

Ramona Behrendt

# Radarsensor für ein Verkehrs- beobachtungssystem



Cuvillier Verlag Göttingen  
Internationaler wissenschaftlicher Fachverlag



## Radarsensor für ein Verkehrsbeobachtungssystem





# Radarsensor für ein Verkehrsbeobachtungssystem

Vom Promotionsausschuss der  
Technischen Universität Hamburg-Harburg  
zur Erlangung des akademischen Grades

Doktor-Ingenieur (Dr.-Ing.)

genehmigte Dissertation

von  
Ramona Behrendt

aus  
Buxtehude

2018



### **Bibliografische Information der Deutschen Nationalbibliothek**

Die Deutsche Nationalbibliothek verzeichnet diese Publikation in der Deutschen Nationalbibliografie; detaillierte bibliografische Daten sind im Internet über <http://dnb.d-nb.de> abrufbar.

1. Aufl. - Göttingen: Cuvillier, 2018

Zugl.: (TU) Hamburg-Harburg, Univ., Diss., 2018

1. Gutachter: Prof. Dr. rer. nat. Dr. h.c. Hermann Rohling

2. Gutachter: Prof. Dr.-Ing. Arne Jacob

Tag der mündlichen Prüfung: 13. Februar 2018

© CUVILLIER VERLAG, Göttingen 2018

Nonnenstieg 8, 37075 Göttingen

Telefon: 0551-54724-0

Telefax: 0551-54724-21

[www.cuvillier.de](http://www.cuvillier.de)

Alle Rechte vorbehalten. Ohne ausdrückliche Genehmigung des Verlages ist es nicht gestattet, das Buch oder Teile daraus auf fotomechanischem Weg (Fotokopie, Mikrokopie) zu vervielfältigen.

1. Auflage, 2018

Gedruckt auf umweltfreundlichem, säurefreiem Papier aus nachhaltiger Forstwirtschaft.

ISBN 978-3-7369-9759-2

eISBN 978-3-7369-8759-3



## Danksagung

Zuallererst möchte ich mich bei dem Betreuer dieser Arbeit Prof. Dr. rer. nat. Dr. h.c. Hermann Rohling bedanken, der es mir ermöglicht hat, mich mit diesem sehr spannenden Thema eingehend zu befassen. Dabei hatte er immer ein offenes Ohr für neue Herausforderungen und war stets bereit spannende Diskussionen zu führen. Gleichzeitig waren sein Interesse, seine Ermutigungen und die motivierenden Ansprachen ein großer Grund für das erfolgreiche Gelingen dieser Arbeit.

Weiterhin möchte ich Prof. Dr.-Ing. Arne Jacob für die Übernahme des Zweitgutachtens und seine offene, fröhliche und konstruktive Art sowie Prof. Dr. rer. nat. Ernst Brinkmeyer für den Vorsitz des Prüfungsausschusses danken.

Zusätzlich möchte ich mich bei meinen Kollegen bedanken, die stets zu mir gehalten haben und bedanke mich, dass mit euch alles stets etwas einfacher war. Besonders bedanken möchte ich mich dabei bei Dipl.-Ing. Marc Behrens, der sich im besonderen Maße Zeit genommen hat, um mit mir viele fachliche Diskussionen zu führen und technische Hintergründe zu erläutern.

Ein großer Dank gilt auch allen meinen Freunden. Hervorheben möchte ich dabei Dr. rer. nat. Stefanie Neske, Dipl.-Ing. Stephan Bechstedt und M.Sc. Nike Walter – ihr seid die Besten. Vielen Dank, dass ihr euch die Zeit genommen und die Mühe gemacht habt, die Arbeit Korrektur zu lesen und konstruktiv mitzuwirken. Zusätzlich möchte ich mich für eure stets motivierende Unterstützung herzlichst bedanken. Ebenfalls gilt



Dank den Auflaufauffülllöffeln sowie den Handballern fürs kontinuierliche Daumendrücken und Ablenken.

Ein Dank gebührt ebenfalls Ulrike und Dipl.-Ing. Bernd Thies für die Aufmunterung und die organisatorische Hilfe, sowie dafür, dass ich mich bei euch immer wie zu Hause fühlen darf. Zusätzlich natürlich dafür, dass ihr Borana und Sona mit mir teilt, denen ich auch für ihre ganz spezielle Art der Ablenkung danken möchte.

Ganz besonders möchte ich mich bei meiner Mutter und Rechtschreibfee Brigitte Behrendt sowie meiner Schwester Bianca Behrendt bedanken, dafür dass ihr immer an mich geglaubt habt und immer da seid, wenn ich euch brauche. Ein großes Dankeschön auch an meinen Vater Dipl.-Ing. Henry Behrendt, der mich schon mit 8 Jahren meinen ersten Schaltschrank verdrahten lassen hat und trotzdem nicht wollte, dass ich Elektrotechniker werde. Ich bin sicher, du wärst sehr stolz auf mich.

Am meisten jedoch möchte ich mich bei meinem Freund Dipl.-Ing. Sascha Thies bedanken, ohne dessen Geduld, ständige Unterstützung und kontinuierliche Aufmunterung diese Arbeit wahrscheinlich nie entstanden wäre. Vielen Dank für deinen Rückhalt, deine Sicherheit, dein Interesse und deine bedingungslose Liebe.

Braunschweig, Februar 2018

Ramona Behrendt

*Was wir im Leben am meisten brauchen, ist ein Mensch,  
der uns zwingt, das zu tun, was wir können.*

– Ralph Waldo Emerson



# Inhaltsverzeichnis

<b>1</b>	<b>Einleitung .....</b>	<b>1</b>
<b>2</b>	<b>Straßenverkehr .....</b>	<b>3</b>
2.1	Infrastruktur.....	3
2.1.1	Straßen .....	4
2.1.2	Kreuzungen.....	4
2.2	Verkehrsteilnehmer .....	5
2.3	Modal Split.....	5
2.4	Fahrzeugklassen.....	6
<b>3</b>	<b>Verkehrsbeobachtung .....</b>	<b>9</b>
3.1	Merkmale.....	10
3.2	Im Straßenverkehr eingesetzte Sensoren.....	11
3.2.1	Induktionsschleifen .....	11
3.2.2	Lasersensoren.....	12
3.2.3	Radarsensoren.....	12
3.2.4	Videokamerasystem .....	13
3.3	Sensoren und zu erfassende Merkmale .....	14
<b>4</b>	<b>Applikationen in der Verkehrsbeobachtung .....</b>	<b>15</b>
4.1	Beobachtung einzelner Fahrzeuge .....	15
4.1.1	Geschwindigkeitskontrollen .....	15
4.1.2	Rotlichtüberwachung .....	16





4.1.3	Sonderspurüberwachung .....	16
4.2	Statistische Erhebungen über eine Allgemeinheit der Fahrzeuge .....	17
4.2.1	Verkehrsflussmessungen.....	18
4.2.2	Kreuzungsüberwachung und -steuerung .....	19
4.3	Sensoren und Applikationen.....	20
<b>5</b>	<b>Radartechnik .....</b>	<b>23</b>
5.1	Radartechnische Messgrößen und Anwendungsprinzip .....	24
5.1.1	Definitionen .....	26
5.1.2	Messung der Entfernung .....	26
5.1.3	Messung der radialen Geschwindigkeit .....	27
5.1.4	Messung des Azimutwinkels .....	31
5.2	Sendesignalformen .....	35
5.2.1	Pulsradar.....	35
5.2.2	Dauerstrichradar.....	38
5.2.3	Linear frequenzmoduliertes Radar.....	39
5.2.4	Frequenzumtastendes Radar .....	44
5.2.5	Linear moduliertes frequenzumtastendes Radar.....	46
5.2.6	Weitere Sendesignalformen.....	48
5.3	Detektion .....	49
5.3.1	CFAR-Detektor .....	54
<b>6</b>	<b>Tracking.....</b>	<b>59</b>
6.1	Bewegungsmodelle.....	62
6.2	Initialisierung.....	65
6.3	Filterung mit Prädiktion und Update .....	67



6.3.1	$\alpha$ - $\beta$ -Filter .....	67
6.3.2	Kalman-Filter .....	70
6.3.3	Extended-Kalman-Filter .....	76
6.3.4	Unscented-Kalman-Filter .....	77
6.4	Assoziation .....	80
6.5	Vergleichende Untersuchung der Kalman-Filter .....	83
<b>7</b>	<b>Tracking anhand von bekannten Umgebungsdaten .....</b>	<b>93</b>
7.1	Vorwissen über den Ausrichtungswinkel.....	94
7.2	Schätzen der Beschleunigung mit Vorwissen .....	106
<b>8</b>	<b>Umgebungsdaten für das Vorwissen .....</b>	<b>117</b>
8.1	Umgebungsraster.....	118
8.2	Erkennung der Fahrspuren .....	121
8.2.1	Spurfindungsalgorithmus .....	121
8.2.2	Spurfindungsverfahren von mehreren Fahrspuren .....	128
8.2.3	Erfassung der Fahrtrichtung .....	129
8.2.4	Kreuzende Fahrspuren .....	130
8.3	Extraktion des Vorwissens aus der gefundenen Fahrspur .....	132
8.4	Integration des Vorwissens in das Tracking.....	134
<b>9</b>	<b>Fazit.....</b>	<b>137</b>
<b>10</b>	<b>Symbole und Abkürzungen.....</b>	<b>139</b>
<b>11</b>	<b>Literaturverzeichnis.....</b>	<b>147</b>





# 1 Einleitung

Der Verkehr auf den Straßen nimmt immer weiter zu. Alleine zwischen 2015 und 2016 wuchs die Anzahl der in Deutschland zugelassenen Kraftfahrzeuge um 1,7 % auf 54,6 Millionen [Sta17]. Neben anderen Ursachen führte diese Entwicklung dazu, dass die Gesamtfahrleistung in Deutschland im genannten Zeitraum um 1,8 % anstieg [Bun16] und die erfassten Stautunden sowie Staukilometer um gut 20 % zugenommen haben [ADA17].

Diese Daten können und müssen durch eine umfangreiche Verkehrsbeobachtung ermittelt werden, denn mit ihnen wird die nötige Basis für weiterführende Forschung im Verkehrsbereich gelegt. Zusätzlich zeigen diese Zahlen, wie wichtig es ist, den Verkehr kontinuierlich zu analysieren, um beispielweise den Bedarf des Straßenausbaus zu ermitteln.

Gleichzeitig zeigt der Anstieg der jährlichen Fahrleistung, dass es immer wichtiger wird, den Straßenverkehr zu beaufsichtigen und direkt steuernden Einfluss auf die Verkehrsströme zu nehmen. So können Verkehrsleitschilder bei dichtem Verkehr schneller eine Umleitung empfehlen und den Verkehrsfluss entsprechend lenken, um weiteren Stau zu vermeiden.

In dieser Arbeit werden aktuelle Möglichkeiten der automatisierten Verkehrsbeobachtung aufgezeigt. Der Straßenverkehr besitzt mehrere Merkmale, die mit einer solchen erfasst werden können und die für viele Applikationen zur Verfügung stehen müssen.



