ID	Variable	ID	Variable	ID	Variable	ID	Variable	ID	Variable	ID	Variable	ID	Variable	ID	Variable	ID	Variable	ID	Variable	ID	Variable	ID	Variable	ID	Variable																												
1	ttlc	9	vMax2vActLeft	17	vMax2vActRight	25	timeGapBackCenter	2	deviation	10	vActRefObj2vActLaneLeft	18	vActRefObj2vActLaneRight	26	lengthGapBackCenter	3	vLat	11	timeGapFrontLeft	19	timeGapFrontRight	27	expRateGapBackCenter	4	vMax2vActCenter	12	lengthGapFrontLeft	20	lengthGapFrontRight	28	noPassingLeft	5	dist2LaneEndCenter	13	expRateGapFrontLeft	21	expRateGapFrontRight	29	noPassingRight	6	timeGapBackLeft	14	timeGapBackRight	22	timeGapFrontCenter	30	lanes2mostRightLane	7	expRateGapBackLeft	15	expRateGapBackRight	23	lengthGapFrontCenter	8	dist2LaneEndLeft	16	dist2LaneEndRight	24	expRateGapFrontCenter

- (3) Für jede Teilmenge an Merkmalen werden je zehn Lern- und Testdatensätze extrahiert. Die Lerndatensätze werden entsprechend Unterabschnitt 5.1.3.1 balanciert, die Testdatensätze bleiben unverändert.
- (4) Für jeden Lerndatensatz wird ein von der aktuellen Teilmenge abgeleitetes Naive Bayes'sches Netzwerk als Vorhersagemodell angelernet und ein Klassifikationsergebnis über das in folgendem Abschnitt gegebene Bewertungsschema ermittelt. Die Inferenz erfolgt diagnostisch durch Einbringen der Evidenz in die Variablen. Es wird im Anschluss jeweils der Mittelwert über alle zehn Testdatensätze gebildet sowie der Minimal- und Maximalwert bestimmt.

5.3.2.1 Bewertung des Klassifikationsergebnisses

Für jedes angelernete Vorhersagemodell wird die Trefferwahrscheinlichkeit anhand des zugehörigen Testdatensatzes bestimmt und in einer Konfusionsmatrix abgelegt, vgl. Tabelle 5.8. Die Konfusionsmatrix gibt das Verhältnis des tatsächlichen Zustands (des Referenzzustandes) der Klassenvariable zum vorhergesagten Zustand an, unabhängig von der Häufigkeit seines Auftretens im Referenzdatensatz.

Wird für das Schätzergebnis des Naiven Bayes'schen Netzwerks eine harte Verteilung angenommen, vgl. Unterabschnitt 2.3.2.1, d. h. es gilt Gleichung 5.3, so berechnen sich die Elemente der Matrix nach Gleichung 5.4 mit

- lc_j bzw. lc_i als Bezeichner für die Realisierung des Referenzwertes LC^{gt} bzw. des prädizierten Wertes LC^{pr} , vgl. Tabelle 4.5 s. Seite 103,
- n der Anzahl an Vorhersagen $LC^{pr}=lc_i$ zur Referenz $LC^{gt}=lc_j$ und
- m der Anzahl an Referenzwerten $LC^{gt}=lc_j$.

$$P(LC^{pr}=lc_i) = 1; \quad P(LC^{pr} \neq lc_i) = 0 \quad (5.3)$$

$$P(LC^{pr}=lc_i, LC^{gt}=lc_j) = \frac{n_{(LC^{pr}=lc_i, LC^{gt}=lc_j)}}{m_{(LC^{gt}=lc_j)}}, \text{ mit } i, j = 1..9 \quad (5.4)$$

Es werden im Folgenden zwei Ansätze vorgestellt, mit denen die Klassifikationsergebnisse auf Basis der Konfusionsmatrix bewertet werden können.

Tabelle 5.8: Konfusionsmatrix eines Naive Bayes'schen Netzwerks für die Realisationen des Knoten *lane_change* basierend auf der Menge von 6 Evidenzvariablen bestimmt durch WRAPPER (HART), vgl. Tabelle 5.7.

$P(LC^{pr}, LC^{gt})$ in [%]	$LC^{pr} =$								
	lc_1	lc_2	lc_3	lc_4	lc_5	lc_6	lc_7	lc_8	lc_9
$LC^{gt}=lc_1$	90,54	2,47	0,44	0,18	0,53	3,36	0,24	0,99	1,24
$LC^{gt}=lc_2$	26,42	69,97	3,21	0,27	0,14	0,00	0,00	0,00	0,00
$LC^{gt}=lc_3$	32,20	45,49	16,35	4,55	1,42	0,00	0,00	0,00	0,00
$LC^{gt}=lc_4$	53,85	16,15	12,59	9,48	7,70	0,22	0,00	0,00	0,00
$LC^{gt}=lc_5$	69,36	9,15	2,02	5,35	13,65	0,47	0,00	0,00	0,00
$LC^{gt}=lc_6$	23,00	0,11	0,00	0,00	0,00	74,39	0,60	1,69	0,22
$LC^{gt}=lc_7$	30,90	0,11	0,00	0,00	0,00	46,87	15,37	6,42	0,33
$LC^{gt}=lc_8$	45,11	0,11	0,00	0,00	0,00	18,85	15,68	15,41	4,84
$LC^{gt}=lc_9$	61,04	0,29	0,00	0,00	0,00	12,05	4,13	9,35	13,14

Klassifikationsgüte mit gleicher Gewichtung der Klassenzustände:

Ist eine Maßzahl G um die Klassifikationsleistung der Netzwerkvarianten miteinander vergleichen zu können. Die Diagonalelemente $P(LC^{pr}=lc_j, LC^{gt}=lc_i)$ mit $i=j=1..9$ der Konfusionsmatrix geben die Erkennungsrate des jeweiligen Zustandes, d. h. Zeitintervalles durch das Bayes'sche Netzwerk an. G wird nach Gleichung 5.5 berechnet durch eine Mittelwertbildung über alle Diagonalelemente der Konfusionsmatrix und gibt somit die Erkennungsrate für alle neun Zeitintervalle von LC in einer Maßzahl an.

$$G = \frac{\sum_{i=j=1..9} P(LC^{pr}=lc_j, LC^{gt}=lc_i)}{9} \quad (5.5)$$

Alternativ kann das Vorgehen zur Ermittlung der Klassifikationsgüte auch auf eine weiche Evidenz bzgl. LC angewendet werden, d. h. Gleichung 5.3 wird nicht durch Konvertierung der weichen Evidenz erzwungen. In diesem Fall berechnen sich die Elemente der Konfusionsmatrix nach Gleichung 5.6.

$$P(LC^{pr}=lc_j, LC^{gt}=lc_i) = \frac{\sum_{(LC^{gt}=lc_i)} P(LC^{pr}=lc_j)}{m(LC^{gt}=lc_i)} \quad (5.6)$$

Kostensensitive Bewertung: Während die bisher dargestellten Ansätze das Klassifikationsergebnis allein über eine Mittelung der *true-positive*-Werte bewerten, soll im Folgenden ein kostensensitiver Ansatz vorgestellt werden.

Die Idee ist, dass eine Fehlklassifikation in Abhängigkeit des falsch vorhergesagten Zustandes zum Referenzzustand unterschiedlich stark bestraft werden soll. Das heißt, eine Vorhersage eines Fahrstreifenwechselmanövers in die falsche Richtung soll stärker bestraft werden, als eine Vorhersage in die richtige Richtung aber zum falschen Zeitpunkt. Zu diesem Zweck wird für die Klassenvariable LC expertengestützt eine Kostenmatrix entsprechend Gleichung 5.7 aufgestellt und die Kosten der Klassifikation werden für jeden Datensatz anhand Gleichung 5.8 ermittelt.

$$mis_Cost_{9 \times 9} = \begin{bmatrix} C_{11} & \cdots & C_{19} \\ \vdots & \ddots & \vdots \\ C_{91} & \cdots & C_{99} \end{bmatrix} \tag{5.7}$$

$$Kosten = \sum_{k=1}^N \sum_{i,j=1..9} P(LC^{pr}=lc_j, LC^{gt}=lc_i) * C_{ij} \tag{5.8}$$

Darin bezeichnet N die Größe des Datensatzes und C_{ij} die Kosten für die Vorhersage von Zustand $LC^{pr}=lc_j$ zum Referenzzustand $LC^{gt}=lc_i$.

Tabelle 5.9: Kostenfaktor C_{ij} in Abhängigkeit der Fehlklassifikation

Referenzwert	prädizierter Wert	C_{ij}
Vorhersage = Referenz:		
$LC^{gt} = lc_i$	$LC^{pr} = lc_i$	0,00
kein FSW statt FSW bzw. FSW statt kein FSW:		
$LC^{gt} = lc_1$	$LC^{pr} \neq lc_1$	1,50
$LC^{gt} \neq lc_1$	$LC^{pr} = lc_1$	1,50
korrekte Vorhersage nach links, aber falsches Zeitintervall:		
$LC^{gt}=lc_i, lc_i \in (lc_2..lc_5)$	$LC^{pr}=lc_j, i-j =1$	0,50
	$lc_j \in (lc_2..lc_5) i-j =2$	0,75
	$ i-j =3$	1,00
korrekte Vorhersage nach rechts, aber falsches Zeitintervall:		
$LC^{gt}=lc_i, lc_i \in (lc_6..lc_9)$	$LC^{pr}=lc_j, i-j =1$	0,50
	$lc_j \in (lc_6..lc_9) i-j =2$	0,75
	$ i-j =3$	1,00
Vorhersage in die zum Referenzwert entgegengesetzte Richtung:		
$LC^{gt}=lc_i, lc_i \in (lc_2..lc_5)$	$LC^{pr}=lc_j, lc_j \in (lc_6..lc_9)$	2,00
$LC^{gt}=lc_i, lc_i \in (lc_6..lc_9)$	$LC^{pr}=lc_j, lc_j \in (lc_2..lc_5)$	2,00

Die Kostenfaktoren in Abhängigkeit der Fehlklassifikation sind in Tabelle 5.9 gegeben. Es ist aus Zeile eins ersichtlich, dass für eine korrekte Klassifikation keine Kosten anfallen. Für eine Klassifikation in die zur Referenz entgegengesetzte Richtung fallen, entsprechend der letzten und vorletzten Zeile, Maximalkosten von 2,0 an. Die hier vorgestellte kostensensitive Bewertung ist abhängig von der Anzahl N der im Testdatensatz enthaltenen Datentupel.

5.3.3 Ergebnisse und Diskussion

Die Ergebnisse der auf die Gesamtmenge aller Evidenzvariablen angewendeten Merkmalsauswahlverfahren aus Schritt 1 sind in Tabelle 5.7 gegeben. Die dargestellten Ergebnisse sind teilweise divergent und erlauben nicht die gewünschte Festlegung auf ein kompaktes Set an Evidenzvariablen.

In Schritt 2 wird daher die Klassifikationsgüte aller in Schritt 1 ermittelten Teilmengen anhand des jeweils daraus gebildeten Naive Bayes'schen Netzwerks ermittelt. Es zeigt sich, dass durchgehend eine bessere Güte erzielt wird, wenn die prädierte Verteilung von LC durch die Auswahl des wahrscheinlichsten Zustandes in eine harte Verteilung nach Gleichung 5.3 konvertiert wird. Auch eine Variation des vorgestellten kostensensitiven Ansatzes über verschiedene Kostenmatrizen führt bei einer anschließenden Ermittlung der Klassifikationsgüte zu keinem besseren Resultat. Die Klassifikationsgüten über alle Teilmengen an Evidenzvariablen, die anhand der in Unterabschnitt 5.3.1 vorgestellten Verfahren ermittelt wurden, sind in Abbildung 5.17 gegenübergestellt. Es ist ersichtlich, dass die Klassifikationsgüte des jeweils zugrunde liegenden Naive Bayes'schen Netzwerks mit einer Zunahme an Evidenzvariablen steigt, ihren höchsten Wert jedoch deutlich vor der Maximalanzahl von 30 Evidenzvariablen erreicht. Die jeweils höchste Klassifikationsgüte über alle Verfahren und Kardinalitäten der Teilmengen an Evidenzvariablen sind in Abbildung 5.18 abgebildet. Es ist zu erkennen, dass ein Naive Bayes'sches Netzwerk, dessen Teilmengen an Variablen mit dem Verfahren WRAPPER (HART) erzeugt werden, in fast allen Fällen das beste Ergebnis liefert. Die höchste Klassifikationsgüte liegt bei 40,55 % mit einer Menge von 21 Variablen. Obgleich die per WRAPPER (HART) ermittelten Teilmengen stets im Spitzenfeld bzgl. der Klassifikationsgüte liegen, zeigen die Teilmengen mit sieben und acht bzw. mit neun Variablen, ermittelt über das RELIEF-F- bzw. das χ^2 -Verfahren, dass es durchaus mehrere Variablenkombinationen gibt, um ein ähnliches - hier sogar geringfügig besseres - Klassifikationsergebnis zu erzielen.

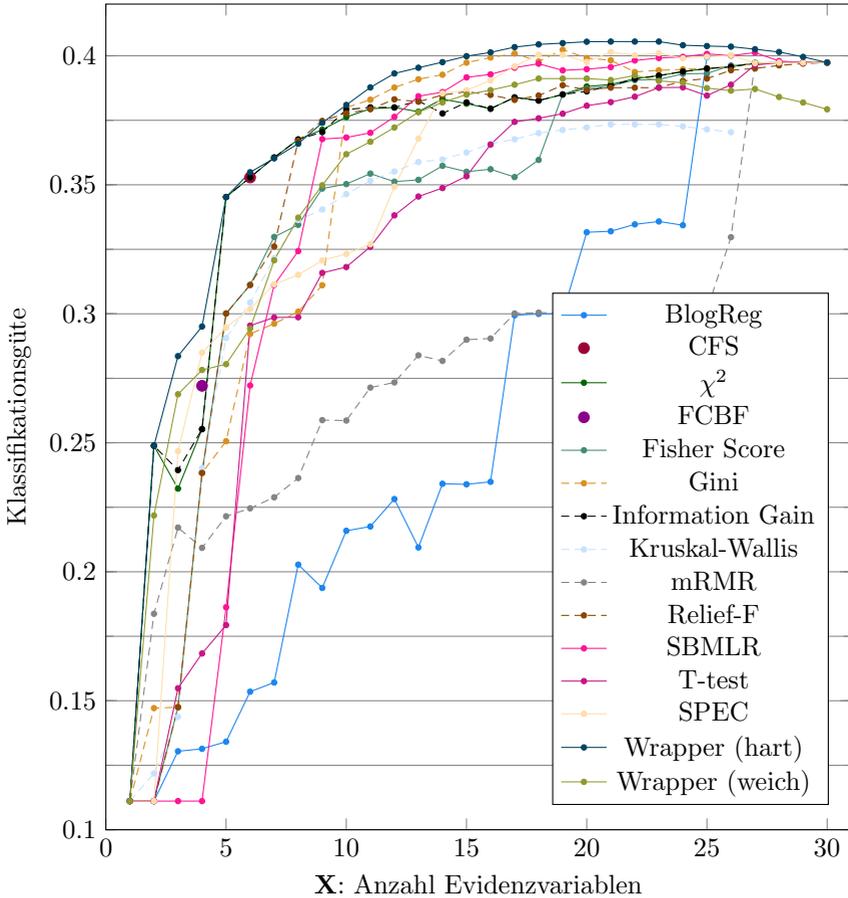


Abbildung 5.17: Vergleich der Klassifikationsgüte für Naive Bayes'sche Netzwerke mit $n = 1..30 + 1$ Variablen für die jeweiligen Merkmalmengen über alle Verfahren

Abbildung 5.18 und 5.19 zeigen die Ergebnisse im Detail. Neben dem Durchschnittswert für die Klassifikationsgüte sind die jeweiligen Minimal- und Maximalwerte infolge unterschiedlicher Lern- und Testdatensätze je Merkmalsmenge abgebildet, ebenso wie die entsprechend Tabelle 5.9 ermittelten Klassifikationskosten. Zusätzlich sind die IDs der Variablen in entsprechender Rangfolge in Abbildung 5.19 angegeben. Die geringe durchschnittliche Abweichung der Klassifikationsgüte vom Mittelwert über die Lern- und

Testdatensätze je Teilmenge zeigt, dass der Einfluss des Datensatzes auf die Klassifikationsgüte gering ist. Zu Vergleichszwecken sind in Abbildung 5.19 ebenfalls für die Wrapper-Methode mit weicher Evidenz die Klassifikationsgüte und Klassifikationskosten je Merkmalsset gegeben. Der Einfluss der weichen Evidenz wird in Unterabschnitt 5.7.2 auf Seite 180 diskutiert.

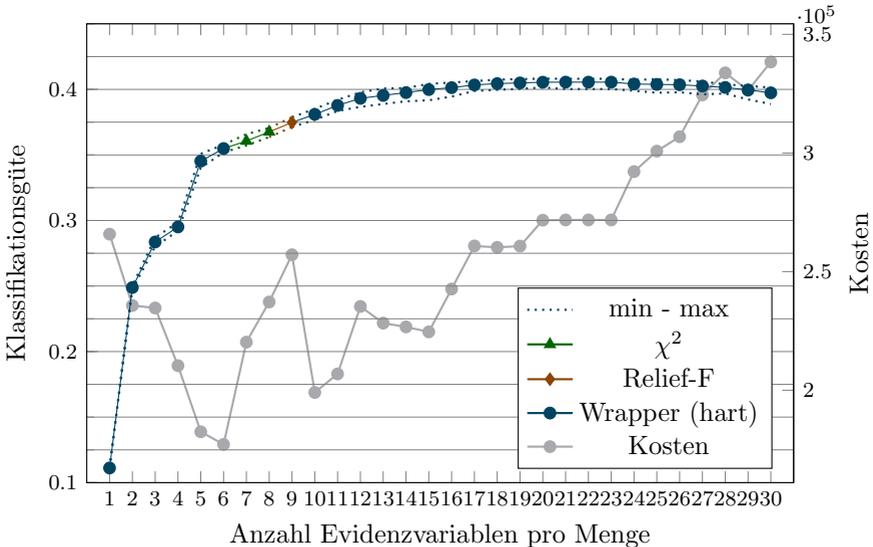
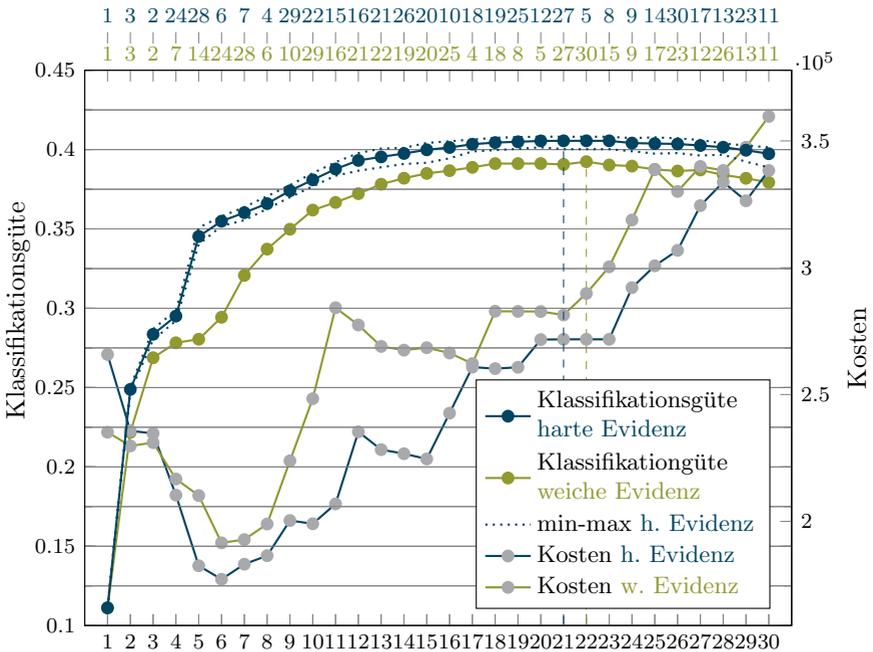


Abbildung 5.18: Höchste Klassifikationsgüte je Variablenset über alle Verfahren

Die Funktion zur Berücksichtigung der Fehlklassifikationskosten erreicht bei einer Menge von sechs Variablen ihr Minimum und steigt bis zu Variablenmenge von 21 um ca. 50 %, wobei der Anstieg keine Monotonieeigenschaften aufweist. Der Grund hierfür ist die Kombination der Fehlklassifikationskosten aus Tabelle 5.9 mit der Häufigkeit des Vorkommens eines gegebenenfalls falsch prädierten Zustandes von LC zur Referenz im Testdatensatz, s. Abbildung 5.5. Bei einer Menge von 6 Variablen wird insbesondere der Zustand $LC = lc_1$, d. h. *kein Fahrstreifenwechsel* - der häufigste Zustand in den Referenzdaten - besser geschätzt als bei einer Menge von 21 Variablen, vgl. Tabelle 5.8 auf Seite 154 und Tabelle 5.11. Demgegenüber verbessert sich mit einer hohen Variablenanzahl die Schätzgenauigkeit für die Zustände mit einer Vorhersagezeit von mehr als 0,5 s. Wird in den Referenzdaten ein Fahrstreifenwechsel angezeigt, ist es sehr unwahrscheinlich, dass eine Prädiktion für ein Zeitintervall in die zur Referenz entgegengesetzte Wechselrichtung erfolgt.

Für das weitere Vorgehen werden vier Naive Bayes'sche Netzwerke erstellt, basierend auf der per WRAPPER (HART) Verfahren ermittelten Auswahl an Evidenzvariablen. Neben dem Maximum von 40,55 % bei 21 Variablen wird zudem die Teilmenge von 16 Variablen bei einer Klassifikationsgüte von 40,13 betrachtet. Weiterhin werden die Teilmengen mit 6 und 10 Variablen weiter verfolgt, da hier jeweils das Minimum bzw. ein lokales Minimum bzgl. der Klassifikationskosten vorliegt, s. Tabelle 5.10.



X: Anzahl Evidenzvariablen (Fußzeile) & Variablen-IDs (Kopfzeile)

Abbildung 5.19: Klassifikationsgüte für ein Naive Bayes'sches Netzwerk mit $n = 1..30 + 1$ Knoten bei harter Evidenz und weicher Evidenz

Tabelle 5.10: Vergleichsbewertung der ermittelten Naiven Bayes'schen Netzwerke

Anzahl Evidenzvariablen	6	10	16	21
BIC-Score	-284431	-460258	-682935	-918568
Klassifikationsgüte [%]	35,48	38,09	40,13	40,55
Klassifikationskosten	177242	229086	240851	277602

Tabelle 5.11: Konfusionsmatrix eines Naive Bayes'schen Netzwerks für die Realisationen des Knoten *lane_change* basierend auf der Menge von 21 Evidenzvariablen bestimmt durch WRAPPER (HART), vgl. Tabelle 5.7.

$P(LC^{pr}, LC^{gt})$ in [%]	$LC^{pr} =$								
	lc_1	lc_2	lc_3	lc_4	lc_5	lc_6	lc_7	lc_8	lc_9
$LC^{gt} = lc_1$	72,98	2,46	1,31	0,66	6,60	4,30	0,83	1,20	9,67
$LC^{gt} = lc_2$	23,21	61,23	12,08	1,23	2,18	0,00	0,00	0,00	0,07
$LC^{gt} = lc_3$	22,81	42,57	21,89	6,54	5,61	0,00	0,00	0,00	0,57
$LC^{gt} = lc_4$	32,00	15,33	15,19	14,44	22,74	0,00	0,00	0,15	0,15
$LC^{gt} = lc_5$	38,87	8,61	3,72	11,02	37,16	0,08	0,00	0,39	0,16
$LC^{gt} = lc_6$	14,39	0,05	0,00	0,00	0,05	75,10	5,89	2,13	2,40
$LC^{gt} = lc_7$	16,52	0,00	0,00	0,00	0,16	48,19	17,12	11,20	6,81
$LC^{gt} = lc_8$	18,30	0,00	0,00	0,11	0,44	21,69	16,52	21,36	21,58
$LC^{gt} = lc_9$	22,78	0,11	0,00	0,06	0,11	14,46	6,54	12,74	43,20

5.4 Struktursuche für zeitinvariante Bayes'sche Netzwerke

Für die Strukturbestimmung eines zeitinvarianten Bayes'schen Netzwerks zur Vorhersage von Fahrstreifenwechselmanövern kommt der in Unterabschnitt 2.3.3.3 beschriebene HNB-Ansatz zur Anwendung. Hierfür bilden die vier im letzten Abschnitt ermittelten Naive Bayes'schen Netzwerke die jeweilige Basis. Analog zur bisherigen Vorgehensweise kommt ein balancierter Lerndatensatz und ein naturalistischer, d. h. unbalancierter Testdatensatz zur Anwendung. Da dem Autor keine verfügbare Implementierung des HNB-Verfahrens bekannt ist, kommt eine eigene Implementierung des Verfahrens zum Einsatz.

Die Laufzeit des Verfahrens wird maßgeblich durch die Kardinalitäten der Latentvariablen bestimmt. Die höchste Kardinalität einer Latentvariable wird durch Gleichung 2.24 auf Seite 52 und damit durch den Zustandsraum der Evidenzvariablen bestimmt, vgl. Tabelle 5.6. Der Minimierung der Zustandsanzahl für jede Evidenzvariable im Diskretisierungsschritt, vgl. Abschnitt 5.2, kommt daher eine laufzeitbestimmende Bedeutung zu. Jede mögliche Kardinalität stellt eine Netzwerkvariante dar, die zu bewerten ist. Bei jeder Variation der Netzstruktur mit einer Latentvariable ist auch die Kardinalität der Elternvariable, sofern latent, neu zu bestimmen. Ist die Elternvariable latent, wird die Kardinalität aller weiteren Latentvariablen, welche mit der

Elternvariable direkt in Verbindung stehen, ebenso neu bestimmt. Die Anzahl der Netzvarianten, welche durch eine Variation zu bewerten ist, beträgt damit im Maximalfall $|Z|_{max}^n$, mit $|Z|_{max}$ als die höchsten Kardinalität einer Latentvariable Z und n als Bezeichner für die Anzahl der verbundenen Latentvariablen.

Die Möglichkeit, ein Bayes'sches Netzwerk entsprechend Absatz 2.3.3.3.3 in Teilnetze zu zerlegen, diese separat anzulernen und zu bewerten, wirkt sich insbesondere bei mehreren Teilnetzen mit latenten Variablen positiv auf die Konvergenzgeschwindigkeit des Algorithmus aus, es ändert jedoch nichts an der beschriebenen Komplexitätsproblematik. Aus diesem Grund wird die Strukturtiefe infolge eingefügter Latentvariablen auf zwei beschränkt. Das heißt, eine Latentvariable darf latente Kindvariablen haben, aber keine latenten Kindeskindern. Weiterhin wird die Anzahl der an einer Eltern-Kindbeziehung beteiligten Latentvariablen auf jeweils vier begrenzt.

Im Folgenden werden zwei verschiedene Zielfunktionen angewendet, BIC-Score und Klassifikationsgüte. Beide werden mit dem jeweiligen Ausgangswert aus Tabelle 5.10 auf Seite 159 verglichen. Resultierende Strukturen sind in den Abbildungen 5.20 bis 5.23 in den Teilen (a) und (b) dargestellt. Jede Abbildung gibt die Netzwerkstruktur für eine bestimmte Anzahl an Evidenzvariablen, d. h. 6, 10, 16 oder 21 wieder. Die gefundenen Netzstrukturen sind in den Abbildungen 5.20(a) bis 5.23(a) dargestellt, die Bewertungsergebnisse sind in Tabelle 5.12 gegeben.

Tabelle 5.12: Bewertung der per HNB mit Zielfunktion BIC-Score ermittelten Bayes'schen Netzwerke

Anzahl Evidenzvariablen	6	10	16	21
Abbildung	5.20(a)	5.21(a)	5.22(a)	5.23(a)
BIC-Score	-260758	-377295	-531439	-638567
Klassifikationsgüte [%]	24,23	29,14	32,97	34,24

Für alle untersuchten Mengen an Evidenzvariablen wird eine ausgeprägte stark verzweigte Netzstruktur gefunden. Die Beschränkung der Strukturtiefe auf maximal zwei aufeinander folgende Latentvariablen wird in allen Strukturen voll ausgeschöpft. Keine Evidenzvariable ist direkt mit der Klassenvariable verbunden. Latente Variablen sind zumeist zwischen Evidenzvariablen eingefügt, zwischen denen bereits in Unterabschnitt 5.1.3.2 eine Abhängigkeit nachgewiesen werden konnte. Auffällig sind hier insbesondere die Variablen der lateralen Evidenz, d. h. ID 1-3, welche in jeder Struktur immer im gleichen Subnetz vorkommen. Die Minimierung des BIC-Score bringt eine Maximierung der Trefferwahrscheinlichkeit für $P(LC^{pr}=no_lc, LC^{gt}=no_lc)$,

vgl. Gleichung 2.22, zu Lasten der übrigen Zustände von LC mit sich. Dies ist auf die hohe Anzahl an Tupel ohne beobachteten Fahrstreifenwechsel im Referenzdatensatz zurück zuführen.

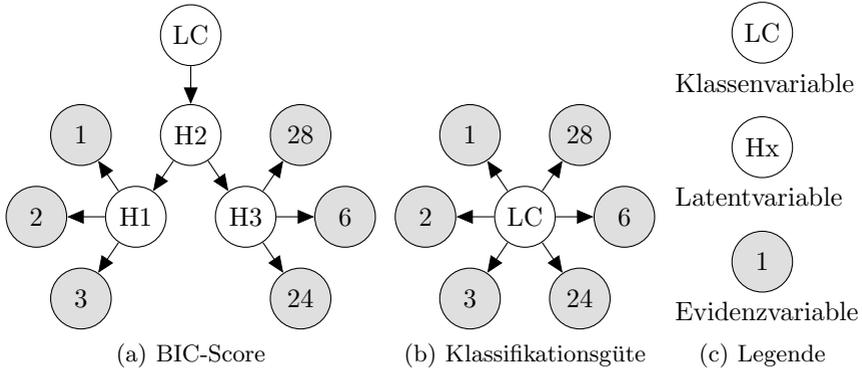


Abbildung 5.20: Ergebnis des HNB-Verfahrens für ein Naive Bayes'sches Netzwerk mit 6 Evidenzvariablen mit dem Bewertungskriterium BIC-Score, 5.20(a) und Klassifikationsgüte, 5.20(b)

Werden die ermittelten Strukturen in den Abbildungen 5.20(a) bis 5.23(a) abschließend nach der Klassifikationsgüte gemäß Tabelle 5.3.2.1 bewertet, ist das Ergebnis gegenüber den jeweiligen Naive Bayes'schen Netzwerk erheblich schlechter, vgl. Tabelle 5.10 zu 5.12.

Vor diesem Hintergrund wird in einer zweiten Variante der Implementierung anstelle des BIC-Score die Klassifikationsgüte als Zielfunktion für das HNB-Verfahren angewendet. Aufgrund des geänderten Bewertungskriteriums sind in dieser Variante die Voraussetzungen zur Nutzung der ggf. zwischengespeicherten Ergebnisse bzgl. der unterhalb der Klassenvariable abbildbaren Subnetze, wie in Absatz 2.3.3.3.3 auf Seite 54 dargestellt, nicht mehr gegeben. Vielmehr wird zusätzlich für jede Netzvariation auf Basis des unbalancierten Testdatensatzes die Klassifikationsgüte bestimmt. Dies führt zu einer Laufzeitverlängerung des gesamten Algorithmus. Weiterhin ist in der Bewertungsfunktion kein Strafterm zur Berücksichtigung der Netzwerkstrukturkomplexität enthalten. Beide letztgenannte Punkte sind dahingehend unkritisch, als dass in der praktischen Anwendung auf Basis der hier genutzten Datensätze und Teilmengen an Evidenzvariablen bereits nach wenigen Iterationen ein Strukturoptimum gefunden wird.

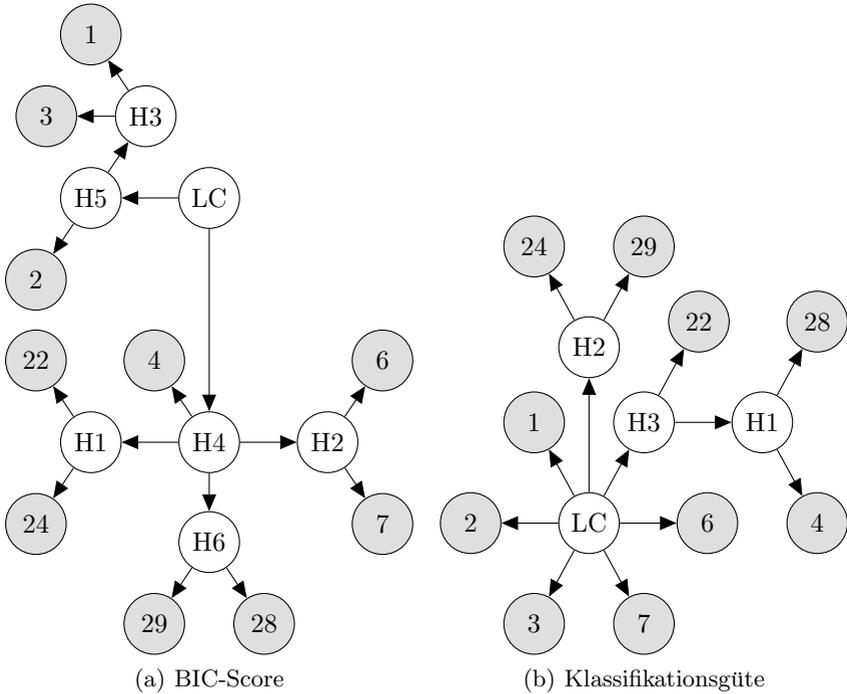


Abbildung 5.21: Ergebnis des HNB-Verfahrens für ein Naive Bayes'sches Netzwerk mit 10 Evidenzvariablen mit dem Bewertungskriterium BIC-Score, 5.21(a) und Klassifikationsgüte, 5.21(b)

Die mit der zweiten Variante ermittelten Netzstrukturen sind in den Abbildungen 5.20(b) bis 5.23(b) ihren per BIC-Score bestimmten Pendanten gegenübergestellt. Eine Bewertung ist in Tabelle 5.13 gegeben.

Für die Menge von sechs Evidenzvariablen konnte keine Struktur bestimmt werden, welche eine bessere Klassifikationsgüte als das zugrunde liegende Naive Bayes'sche Netzwerk aufweist. Die gefundenen Strukturen weisen eine deutlich geringere Verzweigung auf als ihre per BIC-Score optimierten Pendanten. Viele Evidenzvariablen sind weiterhin direkt mit der Klassenvariable verbunden. Die über die latenten Variablen modellierten Abhängigkeiten überraschen, da die betroffenen Evidenzvariablen in keinem offensichtlichen Zusammenhang stehen. Im Vergleich mit den Naive Bayes'schen Netzwerken erhöht sich die Klassifikationsgüte durch die bestimmten Strukturen nur geringfügig um 0,72 % bei 10, 1,1 % bei 16 und 1,65 % bei 21 Evidenzvariablen.

Tabelle 5.13: Bewertung der per HNB mit Zielfunktion Klassifikationsgüte ermittelten Bayes'schen Netzwerke

Anzahl Evidenzvariablen	6	10	16	21
Abbildung	5.20(b)	5.21(b)	5.22(b)	5.23(b)
BIC-Score	-284352	-458279	-680920	-898566
Klassifikationsgüte [%]	35,48	38,81	41,23	42,2

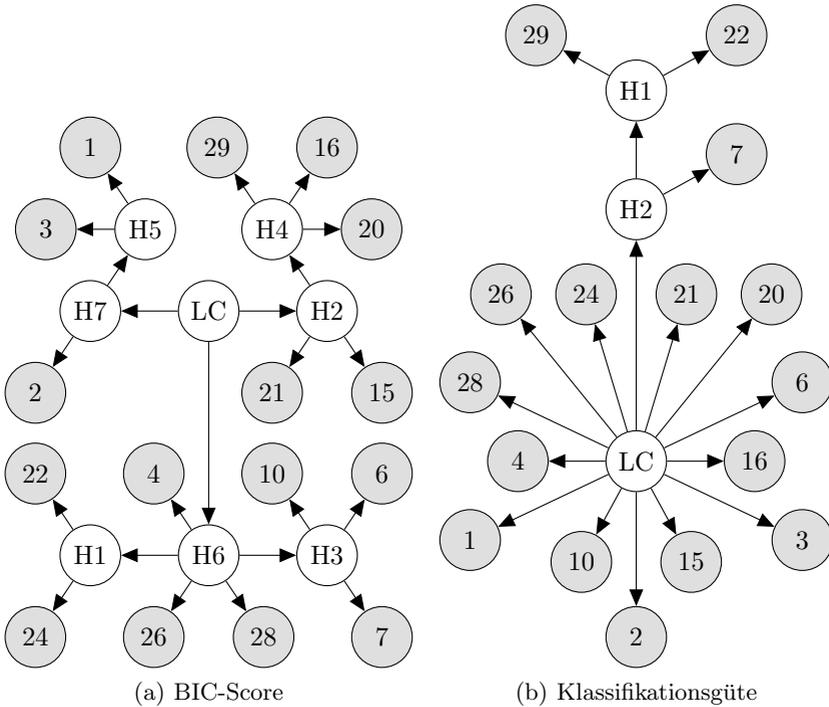
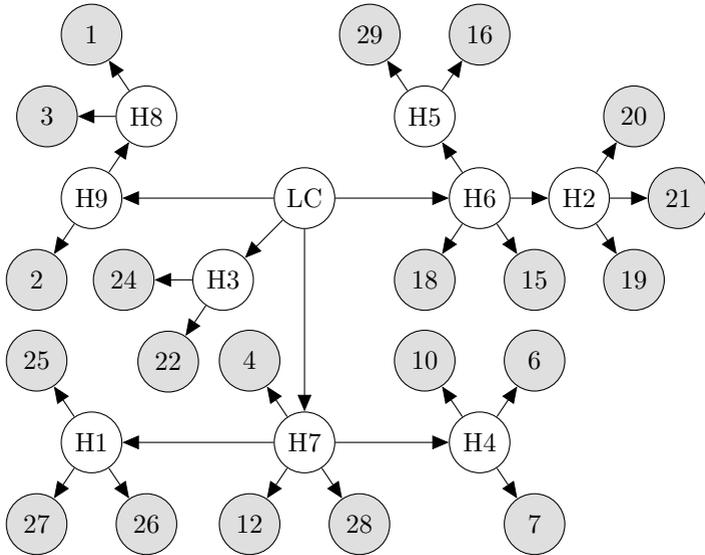
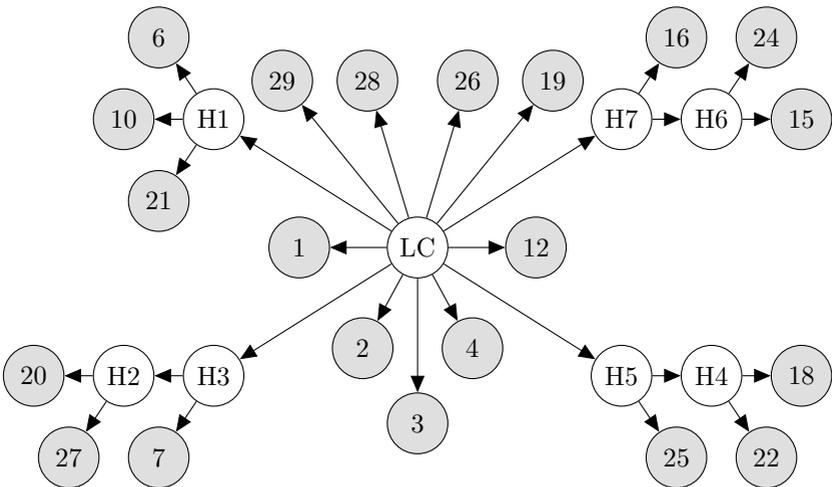


Abbildung 5.22: Ergebnis des HNB-Verfahrens für ein Naive Bayes'sches Netzwerk mit 16 Evidenzvariablen mit dem Bewertungskriterium BIC-Score, 5.22(a) und Klassifikationsgüte, 5.22(b)



(a) BIC-Score



(b) Klassifikationsgüte

Abbildung 5.23: Ergebnis des HNB-Verfahrens für ein Naive Bayes'sches Netzwerk mit 21 Evidenzvariablen mit dem Bewertungskriterium BIC-Score, 5.23(a) und Klassifikationsgüte, 5.23(b)

5.5 Maschinelle Struktursuche für Dynamische Bayes'sche Netzwerke

Im vorhergehenden Abschnitt wird die Struktur eines Bayes'schen Netzwerks per HNB-Verfahren bestimmt. Die in den Lern- und Testverfahren verwendeten Daten für die Klassenvariable und die Evidenzvariablen beziehen sich jeweils auf denselben Zeitschritt, d. h. die selbe Zeitscheibe. Innerhalb dieses Abschnittes wird das Konzept der Dynamischen Bayes'schen Netzwerke in die Struktursuche einbezogen, vgl. Unterabschnitt 2.3.1.3. Ein Dynamisches Bayes'sches Netzwerk besteht jeweils aus einem initialen Netzwerk pro Zeitscheibe, dessen Variablen temporal, d. h. zeitscheibenübergreifend über gerichtete Kanten in Beziehung stehen. Diese zeitscheibenübergreifenden Beziehungen bilden das temporale Netzwerk, welches im Folgenden maschinell bestimmt werden soll. Die per HNB-Verfahren ermittelten Netzwerkstrukturen stellen jeweils das initiale Netzwerk dar. Als Strukturlernverfahren kommt der in Unterabschnitt 2.3.3.4 beschriebene Genetische Algorithmus in abgewandelter Form zur Anwendung, vgl. [Kirschner 2016].

Um eine kontinuierliche Zugehörigkeit der Datentupel zu einem Objekt zu gewährleisten, findet im Folgenden der in Unterabschnitt 5.1.3.3 untersuchte Datensatz Verwendung. Dieser enthält ausschließlich Tupel, welche dem Ego-Fahrzeug zuzuordnen sind. Die entsprechenden Klassifikationsgüten der HNB-Netzwerke sind auf Basis dieses gefilterten Datensatzes neu bestimmt und in Tabelle 5.14 gegeben.

Tabelle 5.14: Bewertung der per HNB mit Zielfunktion Klassifikationsgüte ermittelten Bayes'schen Netzwerke auf Basis des auf Ego-Daten reduzierten Testdatensatzes.

Anzahl Evidenzvariablen	6	10	16	21
Abbildung	5.20(b)	5.21(b)	5.22(b)	5.23(b)
Klassifikationsgüte [%]	48,29	50,17	50,65	51,03

5.5.1 Definition des Genotyps

Formel 5.9 zeigt die im Folgenden zur Strukturbestimmung verwendete Codierung des temporalen Netzwerkes. Darin bezeichnet n die Anzahl an Variablen K_i des initialen Netzwerkes, k_{ij} beschreibt die zeitscheibenübergreifenden gerichteten Kanten von einer Variable K_j des Zeitslots $t(-k_{ij})$ zu

einer Variable K_i des Zeitslots $t(0)$ und O bezeichnet die über den Genotyp maximal codierbare Ordnung ⁶ des Dynamischen Bayes'schen Netzwerkes. Im Gegensatz zu [Dai u. Ren 2015] beinhaltet die hier verwendete Codierung nicht die Struktur des initialen Netzwerkes. Diese soll während der Struktursuche unverändert, d. h. in jedem Zeitslot gleich bleiben. Abbildung 5.24 illustriert die Codierung des Genotyps an einem Minimalbeispiel. Anhand des Beispiels wird die Codierung im Folgenden detailliert erläutert.

$$\underbrace{(K_1, \dots, K_n)}_{\text{Teil 1}}, \underbrace{(k_{ij}, \dots, k_{nn})}_{\text{Teil 2}}, \underbrace{(O)}_{\text{Teil 3}}; \text{ mit } i, j = 1 \dots n, k = 0 \dots O \quad (5.9)$$

Teil 1 der Codierung gibt die Variablen des initialen (HNB-) Netzwerkes an. Bezogen auf das in Abbildung 5.24 gegebene Beispiel mit zwei Variablen im initialen Netzwerk lautet $K_1 = LC$ und $K_2 = X$.

Teil 2 beschreibt die gerichteten Kanten, welche die in Teil 1 gegebenen Variablen zeitscheibenübergreifend verbinden. Ein Wert $k_{ij} > 0$ zeigt die Existenz einer solchen Kante an. Dabei gibt k_{ij} die Anzahl der von der Kante überspannten Zeitscheiben an. Das heißt, die Kante verläuft von einer Variable K_j aus einer Zeitscheibe der Vergangenheit $t(-k < 0)$ zu einer Variable K_i der gegenwärtigen Zeitscheibe $t(0)$. Mit dieser Codierung lässt sich nur eine gerichtete Kante zwischen K_j und K_i beschreiben.

Für das genannte Beispiel gibt ein Wert 1 im Feld $k_{i=1, j=2}$ an, dass eine Kante von der in $K_{j=2}$ in Zeitscheibe $t(-k_{12} = -1)$ gegebenen Variable $X^{k_{12}=1}$ zu der in $K_{i=1}$ in Zeitscheibe $t(0)$ gegebenen Variable LC^0 besteht. Der Wert 2 im Feld k_{11} definiert eine Kante von der Variable LC^2 aus Zeitschritt $t(-k_{11} = -2)$ zur Variable LC^0 aus Zeitscheibe $t(0)$. Die Werte $k_{21} = k_{22} = 0$ zeigen an, dass keine zur Variable X^0 gerichteten Kanten von Variablen aus anderen Zeitscheiben existieren.

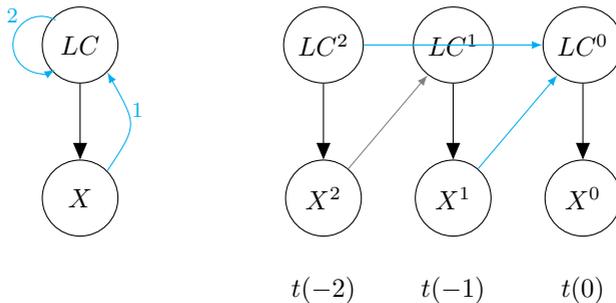
Teil 3 gibt die maximale Ordnung eines Dynamischen Bayes'schen Netzwerkes an, welches mit dem Genotyp codiert werden können soll. Im genannten Beispiel ist $O = 2$, d. h. k_{ij} kann maximal den Wert zwei annehmen. Dies ist mit $k_{11} = 2$ gegeben.

Über die vorgestellte Codierung eines Genotyp lässt sich das temporale Netzwerk für ein Dynamisches Bayes'sches Netzwerk mit folgenden Beschränkungen bestimmen:

⁶ Anzahl an Zeitscheiben.

- Zwischen zwei Variablen K_i und K_j unterschiedlicher Zeitscheiben ist über k_{ij} nur eine Kante codierbar. Im gegebenen Beispiel wäre bei einer möglichen Kante von X^2 nach X^0 keine weitere Kante von X^1 nach X^0 möglich.
- Entgegen der Kausalrichtung der zugrunde liegenden Hierarchischen Naive Bayes'schen Netzwerke wird eine neu hinzuzufügende Kante von einer Variable eines zurück liegenden Zeitschrittes zu einer Variable des aktuellen Zeitschrittes gerichtet.

Durch letztgenannte Beschränkungen kann ausgeschlossen werden, dass eine neu erzeugte Graphenstruktur zyklisch wird. Die Anwendung der Operatoren erfolgt ausschließlich auf Teil 2 des Genotyps. Teil 1 und 3 bleiben während der Struktursuche unverändert.



(a) DBN kompakt

(b) DBN entrollt

K_1	K_2	k_{11}	k_{12}	k_{21}	k_{22}	Ordn.
LC	X	2	1	0	0	2
Teil 1		Teil 2				Teil 3

(c) Codierung

Abbildung 5.24: Abbildung 5.24(c) zeigt ein Minimalbeispiel zur Codierung eines Dynamischen Bayes'schen Netzwerks (DBN) mit drei Zeitscheiben $t(0)$, $t(-1)$ und $t(-2)$ als Genotyp. Das DBN ist gegeben in kompakter Form in 5.24(a) oder entrollter Form in 5.24(b). Das initiale Netzwerk stellt das bei $t(0)$ gegebene Naive Bayes'sche Netzwerk dar, mit den Variablen LC^0 und X^0 .

5.5.2 Durchführung und Ergebnis

Der zeitliche Abstand zwischen zwei aufeinander folgenden Zeitscheiben wird auf 200 ms festgelegt. Das heißt, bei einem Dynamischen Bayes'schen Netzwerk mit drei Zeitscheiben werden für einen Vorhersagezeitpunkt $t(0)$ zusätzlich die Zustände der Variablen aus $t(-200\text{ ms})$ und $t(-400\text{ ms})$ entsprechend der vorhandenen temporalen Kanten während des Inferenzprozesses berücksichtigt. Als Fitnessfunktion kommt, statt des in [Dai u. Ren 2015] verwendeten BIC-Scores, die in Abschnitt 5.3.2.1 definierte Klassifikationsgüte mit gleicher Gewichtung der Klassenzustände zum Einsatz.

Aus der Zeitreihenanalyse bzgl. der statistischen Abhängigkeit, d. h. der Transinformation zwischen Klassenvariable und Evidenzvariablen ist bekannt, dass insbesondere die Variablen der lateralen Evidenz ebenso wie die Klassenvariable für sich selbst eine vergleichsweise hohe Abhängigkeit aufweisen. Analog zu [Dai u. Ren 2015] wird dies zur Initialisierung der Population ausgenutzt, indem temporale Kanten zwischen der Klassenvariable der aktuellen Zeitscheibe und den Variablen der lateralen Evidenz sowie der Klassenvariable aus zurückliegenden Zeitscheiben gesetzt werden. Für ein Netzwerk mit sechs Evidenzvariablen, s. Abbildung 5.25(a), werden beispielsweise Individuen mit gerichteten Kanten zwischen der Klassenvariable und den Variablen 1, 2, 3, 24, 28, LC aus den Zeitscheiben $t(-200\text{ ms})$ und $t(-400\text{ ms})$ im temporalen Netzwerk initialisiert.