Eine von diesen Applikationen ist die Steuerung einer Lichtsignalanlage, so dass möglichst viele Fahrzeuge eine Kreuzung in möglichst kurzer Zeit passieren können und dementsprechend auch weniger Fahrzeuge warten müssen. Hier kann der Verkehrsfluss durch die Beobachtung des Verkehrs mit entsprechender Einflussnahme deutlich verbessert werden.

Die Radartechnik ist im Vergleich zu anderen Messsystemen sehr gut geeignet, um in einer Verkehrsbeobachtung benutzt zu werden. Ein Radarsensor misst zuverlässig und genau die Entfernung  $r$ , den azimutalen Winkel  $\varphi$  und die radiale Geschwindigkeit  $v_r$  von Zielen. Eine zusätzliche Stärke ist seine Allwetterfähigkeit. Viele andere Systeme haben Schwierigkeiten, bei Dunkelheit, Nebel, Regen oder Schnee weiterhin verlässliche Daten zu liefern und die Verkehrsbeobachtung und -steuerung auch unter solchen Bedingungen zu gewährleisten. Ein Radarsensor hingegen wird von den äußeren Wettereinflüssen nur geringfügig beeinflusst.

Da jedoch die Kreuzungen vor allem in großen Städten immer komplexer werden, ist es für den Trackingalgorithmus im Radarsensor auch bei guten Bedingungen eine Herausforderung, sämtliche Fahrzeuge in Kreuzungssituationen richtig zu verfolgen. Dies gilt insbesondere in Straßensituationen mit engen Kurvenbahnen.

Der Radarsensor selbst gewinnt, während er den Verkehr auf einer Kreuzung beobachtet, laufend Daten über die Position und die Geschwindigkeit der vorbeifahrenden Fahrzeuge. Damit ist es möglich, Informationen über die Lage und Ausrichtung der Fahrspuren im Sichtbereich des Radarsensors zu gewinnen. Es wird dargestellt, wie diese Informationen über die Fahrspuren gewonnen werden, und untersucht, wie sehr das Tracking davon profitieren kann. Mit der Annahme, dass weitere Fahrzeuge denselben Fahrspuren folgen, kann das Tracking verbessert werden, so dass Radarobjekte auch in Kurvenfahrten besser verfolgt werden können.

Dieses ist hilfreich, um sämtliche Fahrzeuge in unterschiedlichen Verkehrssituationen mit dem Radarsensor zu erkennen und zu verfolgen. Durch diese Technik der Verkehrsbeobachtung sollen potentielle Stausituationen im Voraus erkannt und durch entsprechende Verkehrsleitetechniken vermieden werden, um den Fahrzeugdurchsatz auf der Straße zu erhöhen.



## 2 Straßenverkehr

Laut Duden ist Verkehr die "Beförderung, Bewegung von Fahrzeugen, Personen, Gütern, Nachrichten auf dafür vorgesehenen Wegen". Dabei gibt es verschiedene Arten von Verkehr, wie den Schiffs-, Flug- und Straßenverkehr, wobei in dieser Arbeit nur auf den Straßenverkehr eingegangen werden soll. Die vorgesehenen Wege sind hierbei die Straßen, auf denen Fahrzeuge bewegt und Personen und Güter befördert werden.

### 2.1 Infrastruktur

Die im Straßenverkehr benutzte Infrastruktur umfasst die Verkehrswege, wie Straßen, Fahrradwege und Bürgersteige, sowie alle dazugehörigen Aufbauten. Eine Straße ist zunächst ein befestigter Verkehrsweg, welcher Fahrzeugen und Fußgängern zur Fortbewegung dient. Sie ist ein Teil des Verkehrsnetzes, welches durch Kreuzungen, Kreiseln, Übergänge, Tunnel und Brücken ergänzt wird. Zusätzlich gehören Verkehrszeichen, Leitplanken sowie Lichtsignalanlagen, die zur Regelung und Lenkung des Verkehrsflusses dienen, zur Infrastruktur des Straßenverkehrs. Darin eingeschlossen sind alle Arten von Masten, die zur Anbringung von Signalen oder Schildern dienen.



### 2.1.1 Straßen

Das Straßennetz für den überörtlichen Verkehr besteht in Deutschland aus Autobahnen, Bundes-, Land-, Kreis- und Gemeindestraßen. Diese haben, Stand 2013, insgesamt eine Länge von ca. 23.4 Tsd. km [Bun15]. Die meist befahrenen Straßen im deutschen Raum sind die Autobahnen, welche im Normalfall zwischen zwei und vier Fahrspuren zusätzlich zu einem Standstreifen je Richtung haben. Den Autobahnen folgen die Bundesstraßen, welche ebenso dem überregionalen Verkehr dienen und dabei maximal 3-spurig sind, dabei jedoch meist nur eine Fahrspur je Richtung besitzen. Die etwas weniger ausgebauten Landesstraßen überbrücken mehrere Landkreise, während die kleineren Kreisstraßen Orte innerhalb eines Landkreises miteinander verbinden. Der Großteil des Straßennetzes, gemessen an der gesamten Straßenlänge, indessen besteht aus Gemeindestraßen.

### 2.1.2 Kreuzungen

Der verkehrstechnische Begriff für die umgangssprachliche Kreuzung ist Knotenpunkt. Ein solcher befindet sich dort, wo sich Verkehrswege gleicher Bauart kreuzen. Kreuzungen sind die Knotenpunkte des Verkehrsnetzes, während die Straßen die Verbindungselemente sind. Je nachdem wie hoch das Verkehrsaufkommen an einer Kreuzung ist, muss an dieser Stelle der Verkehr geregelt werden. Wenn nur wenig Verkehr vorhanden ist, wird die Regelung durch Verkehrsschilder und/oder Verkehrsregeln, wie "rechts vor links", vorgenommen. Wenn die Kreuzung größer ist und ein entsprechend hohes Verkehrsaufkommen besitzt oder keine eindeutige Vorzugsrichtung hat, werden häufig Lichtsignalanlagen zur Regelung eingesetzt, welche umgangssprachlich als Ampeln bezeichnet werden. Je besser die Regelung der Lichtsignalanlage auf die äußeren Verkehrsbedingungen abgestimmt ist, desto besser ist der Verkehrsfluss.



## 2.2 Verkehrsteilnehmer

Als Verkehrsteilnehmer wird jede Person bezeichnet, die aktiv am Straßenverkehr teilnimmt. Unterschieden werden die Verkehrsteilnehmer hauptsächlich in Fußgänger und Fahrzeugführer. Fußgänger sind Personen, die am Verkehr teilnehmen und dabei keine Verkehrsmittel benutzen, während als Fahrzeugführer solche Personen gelten, die ein Verkehrsmittel zur Fortbewegung nutzen. Dazu gehören sowohl Fahrradfahrer als auch Fahrer von Kraftfahrzeugen jeglicher Art.

## 2.3 Modal Split

Ein Modal Split zeigt die Verteilung des Verkehrs auf verschiedene Verkehrsmittel. Er wird im Normalfall für den Personentransport und den Gütertransport getrennt berechnet.

Für den Personentransport zeigt der Modal Split die Verkehrsmittelwahl von Verkehrsteilnehmern, also die Verteilung von Personen auf die verschiedenen Verkehrsmittel. Diese hängt von den Gegebenheiten der Umgebung ab. So werden beispielsweise in Großstädten mehr Strecken mit dem öffentlichen Personennahverkehr zurückgelegt als auf dem Land und dort, wo die Infrastruktur Rücksicht auf Fahrradfahrer nimmt, steigt deren Anzahl. Zusätzlich ist die Verteilung natürlich auch jahreszeitenabhängig, da zum Beispiel im Sommer mehr Motorräder unterwegs sind. Dennoch gibt der Modal Split eine gute Übersicht, welche Verkehrsmittel wie häufig genutzt werden.

Innerhalb der EU legte im Jahr 2012 im Durchschnitt jede Person mit motorisierten Fahrzeugen 12 652 km zurück [Eur14]. Mit ca. 82 % davon entfällt der Großteil der Personenbeförderung auf verschiedene Straßenfahrzeuge, wie Kraftfahrzeuge, Motorräder und Busse.

Der Modal Split im Gütertransport zeigt auf, wie die Güter anhand ihrer Masse auf verschiedene Transportmöglichkeiten verteilt werden. Dabei wurden 2012 innerhalb der EU die geleisteten Tonnenkilometer auf 3 768 Mio. tkm geschätzt [Eur14]. Hiervon





entfielen ca. 45 % auf den Straßenverkehr, der dicht gefolgt vom Schiffsverkehr den größten Anteil am Gütertransport innerhalb der EU hat.

Dadurch, dass sowohl im Personen- als auch im Gütertransport der größte Anteil der Transportleistung auf den Straßenverkehr entfällt, wird eine Beobachtung des Straßenverkehrs immer dringender notwendig, um Kapazitätsengpässe rechtzeitig zu erfassen und beheben zu können.

## 2.4 Fahrzeugklassen


Sowohl im Güter- als auch im Personentransport wird der größte Anteil auf der Straße transportiert, wofür verschiedenste Fahrzeuge genutzt werden. In manuellen Zählungen können durch das menschliche Sehen eine sehr große Zahl verschiedener Fahrzeugklassen unterschieden werden. Um diese Fahrzeuge automatisch unterscheiden zu können, werden sie in verschiedene Klassen aufgeteilt. Nach [FN12] lassen die Klassifizierungsgruppen, in denen die Kraftfahrzeuge (Kfz) jeweils in fünf bzw. acht verschiedene Fahrzeugklassen getrennt werden, eine sehr detaillierte Unterscheidung der einzelnen Fahrzeuge zu. Die Einteilung dieser Klassen wird in Tabelle 1 gezeigt. Dieser Detailgrad wird mittels automatischer Unterscheidung nur von speziellen Messsystemen erreicht.

Klassifizierungsgruppen			
1	2	5+1	8+1
Kfz	Pkw-ähnlich	Nicht klassifizierbare Kfz	Nicht klassifizierbare Kfz
		Pkw-Gruppe	Motorrad
			Pkw
	Transporter		
	Lkw-ähnlich	Pkw mit Anhänger	Pkw mit Anhänger
		Lkw > 3,5t ohne Anhänger	Lkw > 3,5t ohne Anhänger
		Lkw > 3,5t mit Anhänger/Sattelzug	Lkw > 3,5t mit Anhänger
			Sattelzug
Bus	Bus		

**Tabelle 1: Fahrzeugartenerfassung an Zählstellen nach Gerätetyp aus [FN12]**



Die detaillierte Verteilung der Fahrzeugtypen an verschiedenen Orten in Deutschland lässt sich aus [FN12] entnehmen. Abbildung 1 zeigt die Verteilung des Verkehrs auf die verschiedenen Fahrzeugtypen an der A2 bei der Abfahrt Braunschweig-Flughafen, Stand 2012.