Für jedes Individuum einer Population, d. h. für jede Netzstruktur, werden per EM-Algorithmus die bedingten Übergangswahrscheinlichkeiten auf Basis des Lerndatensatzes bestimmt. Im Anschluss erfolgt die Bewertung der Fitness auf Basis des Testdatensatzes mithilfe der Klassifikationsgüte. Das Individuum mit der besten Bewertung wird direkt in die Population der nächsten Generation überführt. Die weitere Population der neuen Generation entsteht durch Anwendung der Operatoren, nach dem in [Dai u. Ren 2015] vorgeschlagenen Verhältnis zueinander, auf die Population der aktuellen Generation. Das heißt, für jedes Individuum besteht eine Chance von 65 %, 34,9 % bzw. 0,1 %, dass es per Selektions-, Kreuzungs- bzw. Mutationsoperator bestimmt wird, vgl. Unterabschnitt 2.3.3.4. Zur Einschränkung des Suchraumes wird die Größe der Population auf maximal 49 Individuen beschränkt. Es werden höchstens acht gerichtete Kanten zwischen Zeitscheiben zugelassen und die Anzahl der Zeitscheiben wird auf drei beschränkt. Der Abbruch des Verfahrens erfolgt nach 100 Generationen mit dem Individuum, das die höchste Klassifikationsgüte aufweist.

Die gefunden Netzstrukturen sind in den Abbildungen 5.25 und 5.26 dargestellt. Eine Bewertung ist in Tabelle 5.15 gegeben.

Tabelle 5.15: Bewertung der per Genetischem Algorithmus erstellten Dynamischen Bayes'schen Netzwerke mit einem zum Start der Struktursuche entsprechend der Transinformation initialisierten temporalen Netzwerk.

Anzahl Evidenzvariablen	6	10	16	21
Abbildung	5.25(a)	5.25(b)	5.25(c)	5.26
Klassifikationsgüte [%]	56,46	56,65	57,47	58,7

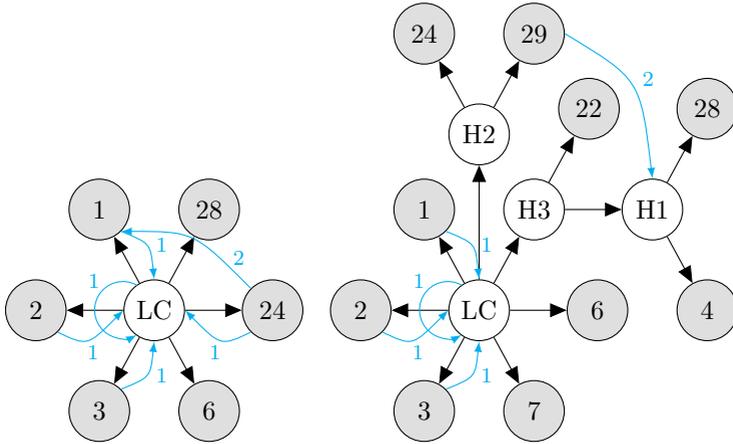
Tabelle 5.16: Bewertung der per Genetischem Algorithmus erstellten Dynamischen Bayes'schen Netzwerke mit einem zum Start der Struktursuche zufällig initialisierten temporalen Netzwerk.

Anzahl Evidenzvariablen	6	10	16	21
Klassifikationsgüte [%]	53,87	53,73	54,38	53,73

Es zeigt sich, dass viele, bereits bei der Initialisierung der Individuen gesetzten temporalen Verbindungen beibehalten werden. Insbesondere Verbindungen zwischen den Variablen zur Beschreibung der lateralen Evidenz ID: 1, 2, 3 und des Fahrstreifenwechsels lc aus Zeitscheibe $t(-200\text{ ms})$ zur Klassenvariable sind in jeder Struktur zu finden. Ein Vergleich der Schätzergebnisse der HNB-Netzwerke, gegeben in Tabelle 5.14, mit den gefundenen Dynamischen Bayes'schen Netzwerken, gegeben in Tabelle 5.15, zeigt eine deutliche Verbesserung hinsichtlich der Klassifikationsgüte.

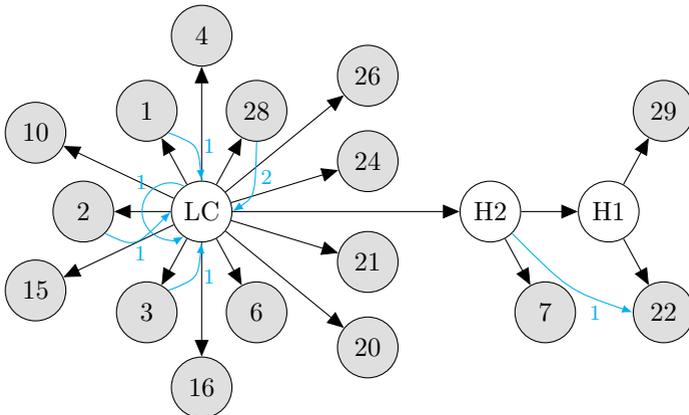
In Tabelle 5.16 ist die jeweilige Klassifikationsgüte für Netzwerkstrukturen mit zufällig initialisiertem temporalen Netzwerk gegeben. In den hier nicht abgebildeten Netzwerkstrukturen ist die Anzahl von Verbindung im temporalen Netzwerk deutlich geringer. Die Klassifikationsgüte liegt für alle bestimmten Strukturen über den HNB-Netzwerken, aber deutlich unter den Konfigurationen die durch den genetischen Algorithmus erzeugt wurden und bei denen die temporalen Netzwerke über die Transinformation zwischen der Klassenvariablen und den Variablen aus den zurückliegenden Zeitscheiben initialisiert werden. Obgleich durch die Anwendung des Genetischen Algorithmus die Möglichkeit gegeben ist auch bei einem zufällig initialisierten temporalen Netzwerk vergleichbare Strukturen zu finden, scheint der mögliche Konfigurationsraum zu groß um innerhalb von 100 Generationen zu einem vergleichbaren Ergebnis zu gelangen. Zusammenfassend wird mit der Struktursuche per Genetischem Algorithmus mit einer über die

Transformation vorinitialisierten Netzwerkstruktur die höchste Klassifikationsgüte bei vertretbarem Aufwand erreicht.



(a) DBN mit 6 Evidenzvariablen

(b) DBN mit 10 Evidenzvariablen



(c) DBN mit 16 Evidenzvariablen

Abbildung 5.25: Ergebnis der Bestimmung der temporalen Netzwerke auf Basis der initialen Netzwerke des HNB-Verfahrens mit 6 Variablen, 5.25(a) mit 10 Variablen, 5.25(b) und 16 Variablen, 5.25(c)

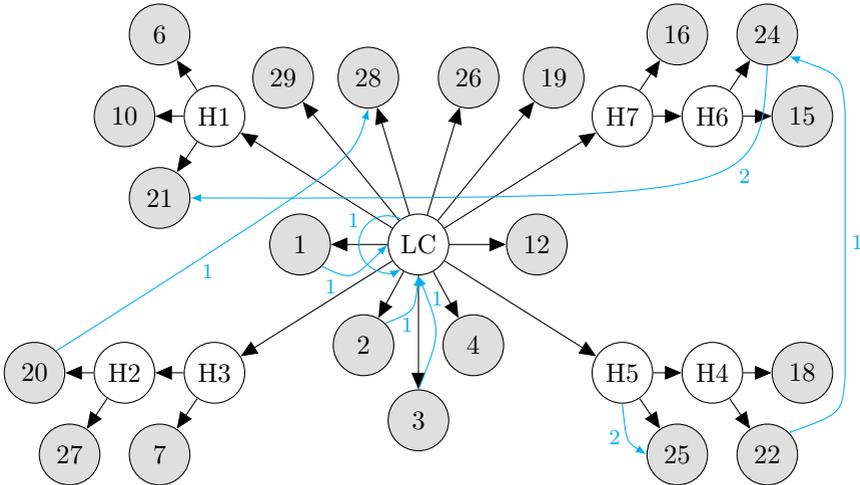


Abbildung 5.26: Ergebnis der Bestimmung des temporalen Netzwerkes auf Basis des initialen Netzes des HNB-Verfahrens mit 21 Evidenzvariablen

5.6 Diskussion des Schätzergebnisses

Innerhalb dieses Kapitels wird ein Weg zur datengetriebenen maschinellen Parameterbestimmung Bayes'scher Netzwerke zum Zwecke einer Fahrstreifenwechselvorhersage aufgezeigt. Als Zielfunktion wird jeweils die Maximierung der Klassifikationsgüte gewählt, d. h. eine gleichgewichtige Mittelung über die Erkennungsrate aller Zustände, vgl. Tabelle 5.3.2.1. Es konnte gezeigt werden, dass jeder Verfahrensschritt zu einer Erhöhung der Klassifikationsleistung führt.

Eine Vorhersage für alle Objekte inkl. des Ego-Fahrzeuges erzielt über ein Naives Bayes'sches Netzwerk mit 21 Evidenzvariablen eine Klassifikationsgüte von 40,55 %, s. Tabelle 5.10 auf Seite 159. Über ein zeitinvariantes Hierarchisches Naives Bayes'sches Netzwerk mit 21 Evidenzvariablen wird eine Klassifikationsgüte von 42,2 % erreicht, s. Tabelle 5.13 auf Seite 164. Werden die über den HNB-Ansatz gefundenen Netzwerkstrukturen auf einen Datensatz angewendet, welcher sich auf die Manöver des Ego-Fahrzeuges beschränkt, lässt sich eine maximale Klassifikationsgüte von 51,03 % erzielen, s. Tabelle 5.14 auf Seite 166. Auf Basis des letztgenannten Datensatzes wird mithilfe eines Dynamischen Bayes'schen Netzwerkes (DBN) mit 21 Evidenzvariablen eine Klassifikationsgüte von 58,7 % erreicht, s. Tabelle 5.15 auf Seite 170.

Das DBN mit 21 Evidenzvariablen weist gegenüber dem DBN mit sechs Evidenzvariablen lediglich eine um 2,24 % höhere Klassifikationsgüte auf. Bezüglich der notwendigen Situationsmerkmale für eine Fahrstreifenwechsellvorhersage ist daher festzustellen, dass ein Großteil der genutzten Information bereits in den Variablen der lateralen Indikation, d. h. *tlc*, *deviation* und *vLat*, sowie in den Variablen *timeGapBackLeft*, *expRateGapFrontCenter* und *noPassingLeft* enthalten ist.

Für das DBN ist in Tabelle 5.17 die Konfusionsmatrix sowie in Abbildung 5.27 bzw. Abbildung 5.28 der zeitliche Verlauf der geschätzten Verteilung für die Fahrstreifenwechsel nach links bzw. rechts gegeben. Die Abbildungen zeigen die über alle im Testdatensatz enthaltenen Fahrstreifenwechsel nach links bzw. rechts gemittelten Verteilungen je Zeitschritt. Nachfolgend wird das Schätzergebnis für das DBN im Detail betrachtet.

Tabelle 5.17: Konfusionsmatrix des Dynamischen Bayes'schen Netzwerks für die Realisationen des Knoten *lane_change* basierend auf der Menge von 21 Evidenzvariablen bestimmt durch Wrapper (hart), vgl. Tabelle 5.7

$P(LC^{pr}, LC^{gt})$ in [%]	$LC^{pr} =$								
	lc_1	lc_2	lc_3	lc_4	lc_5	lc_6	lc_7	lc_8	lc_9
$LC^{gt}=lc_1$	72,87	1,22	0,84	2,67	9,31	0,42	0,79	1,13	10,74
$LC^{gt}=lc_2$	1,24	87,60	8,68	1,65	0,00	0,00	0,00	0,00	0,83
$LC^{gt}=lc_3$	2,07	42,32	43,57	9,96	1,24	0,00	0,00	0,00	0,83
$LC^{gt}=lc_4$	14,10	8,97	14,10	40,60	20,94	0,00	0,00	0,00	1,28
$LC^{gt}=lc_5$	31,22	0,84	1,69	12,24	53,59	0,00	0,00	0,00	0,42
$LC^{gt}=lc_6$	1,56	0,00	0,00	0,00	0,00	80,93	14,40	2,72	0,39
$LC^{gt}=lc_7$	0,77	0,00	0,00	0,00	0,00	23,37	59,39	16,09	0,38
$LC^{gt}=lc_8$	7,57	0,00	0,00	0,00	0,00	2,39	28,69	37,05	24,30
$LC^{gt}=lc_9$	19,92	0,00	0,00	0,00	0,00	1,95	10,16	15,23	52,73

Die Abbildungen zeigen, dass das Vorhersageverhalten für einen Fahrstreifenwechsel nach links in etwa dem für rechts entspricht. Sie zeigen weiterhin, dass innerhalb des betrachteten Vorhersagezeitraumes von 2 s vor dem Manöver mit höchster Wahrscheinlichkeit das korrekte Zeitintervall geschätzt wird, dass aber auch die jeweils benachbarten Intervalle eine hohe Wahrscheinlichkeit aufweisen. Letztgenanntes gilt insbesondere für die jeweils zwei Intervalle zwischen 1,5 s und 0,5 s vor einen Fahrstreifenwechsel. Offensichtlich lassen sich die gewählten Zeitintervalle zur Fahrstreifenwechsellvorhersage schwer von einander trennen.

In Tabelle 5.17 weist lc_5 und lc_9 , d. h. jeweils das Zeitintervall $(1,5; 2]$ s vor einem Fahrstreifenwechsel nach links bzw. rechts, eine vergleichsweise hohe false-positive Rate auf. In beiden Abbildungen ist zu erkennen, dass die Wahrscheinlichkeit für dieses Zeitintervall bereits deutlich vor dem anvisierten Vorhersagezeitraum zu steigen beginnt. Dies erklärt z. T. die false-positive Raten. Die Wahrscheinlichkeit, dass ein gegenteiliges Ereignis geschätzt wird, d. h. beispielsweise ein Fahrstreifenwechsel nach links, obwohl der wahre Wert ein Fahrstreifenwechsel nach rechts ist, liegt bei 0%, mit Ausnahme des Intervalls $lc_right_2_0$ (lc_9), für das eine geringe false-positive Rate bei einem wahren Fahrstreifenwechsel nach links vorliegt.

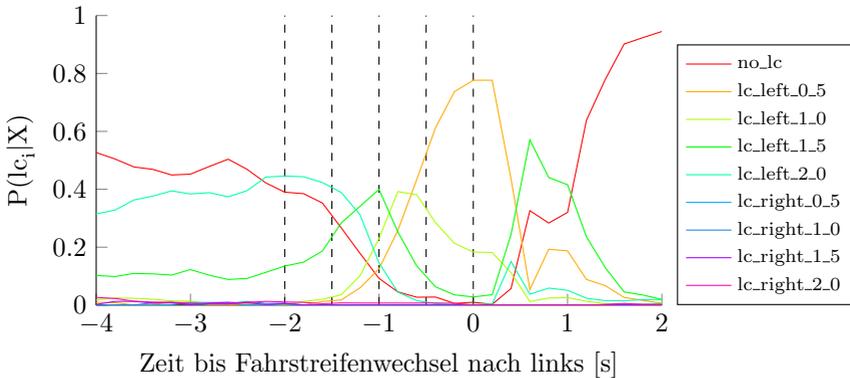


Abbildung 5.27: Zeitlicher Verlauf der geschätzten Verteilung für die Variable Fahrstreifenwechsel, gemittelt über alle Fahrstreifenwechsel nach links

Die Wahrscheinlichkeit für den Zustand *kein Fahrstreifenwechsel* (*no_lc*) liegt bereits 2,5s vor dem relevanten Vorhersagezeitpunkt von $t = 0$ bei unter 50% und sinkt bis 0,5s vor dem Ereignis so stark ab, dass spätestens ab diesem Zeitpunkt mit einem sicher bevorstehenden Fahrstreifenwechsel gerechnet werden muss.

Abschließend ist auffällig, dass die Zustände $lc_left_1_5$ und $lc_right_1_0$ einen bimodalen Verlauf der Wahrscheinlichkeit über die Zeit aufweisen. Innerhalb des betrachteten Vorhersagezeitraumes tritt zwar ein lokales Maximum auf, das globale Maximum liegt jedoch ca. 0,5s nach dem Vorhersagezeitpunkt. Die genaue Ursache hierfür ist unbekannt. Praktisch hat dies keine Auswirkungen, da ab dem Zeitpunkt $t = 0$ das Eintauchen des wechselnden Fahrzeuges in den Nachbarfahrstreifen durch die Umfeldwahrnehmung des TAP detektiert wird.

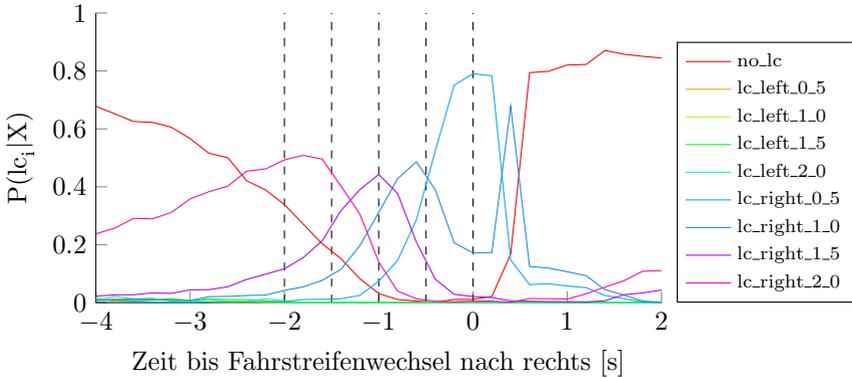


Abbildung 5.28: Zeitlicher Verlauf der geschätzten Verteilung für die Variable Fahrstreifenwechsel, gemittelt über alle Fahrstreifenwechsel nach rechts

Praktische Relevanz für den Temporary Autopilot

Das vorgestellte Verfahren zur Vorhersage von Fahrstreifenwechselmanövern kam für den TEMPORARY AUTOPILOT bisher nicht zur praktischen Anwendung im realen Fahrbetrieb. Entsprechend liegt keine abschließende Bewertung vor, inwieweit das Systemverhalten, z. B. durch eine frühzeitige und komfortable Reaktion auf Einscherer und Ausscherer verbessert wird.

Die Ergebnisse zeigen, dass ein Großteil der in den Testdaten enthaltenen Fahrstreifenwechsel korrekt vorhergesagt werden, bevor das wechselnde Fahrzeug in seinen Zielfahrstreifen eintaucht. Die Klassifikationsgüten von 42,2% für das HNB-Netzwerk bzw. 58,7% für das DBN legen jedoch nahe, dass das exakte Zeitintervall nur unzureichend bestimmt werden kann. Unter Berücksichtigung der gesamten geschätzten Verteilung lässt sich der Zeitrahmen bis zu einem bevorstehenden Fahrstreifenwechsel auf die wahrscheinlichsten Zeitintervalle eingrenzen.

Ein wesentlicher Vorteil der hier vorgestellten maschinellen Struktur- und Parameterbestimmung liegt in der Skalierbarkeit des Aufwandes zur Modellierung des Schätzmodells bei geänderten Einsatzbedingungen: Es ist damit zu rechnen, dass das Fahrstreifenwechselverhalten von Verkehrsteilnehmern international signifikant divergiert, z. B. aufgrund unterschiedlicher Verkehrsregeln aber auch unterschiedlicher Mentalität der Verkehrsteilnehmer. Gegenüber einer manuellen Modellierung der Schätzmodelle zur Fahrstreifenwechselvorhersage für regional unterschiedliche Märkte beschränkt sich der wesentliche Aufwand für die hier vorgestellte Prozesskette auf die

Beschaffung repräsentativer Fahrdaten und eine Durchführung der maschinellen Parameterbestimmung. Ein analoges Vorgehen ist bei unterschiedlichen Sensor-Konfigurationen der mit einem TEMPORARY AUTOPILOT ausgestatteten Fahrzeuge denkbar.

5.7 Diskussion angrenzender Fragestellungen

Dieser Abschnitt dient der Diskussion von vier angrenzenden Fragestellungen, welche in den vorangegangenen Abschnitten implizit mit bearbeitet, deren Ergebnisse aber bisher nicht explizit diskutiert sind. Dazu zählen

- die Diskussion einer manuellen expertengestützten gegenüber einer maschinellen datengetriebenen Strukturbestimmung in Unterabschnitt 5.7.1,
- die Berücksichtigung von Zustandsunsicherheiten der Situationsmerkmale als weiche Evidenz in Unterabschnitt 5.7.2,
- der Einfluss der Datenqualität der Fahrumgebungserfassung auf das Vorhersageergebnis in Unterabschnitt 5.7.3 und abschließend
- die Schätzung einer Fahrstreifenwechselforhersage mit alternativen Methoden in Unterabschnitt 5.7.4.

5.7.1 Struktursuche für Bayes'sche Netzwerke: expertengestützt versus datengetrieben

In diesem Unterabschnitt wird die maschinelle datengetriebene Strukturbestimmung gegenüber einer manuellen expertengestützten Strukturbestimmung diskutiert. Hierfür werden zunächst die Vor- und Nachteile beider Verfahrensweisen diskutiert und im Anschluss zwei Netzwerkstrukturen expertengestützt aufgestellt und bewertet.

Erwähnt werden muss, dass alle im Rahmen der Literaturrecherche gefundenen Realisierungen einer Fahrstreifenwechselforhersage auf Basis Bayes'scher Netzwerke diese mindestens im Hinblick auf die Struktur manuell modelliert haben, vgl. Abschnitt 3.2. In diesem Zusammenhang stellt [Kasper 2013] fest, dass der Prozess zur Auswahl geeigneter Situationsmerkmale und der Strukturbestimmung aufwendig ist und ein hohes Maß an Expertenwissen erfordert. Der Aufwand für die maschinelle Strukturbestimmung Bayes'scher Netzwerke lag im Rahmen dieser Arbeit im Wesentlichen in der Implementierung der dargestellten Prozesskette und der retrospektiven Generierung

gelabelter Lern- und Testdaten. Liegen Daten mit neuen oder geänderten Situationsmerkmalen oder gar aus einer anderen Einsatzdomäne vor, kann ein neues Bayes'sches Netzwerk zur Fahrstreifenwechselvorhersage unter Anwendung der Prozesskette mit überschaubarem Aufwand bestimmt werden. Die hier gefundenen Strukturen an Bayes'schen Netzwerken stehen in ihrer Übersichtlichkeit und Nachvollziehbarkeit einer manuell modellierten Netzwerkstruktur in nichts nach. Gerade gegenüber anderen KI-Methoden wie beispielsweise tiefen Neuronalen Netzen, vgl. Unterabschnitt 5.7.4, bilden die hier gefundenen Strukturen der Bayes'schen Netzwerke das aus den Messdaten gelernte Fahrstreifenwechselverhalten in einer geradezu übersichtlichen und nachvollziehbaren Form ab.

Naive Bayes'sche Netzwerke scheinen das Mittel der Wahl für die maschinelle Bestimmung eines geeigneten Evidenzvariablensets und die darauf aufbauende Identifikation von latenten Variablen zur Bestimmung der Netzwerkstruktur mittels des HNB-Verfahrens. Grund hierfür ist die Modellierung der Kausalitätsrichtung von der Klassenvariable zu den Evidenzvariablen und den damit verbundenen niedrigdimensionalen, d. h. beherrschbaren bedingten Wahrscheinlichkeitstabellen für die Evidenzvariablen. Die Fahrstreifenwechselvorhersage erfolgt für die vorgestellten Naiven und Hierarchisch Naiven Bayes'schen Netzwerke durch diagnostisches Schlussfolgern, vgl. Abbildung 2.11 auf Seite 43. Das in Abschnitt 5.5 gezeigte Konzept zur Bestimmung des temporalen Netzwerks eines Dynamischen Bayes'schen Netzwerks lässt sich hingegen auch auf Netze mit beliebiger Kausalitätsrichtung anwenden.

Manuelle expertengestützte Strukturbestimmung

Auf Basis der in Abschnitt 4.4 gegebenen Variablen werden zwei Netzwerkstrukturen aufgestellt. Zusätzliche Latentvariablen bilden die Kindknoten für nahezu alle Evidenzvariablen und haben die Klassenvariable bzw. weitere Latentvariablen als Kindknoten. Die Kardinalität beträgt jeweils 10. Im Gegensatz zu den bisher verwendeten (Hierarchisch) Naiven Bayes'schen Netzwerken wird die Kausalitätsrichtung von den Evidenzvariablen zur Klassenvariable gewählt. Die Strukturen sind abgebildet in Abbildung 5.29 als Netzwerk mit allen verfügbaren Evidenzvariablen und in Abbildung 5.30 als Netzwerk mit 21 Evidenzvariablen analog zu dem Naiven Bayes'schen Netzwerk aus Unterabschnitt 5.3.3 mit der höchsten Klassifikationsgüte.

Bei der hier gegebenen Modellierung wird angestrebt, sowohl die aus Abbildung 5.7 auf Seite 128 bekannten statistischen Abhängigkeiten zwischen den

Evidenzvariablen, als auch das aus der Literatur bekannte Expertenwissen aus Unterabschnitt 3.2.2 zu berücksichtigen. Über die Latentvariablen *left*, *center* und *right* wird die auf den linken, eigenen und rechten Fahrstreifen bezogene Evidenz des potentiell fahrstreifenwechselnden Bezugsobjektes abgebildet. Als Elternknoten der letztgenannten Variablen modellieren die Latentvariablen *frontLeft*, *backLeft*, *frontCenter*, *backCenter*, *frontRight* und *backRight* die fahrstreifenbezogenen Relationen des Bezugsobjektes zum umgebenden Verkehr, d. h. die Lücken zu den jeweils nächsten Umfeldobjekten, vgl. Abbildung 4.12 auf Seite 115. Über die Latentvariable *trajectory* wird die laterale Evidenz modelliert, vgl. Tabelle 4.6 auf Seite 105. Da das Netzwerk mit 21 Evidenzvariablen jeweils nur die Evidenzvariable *lengthGapFrontLeft* (12) bzw. *expRateGapBackRight* (15) zur Beschreibung der jeweiligen Lückenrelation für *frontLeft* und *backRight* enthält, entfallen die letztgenannten Latentvariablen für dieses Netzwerk.

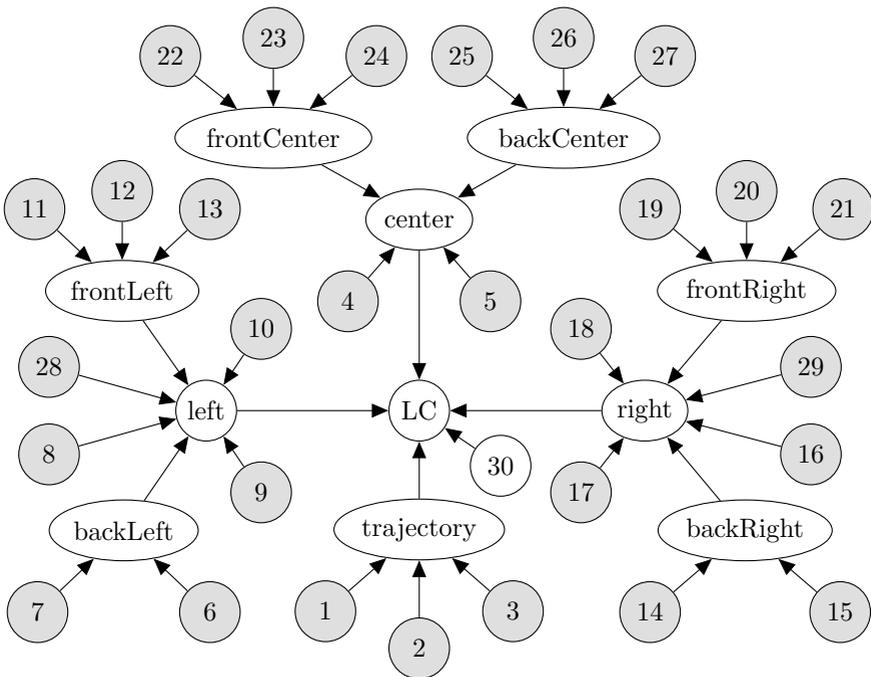


Abbildung 5.29: Mithilfe von Expertenwissen manuell modelliertes Bayes'sches Netzwerk, basierend auf den in Abschnitt 4.4.2 definierten Evidenzvariablen

Die Dimensionalität der bedingten Wahrscheinlichkeitstabellen ist insbesondere für die Latentvariablen *left*, *center* und *right* so hoch, dass eine manuelle Bestimmung nicht praktikabel ist. Während die Struktur jeweils manuell erzeugt wird, werden die Übergangswahrscheinlichkeiten mithilfe des EM-Verfahrens maschinell gelernt.

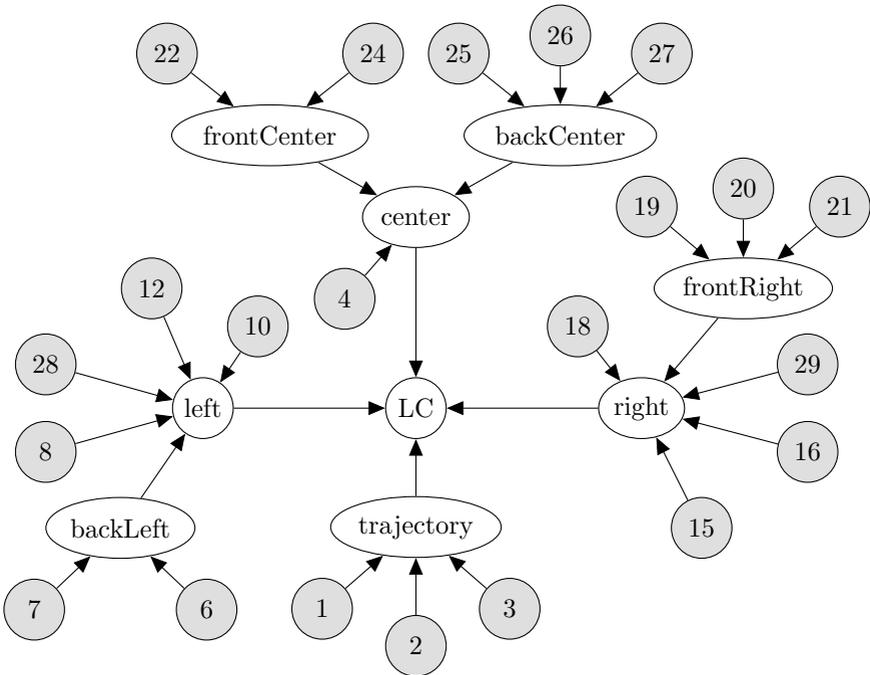


Abbildung 5.30: Mithilfe von Expertenwissen manuell modelliertes Bayes'sches Netzwerk, basierend auf der in Unterabschnitt 5.3.3 bestimmten Menge von 21 Evidenzvariablen

Das Lernen bzw. Testen der Netzwerke erfolgt auf Basis des gemischten balancierten Datensatzes bzw. unbalancierten Testdatensatzes mit harter Evidenz, welche auch in den Abschnitten 5.2 bis 5.4 Anwendung finden. Die Bewertungsergebnisse der hier vorgestellten Netzwerke, gegeben in Tabelle 5.18, können daher mit den Ergebnisse der maschinell bestimmten Bayes'schen Netzwerken aus Tabelle 5.13 auf Seite 164 verglichen werden.

Die Klassifikationsgüte, die durch die expertengestützt manuell ermittelten Bayes'schen Netzwerke erzielt wird, liegt deutlich unter den Ergebnissen, welche mit den vorgestellten maschinell datengetriebenen Ansätzen erzielt

werden. Auffällig ist, dass sich nach Anwendung des EM-Algorithmus große Teile der, im Vergleich zu den Naiven Bayes'schen Netzwerken, hochdimensionalen bedingten Wahrscheinlichkeitstabellen noch im Initialisierungszustand befinden. Ebenso steigt die Ausführungszeit des EM-Algorithmus um ein vielfaches gegenüber den maschinell bestimmten HNB-Netzwerkstrukturen. Zusammengefasst ist das maschinelle Lernen der expertengestützten manuellen Strukturbestimmung sowohl im Hinblick auf die Güte als auch auf den Aufwand vorzuziehen.

Tabelle 5.18: Bewertungsergebnisse der mithilfe von Expertenwissen manuell bestimmten Netzwerkstrukturen gegenüber der besten maschinell bestimmten Struktur eines zeitinvarianten Hierarchisch Naiven Bayes'schen Netzwerks aus Abschnitt 5.4.

Strukturbestimmung	manuell		maschinell
Anzahl Evidenzvariablen	21	30	21
Abbildung	5.30	5.29	5.23(b)
Klassifikationsgüte [%]	19,84	11,08	42,2

5.7.2 Berücksichtigung von Zustandsunsicherheiten der Situationsmerkmale als weiche Evidenz

In der Fahrumgebungserfassung ist unsicheres Wissen typisch. Bei einer auf Kalman-Filter basierten Objektverfolgung wird die Zustandsänderung eines beobachteten Objektes über Dynamikmodelle modelliert. Da diese nur näherungsweise die tatsächliche Objektdynamik abbilden, wird eine mögliche Abweichung durch ein Prozessrauschen modelliert, welches die Zustandsunsicherheit des Objektes infolge der Schätzung erhöht. Ungenauigkeiten der Sensoren, z. B. begrenzte Winkel- und Entfernungsauflösungen, werden durch Messrauschen modelliert, welches die Unsicherheit bzgl. der gemessenen Werte erhöht. Vereinfachend wird eine Normal-Verteilung bei der Modellierung des Mess- und Prozessrauschens angenommen. Die Zustandschätzung des betreffenden Objektes wird mit assoziierten Messwerten der Sensoren aktualisiert, wobei sich die Unsicherheit des geschätzten Zustandes reduziert. Entsprechend liegen die Situationsmerkmale bei Berücksichtigung der Zustandsunsicherheit in Form einer diskretisierten Verteilung vor, welche als weiche Evidenz bzgl. der entsprechenden Zufallsvariablen modelliert werden kann.

Zu Beginn der Arbeit wurde die Hypothese aufgestellt, dass dieses Wissen um die Unsicherheit der Situationsmerkmale das Vorhersageergebnis gegenüber einer Nichtbeachtung verbessern muss.

Das in Unterabschnitt 2.3.2.1 vorgestellte *BN-IPFP-1*-Verfahren zur Realisierung einer weichen Evidenz mithilfe einer virtuellen Variable wurde in Abschnitt 5.3 für die Auswahl relevanter Evidenzvariablen umgesetzt. Die in der genutzten Softwarebibliothek *smile* bereit gestellte Ausführung des EM-Algorithmus ist für eine Anwendung auf harte Evidenz vorgesehen. Vor diesem Hintergrund erfolgte eine Nachimplementierung des EM-Algorithmus zur Kombination mit dem *BN-IPFP-1*-Verfahren, vgl. [Kokoulina 2017]. Abbildung 5.19 auf Seite 159 zeigt die Gegenüberstellung der Klassifikationsgüte von Naiven Bayes'schen Netzwerken, deren Parameter im Rahmen des Wrapperverfahrens mit weicher bzw. harter Evidenz gelernt sind. Die Klassifikationsgüte ist ebenfalls entsprechend mit weicher bzw. harter Evidenz bestimmt. Die Klassifikationsgüte der per weicher Evidenz ermittelten Naiven Bayes'schen Netzwerke liegt für alle Variablenmengen unter der Güte der per harter Evidenz ermittelten Netzwerke bei gleichzeitig höheren Klassifikationskosten. Bei den eingesetzten Naiven Bayes'schen Netzwerken sind die Evidenzvariablen bzw. deren virtuelle Variablen zur Realisierung der weichen Evidenz zueinander nicht *d*-separiert, d. h. das *BN-IPFP-1*-Verfahren durchläuft nahezu immer mehrere Iterationen, bis sich in den Evidenzvariablen jeweils der zu setzende weiche Evidenzwert einstellt. Insbesondere bei der Bestimmung der bedingten Wahrscheinlichkeitsverteilungen mittels des EM-Algorithmus erhöht sich die Komplexität durch die notwendige Anwendung des *BN-IPFP-1*-Verfahrens zum Setzen der weichen Evidenz erheblich. Zusätzlich wurde die Struktursuche nach dem HNB-Verfahren auf Basis weicher Evidenz und der in dieser Arbeit verwendeten Datensätze untersucht. Gegenüber den Ergebnissen aus Abschnitt 5.4 ergab sich für die so ermittelten Netzwerkstrukturen keine Verbesserung der Schätzgenauigkeit.

Die Modellierung des Mess- und Prozessrauschens und der daraus resultierenden Unsicherheit des geschätzten Objektzustandes im Umfeldwahrnehmungsprozess dient im Wesentlichen einer stabilen Objektverfolgung. Die Eingangs aufgestellte Hypothese, dass eine Berücksichtigung dieser Zustandsunsicherheit bei der Parameterbestimmung und Inferenz im Bayes'schen Netzwerk das Vorhersageergebnis für Fahrstreifenwechsel verbessert, konnte für die vorliegende Arbeit nicht bestätigt werden.

Die Ermittlung der Konfusionsmatrizen auf Basis der weichen Evidenz bzgl. der Klassenvariable *LC*, vgl. Gleichung 5.6 auf Seite 154, führte im Rahmen

der Evidenzvariablenauswahl in Abschnitt 5.4 gegenüber der Anwendung der harten Evidenz ebenfalls zu Ergebnissen mit geringerer Klassifikationsgüte. Aus den genannten Gründen wurde auf die Berücksichtigung der Zustandsunsicherheiten der Eingangsmerkmale in Form der weichen Evidenz verzichtet.

5.7.3 Einfluss von Qualität & Verfügbarkeit der Fahrumgebungsdaten auf die Vorhersage

Der Zustand des Umfeldmodells als rechnerinterne Repräsentation der maschinell wahrgenommenen Fahrumgebung, vgl. Abschnitt 4.3, weicht zu einem gewissen Grad für alle Objekte vom Zustand der tatsächlichen Fahrumgebung ab. Über die Zustandsunsicherheiten der geschätzten Objekt- und Fahrbahndaten lässt sich ein Teil der Unsicherheit über die genaue Kenntnis der jeweiligen Zustände modellieren. Ein Einbezug dieser Zustandsunsicherheiten in die Fahrstreifenwechselvorhersage hat sich für die vorliegenden Arbeit als unvorteilhaft erwiesen, vgl. Unterabschnitt 5.7.2.

Eine Aussage über den Einfluss von Qualität und Verfügbarkeit der Fahrumgebungsdaten auf das Ergebnis einer Fahrstreifenwechselvorhersage lässt sich durch einen Vergleich der Bewertungsergebnisse zwischen einem rein auf das Ego-Fahrzeug bezogenen Datensatz und einem gemischten Datensatz erzielen. Letzterer enthält sowohl auf das Ego-Fahrzeug bezogene Datentupel als auch Datentupel für alle Objekte im Beobachtungshorizont des Ego-Fahrzeuges.

Die Verfügbarkeit der in Unterabschnitt 4.4.2.4 definierten Situationsmerkmale, welche die Beziehung zwischen dem potentiell fahrstreifenwechselnden Bezugsobjekt und dem umgebenden Verkehr beschreiben, sinkt mit zunehmendem Abstand des Objektes vom Ego-Fahrzeug. Ebenso ist eine Zunahme der Unsicherheit bzgl. des Zustandes des Bezugsobjektes wie auch der Zustandsunsicherheit bzgl. der Fahrbahn mit zunehmendem Abstand vom Ego-Fahrzeug zu verzeichnen. Die letztgenannten Punkte haben im Ego-Datensatz einen geringeren Einfluss, da der Zustand des Ego-Fahrzeugs und der Zustand dessen unmittelbarer Fahrumgebung durch die Fahrumgebungserfassung verhältnismäßig gut geschätzt wird. Weiterhin wirken sich insbesondere Artefakte wie Geisterobjekte im gemischten Datensatz mehrfach negativ aus, da einerseits eine unzuverlässige Fahrstreifenwechselvorhersage für diese als Bezugsobjekt erfolgt und sie andererseits die Beziehung zum umgebenden Verkehr für andere Bezugsobjekte verfälschen.

Tabelle 5.19 zeigt eine Gegenüberstellung der Bewertungsergebnisse der in Abschnitt 5.4 gefundenen Netzstrukturen, wobei die bedingten

Wahrscheinlichkeiten (CPTs) im ersten Fall auf Basis des gemischten Datensatzes und im zweiten Fall auf Basis des Ego-Datensatzes bestimmt sind. Die Klassifikationsgüte für den Ego-Datensatz ist bezogen auf den gemischten Datensatz um ca. 20% höher. Eine Anwendung des gemischten Testdatensatzes auf eine mit dem Ego-Datensatz gelernte Netzstruktur führt zu deutlich schlechteren Ergebnissen in der Klassifikationsgüte als bei einer mittels gemischten Datensatz bestimmten Netzstruktur.

Tabelle 5.19: Gegenüberstellung der Bewertungsergebnisse der Hierarchisch Naiven Bayes'schen Netzwerke für eine Bestimmung der CPTs auf Basis des gemischten Datensatzes, vgl. Tabelle 5.13 und des auf Ego-Daten reduzierten Testdatensatzes, vgl. Tabelle 5.14.

Anzahl Evidenzvariablen Abbildung	6	10	16	21
Klassifikationsgüte [%] gemischter Datensatz	5.20(b) 35,48	5.21(b) 38,81	5.22(b) 41,23	5.23(b) 42,2
Klassifikationsgüte [%] Ego-Datensatz	48,29	50,17	50,65	51,03

5.7.4 Vergleich mit alternativer Methode

In diesem Abschnitt sollen die mit Bayes'schen Netzwerken erzielten Schätzergebnisse zur Fahrstreifenwechselvorhersage denen einer alternativen KI-Methode gegenübergestellt werden. Als alternative Methode werden Künstliche Neuronale Netze gewählt, vgl. Abschnitt 2.4, da Verfügbarkeit und Qualität der notwendigen Bibliotheken und Werkzeugketten eine schnelle Implementierung dieser Schätzmethode versprechen. Die Implementierung erfolgt mithilfe der Keras Deep Learning-Bibliothek, vgl. [Chollet 2016].

Es wird ein rekurrentes Neuronales Netzwerk (RNN) gewählt, mit dem sich, vergleichbar zu den Dynamischen Bayes'schen Netzwerken, Zeitabhängigkeiten in den Daten abbilden lassen. Aufgrund vielversprechender Ergebnisse in einer Voruntersuchung findet in dieser Arbeit ein RNN des Typs long short-term memory (LSTM) Modell Anwendung, vgl. [Goodfellow u. a. 2016; Hochreiter u. Schmidhuber 1997]. Das RNN ist rekurrent über drei Zeitschritte mit einer Zeitdifferenz von jeweils 200 ms. Die Eingangsschicht des Netzwerkes besteht, entsprechend der zur Verfügung stehenden Menge an Eingangsmerkmalen, aus 30 Neuronen. Die Ausgangsschicht bildet die Zeitintervalle mit neun Neuronen ab. Es werden zwei versteckte Schichten (hidden layer) verwendet.

Zur Bestimmung eines RNNs mit einer bestmöglichen Klassifikationsleistung, wird die Anzahl der Neuronen in den versteckten Schichten variiert und das jeweils resultierende Netzwerk trainiert und bewertet. Das Training für jede Netzwerkvariation erfolgt über den Backpropagation-Algorithmus und wird abgebrochen, sobald sich eine Überanpassung des Netzwerks an den Datensatz eingestellt. Die Anpassung der Gewichte erfolgt ausgehend von der Ausgabeschicht, so dass die als Fehlermaß gewählte Kreuzentropie minimal wird, vgl. Gleichung 5.10 mit $P(X = x)$ als Bezeichner für die Verteilung der Referenzdaten und $Q(X = x)$ als Verteilung der Vorhersage des RNNs.

$$H(X,P,Q) = - \sum_x P(X = x) \log Q(X = x) \quad (5.10)$$

Als Datenbasis findet der auf Ego-Daten reduzierte Datensatz Anwendung. Die Bewertung erfolgt analog zu den Bayes'schen Netzwerken, vgl. Unterabschnitt 5.3.2.1.

Das ermittelte RNN mit der höchsten Bewertung weist jeweils 190 Neuronen in den versteckten Schichten auf. Tabelle 5.20 und die Abbildungen 5.31 sowie 5.32 zeigen eine Gegenüberstellung der Vorhersageleistung des ermittelten RNN mit denen des Dynamischen Bayes'schen Netzwerks mit 21 Eingangsmerkmalen, vgl. Abbildung 5.26 auf Seite 172. Die zugehörige Konfusionsmatrix des RNN ist in Anhang A.7 gegeben.

Tabelle 5.20: Gegenüberstellung der Ergebnisse eines Dynamischen Bayes'schen Netzwerks und eines Rekurrenten Neuronalen Netzwerks

Methode	DBN	RNN
Klassifikationsgüte [%]	58,7	59,8

Die Wahrscheinlichkeit, dass das ermittelte RNN das korrekte Zeitintervall eines bevorstehenden Fahrstreifenwechsels vorhersagt liegt mit 59,8% zur Vorhersageleistung von 58,7% eines DBN auf einem vergleichbaren Niveau. In den Abbildungen 5.31 und 5.32 ist anhand des zeitlichen Verlaufs der Wahrscheinlichkeitsverteilung über alle Zeitintervalle erkennbar, dass mit Ausnahme der Intervalle `lc_left_2_0` und `lc_right_1_5`, die Schätzung der einzelnen Zeitintervalle stärker ausgeprägt ist, als bei bei einer Schätzung per DBN.

Neben der geringfügig besseren Klassifikationsleistung ist der deutlich geringere Aufwand zur Bestimmung des Neuronalen Netzwerks gegenüber einem Bayes'schen Netzwerk ein wesentlicher Vorteil der Neuronalen Netzwerke.

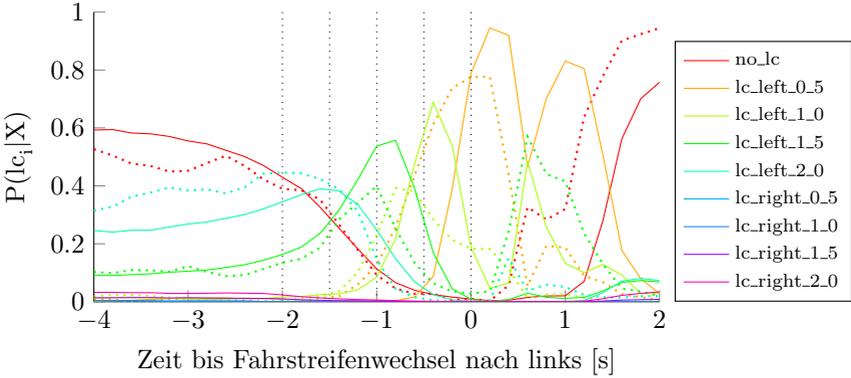


Abbildung 5.31: Zeitlicher Verlauf der Fahrstreifenwechsellvorhersage per RNN (durchgezogene Linie), gemittelt über alle Fahrstreifenwechsel nach links, gegenüber den Ergebnissen des DBN (gepunktete Linie) aus Abbildung 5.27

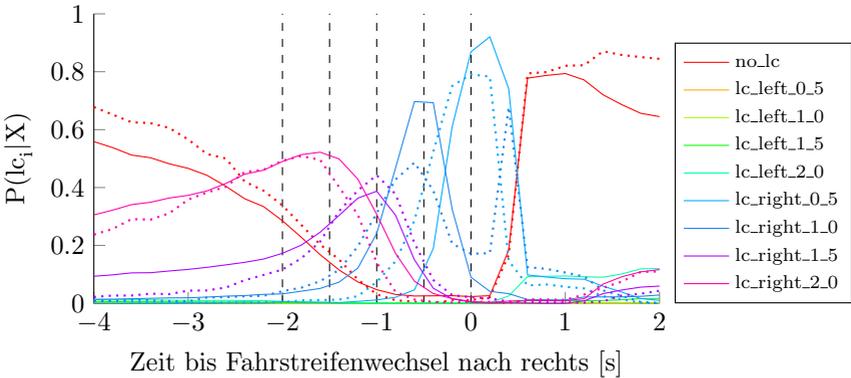


Abbildung 5.32: Zeitlicher Verlauf der Fahrstreifenwechsellvorhersage per RNN (durchgezogene Linie), gemittelt über alle Fahrstreifenwechsel nach rechts, gegenüber den Ergebnissen des DBN (gepunktete Linie) aus Abbildung 5.28

Gegenüber den Bayes'schen Netzwerken ist weder ein expliziter Diskretisierungsprozess noch eine Merkmalsauswahl notwendig. Insbesondere die Merkmalsauswahl erfolgt implizit durch die Bestimmung der Kantengewichte während des Trainings des RNN. Durch die verwendete Keras Deep Learning-Bibliothek konnten Berechnungen zum Trainieren des Netzwerkes auf einen Grafikprozessor ausgelagert und damit hochgradig parallel, d. h. mit vertretbarem Zeitaufwand, ausgeführt werden.

Gleichwohl nachteilig ist, im Vergleich zur Parameteranzahl des hier betrachteten DBN, dass die Anzahl der zu bestimmenden Gewichte des RNN bei 190 Neuronen pro Schicht sehr hoch ist. Eine darauf aufbauende Vorhersage ist für einen menschlichen Betrachter entsprechend schwer nachvollziehbar und als Black-Box-Verhalten anzusehen. Insbesondere ist eine Interpretation des RNNs bezüglich der Relevanz der genutzten Situationsmerkmale schwierig. Demgegenüber zeigen die in Abschnitt 5.6 diskutierten Ergebnisse der Bayes'schen Netzwerke, dass bereits mit einem Bruchteil der zur Verfügung stehenden Situationsmerkmale, z. B. den Merkmalen der lateralen Indikation, ein Großteil der Klassifikationsleistung erbracht werden kann.

6 Zusammenfassung und Ausblick

Moderne Systeme zur automatisierten Fahrzeugführung benötigen ein tiefgreifendes Verständnis der Fahrumgebung zur konfliktfreien Bewältigung der Fahraufgabe. Dieses Verständnis basiert auf der Wahrnehmung und Interpretation des Verkehrsumfeldes und schließt eine Erkennung und Vorhersage von Fahrmanövern des umgebenden Verkehrs ein. Vor diesem Hintergrund beschäftigt sich die vorliegende Arbeit mit der Frage, wie Merkmale eines Fahrstreifenwechsels mithilfe einer Fahrumgebungserfassung wahrgenommen und darauf basierend die Zeitspanne bis zu einem Fahrstreifenwechsel vorhergesagt werden kann.