**Abbildung 1:** Verteilung des Verkehrs in verschiedene Fahrzeugtypen, gemessen auf der A2 an der Abfahrt Braunschweig-Flughafen im Jahr 2012 [FN12]



### 3 Verkehrsbeobachtung

In der automatischen Verkehrsbeobachtung werden Messungen durch verschiedene, wie in Abbildung 2 dargestellte Messsysteme durchgeführt, um verschiedenste Merkmale des Straßenverkehrs zu erfassen. Diese Merkmale liefern Informationen für weitergehende Anwendungen und Applikationen, welche im Straßenverkehr von Nutzen sein können.



**Abbildung 2:** Unter Verkehrsbeobachtung stehende Kreuzung mit in Rot dargestellten Induktionsschleifen und einem neben der Straße angebrachten Messsystem



### 3.1 Merkmale

Um eine Aussage über den Zustand des allgemeinen Verkehrs oder einzelner Verkehrsteilnehmer treffen zu können, werden bei einer Verkehrsbeobachtung verschiedene Merkmale des Verkehrs erfasst.

Das grundsätzliche Merkmal für die Verkehrsbeobachtung ist die **Fahrzeugpräsenz**. Hierbei wird detektiert, ob sich an der beobachteten Stelle ein Fahrzeug befindet. Es gibt dabei Unterschiede, ob diese Präsenz bei bewegten oder stationären Fahrzeugen festgestellt werden soll. Erst wenn die Anwesenheit eines Fahrzeugs detektiert wird, können daraus weitere Merkmale abgeleitet werden.

Eines der am häufigsten genutzten Merkmale ist die **Anzahl der Fahrzeuge**, die eine bestimmte Stelle passieren. Sie wird bei vielen Verkehrszählungen bestimmt und gibt Aufschluss darüber, wie stark eine Straße belastet wird. Die Anzahl pro Zeiteinheit definiert die Verkehrsstärke, d. h. wie viele Fahrzeuge in einer bestimmten Zeit an der beobachteten Stelle vorbeifahren. Die Verkehrsdichte ergibt sich dahingegen aus der Anzahl der Fahrzeuge auf einer bestimmten Strecke [SL11]. So ist bei Stau auf einer Autobahn die Verkehrsdichte sehr hoch, aber die Verkehrsstärke sehr niedrig. Demnach kann hiermit der momentane Verkehrszustand bestimmt werden.

Daneben sind die **Position** und die **Geschwindigkeit** einzelner Fahrzeuge sowie des gesamten Verkehrs von Interesse. Die Position dient dazu, festzustellen, wo Fahrzeuge passieren, so dass beispielsweise eine Spurbelegung oder das Verhalten des Fahrzeugstroms in einer Baustelle erkannt werden kann. Die Geschwindigkeit gibt Aufschluss über die Verkehrsstärke sowie über die Verhaltensweise einzelner Verkehrsteilnehmer.

Zusätzlich ist die Art des Fahrzeuges, welches eine Beobachtungsstelle passiert, die sogenannte **Fahrzeugklasse**, von Interesse. Das Einordnen der Fahrzeuge in die in Abschnitt 2.4 dargestellten Klassen wird daher als Klassifikation bezeichnet.



## 3.2 Im Straßenverkehr eingesetzte Sensoren

Es existieren viele unterschiedliche Sensorsysteme, die alle ihre Vor- und Nachteile haben, um die zuvor beschriebenen Merkmale des Straßenverkehrs zu ermitteln. Welches System für welche Anwendungen einsetzbar ist, wird auf Grund der Leistungsfähigkeit und der Systemkosten abgewogen. Ebenso spielen der Einsatzort und die Dauer der Anwendung eine wichtige Rolle. Im Folgenden sollen zusammenfassend verschiedene Messsysteme mit ihren Vor- und Nachteilen aufgezeigt werden. Siehe [For10], wo diese detailliert aufgeführt und erklärt werden.

### 3.2.1 Induktionsschleifen

Für dauerhafte Anwendungen werden Induktionsschleifen in der Fahrbahnoberfläche verlegt. Eine Schleife besteht dabei aus drei bis vier Windungen eines Kupferdrahtes, so dass sie als Spule gemeinsam mit einem Kondensator einen Schwingkreis mit einer festen Resonanzfrequenz bildet. Wenn sich ein Fahrzeug über der Induktionsschleife befindet, verändert sich durch das Metall die Induktivität der Spule und dementsprechend die Resonanzfrequenz des Schwingkreises. Dieses kann detektiert werden und führt so zu einer Erkennung der Fahrzeugüberfahrt oder -präsenz. Mit einer Schleife pro Fahrspur können so die Fahrzeugpräsenz sowie die Geschwindigkeit und eine grobe Klassifikation des Fahrzeugtyps erfasst werden. Hierbei wird ausgenutzt, dass sich die Resonanzfrequenz ändert, je mehr von der Fläche des Fahrzeugs sich über der Schleife befindet. Das Maximum der Änderung ist dann erreicht, wenn das Fahrzeug die Schleife komplett bedeckt. Durch die Zeit, die vom Beginn der Überdeckung bis zum Erreichen dieses Maximums gebraucht wird, kann eine ungefähre Geschwindigkeit errechnet werden. Mit dieser kann darauffolgend durch die Belegungszeit der Schleife eine ungefähre Länge des Fahrzeugs ermittelt werden. Mit zwei Schleifen hintereinander wird die Genauigkeit der Geschwindigkeitserfassung und der Klassifikation stark erhöht. Bei der Geschwindigkeitsmessung muss hierbei nur noch die Zeit ermittelt werden, die zwischen dem Erreichen der beiden Schleifen liegt. Eine Klassifikation mittels zwei Induktionsschleifen kann einen sehr hohen Unterscheidungsgrad zwischen den Fahrzeugklassen und eine hohe Genauigkeit erreichen.



Hierbei werden Änderungsprofile der Induktivität der Schleifen bei der Überfahrt aufgezeichnet, die von Fahrzeugtyp zu Fahrzeugtyp unterschiedlich sind.

### 3.2.2 Lasersensoren

Ein Lasersensor wird meist neben der Fahrbahn installiert und ermittelt Objektentfernungen durch eine Laufzeitmessung. Er sendet einen gebündelten Laserstrahl aus, der von den im Beobachtungsbereich vorhandenen Objekten reflektiert wird. Durch die Laufzeitverschiebung zwischen Sende- und Empfangssignal kann die Entfernung des getroffenen Objektes gemessen werden. Wenn sich ein Fahrzeug in die Detektionszone begibt, werden viele dieser Laufzeitmessungen in einem kurzen Abstand zueinander durchgeführt. Aus der Änderung der Entfernung über die Dauer der Messungen kann anschließend die Geschwindigkeit des Fahrzeugs sehr genau ermittelt werden.

### 3.2.3 Radarsensoren

Ein im Straßenverkehr eingesetzter Radarsensor strahlt ein elektromagnetisches Signal meist mit einer Frequenz von 24 GHz ab. Dieses wird von Fahrzeugen reflektiert und nach der Laufzeit des Signals am Sensor detektiert. Über diese Laufzeit kann anschließend die Distanz zum Objekt bestimmt werden und durch spezielle Verfahren kann damit die Position mittels einer Winkelmessung errechnet werden. Wenn sich das Fahrzeug bewegt, verändert sich die Frequenz des empfangenen Signals und die Fahrzeuggeschwindigkeit kann darüber bestimmt werden. Einfache Sensoren messen nur die Geschwindigkeit, wohingegen gute Sensoren die Position über eine Laufzeitmessung und die Geschwindigkeit von einem oder mehreren Fahrzeugen gleichzeitig bestimmen können. Radarsensoren werden neben oder oberhalb der Fahrbahn an bestehenden Lichtmasten oder Brücken angebracht. Sie ermöglichen den Einsatz bei jeglichen Wetterbedingungen, wie Schnee und Regen sowie Dunkelheit.



### 3.2.4 Videokamerasystem

Die Videodetektion hat anderen Sensoren gegenüber einen großen Vorteil. Durch die aufgenommenen Bilder kann zu jeder Zeit überprüft werden, ob die Daten korrekt ausgewertet wurden oder ob bei der Auswertung Fehler unterlaufen sind. Dieses ist bei anderen Methoden ohne begleitendes Videobild nur sehr schwer, meistens aber gar nicht möglich. Zusätzlich können Kennzeichen direkt aus dem Videobild extrahiert werden. Damit ist jedoch eine wichtige Einschränkung der Videodetektion beschrieben – der Datenschutz. In einem Video werden alle passierenden Fahrzeuge mit ihren Kennzeichen sowie auch Fußgänger erfasst. Daher müssen solche Daten extrem vorsichtig behandelt und extra gesichert gespeichert werden [For10].

Lange Zeit wurden Videodaten hauptsächlich manuell ausgewertet, was einen extrem hohen Personalaufwand zur Folge hatte. Neuerdings existieren automatisierte Verfahren, wie sie beispielsweise in [Dög13] beschrieben werden. Mittels Videodetektion ist es möglich, Fahrzeuge zu erkennen und eine Klassifizierung vorzunehmen. Bei einer manuellen Auswertung kann diese Klassifikation sehr genau und in beliebige Klassen erfolgen, wohingegen mittels automatischer Auswertung meist eine grobe Klassifikation über die Fahrzeuglänge möglich ist. Durch spezielle computergestützte Verfahren kann die Geschwindigkeit der Fahrzeuge ebenfalls grob bestimmt werden. Dabei wird in einer Videosequenz analysiert, wie schnell sich eine Fahrzeugkante, die durch hohen Kontrast einfach zu beobachten ist, durch das Videobild bewegt. Dieses ist jedoch sehr aufwändig und kann oft nicht im Sensor selbst berechnet werden.

Ein weiterer Nachteil ist, dass die Kamera sehr abhängig von den äußeren Umwelteinflüssen ist. Bei ungünstigen Licht- oder Wetterverhältnissen können die Bilder unter Umständen nicht mehr automatisch ausgewertet werden. Schnee und Regen können dabei ebenfalls zu Fehlmessungen führen. Zusätzlich ist Dunkelheit ein Problem, welches nur mit kostenintensiven Infrarotkameras umgangen werden kann, falls Messungen in der Nacht durchgeführt werden sollen.





### 3.3 Sensoren und zu erfassende Merkmale

Die in 3.2 vorgestellten Messverfahren sollen vergleichend untersucht werden. Dabei steht die Erfassung der in Abschnitt 3.1 aufgezeigten Merkmale im Vordergrund. Dieses wird in Tabelle 2 zusammenfassend aufgeführt, wobei ein + andeutet, dass dieses Verfahren einsetzbar ist, ein o spricht für eine Anwendungsmöglichkeit mit gewissen Nachteilen und ein ++ für ein Vorteil von diesem System gegenüber den anderen Systemen. Zusätzlich werden die notwendigen Maßnahmen zum Einsetzen der Methode aufgezeigt.

	Induktionsschleife	Lasersensor	Radarsensor	Videokamera
Fahrzeugpräsenz	+	+	+	+
Fahrzeuganzahl	+	+	+	+
Position	o	+	+	+
Geschwindigkeit	+	+	++	+
Fahrzeugklasse	++	+	+	+
Allwetterfähigkeit	++	o	++	o
Montageart	In der Fahrbahn	Am Mast	Am Mast	Am Mast
Verkehrseingriff bei Montage	nötig	Nicht nötig	Nicht nötig	Nicht nötig

**Tabelle 2: Vergleich der verschiedenen Messverfahren mittels der zu erfassenden Merkmale**

In Tabelle 2 ist zu erkennen, dass alle zuvor kurz beschriebenen Messverfahren geeignet sind, um eine Verkehrsbeobachtung durchzuführen.