Zur Wahrnehmung der Fahrumgebung auf Autobahnen wird ein Versuchsfahrzeug mit umfelderfassenden Sensoren ausgestattet, deren Messwerte in ein modulares Umfeldmodell als rechnerinternes Abbild der Fahrumgebung fusioniert werden. Mithilfe eines Bayes'schen Netzwerks erfolgt eine Interpretation der wahrgenommenen Fahrumgebung zur zeitlichen Vorhersage von Fahrstreifenwechselmanövern. Diese wird angewendet auf die Fahrzeuge des umgebenden Verkehrs als auch auf das Ego-Fahrzeug selbst. Die Vorhersage des Fahrstreifenwechselmanövers nach links bzw. rechts erfolgt durch die Schätzung einer diskreten Wahrscheinlichkeitsverteilung mit einer Vorhersagezeit von 0-2s vor Eintritt in den Zielfahrstreifen. Die Verteilung ist charakterisiert durch jeweils vier äquidistante Zeitintervalle von 0,5s Dauer sowie den Zustand *kein Fahrstreifenwechsel*.

Zu diesem Zweck wird die Umfeldwahrnehmungsplattform des Versuchsfahrzeuges um ein Modul zur Manöर्वorhersage erweitert, welches das Bayes'sche Netzwerk als Schätzmodell enthält und Schnittstellen zu den Teilmodulen der Umfeldwahrnehmung bietet. Auf Basis des Umfeldmodells wird die für das betrachtete Objekt relevante Verkehrsszene aufgestellt und daraus verfügbare Situationsmerkmale extrahiert. Darauf aufbauend wird die Inferenz im Bayes'schen Netzwerk durchgeführt. Schließlich wird die erweiterte Zustandsbeschreibung für jedes betrachtete Objekt um die Information zu einem bevorstehenden Fahrstreifenwechsels ergänzt.

Zur datengetriebenen Struktur- und Parameterbestimmung von Bayes'schen Netzwerken sind bzgl. Fahrstreifenwechseln referenzierte Lern- und Testdaten

notwendig. Im Rahmen einer Realfahrstudie wird der umgebende Verkehr und das Fahrverhalten auf einer Strecke von insgesamt knapp 1900 km aufgezeichnet. Durch eine maschinelle Auswertung der Trajektorien des Ego-Fahrzeuges und aller beobachteten Fahrzeuge der Fahrumgebung werden im Zuge einer Offline-Prozessierung der Messdaten die Fahrstreifenwechsel aller beobachteten Fahrzeuge einschließlich des Ego-Fahrzeuges retrospektiv ermittelt und in eine Referenzdatenbank überführt.

Eine wesentliche Herausforderung liegt in der Strukturbestimmung des Bayes'schen Netzwerks. Durchgeführte Untersuchungen zur manuellen, d. h. expertengestützten Modellierung der Struktur führten zu unbefriedigenden Ergebnissen. Vor diesen Hintergrund wird die Eingangs aufgestellte Hypothese überprüft, ob sich das problemspezifische Wissen über das Fahrstreifenwechselverhalten von Verkehrsteilnehmern, welches implizit in den Messdaten der Realfahrstudie enthalten ist, durch maschinelle Lernverfahren in die explizite Repräsentationsform eines Bayes'schen Netzwerks zur Schätzung einer Fahrstreifenwechselwahrscheinlichkeit übertragen lässt.

Aufgrund der Größe des Parametersuchraumes stellt die datengetriebene maschinelle Bestimmung der optimalen Netzwerkstruktur eine Herausforderung dar. Um die Komplexität dennoch zu beherrschen, werden die Parameter des Bayes'schen Netzwerks in einem Vorgehen bestimmt, das sich in vier aufeinander aufbauende Schritte gliedert. In jedem dieser Schritte wird separat ein lokales Optimum bestimmt.

- 1.) Überführung der Situationsmerkmale in diskrete Evidenzvariablen durch eine informationstheoretische Bestimmung des diskreten Zustandsraumes für jede Variable. Ziel der Optimierung ist die Maximierung des verbleibenden Informationsgehaltes bei einer minimalen Anzahl von Zuständen.
- 2.) Bestimmung eines Naiven Bayes'schen Netzwerks aus der Menge der zur Verfügung stehenden Evidenzvariablen unter Vernachlässigung der statistischen Abhängigkeiten zwischen den Evidenzvariablen. Die Zielfunktion dieses und der nachfolgende Schritte ist jeweils die Maximierung der Klassifikationsleistung.
- 3.) Identifizierung latenter Variablen und deren Zustandsraum über das HNB-Verfahren. Hierbei wird durch geschicktes Einfügen latenter Variablen in die Struktur des Naiven Bayes'schen Netzwerks versucht, die in Schritt zwei vernachlässigten statistischen Abhängigkeiten zu modellieren.

- 4.) Auf Basis des gefundenen Hierarchisch Naiven Bayes'schen Netzwerks werden mithilfe eines Genetischen Algorithmus temporale Kanten zwischen den Variablen gesucht. Anhand dieser wird die Struktur für ein Dynamisches Bayes'sches Netzwerk bestimmt.

Schritt zwei bis drei nutzen jeweils eine gerichtete Suche zur Optimierung der Struktur. In Schritt vier wird ein evolutionärer Ansatz verfolgt.

Bereits die in Schritt zwei ermittelten Naiven Bayes'schen Netzwerke ermöglichen eine Vorhersage von Fahrstreifenwechselmanövern, wenn auch mit deutlichen Einschränkungen in der Schätzgenauigkeit. So lässt sich mit einem der ermittelten Naiven Bayes'schen Netzwerke bspw. das Zeitintervall $(0,0; 0,5]$ s vor einem Fahrstreifenwechsel nach links oder rechts durchschnittlich in 68,16 % und das Zeitintervall $(1,5; 2,0]$ s in 40,18 % aller Fälle korrekt schätzen. Eine Erweiterung der Netzstruktur durch die Identifikation latenter Variablen mithilfe des HNB-Verfahrens verbessert das Schätzergebnis nur leicht. Die Schätzung für beide Netzwerktypen erfolgt auf Basis von Situationsmerkmalen des Verkehrsumfeldes aus jeweils einem Zeitschritt. Obschon Merkmale genutzt werden, welche die zeitliche Dynamik des Fahrstreifenwechselvorganges beschreiben, kann erst mit der Modellierung zeitlicher Abhängigkeiten zwischen den Zufallsvariablen über mehrere Zeitscheiben in Form eines Dynamischen Bayes'schen Netzwerks eine deutliche Verbesserung des Schätzergebnisses erreicht werden. So lässt sich darüber bspw. das Zeitintervall $(0,0; 0,5]$ s vor einem Fahrstreifenwechsel nach links oder rechts durchschnittlich in 84,27 % und das Zeitintervall $(1,5; 2,0]$ s in 53,19 % aller Fälle korrekt als das wahrscheinlichste Intervall bestimmen.

Ein Großteil der verbleibenden Evidenzmasse, welche nicht dem wahrscheinlichsten Zustand zugeordnet ist, entfällt auf dessen direkt benachbarte Zeitintervalle. Entsprechend lässt sich, unter Berücksichtigung der gesamten Wahrscheinlichkeitsverteilung einer Schätzung, der Zeitrahmen bis zu einem bevorstehenden Fahrstreifenwechsel auf die wahrscheinlichsten Zeitintervalle eingrenzen und damit das Eintreten des Fahrstreifenwechselereignisses zu Lasten der zeitlichen Vorhersagegenauigkeit mit einer höheren Sicherheit bestimmen.

Die Unsicherheit über den Zustand der Fahrumgebung kann in den betreffenden Evidenzvariablen über weiche Evidenz, d. h. über die Abbildung einer beliebigen Unsicherheitsverteilung in der Variable, modelliert werden. Die Berücksichtigung von weicher Evidenz bei der Bestimmung der Netzwerkstruktur wurde auf Basis des BN-IPFP-1-Verfahrens untersucht. Im Ergebnis konnte hiermit keine Verbesserung des Klassifikationsergebnisses

gegenüber der Verwendung von harter Evidenz, d. h. des Erwartungswertes statt einer vollständigen Unsicherheitsverteilung für die jeweilige Variable, erzielt werden. Auf Basis dieser Erkenntnisse wurde die explizite Modellierung der Unsicherheiten bzgl. der Fahrumgebung bei der Parameter- und Netzwerkstrukturbestimmung der Bayes'schen Netzwerke vernachlässigt.

Ein zu Vergleichszwecken, auf Basis eines Rekurrenten Neuronalen Netzwerkes, ebenfalls maschinell bestimmtes Schätzmodell bestätigt die Vorhersageleistung des Dynamischen Bayes'schen Netzwerks durch qualitativ vergleichbare Vorhersageergebnisse. Die Nachvollziehbarkeit der Ergebnisse wird jedoch durch eine, gegenüber den Dynamischen Bayes'schen Netzwerken, deutlich komplexere Netzwerkstruktur erschwert.

Die in Abschnitt 5.6 diskutierten Ergebnisse zeigen, dass sich über die eingesetzten maschinellen Lernverfahren geeignete Bayes'sche Netzwerke zur Schätzung einer Wahrscheinlichkeitsverteilung ermitteln lassen, welche den Zeitraum bis zu einem bevorstehenden Fahrstreifenwechsel beschreibt. Der Aufwand zur Neubestimmung des Schätzmodells wird durch den Einsatz der vorgestellten Prozesskette im Wesentlichen auf die Beschaffung repräsentativer Fahrdaten und deren Neuprozessierung reduziert.

Ausblick

Die in dieser Arbeit ermittelten Ergebnisse zeigen das Potential für einen praxisrelevanten Einsatz des Verfahrens, lassen jedoch bzgl. der Schätzgenauigkeit der einzelnen Zeitintervalle Raum für Verbesserungen. Im Rahmen des bestehenden Konzeptes werden folgende Maßnahmen zur Verbesserung der Schätzgenauigkeit vorgeschlagen:

- Für die zu schätzende Verteilung bzgl. eines bevorstehenden Fahrstreifenwechsels sollten Untersuchungen zur Neujustierung der Intervallgrenzen und ggf. eine Reduktion der Anzahl an Zeitintervallen vorgenommen werden.
- Vielversprechend ist die Bereitstellung weiterer Situationsmerkmale über die Umfeldwahrnehmungsplattform wie z. B. eine Erkennung des Fahrtrichtungsanzeigers oder eine Typklassifizierung der umgebenden Fahrzeuge.

Eine Weiterentwicklung oder Abwandlung des Konzeptes zur Vorhersage von Fahrstreifenwechselmanövern ist unter folgenden Aspekten vorstellbar:

- Diskrete Bayes'sche Netzwerke zur Fahrstreifenwechselvorhersage wurden innerhalb dieser Arbeit intensiv untersucht. Lohnenswert scheint eine weitere Untersuchung Bayes'scher Netzwerke mit kontinuierlichen Zufallsvariablen, da für diese die kontinuierliche Ausgangsform der Situationsmerkmale nicht diskretisiert werden muss und der damit verbundene Informationsverlust ausbleibt. Ebenfalls scheint eine weitere Untersuchung alternativer Schätzmethoden lohnenswert.
- Ebenso untersuchenswert ist eine dem vorgestellten Schätzmodell vorgelagerte Instanz zur Situationsklassifikation, z. B. nach *Fahrstreifenwechselsituation* oder *keine Fahrstreifenwechselsituation*. Erwartet wird hierdurch die Reduktion der falsch-positive Rate bzgl. der Vorhersage von *kein Fahrstreifenwechsel* und gleichzeitig das Erzielen eines präziseren Schätzergebnisses des zeitlichen Verlaufs in einer Fahrstreifenwechselsituation.
- Die Schätzung von Fahrstreifenwechselmanövern des Ego-Fahrzeuges liefert in der vorliegenden Arbeit aufgrund der Datenlage die besten Ergebnisse. Das Hinzuziehen zusätzlicher Situationsmerkmale, welche bei einer Schätzung für Fremdfahrzeuge bislang nicht gegeben sind, z. B. Daten der Fahrerzustandserfassung, könnten das Ergebnis weiter verbessern. Für die Zukunft wäre eine Übertragung voraussichtlicher Manöver eines Fahrers oder geplanter Manöver einer automatischen Fahrfunktion an den umgebenden Verkehr via Car2X-Technologien denkbar.

A Anhang

A.1 Information und Transinformation

Die statistische Abhängigkeit einer Zufallsvariable lässt sich durch die Begriffe Entropie und Transinformation formalisieren:

Der informationstheoretische Begriff der Entropie H gibt den mittleren Informationsgehalt eines Ereignisses $x \in X$ einer Zufallsvariable X an und lässt sich durch folgende Formel ausdrücken, vgl. [Shannon 1948]:

$$H(X) = - \sum_{x \in X} P(X = x) \cdot \log_2 \frac{1}{P(X = x)}. \quad (\text{A.1})$$

Mit $P(X = x)$ gleich der Auftretswahrscheinlichkeit des Ereignisses x und $\log_2 \frac{1}{P(X=x)}$ gleich dem Informationsgehalt dieses Ereignisses in Bits.

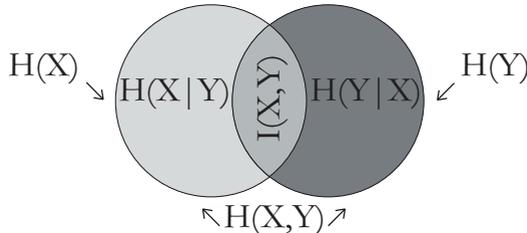


Abbildung A.1: Grafische Darstellung der Zusammenhänge von Entropie H und Transinformation I zweier Zufallsvariablen X und Y als Venndiagramm nach [Cover u. Thomas 1991]

Ist der Informationsgehalt einer Zufallsvariable in einem bestimmten Maß in dem Informationsgehalt einer zweiten Zufallsvariable enthalten, so sind diese statistisch abhängig. Ein Maß, mit dem der Informationsgehalt einer Zufallsvariable X über eine andere Zufallsvariable Y und der Verbundverteilung bestimmt werden kann, ist die Transinformation¹ I , vgl. [Cover u. Thomas 1991]:

$$I(X,Y) = \sum_{x \in X} \sum_{y \in Y} P(X = x, Y = y) \cdot \log_2 \frac{P(X = x, Y = y)}{P(X = x) \cdot P(Y = y)} \quad (\text{A.2})$$

¹ Transinformation, engl.: mutual information.

Eine grafische Darstellung der Zusammenhänge von Entropie H und Transinformation I zweier Zufallsvariablen X und Y gibt Abbildung A.1. Die Entropie beider Variablen ist jeweils als Kreis dargestellt. Die Vereinigung beider Kreise stellt die Verbundentropie von X und Y dar, der Schnitt die Transinformation. Anhand des abgebildeten Venn-Diagramms lassen sich folgende Eigenschaften nachvollziehen:

- $I(X,Y) \geq 0$: Die Transinformation ist niemals negativ.
- $I(X,Y) = 0 \Rightarrow H(X) = H(X|Y), H(Y) = H(Y|X)$: Beträgt die Transinformation zweier Zufallsvariable null, so erhält man mit Kenntnis über eine Zufallsvariable keine Kenntnis über die andere Variable, d. h. beide Variablen sind statistisch unabhängig.
- $MAX(I(X,Y)) \Rightarrow I(X,Y) = H(X,Y) = H(Y) = H(X)$: Die Transinformation zweier Zufallsvariablen ist maximal, wenn mit vollständiger Kenntnis einer Zufallsvariablen auch vollständige Kenntnis über eine andere Zufallsvariable erlangt wird, d. h. beide Variablen sind vollständig abhängig.

Die Transinformation ist somit nach Gleichung A.2 die relative Entropie zwischen einer Verbundverteilung $p(x,y)$ und der Produktverteilung $p(x)p(y)$. Äquivalent kann die Transinformation als Summe der Entropie von X und Y abzüglich der Verbundentropie von X und Y ausgedrückt werden, vgl. [Cover u. Thomas 1991]:

$$I(X,Y) = H(X) + H(Y) - H(X,Y) \quad (\text{A.3})$$

Die Transinformation einer Zufallsvariable mit sich selbst ist folglich die Entropie der Zufallsvariable:

$$I(X,X) = H(X) + H(X) - H(X,X) = H(X) \quad (\text{A.4})$$

A.2 Hard- & Softwareumgebung

Die Realisierung der Fahrstreifenwechselvorhersage erfolgt in der Programmiersprache C++ als Softwaremodul innerhalb der Umfeldwahrnehmungsplattform des TEMPORARY AUTOPILOT, vgl. Abschnitt 4.3. Hiermit ergeben sich folgende Randbedingungen bzgl. Hard-, Software und des Laufzeitverhaltens:

- Hardware: Als zentraler Umfeldwahrnehmungsrechner steht ein hochkompakter cPCI-Rechner mit Intel T7500 Doppelkernprozessor², 2 GB Hauptspeicher und 8 GB compactFlash-Karte als Massenspeicher zur Verfügung.
- Softwareumgebung: Als Softwareumgebung kommt ADTF³ und ein Linux-Betriebssystem⁴ mit Echtzeiterweiterung für den Online-Betrieb im Versuchsträger zum Einsatz. Der Offline-Betrieb während der Entwicklung, u. a. zum Prozessieren der Messdateien, erfolgt größtenteils unter Microsoft Windows XP bzw. Windows 7.
- Laufzeitverhalten: Der gesamte Wahrnehmungsprozess weist ein deterministisches Zeitverhalten auf. Sowohl die Datenverarbeitungs-, als auch die Ausgabeprozesse werden zyklisch von einer zentralen Zeitsteuerung gestartet und in ihrer Ausführungszeit überwacht. Das Modul Manöर्वorhersage wird über den Ausgabezyklus von 100 *ms* der Objektfusion gesteuert. Für die Berechnung der Fahrstreifenwechselwahrscheinlichkeiten der betreffenden Objekte stehen somit maximal 100 *ms* zur Verfügung, bevor neue Eingangsdaten verarbeitet werden müssen.

Zur Umsetzung des Bayes'schen Netzwerks wird die an der Universität von Pittsburg entwickelte Werkzeugkombination GeNIe/SMILE verwendet, vgl. [DSL 2013]. SMILE ist eine C++-Bibliothek zur Modellierung Bayes'scher Netzwerke. GeNIe bildet die grafische Benutzeroberfläche. Unsicheres Wissen aus dem Wahrnehmungsprozess kann mit den in Unterabschnitt 2.3.2.1 gegebenen Formalismen in eine virtuelle Evidenz transformiert und in Form einer diskreten Verteilung eingebracht werden ohne eine direkte Manipulation der Netzstruktur. Das gewählte Werkzeug erlaubt somit eine durchgehend probabilistische Datenverarbeitung. Ausschlaggebend für die Auswahl war neben der obligatorischen Verfügbarkeit in der Programmiersprache C++ und der Unterstützung von Windows- und Unix-Betriebssystemen eine große Anzahl an verfügbaren Inferenzalgorithmen und Parameterlernverfahren, die vollständige Trennung der grafischen Benutzeroberfläche von den Modellierungs- und Inferenzalgorithmen und nicht zuletzt eine brauchbare Dokumentation in Form von Online-Hilfe, Wiki und Tutorien.

² Core2Duo, 2,2 GHz Taktfrequenz.

³ ADTF - Automotive Data and Time-Triggered Framework: Softwareumgebung zur Realisierung von Fahrerassistenzsystemen, vgl. [AEV 2013].

⁴ Ubuntu 10.04.3 LTS mit PREEMPT_RT-Echtzeitkernel.

A.3 Herleitung des Eingangsmerkmals T_{tlc} - Zeit bis zum Queren der Markierung

Nachfolgend ist die Herleitung des Eingangsmerkmals T_{tlc} beschrieben durch Gleichung 4.3b in Unterabschnitt 4.5.1 gegeben:

$$\begin{aligned} a &= \text{const}, \\ v(t) &= a \cdot t + v_0, \\ s(t) &= \frac{1}{2}a \cdot t^2 + v_0 \cdot t + s_0, \end{aligned}$$

für t_{tlc} zur linken Markierung, d. h. $v_{lat} > 0$, $\frac{w-w_0}{2} > |d|$:

$$s(t) \stackrel{!}{=} \frac{1}{2} \cdot w - \frac{1}{2} \cdot w_0 = \frac{1}{2}a \cdot t^2 + v_0 \cdot t + s_0$$

gegeben: $v_0 = v_{lat}$, $s_0 = d$,

gesucht: $t = t_{tlc}$ an der Stelle $s(t) = 0$,

$$\begin{aligned} \rightarrow 0 &\stackrel{!}{=} \frac{1}{2}a \cdot t^2 + v_{lat} \cdot t + d_0 - \frac{1}{2}w + \frac{1}{2}w_0 \\ \stackrel{a \neq 0}{\rightarrow} 0 &= t^2 + 2\frac{v_{lat}}{a} \cdot t + \frac{2}{a} \left(d - \frac{1}{2}w + \frac{1}{2}w_0 \right) \\ \rightarrow t_{1,2} &= -\frac{v_{lat}}{a} \pm \sqrt{\frac{v_{lat}^2}{a^2} - \frac{2d - w + w_0}{a}} \\ &= -\frac{1}{a} \left(v_{lat} \pm \sqrt{v_{lat}^2 - 2a(d - w + w_0)} \right) \end{aligned}$$

Gewählt wird die größere der beiden Lösungen da $a > 0$ und $t_{tlc} > 0$ definiert ist:

$$t_{tlc} = -\frac{1}{a} \left(v_{lat} - \sqrt{v_{lat}^2 - a(2d - w + w_0)} \right)$$

Analog gilt für t_{tlc} zur rechten Markierung, d. h. $v_{lat} < 0$, $\frac{w-w_0}{2} > |d|$:

$$\begin{aligned} s(t) &\stackrel{!}{=} -\frac{1}{2} \cdot w + \frac{1}{2} \cdot w_0 = \frac{1}{2}a \cdot t^2 + v_0 \cdot t + s_0 \\ t_{1,2} &= -\frac{v_{lat}}{a} \pm \sqrt{\frac{v_{lat}^2}{a^2} - \frac{2d + w - w_0}{a}} \end{aligned}$$

Gewählt wird die größere der beiden Lösungen, da $a < 0$ und $t_{tlc} < 0$ definiert ist:

$$t_{tlc} = \frac{1}{a} \left(v_{lat} + \sqrt{v_{lat}^2 - a(2d + w - w_O)} \right)$$

A.4 Funktionsweise der gewählten Diskretisierungsverfahren

In diesem Abschnitt wird die Funktionsweise der in Abschnitt 5.2 angewendeten Diskretisierungsverfahren erläutert.

A.4.1 Minimum Description Length Principle Diskretisierung

Minimum Description Length Principle (MDLP) ist ein Entropieminimierungsverfahren nach [Fayyad u. Irani 1993]. Zu Beginn des Verfahrens wird der Datensatz S entsprechend der Auftretenshäufigkeit $|S| = N$ der enthaltenen kontinuierlichen Werte aufsteigend sortiert. Alle Nachbarschaften stellen einen potentiellen Schnittpunkt, d. h. Trennpunkt T zur Bildung von Teilmengen dar. Ausgehend von der Entropiegleichung A.1 wird nachfolgend die Klassenentropie KH für je zwei Teilmengen S_1, S_2 bestimmt, mit $S_1, S_2 \subset S, S_1 \cup S_2 = S$. Über alle potentiellen Schnittpunkte wird jener als Diskretisierungsschwelle gewählt, welcher die minimale Klassenentropie aufweist. Das Verfahren wird rekursiv auf alle durch den Trennpunkt entstandenen Teilintervalle angewendet, vgl. Abbildung A.2.

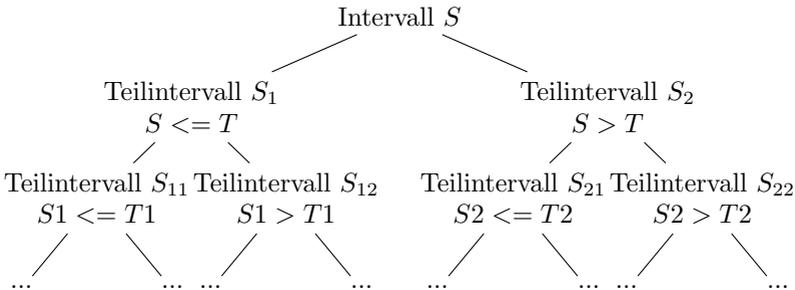


Abbildung A.2: Rekursive Bestimmung der Teilintervalle im Entropie-Minimierungsverfahren MDLP

$$KH(S,T) = \frac{|S_1|}{|S|} \cdot H(S_1) + \frac{|S_2|}{|S|} \cdot H(S_2) \quad (\text{A.6})$$

Die Rekursionstiefe wird über das Abbruchkriterium in Gleichung A.7 bestimmt, wobei K die Anzahl der bestimmten Klassen bezeichnet.

$$AK(S,T) = H(S) - KH(S,T) < \delta, \text{ mit } \delta = \quad (\text{A.7})$$

$$\frac{[\log_2(N-1) + \log_2(3^K - 2) - [K \cdot H(S) - K_1 \cdot H(S_1) - K_2 \cdot H(S_2)]]}{N}$$

A.4.2 Diskretisierung nach dem Gini-Verfahren

Ist ein an MDLP angelehntes verfahren nach [Zhang u. a. 2007]. Wie im MDLP-Verfahren erfolgt eine Sortierung aller kontinuierlichen Werte entsprechend ihrer Häufigkeit im Datensatz. Ebenso stellen alle Nachbarschaften einen potentiellen Schnittpunkt zur Bildung von Teilmengen dar. Zur Auswahl der ersten Intervallgrenzen werden die Teilintervalle $S_1, S_2 \subset S, S_1 \cup S_2 = S$ ausgewählt, welche nach Gleichung A.8 den größten Gini-Gewinn aufweisen. Statt der Entropie der Teilmengen bildet das Gini-Kriterium aus Gleichung A.9 die Bewertungsgrundlage.

$$GG(S, S_1, S_2) = G(S) - \frac{|S_1|}{|S|} \cdot G(S_1) - \frac{|S_2|}{|S|} \cdot G(S_2) \quad (\text{A.8})$$

$$G(S) = 1 - \sum_{i=1}^K p_i^2 \quad (\text{A.9})$$

Das Verfahren wird rekursiv auf alle die durch den Trennpunkt entstandenen Teilintervalle angewendet. Das Abbruchkriterium ist definiert über die Gleichung A.10, mit n als Bezeichner für die Anzahl an Intervallen und p einem benutzerdefinierten ganzzahligen Wert. In dieser Arbeit wird $p = 2$ gesetzt.

$$G_{n+1} \cdot \ln(n+1+p) > G_n \cdot \ln(n+p) \quad (\text{A.10})$$

$$\text{mit } G_n = \sum_{i=1}^n \frac{|S_i|}{|S|} \cdot G(S_i) \quad (\text{A.11})$$

A.4.3 Diskretisierung nach dem χ -Merge Verfahren

χ -Merge stellt ein überwachtes deterministische Diskretisierungsverfahren dar, welches in [Kerber 1992] beschrieben wird. Ziel des Verfahrens ist es in jedem Diskretisierungsintervall möglichst geringe Unterschiede bzgl. der Klassenzugehörigkeitsverhältnisse zu erzielen. Das Verfahren geht von „unten nach oben“ vor, d. h. zu Beginn wird jeder kontinuierliche Wert als eigenes Diskretisierungsintervall betrachtet. Im Anschluss werden benachbarte Diskretisierungsbereiche iterativ in Abhängigkeit des χ^2 -Tests zusammengefasst. Hierbei wird jeweils in jeder Iteration das Paar mit dem kleinsten χ^2 -Wert zusammengefasst. Das Verfahren wird wiederholt bis die gegebenen Anzahl von Diskretisierungsintervallen erreicht wird. Die Abhängigkeit bzgl. der Klassenzugehörigkeit zweier benachbarter Intervalle wird mit dem χ^2 -Test nach Gleichung A.12 überprüft:

$$\chi^2 = \sum_{i=1}^2 \sum_{j=1}^k \frac{(A_{ij} - E_{ij})^2}{E_{ij}} \quad (\text{A.12})$$

- mit der Anzahl an Klassen k ,
- mit der erwarteten Häufigkeit $E_{ij} = \frac{R_i \cdot C_j}{N}$,
- mit der Gesamtanzahl an Mustern $N = \sum_{j=1}^k C_j$,
- mit der Anzahl an Mustern in der j -ten Klasse $C_j = \sum_{i=1}^2 A_{ij}$,
- mit der Anzahl an Mustern in der i -ten Intervall $R_i = \sum_{j=1}^k A_{ij}$,
- mit der Anzahl an Muster im i -ten Intervall der j -ten Klasse A_{ij} .

A.4.4 Äquidistante Diskretisierung (ÄDD)

Der Algorithmus bestimmt zunächst das Maximum (*max*) und Minimum (*min*) der gegebenen Verteilung. Unter einer gegebenen Intervallanzahl (*NrOfBins*) wird der Inkrementierungsschritt (*increment*) wie folgt bestimmt:

$$\text{increment} = \frac{\text{max} - \text{min}}{\text{NrOfBins}}$$

Die Diskretisierungsschwellen *threshold* lassen sich nun für jedes Intervall $i \in N, [1..NrOfBins]$ wie folgt bestimmen:

$$\text{threshold}(i) = \text{min} + i \cdot \text{increment} \quad (\text{A.13})$$

Für nicht annähernd gleichverteilte Daten besteht die Gefahr, dass einige Intervalle deutlich mehr Daten⁵ repräsentieren als andere.

A.4.5 Häufigkeitsbasierte Diskretisierung (HBD)

Mit diesem Algorithmus wird versucht die Beschränkungen des in A.4.4 dargestellten Algorithmus aufzuheben indem für jedes Intervall eine gleichmächtige Datenrepräsentation angestrebt wird, d. h. jedes Intervall repräsentiert die gleiche Anzahl von Messpunkten. Vergleichbar zu A.4.4 werden zunächst die Maximum und Minimum bestimmt, die Daten sortiert und die Datenmenge gleichmäßig entsprechend der gegebenen Anzahl von Intervallen aufgeteilt. Die Diskretisierungsschwellen sind adäquat zu den Intervallgrenzen.

A.4.6 K-Means Cluster-Algorithmus

Bei einer gegebenen Anzahl von Clustern, d. h. Diskretisierungsintervallen, hat der Algorithmus folgende Schritte:

- (a) Initialisierungsschritt: zufällige Auswahl von k -Objekten als Anfangsclusterzentren.
- (b) Jedes Objekt wird dem Cluster zugeordnet, dem es am ähnlichsten ist.
- (c) Die Clusterzentren werden neu bestimmt durch eine Mittelwertbildung über alle dem jeweiligen Cluster zugeordneten Objekte.

Die Schritte b-c werden solange wiederholt, bis die Anzahl der Neuuzuordnungen eine bestimmte Konstante unterschreitet. Der Algorithmus ist so entworfen, dass die Summe der quadratischen Funktion über die Zuordnung der Objekte x zu den Clustern $i = 1, 2, \dots, k$ minimiert wird, wobei C_i den Schwerpunkt der Cluster und d das Distanzmaß eines Objektes zu C_i ist:

$$SSD = \sum_{i=1}^k \sum_{x \in clusterSet} d(x, C_i)^2$$

⁵ Anzahl von Tupeln im Datensatz.

A.5 Algorithmus BN-IPFP-1

Listing A.1: Algorithmus BN-IPFP-1 nach [Peng u. a. 2010]

```

1   $Q_0(X) = P(X); k = 1$ 
2  Wiederhole bis Konvergenz eintritt:
3     $a = 1 + (k - 1) \bmod s; \quad l = 1 + \lfloor \frac{k-1}{s} \rfloor$ 
4    Konstruiere virtuelle Evidenzen und
      Wahrscheinlichkeitsquotienten:
      
$$\lambda_1^{a,l} : \dots : \lambda_m^{a,l} = \frac{q_1^a}{Q_{k-1}(x_1^a)} : \dots : \frac{q_m^a}{Q_{k-1}(x_m^a)}$$

5    Erhalte  $Q_k(X)$  nach dem Update von  $Q_{k-1}(X)$  mit
      
$$\lambda_1^{a,l} : \dots : \lambda_m^{a,l}$$

6     $k = k + 1$ 
7  Ende

```

Es finden folgende Bezeichner Verwendung: $Q(x)$ - Posteriorverteilung, $P(X)$ - Priorverteilung, s - Anzahl der Knoten für welche weiche Evidenz vorliegt, m - Anzahl der Zustände von X , a - Index der aktuellen Lösung, l - Index der Iterationen pro Lösung und λ - Wahrscheinlichkeitsquotient.

A.6 Komplexitätsanalyse der Merkmalsauswahl mithilfe Wrapper-Verfahren

Es wird sich auf den in Abschnitt 5.3 verwendeten Merkmalsraum von 30 Merkmalen bezogen. Zum Einsatz kommt jeweils ein Naives BN.

A.6.1 Wrapper mit Brute-Force Verfahren

In Listing A.2 ist die Komplexitätsanalyse auf Basis des Pseudocodes eines Wrappers mit Brute-Force Verfahren zur Merkmalsauswahl gegeben.

Es ergibt sich pro Zeile die in Tabelle A.1 gegebene Komplexität, wobei n die Anzahl der Elemente im Merkmalsraum und m die Anzahl an Tupel im Datensatz bezeichnet. In Zeile vier werden jeweils zehn Lern- und Testdatensätze aus den Lerndaten, vgl. Tabelle 5.3 extrahiert um im Lern- und

Evaluationsschritt in Zeile sechs und sieben den Einfluss des Datensatzes zu minimieren. Die Komplexität des Lernschrittes sowie des Evaluations-schrittes ist unbekannt, da die verwendete Softwarebibliothek *smile* nicht quelloffen ist. Von praktischer Relevanz dürfte hier insbesondere die Auslegung des EM-Verfahrens bzgl. des Abbruchkriteriums, d. h. der Anzahl der Iterationen sein.

Listing A.2: Pseudocode Wrapper mit Brute-Force Verfahren

```

1 Subset = {1,2,3,4,5,6,7,8,9,10,11,12,13,14,15,16,
            17,18,19,20,21,22,23,24,25,26,27,28,29,30}
2
3 for(alle Elemente in der Potenzmenge von Subset) do
4   Lern- & Testdatensätze erzeugen
5   for(jeden Lerndatensatz) do
6     Naives BN anlernen mit EM-Algorithmus
7     Naives BN mit Testdatensatz evaluieren
8   end
9 end
10
11 Ergebnisse evaluieren, ausgeben

```

Tabelle A.1: Komplexitätsbetrachtung Wrapper-Methode mit Brute-Force

1. $O(n)$	6. $O(\text{Lernen})$
3. $O(2^n)$	7. $O(\text{Testen})$
4. $O(n \cdot m \cdot 2 \cdot 10)$	11. $O(1)$
5. $O(10)$	

Entsprechend ergibt sich aus Listing A.2 und Tabelle A.1 Gleichung A.14:

$$O(n) = O(n) + O(2^n) \cdot [O(n \cdot m \cdot 2 \cdot 10) + O(10) \cdot [O(\text{Lernen}) + O(\text{Testen})]] + O(1) \quad (\text{A.14})$$

Werden Summanden und Multiplikatoren niederer Ordnung nicht betrachtet, kürzt sich Gleichung A.14 zu Gleichung A.15.

$$O(n) = O(2^n) \cdot O(n \cdot m) \cdot [O(\text{Lernen}) + O(\text{Testen})] \quad (\text{A.15})$$

A.6.2 Wrapper-Verfahren mit gerichteter Suche

Im Folgenden ist die Komplexitätsanalyse auf Basis des Pseudocodes einer Wrapper-Methode mit gerichteter Suche zur Merkmalsauswahl analog zu Unterabschnitt A.6.1 gegeben.

Listing A.3: Pseudocode Wrapper-Methode mit gerichteter Suche

```

1 Subset = {1,2,3,4,5,6,7,8,9,10,11,12,13,14,15,16,
           17,18,19,20,21,22,23,24,25,26,27,28,29,30}
2 Pool = {31}
3 for(Anzahl an Elementen aus Subset) do
4   for(alle Elemente, die nicht Element von Pool) do
5     tmpPool = Pool + neues Element
6     Lern- & Testdatensätze erzeugen
7     for(jeden Lerndatensatz) do
8       Naives BN anlernen mit EM-Algorithmus
9       Naives BN mit Testdatensatz evaluieren
10    end
11  end
12  Pool += bestes Netz aus tmpPool
13 end
14
15 Ergebnisse Evaluieren, ausgeben

```

Es ergibt sich pro Zeile die in Tabelle A.2 gegebene Komplexität, mit p als Bezeichner der Elemente im Pool. Die weitere Parameterbeschreibung ist analog zu Unterabschnitt A.6.1.

Tabelle A.2: Komplexität pro Zeile

1.	$O(n)$	7.	$O(10)$
2.	$O(1)$	10.	$O(Lernen)$
3.	$O(n)$	11.	$O(Testen)$
4.	$O(n - p)$	12.	$O(1)$
5.	$O(1)$	15.	$O(1)$
6.	$O(p \cdot m \cdot 2 \cdot 10)$		

Entsprechend ergibt sich aus Listing A.3 und Tabelle A.2 Gleichung A.16.

$$\begin{aligned}
 O(n) = & O(n) + O(1) + O(n) \cdot [O(n - p) \cdot [O(1) \\
 & + O(p \cdot m \cdot 2 \cdot 10) + O(10) \cdot [O(Lernen) \\
 & + O(Testen)]] + O(1)] + O(1)
 \end{aligned} \tag{A.16}$$

Werden Summanden und Multiplikatoren niederer Ordnung nicht betrachtet, kürzt sich Gleichung A.16 zu Gleichung A.17.

$$O(n) = O(n) \cdot O(n - p) \cdot [O(p \cdot m) + O(Lernen) + O(Testen)] \tag{A.17}$$

A.7 Konfusionsmatrizen

Nachfolgend ist die Konfusionsmatrix des in Unterabschnitt 5.7.4 auf Seite 183 ermittelten Rekurrenten Neuronalen Netzwerks (RNN) gegeben:

Tabelle A.3: Konfusionsmatrix eines RNN mit zwei versteckten Schichten zu jeweils 190 Neuronen. Das Netzwerk ist rekurrent über drei Zeitschritte zu jeweils 200 ms.

$P(LC^{pr}, LC^{gt})$ in [%]	$LC^{pr} =$								
	lc_1	lc_2	lc_3	lc_4	lc_5	lc_6	lc_7	lc_8	lc_9
$LC^{gt}=lc_1$	73,99	1,18	0,43	1,73	6,46	0,48	0,56	1,82	13,35
$LC^{gt}=lc_2$	0,53	51,54	46,96	0,96	0,00	0,00	0,00	0,00	0,00
$LC^{gt}=lc_3$	3,62	0,21	42,64	52,24	1,28	0,00	0,00	0,00	0,00
$LC^{gt}=lc_4$	13,38	0,00	1,18	59,85	25,59	0,00	0,00	0,00	0,00
$LC^{gt}=lc_5$	33,69	0,21	0,32	17,70	47,85	0,00	0,00	0,00	0,21
$LC^{gt}=lc_6$	0,75	0,00	0,00	0,00	0,00	70,78	28,28	0,09	0,09
$LC^{gt}=lc_7$	1,23	0,00	0,00	0,00	0,00	0,85	81,25	14,77	1,89
$LC^{gt}=lc_8$	3,78	0,00	0,00	0,00	0,00	0,38	13,79	42,49	39,57
$LC^{gt}=lc_9$	14,49	0,00	0,00	0,00	0,00	0,19	4,36	13,54	67,42

Tabellenverzeichnis

1.1	Automatisierungsgrade der Fahrzeugführung	13
2.1	Potenzmenge	33
2.2	Schnittmengendiagramm	35
3.1	Kategorisierung von Fahrstreifenwechseln	64
3.2	Modellierungsansätze zum Eigenfahrstreifenwechsel	76
3.4	Eingangsmerkmale	78
3.5	Eingangsmerkmal Freiraumhypothese	81
4.1	Egozustandsvektor	97
4.2	Zustandsvektor für Objekte	98
4.3	Zustandsvektor Fahrbahn	100
4.4	Merkmale Fahrbahnmarkierung	101
4.5	Zeitintervalle	103
4.6	laterale Indikation	105
4.7	Fahrbahn	105
4.8	Verkehrsgeschwindigkeit	106
4.9	Beziehung zu Umfeldobjekten	107
5.1	Bezugsstatistik	121
5.2	Stichprobe	121
5.3	Eigenschaften der Datenbasis	124
5.4	χ -Merge Intervall- grenzen 12 und 19	139
5.5	Intervallgrenzen χ -Merge und relative Transformation . . .	140
5.6	Diskretisierungsschwellen der kontinuierlichen Evidenzvariablen	144
5.7	Sortierung der Variablen	152

5.8	Konfusionsmatrix WRAPPER (HARD) mit 6 Evidenzvariablen	154
5.9	Festlegung des Kostenfaktor C_{ij}	155
5.10	Vergleichsbewertung der ermittelten Naiven Bayes'schen Netzwerke	159
5.11	Konfusionsmatrix WRAPPER (HARD) mit 21 Evidenzvariablen	160
5.12	Bewertung der per HNB mit Zielfunktion BIC-Score ermittelten Bayes'schen Netzwerke	161
5.13	Bewertung der per HNB mit Zielfunktion Klassifikationsgüte ermittelten Bayes'schen Netzwerke	164
5.14	Bewertung der per HNB mit Zielfunktion Klassifikationsgüte ermittelten Bayes'schen Netzwerke auf Basis des auf Ego-Daten reduzierten Testdatensatzes.	166
5.15	Bewertung der per Genetischem Algorithmus erstellten Dynamischen Bayes'schen Netzwerke mit einem zum Start der Struktursuche entsprechend der Transinformation initialisierten temporalen Netzwerk.	170
5.16	Bewertung der per Genetischem Algorithmus erstellten Dynamischen Bayes'schen Netzwerke mit einem zum Start der Struktursuche zufällig initialisierten temporalen Netzwerk.	170
5.17	Konfusionsmatrix Dynamisches Bayes'sches Netzwerk mit 21 Evidenzvariablen	173
5.18	Bewertungsergebnisse einer manuell und maschinell bestimmten Struktur	180
5.19	Bewertungsergebnisse in Abhängigkeit der CPT-Bestimmung vom Datensatzes	183
5.20	Gegenüberstellung der Klassifikationsergebnisse Bayes'sches Netzwerk und Künstliches Neuronales Netzwerk	184
A.1	Wrapper-Methode mit Brute-Force	202
A.2	Komplexität pro Zeile	203
A.3	Konfusionsmatrix RNN	204

Abbildungsverzeichnis

1.1	Systemstatusdiagramm des TEMPORARY AUTOPILOT	11
2.1	Messen und Wahrnehmen	16
2.2	Objektbasierte Umfeldwahrnehmung	21
2.3	Gitterkartenbasierte Umfeldwahrnehmung	23
2.4	Graphenbasierte Umfeldrepräsentation	24
2.5	Übersicht Modellierungsverfahren	26
2.6	Beispiel für das Modell eines Neurons	36
2.7	Aufbau eines Bayes'schen Netzwerks	38
2.8	Typen von Kausalstrukturen	40
2.9	Aufbau eines Naive Bayes'schen Netzwerks	42
2.10	Dynamisches Bayes'sches Netzwerk	42
2.11	Arten des Schlussfolgerns	43
2.12	Bsp. Evidenzweitergabe	44
2.13	Virtuelle Evidenz	46
2.14	Virtuelle Variablen in einem naiven Bayes'schen Netzwerk	47
2.15	Hill-Climbing Suchverfahren	50
2.16	Operator Parent Introduction	53
2.17	Operator Parent Alliteration	54
2.18	Zerlegung eines Bayes'schen Netzwerks	54
2.19	Genotyp eines Dynamischen Bayes'schen Netzwerks (DBN)	56
2.20	Anwendung der Operatoren	56
2.21	Messunsicherheit und Vagheit	59
3.1	Fahrstreifenwechsel von rechts nach links	62
3.2	Spurwechsel vs. Fahrstreifenwechsel	62
3.3	Typisierung des Fahrstreifenwechsellvorgangs	66

3.4	Relevante Bereiche für das Einscheren in eine Lücke	69
3.5	3-Ebenenmodell zur Fahrmanövererkennung	71
3.6	Bayes'sches Netzwerk für laterale Manöverentscheidungen . .	74
3.7	Aktionsmodell nach [Dagli 2005]	77
3.8	Reduziertes Bayes'sches Netzwerk zur Einscherererkennung .	78
3.9	Schicht 1 & 2 eines objektorientierten Bayes'schen Netzwerks	80
3.10	Schicht 3 eines objektorientierten Bayes'schen Netzwerks . .	81
3.11	Objektorientiertes Bayes'sches Netzwerk	82
3.12	Fahrmanöver	83
3.13	Situationsmerkmale des Fahrstreifenwechsels	86
4.1	Ziel der Vorhersage	88
4.2	Strukturdiagramm Umfeldwahrnehmung	92
4.3	Struktur & Ablauf im Modul <i>Maneuver-Prediction</i>	93
4.4	Ablauf der Fahrstreifenwechselschätzung	93
4.5	Versuchsfahrzeug, Umfeldsensoren und Sichtbereiche des TAP	95
4.6	Trajektorie des Ego-Fahrzeuges auf einer Kreisbahn	97
4.7	Objektfusion	98
4.8	Fahrbahnfusion: Eingangsdaten und Fahrbahnmodell	99
4.9	Angewandte Umfeldkoordinatensysteme	101
4.10	Eingangsmerkmale der lateralen Indikation	104
4.11	Beispiel für eine Fahrstreifenzuordnung	114
4.12	Umgebungsmaske	115
4.13	Definition der Lücken	116
5.1	Vorgehen zur Bestimmung eines Bayes'schen Netzwerks . . .	119
5.2	Versuchsstrecke	121
5.3	Fahrscene mit Referenzdaten	123
5.4	Anzahl gültiger Messwerte je Situationsmerkmal	125
5.5	Histogramm der Variable Fahrstreifenwechsel	126
5.6	Histogramme des Merkmales <i>tlc</i>	127

5.7	Transinformationsmatrize der Merkmals- und Klassenvariablen	128
5.8	Transinformation zwischen Klassen- und Evidenzvariablen . . .	130
5.9	Einordnung der angewandten Diskretisierungsverfahren . . .	132
5.10	Diskretisierungsschwellen des Merkmals <i>vMax2vActRight</i> . . .	135
5.11	Diskretisierung mithilfe des HBD-Verfahrens	136
5.12	Rel. Transinformation von <i>Ablage</i> zu <i>Fahrstreifenwechsel</i> . . .	137
5.13	Rel. Transinformation von <i>Zeitlücke</i> zu <i>Fahrstreifenwechsel</i> .	139
5.14	Rel. Transinformation von <i>Zeitlücke</i> zu <i>Fahrstreifenwechsel</i> nach der Evaluierung	140
5.15	Diskretisierungsverfahren für <i>Lückenwachstumsrate</i> und <i>tlc</i> .	142
5.16	Klassifikationsgüte für Mengen von Evidenzvariablen	151
5.17	Vergleich der Klassifikationsgüte für Naive Bayes'sche Netz- werke	157
5.18	Höchste Klassifikationsgüte je Variablenset	158
5.19	Klassifikationsgüte für harte und weiche Evidenz	159
5.20	HNB für 6 Evidenzvariablen	162
5.21	HNB für 10 Evidenzvariablen	163
5.22	HNB für 16 Evidenzvariablen	164
5.23	HNB für 21 Evidenzvariablen	165
5.24	Genotypcodierung Dynamisches Bayes'sches Netzwerk (DBN)	168
5.25	Ergebnis der Bestimmung der temporalen Netzwerke	171
5.26	Ergebnis der Bestimmung des temporalen Netzwerkes	172
5.27	DBN Vorhersageergebnis je Zeitschritt für Fahrstreifenwechsel nach links	174
5.28	DBN Vorhersageergebnis je Zeitschritt für Fahrstreifenwechsel nach rechts	175
5.29	Manuell modelliertes Bayes'sches Netzwerk mit 30 Evidenzva- riablen	178
5.30	Manuell modelliertes Bayes'sches Netzwerk mit 21 Evidenzva- riablen	179
5.31	RNN Vorhersageergebnis je Zeitschritt für Fahrstreifenwechsel nach links	185

5.32 RNN Vorhersageergebnis je Zeitschritt für Fahrstreifenwechsel nach rechts	185
A.1 Entropie Venndiagramm	193
A.2 Rekursive Bestimmung der Teilintervalle im Verfahren MDLP	197

Literaturverzeichnis

AEV 2013

AEV: *ADTF - Internetpräsenz der Audi Electronic Venture GmbH*. Internetseite, 2013. – Verfügbar unter: <http://www.audi-electronics-venture.de/aev/brand/de/leistungen/Entwicklungstools/adtf.htm>; letzter Zugriff 07.01.2013

Ahlers u. Westhoff 2009

AHLERS, Florian ; WESTHOFF, Daniel: Laserscanner-based lane detection and relative positioning. In: *Conference Proceedings of the 16th World Congress on ITS* (2009)

Aizerman 1977

AIZERMAN, Mark: Some unsolved problems in the theory of automatic control and fuzzy proofs. In: *IEEE Transactions on Automatic Control* 22(1) (1977), S. 116–118

AKTIV-Konsortium 2009

AKTIV-KONSORTIUM: *Internetpräsenz des durch das BMWi geförderten Forschungsprojektes aktiv (Adaptive und Kooperative Technologien für den Intelligenten Verkehr)*. Internetseite, 2009. – Verfügbar unter: <http://www.aktiv-online.org/>; letzter Zugriff 10.09.2012.