Die Einschränkungen bei Anwendung von Induktionsschleifen liegen vor allem in dem begrenzten Beobachtungsbereich. Beim Einsatz von Lasersensoren und Videokameras kann es dahingegen zu Problemen bei extremen Wetterbedingungen oder Dunkelheit kommen.



## 4 Applikationen in der Verkehrsbeobachtung

Durch eine Verkehrsbeobachtung und die Feststellung der verschiedenen Merkmale des Gesamtverkehrs und einzelner Fahrzeuge werden verschiedene Anwendungen möglich. Im Folgenden werden verschiedene Applikationen in der Verkehrsbeobachtung beschrieben sowie die Vor- und Nachteile der eingesetzten Messverfahren analysiert.

### 4.1 Beobachtung einzelner Fahrzeuge

Wenn einzelne Fahrzeuge näher beobachtet werden, geht es im Allgemeinen darum, einen Regelverstoß zu erkennen. Hierbei gibt es verschiedene Applikationen, welche mit den verschiedenen Sensoren abgedeckt werden können.

#### 4.1.1 Geschwindigkeitskontrollen

Bei Geschwindigkeitskontrollen können sämtliche in 3.2 vorgestellten Sensoren benutzt werden, um die Geschwindigkeit eines einzelnen Fahrzeugs zu ermitteln. Für die Auswahl des Sensors kommt es vor allem darauf an, ob zusätzlich noch die Fahrzeugklasse erfasst werden soll. Dieses ist dann wichtig, wenn eine Überwachungs-



anlage für Personen- und Lastkraftwagen gleichzeitig eingesetzt werden soll, während für diese unterschiedliche Höchstgeschwindigkeiten gelten.

Zusätzlich hängt die Systemwahl hauptsächlich von dem Messzeitpunkt, der Messdauer und dem Messort ab. Soll nur eine kurze Spontanüberwachung stattfinden, lohnt es sich im seltensten Fall, Induktionsschleifen in die Fahrbahn zu integrieren, es sein denn, es soll öfter an der gleichen Stelle gemessen werden. Häufig werden dann Verfahren benutzt, die seitlich neben der Fahrbahn in kurzer Zeit auf- und abgebaut werden können, wie Radar- und Lasersensoren oder Videosysteme. Dabei ist normalerweise nur ein Sensor nötig, da ein begrenzter Bereich überwacht wird.

#### 4.1.2 Rotlichtüberwachung

Neben der Geschwindigkeitskontrolle gibt es weitere Überwachungssysteme, wie beispielsweise die Rotlichtüberwachung. Bei der Erfassung von Rotlichtverstößen wird überprüft, ob ein Fahrzeug während einer Rotlichtphase an einer Ampel die Haltelinie überquert. Dieses kann durch eine Präsenzdetektion geschehen, die den Bereich auf der Kreuzung kurz hinter der Haltelinie überwacht. Häufig werden hierfür Induktionsschleifen verwendet, aber auch alle anderen Arten von Sensoren, welche von oben auf die Kreuzung einsehen. Falls ein Fahrzeug beim Überqueren der Haltelinie detektiert wird, werden mittels einer Kamera zwei Beweisbilder in einem Abstand von wenigen Sekunden angefertigt. Damit kann überprüft werden, ob das Fahrzeug wirklich in den Kreuzungsbereich eingefahren ist oder ob es sich nur minimal über die Haltelinie bewegt hat. Für diese Anwendung sind zwei Induktionsschleifen nötig, die jeweils vor und hinter der Haltelinie angebracht sind, oder einer der anderen Sensoren.

#### 4.1.3 Sonderspurüberwachung

Es gibt hin und wieder einige Fahrspuren, die nur von bestimmten Fahrzeugen befahren werden dürfen. Ein relativ bekanntes Beispiel hierfür sind Busspuren. Regelwidrig werden diese von anderen Fahrzeugführern benutzt, um schneller



voranzukommen. Dagegen gibt es Überwachungssysteme, welche diese Fahrzeuge erkennen und zum Beweis ablichten.

Um eine solche Überwachung zu ermöglichen, muss das Messsystem in der Lage sein die Fahrzeuge zu klassifizieren. Im Falle einer Busspur muss zumindest eine Unterscheidung in Leicht- und Schwerverkehr möglich sein, falls in Kauf genommen wird, dass Lastkraftwagen dann nicht detektiert werden würden. Für eine sehr genaue Klassifikation würden sich Induktionsschleifen anbieten, die jedoch zumeist nur einen sehr kleinen Teil der Fahrspur überwachen können. Einen größeren Bereich können Systeme abdecken, die die Fahrspur beobachten können und daher entweder über oder neben der Straße angebracht werden. Dieses ist mit Radar- und Lasersensoren oder Videoüberwachung möglich. Die Anzahl der eingesetzten Sensoren hängt dabei von der Länge der zu überwachenden Fahrspur ab.

## 4.2 Statistische Erhebungen über eine Allgemeinheit der Fahrzeuge

Bei diesen Messungen geht es anders als bei Einzelmessungen nicht darum, Verkehrsverstöße einzelner Verkehrsteilnehmer zu erfassen und zu ahnden, sondern darum, eine Aussage über den allgemeinen Verkehrsfluss zu treffen. Dabei gibt es die verschiedensten Applikationen und Anwendungsgebiete. Häufig werden hierfür stationäre Messgeräte benutzt, welche den Verkehr über einen langen Zeitraum beobachten und die erwünschten Daten generieren können. Diese Sensoren werden meist vor Ort einmal eingerichtet und sammeln dann selbstständig die gewünschten Daten.

Hierbei können verschiedene Daten gewünscht sein. Zum Beispiel kann es interessant sein, herauszufinden, wie viele Fahrzeug welcher Art eine bestimmte Straße zu welcher Zeit passieren. Hieraus können anschließend eine Verkehrsdichte und das Verkehrsaufkommen abgeleitet werden, um Auskunft zu erhalten, wie stark diese Straße von welchen Fahrzeugklassen befahren wird.

Eine Erfassung ist auch im Bereich der dynamischen Lichtsignalanlagen interessant, welche situationsbedingt den Verkehrsfluss leiten können. Wenn festgestellt wird,



dass an einer Einmündung viele Fahrzeuge warten oder sich erst annähern, kann das Lichtsignal an dieser Seite der Kreuzung auf Grün geschaltet werden.

#### 4.2.1 Verkehrsflussmessungen

Um Änderungen in der Verkehrsdichte und der Belastung einzelner Straßen zu erfassen, werden in regelmäßigen Abständen Verkehrszählungen durchgeführt. Diese dienen der Erfassung darüber, wie viele Fahrzeuge welcher Art sich in einem bestimmten Zeitintervall über die zu untersuchende Straße bewegen. Damit kann ermittelt werden, wann die Straße derart belastet ist, dass ein Ausbau oder eine Umleitungsstrecke nötig wird. Häufig wird zusätzlich der Fahrzeugtyp der erfassten Fahrzeuge ausgewertet, um die zusätzliche Belastung durch den Schwerverkehr zu berücksichtigen.

Bei einer dauerhaften Überwachung kann zusätzlich der Verkehrszustand festgestellt werden, also ob der Verkehr fließend ist oder ob Stausituationen vorherrschen.

Diese Zählungen und Verkehrsflussmessungen können manuell durchgeführt werden, erfordern dann jedoch einen hohen Personalaufwand. Da häufig über einen längeren Zeitraum und an vielen verschiedenen Messorten gezählt wird, lohnt es sich deshalb fast immer, eine automatische Auswertung vorzunehmen, welche zur Überprüfung durch aufgenommene Messdaten reproduzierbar ist. Hierfür bieten sich Systeme an, die über oder neben der Fahrbahn angebracht sind. Diese können sowohl für sehr lange Messungen verwendet werden, als auch im Gegensatz zu Sensoren in der Fahrbahn an andere Messstandorte transportiert werden. Von Vorteil ist, wenn mehrere Fahrspuren beobachtet und so alle Fahrzeuge gleichzeitig detektiert werden können, so dass auch auf mehrspurigen Straßen gezählt werden kann, ohne mehrere Sensorsysteme einzusetzen. Dafür kommen hauptsächlich Radar-, Laser- oder Videosysteme in Frage. Falls nur an einer bestimmten Stelle gezählt werden soll, eignen sich Induktionsschleifen gut, da sie zusätzlich eine hervorragende Klassifikation vorweisen.



#### 4.2.2 Kreuzungsüberwachung und -steuerung

Um der immer größer werdenden Verkehrsstärke gerecht zu werden, ist es von Vorteil, wenn der Verkehrsfluss bedarfsgerecht gesteuert werden kann. Viele Lichtsignalanlagen schalten nach festen Zeitintervallen, so dass sich die Dauer der Rot- und Grünphasen pro Richtung nicht ändert. Da aber die Vorzugsrichtungen bereits mit der Tageszeit variieren können, sollten sich die Lichtsignalanlagen vor allem an viel befahrenen Knotenpunkten an die gegebenen Umstände anpassen.

Als Beispiel wäre eine große Kreuzung bei Dunkelheit in der Nacht zu betrachten. Da die Kreuzung am Tag viel befahren wird, sind die Phasen, in denen es grün beziehungsweise rot ist, sehr lang. Kommt nachts ein einzelnes Auto an die Lichtsignalanlage, so muss es unter Umständen sehr lange warten, bis es in seiner Richtung freie Fahrt angezeigt bekommt, obwohl es das einzige Fahrzeug an der Kreuzung ist. Wenn die Anlage allerdings detektieren kann, dass dieses das einzige Fahrzeug an der Kreuzung ist, könnte sie aus dieser Richtung adaptiv eine Grünphase einleiten. Noch effektiver wäre es, wenn das Fahrzeug schon bei Annäherung an die Kreuzung detektiert und dann entsprechend gehandelt würde. Dieses sehr einfache Beispiel soll die Funktionsweise einer solchen Kreuzungsüberwachung darstellen. Wenn es sich um große Verkehrsflüsse handelt, ist das Funktionsprinzip ähnlich: Wenn schon große Verkehrswellen in der Entfernung erkennbar sind, kann die Lichtsignalanlage entsprechend geschaltet werden, so dass die größeren Verkehrswellen Vorzug vor kleineren erhalten, die dann entsprechend warten müssen. Alternativ kann auch überprüft werden, wie viele Fahrzeuge in einer Richtung an der Kreuzung warten und es wird dann ab einer bestimmten Warteschlangenlänge geschaltet, damit die Warteschlange nicht in einen anderen Kreuzungsbereich hineinragt oder Einmündungen verdeckt.

Um die genannten Anwendungen abzudecken, müssen Fahrzeuge schon aus einer großen Entfernung detektiert und dichter an der Kreuzung in bestimmte Spuren eingeordnet werden können, um Links- und Rechtsabbiegerspuren getrennt von der Geradeauspuren verarbeiten zu können.