Althoff u. a. 2009

ALTHOFF, Matthias ; STURSBURG, Olaf ; BUSS, Martin: Safety Assessment of Driving Behavior in Multi-Lane Traffic for Autonomous Vehicles. In: *Proceedings of Intelligent Vehicles* (2009)

Audi-AG 2016

AUDI-AG: *Audi A4 Stauassistent*. Internetseite, 2016. – Verfügbar unter: <https://www.audi-technology-portal.de/de/elektronik/fahrerassistenzsysteme/audi-a4-stauassistent-de>, Zugriff am 28.04.2017

Bar-Shalom u. Li 1995

BAR-SHALOM, Yaakov ; LI, Xiao-Rong: *Multitarget-Multisensor Tracking: Principles and Techniques*. 3. YBS Publishing, 1995. – ISBN 0-9648312-0-1

Bartels u. a. 2011

BARTELS, Arne ; TO, Thanh B. ; KARENBERG, Simon ; WEISER, Andreas: Temporary Auto Pilot - Teilautomatisches Fahren auf der Autobahn. In: *Automobiltechnische Zeitschrift* 9 (2011)

Bauer 1996

BAUER, Mathias: *Ein evidenztheoretischer Ansatz zur Planerkennung*, Universität des Saarlandes, Diss., 1996

Berndt u. Dietmayer 2009

BERNDT, Holger ; DIETMAYER, Klaus: Driver Intention Inference with Vehicle Onboard Sensors. In: *Proceedings of IEEE International Conference on Vehicular Electronics and Safety*. Pune, India : IEEE, 2009, S. 102–107

Berndt u. a. 2008

BERNDT, Holger ; EMMERT, Jörg ; DIETMAYER, Klaus: Continuous Driver Intention Recognition with Hidden Markov Models. In: *Proceedings of IEEE International Conference on Intelligent Transportation Systems*. Beijing, China : IEEE, 2008

Bernotat 1970

BERNOTAT, Rainer: Anthropotechnik in der Fahrzeugführung. In: *Ergonomics* 13 (1970), S. 353–377

Bhuyian 2016

BHUYIAN, Johana: *Lyft says robots will drive most of its cars in five years*. Internetseite, 2016. – Verfügbar unter: <http://www.recode.net/2016/9/18/12955162/lyft-gm-self-driving-cars> - veröffentlicht am 18.09.2016, letzter Zugriff am 30.12.2016

Blackman u. Populi 1999

BLACKMAN, Samuel ; POPULI, Robert: *Design and Analysis of Modern Tracking Systems*. Artech House, 1999. – ISBN 1–58053–006–0

Blaschke u. a. 2008

BLASCHKE, Christoph ; SCHMITT, Josef ; FÄRBER, Berthold: Überholmanöver-Prädiktion über CAN-Bus-Daten. In: *Automobiltechnische Zeitschrift ATZ* 11 (2008), November

Bocklisch 1987

BOCKLISCH, Steffen F.: *Prozeßanalyse mit unscharfen Verfahren*. Verlag Technik Berlin, 1987

Carvalho 2009

CARVALHO, Alexandra M.: Scoring functions for learning Bayesian networks / IST, TULisbon/INESC-ID. Version: 2009. <http://www.lx.it.pt/~asmc/pub/publications/09-TA/09-c-ta.pdf>. 2009 (54/2009). – Forschungsbericht

Cawley u. a. 2007

CAWLEY, Gavin C. ; TALBOT, Nicola L. ; GIROLAMI, Mark: Sparse Multinomial Logistic Regression via Bayesian L1 Regularisation. Version: 2007. <http://papers.nips.cc/paper/3155-sparse-multinomial-logistic-regression-via-bayesian-l1-regularisation.pdf>. In: SCHÖLKOPF, B. (Hrsg.) ; PLATT, J.C. (Hrsg.) ; HOFFMAN, T. (Hrsg.): *Advances in Neural Information Processing Systems 19*. MIT Press, 2007, 209–216

Cawley u. Talbot 2006

CAWLEY, Gavin C. ; TALBOT, Nicola L. C.: Gene selection in cancer classification using sparse regression with Bayesian regularization. In: *BIOINFORMATICS* 22 (2006), Nr. 19, 2348–2355. <http://bioinformatics.oxfordjournals.org/content/22/19/2348.full.pdf>

Chan u. Darwiche 2005

CHAN, Hei ; DARWICHE, Adnan: On the revision of probabilistic beliefs using uncertain evidence. In: *Artificial Intelligence* 163 (2005), S. 67–90

Chen 2009

CHEN, Jian: *Fahrerassistenzsystem zum autonomen Spurwechsel*, Rheinisch-Westfälische Technische Hochschule Aachen, Diss., 2009. <http://books.google.com/books?id=k07tcQAACAAJ>

Chollet 2016

CHOLLET, François: *Keras: Deep Learning library for Theano and TensorFlow*. Internetseite, 2016. – Verfügbar unter: <https://keras.io/>; letzter Zugriff 06.01.2017

Cover u. Thomas 1991

COVER, Thomas M. ; THOMAS, Joy A.: *Elements of Information Theory*. John Wiley & Sons, 1991. – 12–49 S. <https://web.cse.msu.edu/~cse842/Papers/CoverThomas-Ch2.pdf>

Dagli 2005

DAGLI, Ismail: *Erkennung von Einscherer-Situationen für Abstands-*

regeltempomanten, Eberhard-Karls-Universität Tübingen, Fakultät für Informations- und Kognitionswissenschaften, Diss., 2005

Dai u. Ren 2015

Kapitel Advanced Methodologies for Bayesian Networks. In: DAI, Jing-guo ; REN, Jia: *Unsupervised Evolutionary Algorithm for Dynamic Bayesian Network Structure Learning*. Bd. 9505. Springer, 2015, S. 136–151

Darms 2007

DARMS, Michael: *Eine Basis-Systemarchitektur zur Sensordatenfusion von Umfeldsensoren für Fahrerassistenzsysteme*, Technischen Universität Darmstadt, Diss., 2007

Darpa 2005

DARPA: *Internetpräsenz des DARPA-Wettbewerbes Grand Challenge für autonome Bodenfahrzeuge*. Internetseite, 2005. – Verfügbar unter: <http://archive.darpa.mil/grandchallenge05/>; letzter Zugriff 04.10.2012.

Darpa 2007

DARPA: *Internetpräsenz des DARPA-Wettbewerbes Urban Challenge für autonome Bodenfahrzeuge*. Internetseite, 2007. – Verfügbar unter: <http://archive.darpa.mil/grandchallenge/>; letzter Zugriff 04.10.2012.

Deml u. Neumann 2010

DEML, Barbara ; NEUMANN, Hendrik: *Systematische Abbildung relevanter Fahrerzustände und Fahrerintentionen*. 2010. – Interne unveröffentlichte Studie, Otto von Guericke Universität Magdeburg, Volkswagen AG

Dempster u. a. 1977

DEMPSTER, Arthur P. ; LAIRD, Nan M. ; RUBIN, Donald B.: Maximum Likelihood from Incomplete Data via the EM Algorithm. In: *Journal of the Royal Statistical Society. Series B (Methodological)* 39 (1977), Nr. 1, S. 1–38

Dempster 1967

DEMPSTER, Arthur P.: Upper and lower probabilities induced by a multivalued mapping. In: *Annals of Mathematical Statistics* Bd. 38. Baltimore : Waverly Press, 1967, S. 325–339

Derendarz u. a. 2010

DERENDARZ, Wojciech ; GRAF, Thorsten ; WAHL, Friedrich M.: Monokamerabasierte Fahrzeugumfeldererkennung für Komplexe Umgebung.

In: *VDI-Berichte Optische Technologien in der Fahrzeugtechnik* 2090 (2010), April, S. 141–156

Dickmanns u. a. 1994

DICKMANNS, Ernst D. ; BEHRINGER, Reinhold ; DICKMANNS, Dirk ; HILDEBRANDT, T. ; MAURER, Markus ; SCHIEHLEN, J. ; THOMANEK, F.: The seeing passenger car VaMoRs-P. In: *Proceedings of International Symposium on Intelligent Vehicles*, 1994

Dietmayer 2006

DIETMAYER, Klaus: Evidenztheorie: Ein Vergleich zwischen Bayes- und Dempster-Shafer-Methoden. In: *Informationsfusion in der Mess- und Sensortechnik*, Universitätsverlag Karlsruhe - J. Beyerer, F. Puente León, K.-D. Sommer (Hrsg.), 2006, S. 39–49

Dogan u. a. 2008

DOGAN, Ueruen ; EDELBRUNNER, Hannes ; IOSSIFIDIS, Ioannis: Towards a Driver Model: Preliminary Study of Lane Change Behavior. In: *In proceedings of the 11th International IEEE Conference on Intelligent Transportation Systems*. Beijing, China : IEEE, 2008, S. 931–937

Dornieden u. a. 2012

DORNIEDEN, Bernd ; JUNGE, Lutz ; PASCHEKA, Patrick: Vorausschauende energieeffiziente Fahrzeuglängsregelung. In: *Automobiltechnische Zeitschrift* 03/2012 (2012), S. 230–235

Doshi u. Trivedi 2009

DOSHI, Anup ; TRIVEDI, Mohan M.: On the Roles of Eye Gaze and Head Dynamics in Predicting Driver's Intent to Change Lanes. In: *IEEE Transactions on Intelligent Transportation Systems* Bd. 10, IEEE, 2009, S. 453–462

DSL 2013

DSL: *GeNIe & SMILE-Internetpräsenz des Decision Systems Laboratory (DSL) der Universität Pittsburg*. Internetseite, 2013. – Verfügbar unter: <http://genie.sis.pitt.edu/>; letzter Zugriff 07.01.2013

Duda u. a. 2007

DUDA, R.O. ; HART, P.E. ; STORK, D.G.: Pattern Classification. In: *Journal of Classification* 24 (2007), September, Nr. 2, S. 305–307

ECE 2014

United Nations Economic and Social Council: *Report of the sixty-eighth*

session of the Working Party on Road Traffic Safety. Geneva, April 2014

Ehmanns 2002

EHMANN, Dirk: *Modellierung des taktischen Fahrerverhaltens bei Spurwechselvorgängen*, Rheinisch-Westfälische Technische Hochschule, Diss., 2002. <http://books.google.com/books?id=W0hiAAAACAAJ>

Eichendorf 2012

EICHENDORF, Walter: Vision Zero. In: *Deutscher Verkehrssicherheitsrat - Schriftenreihe Verkehrssicherheit* 16 (2012), 3-16. http://www.dvr.de/download2/p3042/3042_0.pdf. – letzter Zugriff: 20.10.2016

Erke 1993

ERKE, Heiner: Vorgaben an die Verkehrsplanung. Anforderung an den Menschen aus Sicht der ökologischen Psychologie. In: LANG, Erich (Hrsg.) ; ARNOLD, Klaus (Hrsg.): *Der Mensch im Straßenverkehr* Bd. 6. Stuttgart : Enke, 1993, S. 99–112

Etemad 2015

ETEMAD, Aria: A Stepwise Introduction of Automated Driving. In: *Proceedings of 22nd ITS World Congress*, 2015. – Verfügbar unter: https://www.adaptive-ip.eu/index.php/deliverables_papers.html; letzter Zugriff 25.04.2017

Fastenmeier u. a. 2001

FASTENMEIER, Wolfgang ; HINDERER, Jürgen ; LEHNIG, Ulf ; GSTALTER, Herbert: Analyse von Spurwechselvorgängen im Verkehr. In: *Zeitschrift fuer Arbeitswissenschaft* 55 (2001), S. 15–23

Fayyad u. Irani 1993

FAYYAD, Usama M. ; IRANI, Keki B.: Multi-Interval Discretization of Continuous-Valued Attributes for Classification Learning. In: *Proceedings of the 13th International Joint Conference on Artificial Intelligence* (1993), 1022–1027. <http://hdl.handle.net/2014/35171>

Fisher 1925

FISHER, Ronald A.: Applications of “Students’s“ Distribution. Version: 1925. <http://hdl.handle.net/2440/15187>. In: *Fisher: Collected papers relating to statistical and mathematical theory and applications*. Reproduced with permission of Metron, 1925, 90–104

Freyer 2008

FREYER, Jörn: *Vernetzung von Fahrerassistenzsystemen zur Verbesserung des Spurwechselverhaltens von ACC*, Universität der Bundeswehr München, Diss., 2008

Gasser u. a. 2012

GASSER, Tom M. ; ARZT, Clemens ; AYOUBI, Mihir ; BARTELS, Arne ; BÜRKLE, Lutz ; EIER, Jana ; FLEMISCH, Frank ; HÄCKER, Dirk ; HESSE, Tobias ; HUBER, Werner ; LOTZ, Christine ; MAURER, Markus ; RUTH-SCHUMACHER, Simone ; SCHWARZ, Jürgen ; VOGT, Wolfgang: *Rechtsfolgen zunehmender Fahrzeugautomatisierung*. Bundesanstalt für Strassenwesen, 2012 (Berichte der Bundesanstalt für Straßenwesen F38)

Gerdes 2006

GERDES, Arati: Driving Manoeuvre Recognition. In: *Proceedings ITS 2006: 13th World Congress and Exhibition on Intelligent Transport Systems and Services*, London: Ertico, 2006

Gini 1912

GINI, C. ; PIZETTI, E. (Hrsg.) ; SALVEMINI, T. (Hrsg.): *Variabilità e Mutabilità*. Reprinted in *Memorie di metodologia statistica* (Ed. E. Pizetti and T. Salvemini.) Rome: Libreria Eredi Virgilio Veschi, 1955, 1912

Goodfellow u. a. 2016

GOODFELLOW, Ian ; BENGIO, Yoshua ; COURVILLE, Aaron: *Deep Learning*. MIT Press, 2016. – <http://www.deeplearningbook.org>

Graf u. a. 2013

GRAF, Regine ; DEUSCH, Hendrik ; FRITZSCHE, Martin ; DIETMAYER, Klaus: A Learning Concept for Behavior Prediction in Traffic Situations. In: *Proceedings of 2013 IEEE Intelligent Vehicles Symposium, Gold Coast Australia* (2013)

Grubb u. a. 2009

GRUBB, Grant ; JAKOBSSON, Erika ; BEUTNER, Achim ; AHRHOLDT, Malte ; BERGQVIST, Stefan: Automatic Queue Assistance to Aid Underloaded Drivers. In: *Proceedings of 16th ITS World Congress and Exhibition on Intelligent Transport Systems and Services*, 2009

Guyon u. Elisseeff 2003

GUYON, Isabelle ; ELISSEEFF, And e: An Introduction to Variable and Feature Selection. In: *Journal of Machine Learning Research* 3, 2003, 1157-1182

Haak u. a. 2010

HAAK, Ulrich ; SASSE, Andreas ; HECKER, Peter: On the Definition of Lane Accuracy for Vehicle Positioning Systems. In: *Proceedings of 7th Symposium on Intelligent Autonomous Vehicles (IAV 2010)* (2010)

Hall u. Smith 1999

HALL, Mark A. ; SMITH, Lloyd A.: Feature Selection for Machine Learning: Comparing a Correlation-Based Filter Approach to the Wrapper. In: *Proceedings of the Twelfth International Florida Artificial Intelligence Research Society Conference, May 1-5, 1999, Orlando, Florida, USA, 1999*, 235–239

Hanser 2007

GMBH, PMDTechnologies (Hrsg.): *Sichere Objekterkennung mittels PMD-Sensorik*. 2007 (Automotive electronics+systems)

HAVEit-Konsortium 2009

HAVEIT-KONSORTIUM: *Internetpräsenz des durch die EU geförderten Forschungsprojektes HAVEit (Highly Automated VEHicles and intelligent transportation)*. Internetseite, 2009. – Verfügbar unter: <http://www.haveit-eu.org>; letzter Zugriff 03.11.2009.

Haykin 1999

HAYKIN, Simon: *Neural Networks - A Comprehensive Foundation*. Pearson Education Inc., 1999

He u. a. 2005

HE, Xiaofei ; CAI, Deng ; NIYOGLI, Partha: Laplacian Score for Feature Selection. In: *Advances in Neural Information Processing Systems 18*, 2005

Henning 2010

HENNING, Matthias J.: *Preparation for lane change manoeuvres: Behavioural indicators and underlying cognitive processes*, Technischen Universität Chemnitz, Diss., 2010

Hochreiter u. Schmidhuber 1997

HOCHREITER, Sepp ; SCHMIDHUBER, Jürgen: Long Short-Term Memory. In: *Neural Comput.* 9 (1997), November, Nr. 8, 1735–1780. <http://dx.doi.org/10.1162/neco.1997.9.8.1735>. – DOI 10.1162/neco.1997.9.8.1735. – ISSN 0899-7667

Hughes u. Murphy 1992

HUGHES, Kenneth F. ; MURPHY, Robin R.: Ultrasonic robot localization

using Dempster-Shafer theory. In: *Proceedings of SPIE - Neural and Stochastic Methods in Image and Signal Processing 1766* (1992), S. 2–11

INVENT-Konsortium 2002

INVENT-KONSORTIUM: *Internetpräsenz des durch das BMBF geförderte Forschungsprojekts INVENT (INtelligenter VERkehr und Nutzergerechte Technik)*. Internetseite, 2002. – Verfügbar unter: <http://www.invent-online.org>; letzter Zugriff 14.09.2012

Kalanick 2016

KALANICK, Travis: *Uber Newsroom: Rethinking transportation*. Internetseite, 2016. – Verfügbar unter: <https://newsroom.uber.com/rethinking-transportation/> - veröffentlicht am 18.08.2016, letzter Zugriff am 30.12.2016

Kalman 1960

KALMAN, R. E.: A New Approach to Linear Filtering and Prediction Problems. In: *Transactions on the ASME - Journal of Basic Engineering* 82 (Series D) (1960), S. 35–45

Kammel u. a. 2008

KAMMEL, Sören ; LULCHEVA, Irina ; STILLER, Christoph ; WEISER, Andreas: *Logiken und Ihre Anwendbarkeit auf FAS*. August 2008. – Interne unveröffentlichte Studie; Volkswagen AG, Universität Karlsruhe

Kasper 2013

KASPER, Dietmar: *Erkennung von Fahrmanövern mit objektorientierten Bayes-Netzen in Autobahnszenarien*, Eberhard Karls Universität Tübingen, Diss., 2013

Kerber 1992

KERBER, Randy: ChiMerge: discretization of numeric attributes. In: *Proceedings of the tenth national conference on Artificial intelligence (AAAI'92)* (1992), S. 123–128

Kira u. Rendell 1992

KIRA, Kenji ; RENDELL, Larry A.: A Practical Approach to Feature Selection. In: *Proceedings of the 9th International Workshop on Machine Learning*. San Francisco, CA, USA : Morgan Kaufmann Publishers Inc., 1992, 249–256

Kirchner u. a. 2001

KIRCHNER, A. ; WEISSER, H. ; SCHARNHORST, Th. ; STÜKER, D.:

Sensor Fusion - a Research Perspective. In: *Konferenzband: Sicherheit im Automobil (Vehicle Safety)*. München : Verlag Moderne Industrie, März 2001

Klar u. a. 2012

KLAR, Tilman ; SASSE, Andreas ; HECKER, Peter: Model Based Benchmarking of Spatial Data for ADAS Applications. In: *Mobilität und Umwelt, Geoinformatik, 2012 - Berichte aus der Geoinformatik* (2012)

Klee u. Lee 2009

Schutz EP2081052 (July 2009). KLEE, Ulrich ; LEE, Wei-Chia (Erfinder); Robert Bosch GmbH (Anmelder). *Detection device for a vehicle and relevant detection procedure*

Knaup u. Homeier 2010

KNAUP, Jörn ; HOMEIER, Kai: RoadGraph - Graph based environmental modelling and function independent situation analysis for driver assistance systems. In: *Proceedings of 13th Annual Conference on Intelligent Transportation System, Madeira Island, Portugal* (2010), September

Knaup 2012

KNAUP, Jörn C.: *Kooperative Umfeldwahrnehmung für Fahrerassistenzsysteme am Beispiel urbaner Kreuzungsassistenz*, Technische Universität Braunschweig, Diss., 2012

Kononenko 1994

KONONENKO, Igor: Estimating Attributes: Analysis and Extension of RELIEF. In: RAEDT, L.D. (Hrsg.) ; BERGADANO, F. (Hrsg.): *European Conference on Machine Learning*. Catania, Italy : Springer Verlag, New York, 1994, S. 171–182

Korb u. Nicholson 2010

KORB, Kevin B. ; NICHOLSON, Ann E.: *Bayesian Artificial Intelligence, Second Edition*. 2. Boca Raton, FL, USA : CRC Press, Inc., 2010. – ISBN 1439815917, 9781439815915

Kosch u. a. 2012

KOSCH, Timo ; SCHROTH, Christoph ; STRASSBERGER, Markus ; BECHLER, Marc: *Automotive Inter-networking (Intelligent Transport Systems)*. John Wiley & Sons, 2012. – 398 S.

Kruskal u. Wallis 1952

KRUSKAL, William H. ; WALLIS, Allen W.: Use of ranks in one-criterion

variance analysis. In: *Journal of the American statistical Association* 47 (1952), Nr. 260, S. 583–621

Kuge u. a. 2000

KUGE, Nobuyuki ; YAMAMURA, Tomohiro ; SHIMOYAMA, Osamu ; LIU, Andrew: A driver behavior recognition method based on a driver model framework. In: *Proceedings of the 2000 SAE World Congress*. Detroit : Society of Automotive Engineers, Inc., 2000

L3pilot-Konsortium 2017

L3PILOT-KONSORTIUM: *Internetpräsenz des durch die EU geförderten Forschungsprojektes L3pilot*. Internetseite, 2017. – <http://l3pilot.eu>; Zugriff ab September 2017

Lambert 2016

LAMBERT, Fred: *Tesla announces all production cars now have fully self-driving hardware*. Internetseite, 2016. – Verfügbar unter: <https://electrek.co/2016/10/19/tesla-fully-autonomous-self-driving-car/> - veröffentlicht am 19.10.2016, letzter Zugriff am 30.12.2016

Langer 2016

LANGER, Ingmar: *Analyse von Aktivitäten eines Fahrzeugführers zur Verhaltensbeschreibung am Beispiel des Fahrstreifenwechsels*, Technischen Universität Darmstadt, Diss., 2016. http://tuprints.ulb.tu-darmstadt.de/5767/1/Dissertation_IngmarLanger.pdf

Lauritzen u. Spiegelhalter 1988

LAURITZEN, Steffen ; SPIEGELHALTER, David: Local computations with probabilities on graphical structures and their application to expert systems. In: *Journal of the Royal Statistical Society B* 50(2) (1988), S. 157–222

Linzmeier u. Bär 2006

LINZMEIER, Dirk ; BÄR, Tobias: Fusion von Radar- und Thermopilensensoren zur Fußgängerdetektion. (2006), S. 239–250

Liu u. a. 2002

LIU, Huan ; HUSSAIN, Farhad ; TAN, Chew L. ; DASH, Manoranjan: Discretization: An enabling technique. In: *Data mining and knowledge discovery* 6 (2002), 393–423. <https://www1.comp.nus.edu.sg/~tancl/publications/j2001-2/DMKD-Liu-2002.pdf>

Liu u. Motoda 2007

LIU, Huan ; MOTODA, Hiroshi: *Computational Methods of Feature Selection*. Chapman & Hall/CRC, 2007

Liu u. Setiono 1995

LIU, Huan ; SETIONO, Rudy: Chi2: Feature Selection and Discretization of Numeric Attributes. In: *2012 IEEE 24th International Conference on Tools with Artificial Intelligence 0* (1995), 388. <http://doi.ieeecomputersociety.org/10.1109/TAI.1995.479783>

Lüke u. Strauss 2012

LÜKE, Stefan ; STRAUSS, Matthias: Exemplarische Darstellung einer hochautomatisierten Fahrfunktion im Projekt HAVEit. In: *Tagungsband zum 13. Braunschweiger Symposium AAET - Automatisierungssysteme, Assistenzsysteme und eingebettet Systeme für Transportmittel* (2012), S. 234–250

Lloyd 1982

LLOYD, Stuart P.: Least squares quantization in PCM. In: *IEEE Transactions on Information Theory* 28 (1982), S. 129–137

Luger 2001

LUGER, George F.: *Künstliche Intelligenz - Strategien zur Lösung komplexer Probleme*. 4. München : Person Education Deutschland, 2001. – ISBN 3–8273–7002–7

Macht u. a. 2009

MACHT, Sabine ; SASSE, Andreas ; HECKER, Peter ; KAHMANN, Andreas: Verfügbarkeitssicherung und Integrität einer hochgenauen GPS-Phasenlösung zum automatischen Fahren im Rahmen des Projektes Intelligent Car. In: *AAET 2009, Beiträge zum gleichnamigen 10. Braunschweiger Symposium vom 11. bis 12. Februar 2009 im DLR e.V., Braunschweig GZVB, Gesamtzentrum für Verkehr Braunschweig e.V.* (Hrsg.), 2009

Margaritis 2003

MARGARITIS, Dimitris: *Learning Bayesian Network Model Structure from Data*. Pittsburgh, PA 15213, School of Computer Science, Carnegie Mellon University, Diss., 2003

McCall u. a. 2007

MCCALL, Joel C. ; TRIVEDI, Mohan M. ; WIPF, David ; RAO, Bhaskar: Lane Change Intent Analysis Using Robust Operators and Sparse

Bayesian Learning. In: *IEEE Transactions on Intelligent Transportation Systems* Bd. 8, IEEE, 2007, S. 431–440

MDR 2014

MDR: *Auf großer Spur - Bildergalerie*. Internetseite. <http://www.mdr.de/damals/umspurarbeiten-brest100.html>. Version: 12 2014. – Zugriff am 15.12.2014, Bildrechte MDR/Stephan John

Meinecke u. a. 2011

MEINECKE, Marc-Michael ; GALLA, Andreas ; KLEEN, Andro ; OBOJSKI, Andrzej M. ; SCHOLZ, Stephan ; NGUYEN, Nghia T.: Schlussbericht Aktiv-AS der Volkswagen AG zur Forschungsinitiative AKTIV / Volkswagen AG. 2011. – Forschungsbericht

Meyer 2015

MEYER, Britta: *CES 2015: Mit Jack durch Kalifornien*. Audi-Blog, 2015. – Verfügbar unter: <http://blog.audi.de/2015/01/05/mit-jack-durch-kalifornien/>; letzter Zugriff 14.12.2015

Michon 1985

MICHON, John A.: A critical view of driver behavior models: what do we know, what should we do? In: EVANS, Leonard (Hrsg.): *Human behavior and traffic safety*. New York : Plenum Press, 1985, S. 485–520

Mihajlovic u. Petkovic 2001

MIHAJLOVIC, Vojkan ; PETKOVIC, Milan: Dynamic bayesian networks: A state of the art / University of Twente, Centre for Telematics and Information Technology. Version: 2001. <http://doc.utwente.nl/36632/>. 2001. – Forschungsbericht. – DMW-project

Mirwaldt u. a. 2012

MIRWALDT, Peter ; BARTELS, Arne ; TO, Thanh-Binh ; PASCHEKA, Patrick ; LEMMER, Karsten ; HUHLE, Robert ; MALBERG, Hagen ; ZAUNSEDER, Sebastian: Gestaltung eines Notfallassistentensystems bei medizinisch bedingter Fahruntfähigkeit. In: *Beitragsband 5. Tagung Fahrerassistenz* (2012)

Moravec u. Elfes 1984

MORAVEC, Hans P. ; ELFES, Alberto: High Resolution Maps from Wide Angle Sonar / Carnegie-Mellon University, The Robotics Institute. 1984. – Forschungsbericht

Mrad u. a. 2015

MRAD, Ali B. ; DELCROIX, Veronique ; PIECHOWIAK, Sylvain ; LEICESTER, Philip ; ABID, Mohamed: An explication of uncertain evidence in Bayesian networks: likelihood evidence and probabilistic evidence. In: *Applied Intelligence* 43 (2015), 12, S. 802–824. <http://dx.doi.org/10.1007/s10489-015-0678-6>. – DOI 10.1007/s10489-015-0678-6

Murphy 2005

MURPHY, Kevin: *Software Packages for Graphical Models / Bayesian Networks*. Internetseite, 2005. – Verfügbar unter: <http://www.cs.ubc.ca/~murphyk/Bayes/bnsoft.html>; letzter Zugriff 01.04.2011.