Es ist möglich, dieses über viele Induktionsschleifen abzudecken, die auf jeder Fahrspur sowohl direkt an der Kreuzung als auch weiter entfernt zur Annäherungsdetektion



ausgelegt werden müssten. Dieses ist jedoch sehr aufwändig, da für jede Induktionsschleife ein Eingriff in den Straßenverkehr in Form einer Baustelle vorgenommen werden muss. Zusätzlich werden sehr viele Schleifen benötigt, da sowohl welche im Nahbereich, als auch im Fernbereich zur Annäherungsdetektion nötig sind.

Eine weitere Möglichkeit ist die Abdeckung mittels Videoüberwachung. Diese hat in größeren Entfernungen ihre Schwächen, da eine hohe Bildauflösung nötig ist, um Objekte in großer Entfernung als solche sicher zu erkennen. Zusätzlich müssen für die Anwendung bei Nacht zusätzliche Maßnahmen ergriffen werden, wie die Installation von Infrarotkameras.

Eine gute Lösung für einen solchen Anwendungsfall, in dem in verschiedenen Entfernungsbereichen agiert werden soll, ist ein Radarsensor. Dieser hat eine sehr große Detektionsreichweite und kann somit heranfahrende Fahrzeuge schon früh erkennen. Zusätzlich ist es mit einer guten Objektverfolgung möglich, die Fahrzeuge in die entsprechenden Fahrspuren einzuordnen und zu erkennen, wo sich die Fahrzeuge an der Kreuzung befinden. Dadurch kann mit einem Radarsensor ein großer Bereich vor einer Kreuzung überwacht werden. Dabei ist zu beachten, dass nur ein Sensor pro Kreuzungsrichtung notwendig ist, nicht jedoch pro Fahrspur oder Entfernungsbereich. Die Sensoren können dabei an den vorhandenen Lichtsignalanlagen montiert werden, so dass keine weitere Infrastruktur nötig ist. Das Detektionssignal kann dabei zusätzlich direkt an die Lichtsignalanlage weitergegeben werden.

### 4.3 Sensoren und Applikationen

Die in 3.2 vorgestellten Messverfahren sollen vergleichend untersucht werden. Dabei steht die Anwendung der in Abschnitt 4.1 und 4.2 beschriebenen Applikationen im Vordergrund, so dass das am besten dazu geeignete Messsystem ausgewählt wird. Dieses wird in Tabelle 3 zusammenfassend aufgeführt, wobei ein + andeutet, dass dieses Verfahren einsetzbar ist, ein o spricht für eine Anwendungsmöglichkeit mit gewissen Nachteilen und ein ++ für ein Vorteil von diesem System gegenüber den anderen Systemen.



	Induktionsschleife	Lasersensor	Radarsensor	Videokamera
Geschwindigkeitskontrolle	+	+	++	0
Rotlichtüberwachung	++	+	+	+
Sonderspurüberwachung	0	+	+	+
Verkehrsflussmessungen	+	+	+	+
Kreuzungsüberwachung	+	+	++	+
Allwetterfähigkeit	++	0	++	0
Nachteile	Lokale Anwendung, Eingriff in den Straßenverkehr	Probleme mit Schnee und Nebel		Datenschutz, Probleme mit Nacht, Schnee und Nebel

**Tabelle 3: Einsatzmöglichkeit von verschiedenen Messverfahren in Verkehrsapplikationen**

Induktionsschleifen werden von weiteren Überlegungen ausgeschlossen, da, wie beschrieben, der Aufbau von Induktionsschleifen immer einen Eingriff in den Straßenverkehr bedeutet und sie örtlich unflexibel sind. Zusätzlich beschränkt sich der Raum, der von den Schleifen beobachtet wird, immer auf einen festen Bereich.

Die Videodetektion hat den Nachteil, dass sehr vorsichtig mit den aufgenommenen Daten umgegangen werden muss, da es sonst zu Problemen mit dem Datenschutz der Verkehrsteilnehmer kommen kann. Weiterhin ist ein zusätzlicher Aufwand im Sinne von Infrarotkameras nötig, damit dieses System rund um die Uhr gute Ergebnisse liefern kann.

Da ein Lasersystem, ähnlich wie die Videobeobachtung, auch Probleme in Nebel- und Schneesituationen haben kann und mehrere Messungen zur Ermittlung der Geschwindigkeit eines Fahrzeugs benötigt, fällt die Wahl für die Verkehrsbeobachtung auf einen Radarsensor. Dieser ist bei allen Wetterbedingungen gut einsetzbar und kann in jeder einzelnen Messung die Geschwindigkeit von mehreren Fahrzeugen ermitteln.

Im folgenden Kapitel werden daher Informationen über die Geschichte und die Funktionsweise eines Radarsensors dargestellt.







## 5 Radartechnik

Bevor die Technik der Radarsensoren betrachtet wird, soll die Geschichte des Radars, die vor mehr als hundert Jahren zu Beginn des 20. Jahrhunderts seinen Anfang nahm, näher betrachtet werden.

Der wichtigste Grundstein für diese Entdeckung wurde bereits in der Mitte des 19. Jahrhunderts von dem schottischen Physiker James Clerk Maxwell gelegt. Dieser veröffentlichte 1865 erstmals die nach ihm benannten Maxwell-Gleichungen [Max65] in ihrer ursprünglichen Form von acht Gleichungen, welche das Verhalten von elektrischen und magnetischen Feldern sowie deren Verknüpfung mit Ladungen und Strömen behandeln. Er sagte mit diesen Gleichungen die Existenz von elektromagnetischen Wellen voraus, die sich im Raum ausbreiten.

Einige Jahre später gelang es Heinrich Hertz 1887, die von Maxwell beschriebenen elektromagnetischen Wellen experimentell nachzuweisen und zu zeigen, dass sich diese mit der Geschwindigkeit des Lichts fortbewegen [Föl97].

Im Jahre 1894 nutzte der Italiener Guglielmo Marconi diese Wellen für Versuche zur drahtlosen Telegraphie und baute im Dezember 1901 die erste transatlantische Funkstrecke [Bel95]. Im Jahr 1909 erhielt er gemeinsam mit Ferdinand Braun für ihre Arbeiten im Bereich der Funktelegraphie den Nobelpreis in Physik.

Noch vor diesem Nobelpreis im Jahr 1904 machte sich Christian Hülsmeier die Eigenschaften der elektromagnetischen Wellen, vor allem die bereits bekannte



Reflexionseigenschaft, zunutze: Er erfand das erste Radar, welches damals den Namen Telemobiloskop trug. Seine Motivation dafür war ein vorhergegangenes Schiffsunglück, bei dem zwei Schiffe miteinander kollidiert sind.

Daraufhin machte er sich auf die Suche nach einer Vorrichtung, um solche Unfälle zu vermeiden. Am 30. April 1904 bekam er sein Patent "Verfahren, um entfernte metallische Gegenstände mittels elektrischer Wellen einem Beobachter zu melden." mit der Nummer 165546 vom Kaiserlichen Patentamt erteilt [Hül04a]. Nur wenige Monate später erweiterte er dieses Patent, so dass nicht nur Gegenstände erkannt wurden, sondern auch deren Entfernung gemessen werden konnte [Hül04b]. Dieses waren die ersten Grundprinzipien des Radars, welche schon damals den Anwendungszweck hatten, die Schifffahrt sicherer zu machen.

Zunächst war das Interesse an der Benutzung dieses Patentbesitzes gering. Erst während des zweiten Weltkrieges wurde das Thema Radar wieder aufgegriffen, so dass fast gleichzeitig eine Entwicklung in England, Frankreich, Deutschland und den USA stattfand [Lud02].

Erst nach 1945 traten wieder zivile Nutzungsmöglichkeiten des Radars in den Vordergrund: Allen voran das Nutzen zum Zweck einer erhöhten Sicherheit in Verkehrssystemen, wofür das Radar schon von Christian Hülsmeier genutzt worden war. Daher werden Radare heutzutage in vielen Anwendungen eingesetzt, wie beispielsweise der Luftraumüberwachung, in der Schifffahrt oder wie hier im Weiteren in der Überwachung und Beobachtung von Verkehrswegen im Straßenverkehr.

## 5.1 Radartechnische Messgrößen und Anwendungsprinzip

Radar steht für "**RA**dio **D**etection **A**nd **R**anging", wobei diese Abkürzung dabei nur eine von drei verschiedene Messgrößen beschreibt, die mit einem Radarsensor erfasst werden können. Dazu gehören die Entfernung  $r$ , die radiale Geschwindigkeit  $v_r$  und der Azimutwinkel  $\varphi$ , auch Horizontalwinkel genannt. Diese Messgrößen werden in Abbildung 3 dargestellt. Die Sichtachse des Sensors entspricht im Folgenden immer der  $x$ -Achse des Koordinatensystems.

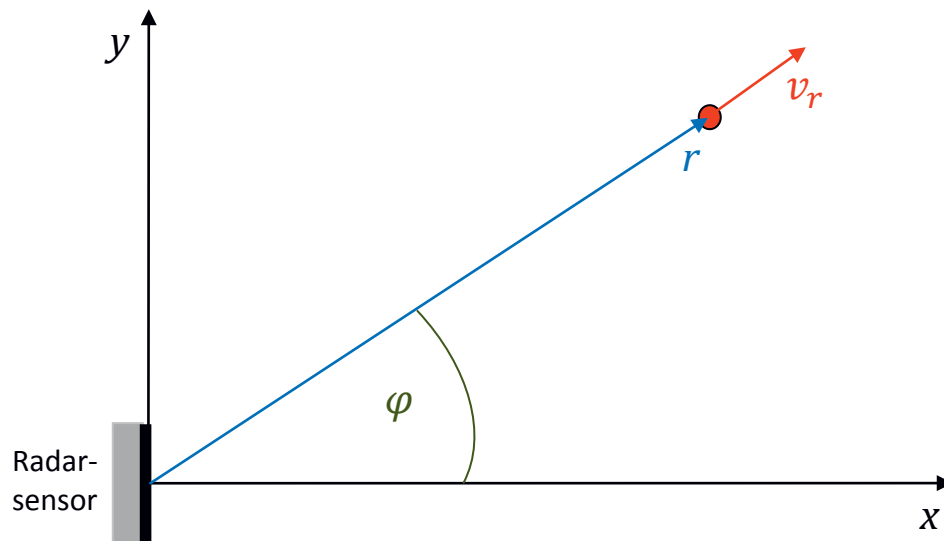


Abbildung 3: Messgrößen der Entfernung  $r$ , der radialen Geschwindigkeit  $v_r$  und des Azimutwinkels  $\varphi$  aus Sicht des Radarsensors

Ein Radarsystem sendet elektromagnetische Wellen und empfängt deren Echosignale, die an Objekten reflektiert werden. Durch Berechnungen kann damit Kenntnis über Position und Geschwindigkeit des reflektierenden Objektes gewonnen werden.

In dieser Arbeit wird ein monostatisches Primärradar betrachtet [Göb00], in dem Sender und Empfänger in einem System integriert sind. Das Radar sendet eine elektromagnetische Welle über eine Antenne aus und diese Sendesignale werden von im Beobachtungsbereich positionierten Objekten reflektiert. Durch diese Reflektion fällt ein Teil der ausgesendeten Signalleistung wieder zurück zum Radarsensor und wird im Empfänger aufgenommen. Aus dieser reflektierten und im Radarsystem empfangenen Welle können anschließend je nach Sendesignalform die radartechnischen Messgrößen der Entfernung  $r$ , des Azimutwinkels  $\varphi$  und der radialen Geschwindigkeit  $v_r$  eines Objektes gewonnen werden.



### 5.1.1 Definitionen

Bevor die Bestimmung der einzelnen Messgrößen aufgeführt wird, sollen vorher einige wichtige Definitionen erläutert werden. Dabei wird besonders darauf Wert gelegt, den Unterschied zwischen den Begriffen der Genauigkeit und der Auflösung darzustellen.

Der Begriff **Genauigkeit** wird in der Radartechnik in Einzielsituationen benutzt. Er beschreibt in quantitativer Form die Präzision und die Richtigkeit, mit der die Zielparameter Entfernung, Azimutwinkel und radiale Geschwindigkeit gemessen werden können.

Der Begriff **Auflösung** hingegen wird in Mehrzielsituationen benutzt und ist für die Charakterisierung eines Radarsystems von großer Bedeutung. Dieser Begriff gibt an, wie gut zwei verschiedene, aber nah benachbarte Ziele voneinander unterschieden werden können. Die Auflösung gibt dabei den Abstand an, der mindestens zwischen zwei Zielen bestehen muss, um sie getrennt wahrzunehmen. Die Auflösung ist deshalb besser, je kleiner dieser Abstand ist. Die Auflösung ist damit ein sehr wichtiges Qualitätsmerkmal eines Radarsensors, um einschätzen zu können, wie gut einzelne Objekte voneinander getrennt werden können.

Die letzte Größe ist die Festlegung des **Eindeutigkeitsbereichs**. Dieser beschreibt die maximale Entfernung oder Geschwindigkeit, die eindeutig gemessen werden kann. Messergebnisse mit einem höheren Wert können nicht eindeutig bestimmt werden. Das führt zum Beispiel zu folgendem Szenario: Wenn der Eindeutigkeitsbereich der Entfernung zwischen null und hundert Metern liegt und ein Ziel mit 102m Entfernung gemessen wird, dann ist nicht bestimmbar, ob sich dieses Ziel in 2m oder 102m Entfernung aufhält.

### 5.1.2 Messung der Entfernung

Alle elektromagnetischen Wellen breiten sich im Vakuum mit der Lichtgeschwindigkeit  $c$  aus. Die Geschwindigkeit der Radarwellen in der Luft kann näherungsweise ebenfalls mit dieser angenommen werden [RSH10], da der Brechungsindex von Luft nahe 1 ist. Da diese Geschwindigkeit bekannt ist, kann die Entfernung  $r$  eines Objektes durch eine



Laufzeitmessung bestimmt werden. Es wird die Laufzeit  $\tau$  gemessen, die zwischen dem Aussenden der Welle und der Ankunft der reflektierten Welle vergeht. Während dieser Zeit legt die Welle die doppelte Wegstrecke zurück, die das Zielobjekt von dem Radarsensor entfernt ist. Das Prinzip wird in Abbildung 4 verdeutlicht.



**Abbildung 4:** Wegstrecke, die ein elektromagnetisches Signal zurücklegt, wenn es an einem Objekt reflektiert wird

Die Entfernung  $r$  ist nur von der Laufzeit  $\tau$  abhängig und ergibt sich über folgende Gleichungen:


$$\tau = \frac{2r}{c}, \quad (5.1)$$

$$r = \frac{c}{2} \tau. \quad (5.2)$$

### 5.1.3 Messung der radialen Geschwindigkeit

Um näher auf die Geschwindigkeitsmessung einzugehen, muss zunächst der **Doppler-Effekt** erläutert werden. Dieser Effekt wurde erstmals 1842 von Christian Doppler nach astronomischen Beobachtungen von Doppelsternen erwähnt [Dop42].

Wenn eine elektromagnetische Welle auf ein stehendes Objekt trifft, dann wird die Welle von diesem mit der gleichen Frequenz reflektiert. Falls dieses Objekt sich jedoch bewegt, wird die Wellenlänge in die Bewegungsrichtung des Objektes zusammengestaucht und entgegen der Bewegungsrichtung auseinandergezogen. Diese in Abbildung 5 zu erkennende Wellenverschiebung wird als Doppler-Effekt bezeichnet.



**Abbildung 5: Schematische Darstellung der Frequenzverschiebung beim Doppler-Effekt**

Wenn das rot dargestellte Objekt auf den stationären Beobachter, welcher in diesem Fall der Empfänger des Radarsensors in Abbildung 5 ist, zufährt, wird im Beobachter eine kürzere Wellenlänge registriert. Das empfangene Signal hat also eine höhere Frequenz als das, welches vom Sender ausgestrahlt wurde. Wenn sich das Objekt entfernt, wird demnach eine niedrigere Frequenz gemessen.

Herleiten kann man den Effekt, in dem ein sinusförmiges Sendesignal  $s_S$  mit einer konstanten Amplitude  $A_S$  und konstanten Frequenz  $f_S$  in der folgenden Form angenommen wird:

$$s_S(t) = A_S \sin(2\pi f_S t) . \quad (5.3)$$

Dieses Signal wird nach einer Laufzeit  $\tau$  mit einer abgeschwächten Amplitude  $A_E$  empfangen:

$$s_E(t) = A_E \sin(2\pi f_S (t - \tau)) . \quad (5.4)$$

Wenn für  $\tau$  die Gleichung (5.1) angenommen wird, ergibt sich folgende Form des Empfangssignals:

$$s_E(t) = A_E \sin\left(2\pi f_S \left(t - \frac{2r}{c}\right)\right) , \quad (5.5)$$



$$s_E(t) = A_E \sin \left( 2\pi f_S t - \underbrace{\frac{4\pi r f_S}{c}}_{\phi_E} \right). \quad (5.6)$$

Die Sendefrequenz  $f_S$  und die Empfangsfrequenz sind dabei exakt gleich. Der einzige Unterschied ist in der Amplitude  $A_E$  und in der Phasenverschiebung  $\phi_E$  des Empfangssignals.

Wenn sich das Objekt allerdings bewegt, ändert sich dessen Entfernung  $r$ , ausgehend von  $r_0$ , während der Laufzeit  $\tau$  mit der Radialgeschwindigkeit  $v_r$  des Objektes:

$$r = r_0 + v_r t. \quad (5.7)$$

Mit dieser Änderung ergibt sich die Gleichung (5.1) zu

$$\tau = 2 \frac{r_0 + v_r t}{c}. \quad (5.8)$$

Damit verändert sich das Empfangssignal von Gleichung (5.4) wie folgt:

$$s_E(t) = A_E \sin \left( 2\pi f_S \left( t - 2 \frac{r_0 + v_r t}{c} \right) \right), \quad (5.9)$$

$$s_E(t) = A_E \sin \left( 2\pi \underbrace{\left( f_S - f_S \frac{2v_r}{c} \right)}_{f_E} t - \underbrace{f_S \frac{4\pi r_0}{c}}_{\phi_E} \right), \quad (5.10)$$

$$s_E(t) = A_E \sin(2\pi f_E t + \phi_E). \quad (5.11)$$

Die Empfangsfrequenz  $f_E$  hat sich gegenüber der Sendefrequenz  $f_S$  verschoben. Die Differenz der beiden Frequenzen wird als **Dopplerfrequenz**  $f_D$  bezeichnet:

$$f_D = f_E - f_S. \quad (5.12)$$

Mit den Ergebnissen aus Gleichung (5.10) für die Empfangsfrequenz  $f_E$  ergibt sich das Ergebnis für die Dopplerfrequenz

$$f_D = \left( f_S - f_S \frac{2v_r}{c} \right) - f_S, \quad (5.13)$$





$$f_D = -f_s \frac{2v_r}{c} = -\frac{2v_r}{\lambda} . \quad (5.14)$$

Diese Dopplerfrequenz ist die Frequenzverschiebung, die gemessen werden kann, wenn das Sendesignal von einem bewegten Objekt mit der Radialgeschwindigkeit  $v_r$  reflektiert wird. Häufig wird diese Gleichung (5.14) dabei mit der Wellenlänge

$$\lambda = \frac{c}{f_s} \quad (5.15)$$

beschrieben.

Durch Bestimmung dieser Frequenzverschiebung  $f_D$  kann die radiale Geschwindigkeit  $v_r$  des Objektes sehr genau bestimmt werden. Diese genaue Bestimmung der Geschwindigkeit ist eine Stärke der Radartechnik, mit der sie sich von anderen Messsystemen abheben kann.

Dabei wird nur die radiale Komponente  $v_r$  der Geschwindigkeit durch die Frequenzverschiebung erfasst, mit der sich das Objekt vom Sensor entfernt oder sich auf diesen zubewegt. Da die tangential Komponente  $v_t$  nicht ermittelt wird, bedeutet dies, dass nicht die absolute Geschwindigkeit des beobachteten Objektes gemessen werden kann, sondern lediglich eine der in Abbildung 6 dargestellten Komponenten.




Abbildung 6: Darstellung der Geschwindigkeitskomponenten eines detektierten Objektes (rot)



Die absolute Geschwindigkeit  $v$  eines Objektes kann erst durch mehrere Messungen am gleichen Objekt ermittelt werden. Dabei können entweder mehrere gleichzeitige Reflexionen genutzt werden, um eine tangentielle Geschwindigkeitskomponente des Objektes [RFR07] zu gewinnen, oder die absolute Geschwindigkeit wird über mehrere Messzyklen durch eine Objektverfolgung bestimmt.

#### 5.1.4 Messung des Azimutwinkels

Der in Abbildung 3 dargestellte Azimutwinkel  $\varphi$  kann mittels verschiedener Verfahren gemessen werden. Zusammen mit der Entfernung wird damit die Position des reflektierenden Objektes ermittelt. Ein übliches Verfahren, welches beispielsweise in der Luftfahrt verwendet wird, ist die Benutzung einer sich drehenden Antenne. Der Azimutwinkel wird danach bestimmt, in welcher Antennenausrichtung die Amplitude des reflektierten Signals maximal ist. Dazu werden verschiedene Messungen in unterschiedliche Antennenausrichtungen durchgeführt.

Im Verkehrsbereich ändern die Ziele ihre Positionen allerdings deutlich schneller, als durch die Drehzeit einer solchen Antenne von mehr als einer Sekunde überwacht werden kann. Deshalb kommen andere Messverfahren zur Anwendung. Zwei dieser Verfahren, auf die hier eingegangen werden soll, sind das Monopulsverfahren [She85] und die Trilateration [Tor84].

Das Monopuls-Verfahren macht es möglich, die Position eines Objektes innerhalb eines Messzyklus festzustellen. Dafür sind immer zwei Empfangsantennen nötig. Für das Verfahren kann entweder die Amplitude oder die Phase des Empfangssignals als Indikator für die Messung des Azimutwinkels genutzt werden.