Oliver u. Pentland 2000

OLIVER, Nuria ; PENTLAND, Alex P.: Graphical Models for Driver Behavior Recognition in a SmartCar. In: *Intelligent Vehicles 2000*, 2000

Panwai u. Dia 2007

PANWAI, Skada ; DIA, Hussein: Neural agent car-following models. In: *IEEE Transactions On Intelligent Transportation Systems* 8 (2007), Nr. 1, S. 60–70

Pearl 1988

PEARL, Judea: *Probabilistic Reasoning in Intelligent Systems*. Morgan Kaufmann Direct Distribution 27 Palmeira Mansions, 1988. – ISBN 9781558604797

Pellkofer 2003

PELLKOFER, Martin: *Verhaltensentscheidung fuer autonome Fahrzeuge mit Blickrichtungssteuerung*, Universitäts der Bundeswehr, München, Diss., 2003

Peng u. a. 2005

PENG, Hanchuan ; LONG, Fuhui ; DING, Chris: Feature Selection Based on Mutual Information: Criteria of Max-Dependency, Max-Relevance, and Min-Redundancy. In: *IEEE Transactions on Pattern Analysis and Machine Intelligence* 27 (2005), S. 1226–1238

Peng u. a. 2010

PENG, Yun ; ZHANG, Shenyong ; PAN, Rong: Bayesian network reasoning with uncertain evidences. In: *International Journal of Uncertainty, Fuzziness and Knowledge-Based Systems* 18 (2010), Nr. 5, S. 539–564. <http://dx.doi.org/10.1142/S0218488510006696>. – DOI 10.1142/S0218488510006696

Polling u. a. 2005

POLLING, D. ; MULDER, Mark ; PAASSEN, Marinus M. ; CHU, Q. P.: Inferring the driver's lane change intention using context-based dynamic Bayesian networks. In: *Proceedings of IEEE International Conference on Systems, Man and Cybernetics* IEEE, 2005, S. 853–858

Rasmussen 1983

RASMUSSEN, Jens: Skills, rules, and knowledge; signals, signs, and symbols, and other distinctions in human performance models. In: *IEEE Transactions on Systems, Man, and Cybernetics* smc-13 (1983), May, Nr. 3, S. 257–266

Rauscher 2007

RAUSCHER, Hubert: Empirische Untersuchung des Spurwechsels und Ausweichens von einspurigen Fahrzeugen. In: *VKU Verkehrsunfall und Fahrzeugtechnik* Februar 2007 (2007), S. 55–60

Ristic u. a. 2004

RISTIC, Branko ; ARULAMPALAM, Sanjeev ; GORDON, Neil: *Beyond the Kalman Filter: Particle Filters for Tracking Applications*. Artech House, 2004

Rohloff 2002

Norm 202 2002. *Richtlinien für die Anlage von Autobahnen: RAA*

Ross u. Zuviria 2007

ROSS, Brian J. ; ZUVIRIA, Eduardo: Evolving Dynamic Bayesian Networks with Multi-objective Genetic Algorithms. In: *Applied Intelligence* 26 (2007), February, Nr. 1, S. 13–23

Roth u. a. 2011

ROTH, Martin ; RADKE, Tobias ; LEDERER, Matthias ; GAUTERIN, Frank ; FREY, Michael ; STEINBRECHER, Christian: Porsche InnoDrive / Ein innovativer Ansatz für das Fahren von Morgen. In: *Tagungsband: 20. Aachener Kolloquium Fahrzeug- und Motorentchnik 20* (2011)

Runkel 1969

RUNKEL, Martin: *Die Bedeutung der Sichtbehinderung durch Lastkraftwagen für Überholvorgänge auf zweispurigen Landstraßen.*, Technische Hochschule Stuttgart, Diss., 1969

Russell u. a. 2004

RUSSELL, Stuart ; NORVIG, Peter ; CANNY, John F. ; EDWARDS, Douglas D. ; MALIK, Jitendra M. ; THRUN, Sebastian: *Künstliche Intelligenz*

- *Ein moderner Ansatz*. 2. München : Pearson Education Deutschland, 2004. – ISBN 3-8273-7089-2

SAE 2016

SAE International: *SAE J3016: Taxonomy and Definitions for Terms Related to Driving Automation Systems for On-Road Motor Vehicles*. 2016

Salvucci u. Mandalia 2005

SALVUCCI, Dario D. ; MANDALIA, Hiren M.: Using Support Vector Machines for Lane Change Detection. In: *Human Factors and Ergonomics Society Annual Meeting Proceedings*, 2005, S. 1965–1969

Salvucci u. a. 2007

SALVUCCI, Dario D. ; MANDALIA, Hiren M. D. ; KUGE, Nobuyuki ; YAMAMURA, Tomohiro: Lane-Change Detection Using a Computational Driver Model. In: *HUMAN FACTORS* 49 (2007), S. 532–542

Sanfridson u. a. 2011

SANFRIDSON, Martin ; LUNDGREN, Astrid ; JARLENGRIP, Johan ; GRUBB, Grant ; FENG, Lei ; BRUCE, Maria: HAVEit Deliverable D54.3 Active Green Driving: 1st System Functionality / Volvo Technology Corporation AB. Version: 11 2011. http://haveit-eu.org/LH2Uploads/ItemsContent/24/HAVEit_212154_D54.3_Public.pdf. 2011. – Forschungsbericht

Saust u. a. 2010

SAUST, Falko ; WILLE, Joern M. ; MAURER, Markus ; LICHTER, Bernd: Stadtpilot: Driving autonomously on Braunschweig's inner ring road. In: *IEEE Intelligent Vehicles Symposium (IV)*, 2010, S. 169–174

Schmitt u. Färber 2005

SCHMITT, Josef ; FÄRBER, Berthold: Verbesserung von FAS durch Fahrerabsichtserkennung mit Fuzzy Logic. In: *VDI-Berichte* 1919 (2005), S. 177–186

Schroven u. Giebel 2008

SCHROVEN, Frank ; GIEBEL, Tobias: Fahrerintentionserkennung für Fahrerassistenzsysteme. In: *VDI-Berichte, Band 2048: Proceedings der 24. VDI/VW-Gemeinschaftstagung - Integrierte Sicherheit und Fahrerassistenzsysteme*, 2008

Schubert u. Wanielik 2010

SCHUBERT, Robin ; WANIELIK, Gerd: A Unified Bayesian Approach for

Tracking and Situation Assessment. In: *Intelligent Vehicles Symposium* (2010)

Schwarz 1978

SCHWARZ, Gideon: Estimating the Dimensions of a Model. In: *Annals of Statistics* Bd. 6, JSTOR, March 1978, S. 461–464

Seliger 1998

Norm 1998. *Richtlinien für die Markierung von Straßen RMS - Teil 1 Abmessungen und geometrische Anordnung von Markierungszeichen*

Senliol u. a. 2008

SENLIOL, Baris ; GULGEZEN, Gokhan ; YU, Lei ; CATALTEPE, Zehra: Fast Correlation Based Filter (FCBF) with a different search strategy. Version: 2008. http://web.itu.edu.tr/~cataltepe/pdf/2008_ISCIS_BarisFeatSelect.pdf. In: *Computer and Information Sciences, 2008. ISCIS'08. 23rd International Symposium on.* 2008

Shafer 1976

SHAFER, Glenn: *A mathematical theory of evidence*. Princeton University Press, 1976

Shannon 1948

SHANNON, Claude E.: A Mathematical Theory of Communication. In: *The Bell System Technical Journal* 27 (1948), 10, 379-423, 623-656. <http://cm.bell-labs.com/cm/ms/what/shannonday/shannon1948.pdf>

Shevade u. Keerthi 2003

SHEVADE, S. K. ; KEERTHI, S. S.: A simple and efficient algorithm for gene selection using sparse logistic regression. In: *BIOINFORMATICS* 19 (2003), Nr. 17, 2246–2253. <http://bioinformatics.oxfordjournals.org/content/19/17/2246.full.pdf>

Sparmann 1978

SPARMANN, Udo: *Spurwechselvorgaenge auf zweispurigen BAB-Richtungsfahrbahnen*, Universität (TH) Karlsruhe, Diss., 1978

Spindler 1963

SPINDLER, Walter: *Wege, Querbeschleunigungen und die Wahl der Überholwege bei der Kurvenfahrt von Kraftfahrzeugen*, TU-München, Diss., 1963

Spirtes u. a. 1993

SPIRTEs, Peter ; GLYMOUR, Clark ; SCHEINES, Richard: *Causation, Prediction and Search*. Springer-Verlag Berlin and Heidelberg GmbH & Co., 1993 <https://www.cs.cmu.edu/afs/cs.cmu.edu/project/learn-43/lib/photoz/.g/scottd/fullbook.pdf>

Sporrer u. a. 1998

SPORRER, A. ; PRELL, G. ; BUCK, J. ; SCHAIBLE, S.: Realsimulation von Spurwechselvorgängen im Straßenverkehr. Version: 1998. <http://unfallanalytik.de>. Karl-Mangold Str. 17, 81245 München : Ingenieurbüro Nickl, 1998. – Forschungsbericht. – Internetzugriff am 14.10.2009

Stanczyk u. Jain 2015

STANCZYK, Urszula (Hrsg.) ; JAIN, Lakhmi C. (Hrsg.): *Studies in Computational Intelligence*. Bd. 584: *Feature Selection for Data and Pattern Recognition*. Springer Verlag Berlin Heidelberg, 2015

Steinhaus 1957

STEINHAUS, Hugo: Sur la division des corps matériels en parties. In: *Bulletin de l'Académie Polonaise des Sciences, Classe 3*. (1957), S. 801–804

Steinmeyer 2009

STEINMEYER, Simon: Handling Contradictory Sensor Data In Environment Maps For Advanced Driver Assistance Systems. In: *Informatik 2009 im Focus Leben: Jahrestagung Lübeck*, 2009, S. 301

Steinmeyer u. a. 2010

STEINMEYER, Simon ; BARTELS, Arne ; MUSIAL, Marek ; SCHULTZE, Karsten ; TO, Thanh-Binh ; WEISER, Andreas: Modulare Sensordatenfusions-Architektur am Beispiel des Temporary Auto Pilot. In: *AAET 2010, Beiträge zum gleichnamigen 11. Braunschweiger Symposium vom 10. bis 11. Februar 2010 im DLR e.V., Braunschweig* (2010), S. 89–104

Stüker 2004

STÜKER, Dirk: *Heterogene Sensordatenfusion zur robusten Objektverfolgung im automobilen Straßenverkehr*, Carl von Ossietzky-Universität Oldenburg, Diss., September 2004

Student 1908

STUDENT: The probable error of mean. In: *Biometrika* 6 (1908), S. 1–25

Sucar 2015

SUCAR, Luis E.: *Probabilistic Graphical Models - Principles and Applications*. Springer, 2015. <http://dx.doi.org/10.1007/978-1-4471-6699-3>. <http://dx.doi.org/10.1007/978-1-4471-6699-3>. – ISBN 978-1-4471-6698-6

Tenzer 2004

TENZER, Axel: Integrierte Sicherheit und Fahrerassistenzsysteme. In: *21. Internationale VDI/VW-Gemeinschaftstagung, Wolfsburg, 2004*

Tezuka u. a. 2006

TEZUKA, Shigeki ; SOMA, Hitoshi ; TANIFUJ, Katsuya: A Study of Driver Behavior Inference Model at Time of Lane Change using Bayesian Networks. In: *In Proceedings of the 2006 IEEE Conference on Industrial Technologic*. Mumbai : IEEE, 2006, S. 2308–2313

Thomas 2003

THOMAS, Wolfgang: *Applied Automata Theory*. Aachen : lecture notes, 2003

Thrun u. a. 2005

THRUN, Sebastian ; BURGARD, Wolfram ; FOX, Dieter: *Probabilistic Robotics*. The MIT Press, 2005. – ISBN 0262201623

Thrun u. Urmson 2011

THRUN, Sebastian ; URMSON, Chris: Self-driving cars. In: *IEEE/RSJ Conference on Intelligent Robots and Systems (IROS)*, 2011

To u. Bartels 2010

TO, Than B. ; BARTELS, Arne: Deliverable D53.3 Temporary Auto Pilot: 1st System Functionality / Volkswagen AG. Version:12 2010. http://www.haveit-eu.org/LH2Uploads/ItemsContent/24/HAVEit_212154_D53.3_Public.pdf. 2010. – Forschungsbericht

To u. a. 2008

TO, Thanh B. ; MEINECKE, Marc-Michael ; SCHROVEN, Frank ; NEDEVSCHI, Sergiu ; KNAUP, Jörn C.: CityACC - On the way towards an intelligent autonomous driving. In: *ifac 2008* (2008)

Trabelsi 2005

TRABELSI, Ahmed: *Automotive Reibwertprognose zwischen Reifen und Fahrbahn*, Technische Universität Hannover, Diss., 2005

Treiber u. Helbing 2002

TREIBER, Martin ; HELBING, Dirk: Realistische Mikrosimulation von Straßenverkehr mit einem einfachen Modell. (2002), S. 514–520

Tucker u. a. 2001

TUCKER, Allan ; LIU, Xiaohui ; OGDEN-SWIFT, Andrew: Evolutionary Learning of Dynamic Probabilistic Models with Large Time Lags. In: *International Journal of Intelligent Systems* 16 (2001), Nr. 5, S. 621–645

Ulmer 1994

ULMER, B.: Autonomous Automated Driving in Real Traffic. In: *Proceedings of the first world congress on applications of transport telematics and intelligent vehicle-highway systems* 1 (1994), S. 2118–25

UN/ECE 2006

UN/ECE: *ECE-Regelung 79 - Lenkanlagen*. 2. Geneva, Switzerland: UN-Wirtschaftskommission für Europa, Januar 2006. <http://www.bmvbs.de/cae/servlet/contentblob/44484/publicationFile/11168/r-79-lenkanlagen-pdf.pdf>

Valtorta u. a. 2002

VALTORTA, Marco ; KIM, Young-Gyun ; VOMLEL, Jiri: Soft evidential update for probabilistic multiagent systems. In: *International Journal of Approximate Reasoning* 29 (2002), S. 71–106. [http://dx.doi.org/10.1016/S0888-613X\(01\)00056-1](http://dx.doi.org/10.1016/S0888-613X(01)00056-1). – DOI 10.1016/S0888-613X(01)00056-1

VDA 2013

Verband der Automobilindustrie: *VDA-Position Automatisiertes Fahren*. 2013

VW-AG 2017

VW-AG: *VW Golf: Stauassistent und Emergency Assist*. Internetseite, 2017. – Verfügbar unter: <https://www.volkswagen.at/golf/golf/stauassistent>, Zugriff am 28.04.2017

Wei 1981

WEI, L. J.: Asymptotic Conservativeness and Efficiency of Kruskal-Wallis Test for K Dependent Samples. In: *Journal of the American Statistical Association* 76 (1981), Nr. 376, S. 1006–1009

Weiser 2010

WEISER, Andreas: A probabilistic lane change prediction module for

highly automated driving. In: *Proceedings on 7th International Workshop on Intelligent Transportation (WIT 2010)* Hamburg University of Technology, Institute of Telecommunications, Hermann Rohling, 2010, S. 155–160

Weiser u. a. 2009

WEISER, Andreas ; BARTELS, Arne ; STEINMEYER, Simon ; SCHULTZE, Karsten ; MUSIAL, Marek ; WEISS, Kristian: Intelligent Car - Teilautomatisches Fahren auf der Autobahn. In: *AAET 2009, Beiträge zum gleichnamigen 10. Braunschweiger Symposium vom 11. bis 12. Februar 2009 im DLR e.V., Braunschweig* GZVB, Gesamtzentrum für Verkehr Braunschweig e.V. (Hrsg.), 2009, S. 11–26

Weiser u. a. 2012

WEISER, Andreas ; DORNIEDEN, Bernd ; SCHAPER, Thilo ; JUNGE, Lutz ; PETERS, Ronald: FAMOS - Galileo for Future Automotive Systems, öffentlicher Abschlussbericht zum Forschungsprojekt, Teilvorhaben Volkswagen AG / Volkswagen AG. Version: 2012. <http://famos-project.eu/>. 2012. – Forschungsbericht

Weiser u. To 2009

Schutz DE 10 2009 060 600.9 (2009). WEISER, Andreas ; TO, Binh T. (Erfinder); Volkswagen AG (Anmelder). *Verfahren zur Zuordnung von Fahrstreifen zu einem Fahrzeug*

Weiser u. Weiss 2009

Schutz DE 102009007395 B4 (2009). WEISER, Andreas ; WEISS, Kristian (Erfinder); Volkswagen AG (Anmelder). *Verfahren zur kartenbasierten Umfelddarstellung eines Fahrzeugs*

Weiser u. a. 2008

WEISER, Andreas ; WEISS, Kristian ; STÜKER, Dirk: Kartenbasierte Umfeldwahrnehmung unter Nutzung der Evidenztheorie. In: *5. Workshop Fahrerassistenzsysteme* Bd. 5. Walting im Altmühltal : Markus Maurer and Christoph Stiller, 2008, S. 20–29

Weiss u. Dietmayer 2008

WEISS, Thorsten ; DIETMAYER, Klaus: Positionierung eines Fahrzeugs in unbekanntem Gebieten mit Hilfe von Laserscannern. In: *at - Automatisierungstechnik* 56 (2008), Nr. 11, S. 554–562

Winner u. a. 2012

WINNER, Hermann (Hrsg.) ; HAKULI, Stephan (Hrsg.) ; WOLF, Gabriele

(Hrsg.): *Handbuch Fahrerassistenzsysteme*. Bd. 2. Vieweg+Teubner Verlag / GWV Fachverlage GmbH, Wiesbaden, 2012

Xiao u. a. 2009

XIAO, Xu H. ; LE, Hian B. ; NG, Gee W.: LEARNING BAYESIAN NETWORK PARAMETERS FROM SOFT DATA. In: *International Journal of Uncertainty, Fuzziness and Knowledge-Based Systems* 17 (2009), 281-294. <http://dx.doi.org/10.1142/S0218488509005863>

Yu u. Liu 2003

YU, Lei ; LIU, Huan: Feature selection for high-dimensional data: A fast correlation-based filter solution. In: *Proceedings of the Twentieth International Conference on Machine Learning*, 2003, 856–863

Zadeh 1965

ZADEH, Lotfi A.: Fuzzy Sets. In: *Information and Control* 8 (1965), S. 338–353

Zapp 1988

ZAPP, Alfred: *Automatische Straßenfahrzeugführung durch Rechnersehen*, Universität der Bundeswehr München, Fakultät für Luft- und Raumfahrttechnik, Diss., 1988

Zavrel 2002

ZAVREL, Martin: Teilautomatisierte Längs- und Querführung im Niedergeschwindigkeitsbereich. In: *Telematik im Kraftfahrzeug*, VDI, 2002

Zeller 1996

ZELLER, Martin: *Planerkennung im Straßenverkehr*, Universität Ulm, Diss., 1996

Zhang u. a. 2004

ZHANG, Nevin L. ; NIELSEN, Thomas D. ; JENSEN, Finn V.: Latent variable discovery in classification models. In: *Artificial Intelligence in Medicine* 30 (2004), Nr. 3, 283-299. <http://www.sciencedirect.com/science/article/pii/S0933365703001350>

Zhang u. a. 2007

ZHANG, Xiao-Hang ; WU, Jun ; LU, Ting j. ; JIANG, Yuan: A discretization algorithm based on Gini criterion. In: *Machine Learning and Cybernetics, 2007 International Conference on* 5 (2007), S. 2557–2561

Zhao u. a. 2015

ZHAO, Zheng ; MORSTATTER, Fred ; SHARMA, Shashvata ; ALELYANI, Salem ; ANAND, Aneeth ; LIU, Huan: Advancing Feature Selection Research - ASU Feature Selection Repository / Arizona State University. Version:2015. http://featureselection.asu.edu/featureselection_techreport.pdf. 2015. – Forschungsbericht. – Zugriff am 12.09.2015

Zheng u. Liu 2007

ZHENG, Zhao ; LIU, Huan: Spectral Feature Selection for Supervised and Unsupervised Learning. In: *Proceedings of the 24th International Conference on Machine Learning*, 2007, 1151-1157

Ziegler 2016

ZIEGLER, Chris: *Google and Fiat Chrysler ink deal to build self-driving Pacifica minivans for testing*. Internetseite, 2016. – Verfügbar unter: <http://www.theverge.com/2016/5/3/11582614/google-fiat-chrysler-self-driving-car-pacifica-minivan> - veröffentlicht am 03.05.2016, letzter Zugriff am 30.12.2016

Ziegler u. a. 2014

ZIEGLER, Julius ; BENDER, Philipp ; SCHREIBER, Markus ; LATEGAHN, Henning ; STRAUSS, Tobias ; STILLER, Christoph ; DANG, Thao ; FRANKKE, Uwe ; APPENRODT, Nils ; KELLER, Christoph G. ; KAUS, Eberhard ; HERRTWICH, Ralf G. ; RABE, C. ; PFEIFFER, D. ; STEIN, F. Lindnerand F. ; ERBS, F. ; ENZWEILER, M. ; KNÖPPEL, C. ; HIPPE, J. ; HAUEIS, M. ; TREPTE, M. ; BRENK, C. ; TAMKE, A. ; BRAUN, M. Ghanaatand M. ; JOOS, A. ; FRITZ, H. ; MOCK, H. ; HEIN, M. ; ZEEB, E.: Making Bertha Drive - An Autonomous Journey on a Historic Route. In: *IEEE Intelligent Transportation Systems Magazine* 6 (2014), Nr. 2, S. 8–20

Betreute Arbeiten

Ghassemi 2015

GHASSEMI, Raziye: *Comparison and Application of Structure Learning Approaches for Bayesian Network to Predict the Lane Change of Vehicles*, Otto von Guericke Universität Magdeburg, Faculty of Computer Science, Institute for Distributed Systems, Department of Embedded Smart System, Bachelorthesis, June 2015

Grewe 2010

GREWE, Carl M.: *Bewertung der Software zur Sensordatenfusion des Temporary Auto-Pilot durch Entwicklung von Algorithmen zur automatischen Generierung von Referenzdaten und Verwendung hochgenauer Referenzsensorik*, Westfälische Wilhelms-Universität Münster, Bachelorthesis, April 2010

Kirschner 2016

KIRSCHNER, Jana: *Modellierung temporaler Abhängigkeiten von Situationsmerkmalen mit einem dynamisch Bayes'schen Netz*, Universität Kassel, Bachelorarbeit, Juli 2016

Klass 2009

KLASS, Alexander: *Modellierung eines Fahrermodells zur Fahrstreifenwechselprädiktion für detektierte Umfeldobjekte*, Universität Paderborn, Masterthesis, Dezember 2009

Kokoulina 2017

KOKOULINA, Ekaterina: *Untersuchung des Einflusses von weicher Evidenz gegenüber harter Evidenz auf die Vorhersagegüte eines Bayes'schen Netzwerkes*, RWTH Aachen, Institut für Kraftfahrzeuge, Bachelorarbeit, März 2017

Liensdorf 2009

LIENSDFORF, Tino: *Entwurf und Implementation einer Ego-Fahrstreifenzuordnung*, Hochschule Harz, Diplomarbeit, 2009

Montemayor Ayala 2011

MONTEMAYOR AYALA, Hector: *Probabilistic Lane Change Prediction in Highway Scenarios*, School of Information Science, Computer and

Electrical Engineering Halmstad University, Masterthesis, September 2011

Vogel 2014

VOGEL, Lars: *Statistische Analyse von Umfelddaten zur Fahrstreifenwechselvorhersage*, Technische Universität Ilmenau, Bachelorarbeit, Mai 2014