Für das **Amplituden-Monopulsverfahren** werden mindestens, wie in Abbildung 7(a) dargestellt, zwei verschiedene Empfangsantennen benötigt, die in ihrer Hauptstrahlrichtung leicht gegeneinander versetzt sind.

Beide Antennen empfangen das reflektierte Signal mit unterschiedlichen Amplituden  $A_1$  und  $A_2$ . Aus diesen Amplituden werden eine Summe und eine Differenz gebildet. Das Summensignal beider Antennen wird zur Zieldetektion herangezogen, während



das Differenzsignal für die Messung des Azimutwinkels benutzt wird. Dabei ergibt jede Differenz einen eindeutigen Azimutwinkel, solange das Ziel von beiden Antennen mit der Hauptkeule gesehen werden kann [Hud99]. Je besser sich das Ziel dabei zwischen den beiden Antennenhauptstrahlrichtungen befindet, desto genauer ist die Winkelmessung, da die Differenz sich hier stärker mit dem Azimutwinkel ändert.

Im **Phasen-Monopulsverfahren** werden ebenfalls zwei Empfangsantennen genutzt, die allerdings in Ausrichtung und Empfangseigenschaften identisch sind. Diese beiden Antennen liegen sehr dicht beieinander und haben etwa den Abstand entsprechend einer halben Wellenlänge  $\lambda$  des Sendesignals. Dadurch erreicht das Signal die Antennen mit gleicher Amplitude, aber die Phase des Signals ist unterschiedlich [Rit13].

Dieser Phasenunterschied  $\Delta\phi$  wird dazu genutzt, den Azimutwinkel des Ziels zu bestimmen, da eine eindeutige Abhängigkeit zwischen diesen Werten vorhanden ist. Wenn die Welle senkrecht auf beide Antennen fällt, der Azimutwinkel also  $0^\circ$  beträgt, ist der Phasenunterschied null. Bei einem Azimutwinkel von  $90^\circ$  würde der Gangunterschied hingegen exakt dem Abstand  $d$  der beiden Antennen entsprechen. Phasenunterschied  $\Delta\phi$  und Gangunterschied  $\Delta s$  hängen dabei wie folgt von der Wellenlänge  $\lambda$  des Signals ab:

$$\Delta s = \frac{\Delta\phi}{2\pi} \lambda . \quad (5.16)$$

In Abbildung 7(b) wird der Zusammenhang zum Azimutwinkel des Ziels deutlicher. Der Winkel lässt sich in dem rechtwinkligen Dreieck aus Gangunterschied und Antennenabstand errechnen.

$$\sin(\varphi) = \frac{\Delta s}{d} = \frac{\Delta\phi}{2\pi} \frac{\lambda}{d} . \quad (5.17)$$

Mit Gleichung (5.16) für den Gangunterschied ergibt sich der Azimutwinkel aus dem Phasenunterschied der beiden Eingangssignale wie folgt:

$$\varphi = \sin^{-1}\left(\frac{\Delta\phi}{2\pi} \frac{\lambda}{d}\right) . \quad (5.18)$$



Um die **Trilateration-Berechnung** nutzen zu können, sind zwei Antennen mit einer hohen Genauigkeit in der Entfernungsmessung nötig. Von beiden wird die Entfernung zum Objekt gemessen, die dann zusammen mit dem Abstand der beiden Antennen zueinander ausreicht, um Informationen über den Winkel zu erhalten. Dies geschieht, da diese drei Größen, wie in Abbildung 7(c) gezeigt, ein eindeutiges Dreieck definieren, von dem alle drei Seitenlängen bekannt sind. Je größer der Antennenabstand  $d$ , desto genauer wird das Messergebnis.

Die Funktionsweise ist wie folgt: Die erste Antenne detektiert ein Ziel und misst die Entfernung  $r$ . Es ist also nun möglich, einen Kreis mit dieser Entfernung um die Antenne zu ziehen, so dass dieser alle möglichen Positionen des Ziels markiert. Auch die zweite Antenne erfasst eine gewisse Entfernung und erhält so einen Kreis mit den möglichen Positionen. Dort wo sich beide Kreise in Blickrichtung des Sensors schneiden, befindet sich das entsprechende Ziel. Wie sich ein Fehler in der Entfernungsmessung in der Winkelmessung auswirkt, wird in [Klo02] gezeigt. Zusätzlich befinden sich weitere Berechnungen zur Winkelschätzung z. B. in [Lüb05].

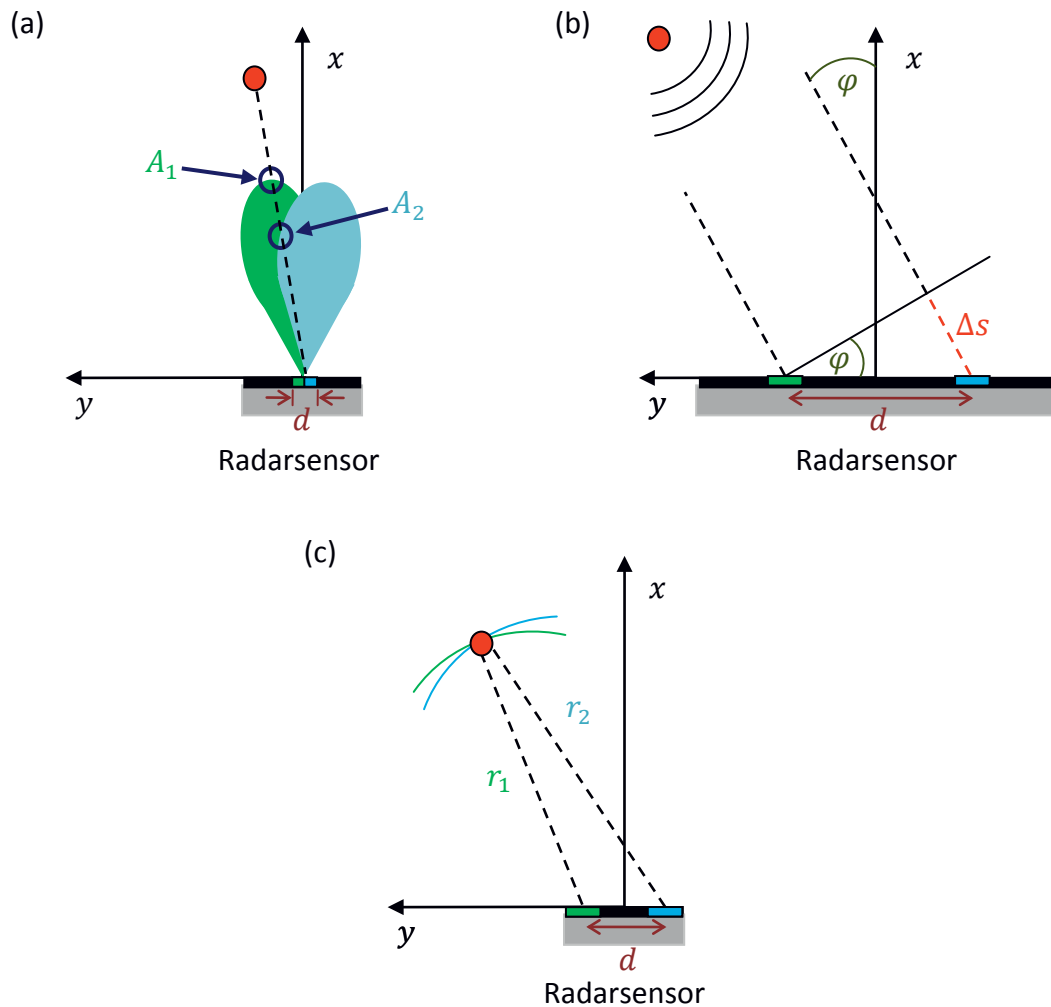


Abbildung 7: (a) Radarsensor mit zwei Empfangsantennen (grün und blau) zur Messung des Azimutwinkels durch Amplituden-Monopulsverfahren  
 (b) Darstellung zur Messung des Azimutwinkels durch Phasen-Monopulsverfahren mit zwei Empfangsantennen (grün und blau)  
 (c) Radarsensor mit zwei Antennen (grün und blau) zur Messung des Azimutwinkels durch Trilateration



## 5.2 Sendesignalformen

Je nach Anwendungen sollen unterschiedliche Messgrößen von Zielen mit verschiedenen priorisierter Genauigkeit ermittelt werden. Dafür werden verschiedene Sendesignalformen genutzt. Auch Mehrzielsituationen stellen diese Sendesignale vor Herausforderungen. Diese Sendesignalformen werden dabei in zwei Oberkategorien aufgeteilt – Pulsradare und Dauerstrichradare [RSH10].

### 5.2.1 Pulsradar

Pulsradare sind die ursprünglich genutzte Version des Radars. Sie werden häufig in Anwendungen genutzt, wo eine sehr hohe Reichweite erzielt werden muss [Göb00], wie beispielsweise in der Luftraumüberwachung. Ein Pulsradar sendet einen sehr kurzen elektromagnetischen Puls mit sehr hoher Sendeleistung  $P$  aus. Während dieser Zeit ist der Empfänger ausgeschaltet, so dass er durch die hohe Sendesignalleistung nicht beschädigt werden kann.

Wie in Abbildung 8 dargestellt, hat ein Pulsradar über der Zeit  $t$  klar abgetrennte Sende- und Empfangsphasen. Solange kein Puls gesendet wird, wartet das Pulsradar auf reflektierte Signale. Ein kompletter Zyklus besteht aus Sendezeit  $t_S$  und Empfangszeit  $t_E$  und seine Dauer wird als Pulswiederholungsintervall  $t_{PI}$  bezeichnet. Häufig wird diese Größe durch die Pulswiederholungsfrequenz  $f_{PF}$  angegeben, welche zeigt, wie viele Messzyklen im Radar pro Sekunde stattfinden. Der Zusammenhang ist mit

$$f_{PF} = \frac{1}{t_{PI}} \quad (5.19)$$

gegeben.




Abbildung 8: Schematische Darstellung der Sendeleistung eines Pulsradars über der Zeit

Die Bestimmung der Laufzeit  $\tau$  bei einem Pulsradar ist in Abbildung 9 dargestellt. Es ist die Zeit, die zwischen dem Aussenden des Sendesignals und dem Eintreffen eines Empfangssignals verstreicht.




Abbildung 9: Schematische Darstellung der Laufzeit  $\tau$  eines Pulsradars mit Sendesignal (blau) und Empfangssignal (rot) über der Zeit

Die **Entfernung**  $r$  wird in einem Pulsradar durch Messung der Signallaufzeit  $\tau$  nach Gleichung (5.2) berechnet. Die Auflösung wiederum hängt davon ab, wie zwei reflektierte Signale, in diesem Fall die Pulse, unterschieden werden können. Um hier einen Puls von einem anderen zu trennen, darf das zweite Echosignal erst eintreffen, nachdem die Pulsdauer  $t_S$ , die der Sendezeit entspricht, des ersten Echos vergangen ist. Damit ergibt sich die Entfernungsauflösung  $\Delta r$  zu:



$$\Delta r = \frac{c}{2} t_S . \quad (5.20)$$

Zwei Ziele müssen radial mindestens den Abstand  $\Delta r$  voneinander haben, um getrennt betrachtet werden zu können. Die Auflösung des Radars ist demnach besser, je kürzer die Sendezeit  $t_S$  gewählt wird.

Eine weitere Größe ist die Entfernungseindeutigkeit. Die Laufzeit  $\tau$  eines Signals wird immer relativ zum letzten gesendeten Puls bestimmt. Wenn ein Empfangssignal also erst eintrifft, wenn bereits der nächste Puls gesendet wurde, ist dessen Entfernung nicht mehr eindeutig bestimmbar. Deswegen ist dieser Wert gleichzusetzen mit der maximalen Entfernung  $r_{max}$ . Dieser Wert hängt davon ab, wie weit zwei Pulse auseinander liegen, also von dem Pulswiederholungsintervall  $t_{PI}$ :

$$r_{max} = \frac{c}{2} t_{PI} . \quad (5.21)$$

Die Genauigkeit der Entfernungsmessung hängt vor allem vom Signal-zu-Rauschabstand und proportional von der Pulsbreite ab. Je breiter also der ausgesendete Puls ist, desto genauer wird die Messung. Die Entfernungsauflösung wird dadurch allerdings wiederum schlechter.

Bei einem Puls-Doppler-Radar wird die **radiale Geschwindigkeit** durch die Messung der Dopplerfrequenz  $f_D$ , wie in [Rit13] beschrieben, ermittelt. Mit einem reinen Pulsradar kann die radiale Geschwindigkeit eines Objektes durch die Entfernungsänderung zwischen zwei Messungen bestimmt werden [Hud99]. Werden dementsprechend in zwei aufeinanderfolgenden Messungen die Entfernungen  $r_1$  und  $r_2$  detektiert, ergibt sich die radiale Geschwindigkeit  $v_r$  dieses Objektes zu

$$v_r = \frac{r_2 - r_1}{t_{PI}} . \quad (5.22)$$






### 5.2.2 Dauerstrichradar

Im Gegensatz zum Pulsradar sendet ein *Continuous Wave Radar*, im Folgenden **CW-Radar** oder Dauerstrichradar genannt, über die komplette Zeit ein Signal aus und wartet währenddessen auf die von Objekten reflektierten Wellen. Daraus folgt, dass es hier keine getrennten Sende- und Empfangszeiten gibt und auch der Empfänger kontinuierlich eingeschaltet ist. Dadurch bedingt haben Dauerstrichradare eine geringere Sendesignalleistung, um den eigenen Empfänger nicht zu stören [RSH10].

Um die Entfernung des reflektierenden Objektes ermitteln zu können, ist es wichtig, dass das Sendesignal eines CW-Radars in der Frequenz moduliert wird.

Durch verschiedene Modulationen können unterschiedliche Informationen über das reflektierende Objekt gewonnen werden. Daher sollen verschiedene Varianten im Folgenden abhängig von den gewünschten Messgrößen vorgestellt werden.

Für eine reine Geschwindigkeitsmessung eignen sich monofrequente Dauerstrichradare. Diese senden ein konstantes Signal mit gleichbleibender Frequenz aus, wie es in Abbildung 10 gezeigt ist.



**Abbildung 10: Sendesignal (blau) und Empfangssignal (rot) eines CW-Radars zur Geschwindigkeitsmessung**

Da die ganze Zeit mit konstanter Frequenz gesendet und empfangen wird, können keine Laufzeit  $\tau$  und somit auch keine Entfernung bestimmt werden. Der Frequenzunterschied  $f_v$  zwischen Sende- und Empfangssignal entsteht durch eine Verschiebung der Frequenz durch den Doppler-Effekt und ist identisch zur Dopplerfrequenz  $f_D$ .



### 5.2.3 Linear frequenzmoduliertes Radar

Bei einem Dauerstrichradar ist zur Entfernungsmessung eine Modulation des Sendesignals nötig. Dafür kann ein *Linear Frequency Modulated Continuous Wave-Radar (LFMCW-Radar)* benutzt werden, bei dem sich die abgestrahlte Grundfrequenz  $f_0$  linear über einen bestimmten Zeitraum  $t_c$  verändert. Dieser Zeitraum wird als Chirp bezeichnet. Wenn die Steigung der Frequenz dabei positiv ist, wird er als Upchirp und bei negativer Steigung als Downchirp bezeichnet. Die maximale Veränderung der Frequenz während eines Chirps bewegt sich dabei im Rahmen der Bandbreite  $f_{Hub}$ .

Wie in Abbildung 11 dargestellt, ergibt sich das blaue Sendesignal  $f(t)$  über folgende Gleichung:

$$f(t) = \frac{f_{Hub}}{t_c} t + f_0 . \quad (5.23)$$




Abbildung 11: Sendesignal (blau) und Empfangssignal (rot) eines LFMCW-Radars zur Entfernungsmessung

Die Signallaufzeit  $\tau$ , um die das Empfangssignal zeitlich verschoben ist, kann aufgrund der dauerhaften Sendung nicht wie beim Pulsradar gemessen werden, da der Zeitpunkt der Aussendung der Welle, die reflektiert wurde, nicht bekannt ist. Daher muss die Laufzeit über die momentane Frequenzverschiebung  $f_v$  ermittelt werden. Es gilt:



$$\frac{f_v}{f_{Hub}} = \frac{\tau}{t_c} . \quad (5.24)$$

Mit der Gleichung (5.1), eingesetzt für  $\tau$ , ergibt sich daraus anschließend die Entfernung  $r$  des Ziels, welches das Empfangssignal zurückgeworfen hat:

$$r = \frac{c}{2} \frac{f_v}{f_{Hub}} t_c . \quad (5.25)$$

Mit dem zuvor erwähnten CW-Radar kann nur die Geschwindigkeit eines Objektes bestimmt werden, während das LFM CW-Radar innerhalb eines Chirps die Entfernung ermitteln kann, allerdings nur solange das reflektierende Objekt sich nicht bewegt. Dieses ist dadurch begründet, dass sich die Frequenzverschiebung  $f_v$  bei sich bewegenden Objekten aus der durch die Laufzeit  $\tau$  erzeugte Verschiebung  $f_\tau$  und der Dopplerfrequenz  $f_D$  zusammensetzt:

$$f_v = f_D - f_\tau = -\frac{2}{\lambda} v_r - \frac{2f_{Hub}}{ct_c} r . \quad (5.26)$$

Um daraus **Entfernung und Geschwindigkeit** gleichzeitig zu ermitteln, muss das Sendesignal weiter angepasst werden. Es wird ein erweitertes LFM CW-Radar genutzt, welches allerdings, wie in Abbildung 12 gezeigt, einen Upchirp und einen Downchirp zeitlich nacheinander sendet. Für jede der beiden Rampen können nun getrennte Frequenzverschiebungen ermittelt werden, welche im Folgenden als  $f_a$  und  $f_b$  bezeichnet werden. Dadurch ergeben sich zwei Gleichungen, um die zwei unbekannt Variablen von radialer Geschwindigkeit  $v_r$  und Entfernung  $r$  zu ermitteln.

Dabei ist es wichtig, dass die Frequenzverschiebung  $f_D$ , die durch den Doppler-Effekt zustande kommt, in beiden Echosignalen von Up- und Downchirp das gleiche Vorzeichen hat, da die Richtung der Verschiebung nur von der Fahrtrichtung des reflektierenden Objektes abhängt. Die durch die Zeitverschiebung verursachte Frequenzverschiebung  $f_\tau$  ist dagegen bei steigenden Flanken immer negativ und bei fallenden Flanken positiv.




Abbildung 12: Sendesignal (blau) und Empfangssignal (rot) eines LFM CW-Radars mit Up- und Downchirp

Daraus ergibt sich zusätzlich zur Gleichung (5.26) für den Upchirp, wo  $f_a = f_v$  gilt, die folgende Gleichung für den Downchirp:

$$f_b = f_D + f_\tau = -\frac{2}{\lambda} v_r + \frac{2 f_{Hub}}{c t_c} r . \quad (5.27)$$

Daraus lassen sich dann die einzelnen Frequenzverschiebungen errechnen:

$$f_D = \frac{f_a + f_b}{2} = -\frac{2}{\lambda} v_r , \quad (5.28)$$

$$f_\tau = \frac{f_b - f_a}{2} = \frac{2 f_{Hub}}{c t_c} r . \quad (5.29)$$

Hiermit können anschließend die Entfernung  $r$  und die radiale Geschwindigkeit  $v_r$  des reflektierenden Objektes gleichzeitig berechnet werden.

Einer der größten Vorteile des LFM CW-Radars ist es, dass dabei die Ziele sowohl in Entfernung als auch radialer Geschwindigkeit aufgelöst werden können. Die Auflösung in der Entfernung hängt dabei von der Bandbreite  $f_{Hub}$  des Signals ab. Je größer diese Bandbreite, desto besser können zwei Ziele unterschiedlicher Entfernung voneinander getrennt werden:



$$\Delta r = \frac{c}{2 f_{Hub}} . \quad (5.30)$$

Die Auflösung der Dopplerfrequenz hängt ausschließlich von der Beobachtungszeit ab. Denn je länger zwei Signale mit unterschiedlicher Frequenz beobachtet werden, desto einfacher ist es, sie zu unterscheiden. Damit ergibt sich für die Auflösung der Dopplerfrequenz

$$\Delta f_D = \frac{1}{t_C} . \quad (5.31)$$

Die Auflösung der radialen Geschwindigkeit  $v_r$  ist nach der Gleichung (5.14) für den Doppler-Effekt zusätzlich abhängig von der Wellenlänge des Sendesignals.

$$\Delta v_r = \frac{\lambda}{2 t_C} . \quad (5.32)$$

Damit wird die Auflösung in der radialen Geschwindigkeit  $v_r$  besser, je länger die Beobachtungsdauer  $t_C$  ist und je größer die Sendefrequenz des abgestrahlten Signals ist.

Diese Sendesignalform ist dann in ihrer Anwendung limitiert, wenn mehr als ein Ziel gleichzeitig detektiert wird. Durch mehrere Empfangssignale und dadurch verschiedene Frequenzverschiebungen  $f_r$  und  $f_D$  ist es nicht eindeutig, welche Verschiebungen zu welchem Ziel gehören. Dadurch entstehen mehr Lösungen für die Entfernung und die radiale Geschwindigkeit, wie in Abbildung 13 veranschaulicht. In einer Zwei Zielsituation gibt es dabei vier Möglichkeiten, wie die entsprechenden Verschiebungen zusammenpassen. Zwei davon sind die realen Ziele und die zwei weiteren ergeben so genannte Geisterziele.

Diese Limitierung lässt sich vermeiden, indem das Signal um mindestens einen weiteren Chirp verlängert wird, der eine andere Steigung als die anderen beiden hat. Dadurch ergeben sich weitere Geraden im  $rv_r$ -Diagramm, welche nur zwei der vier Schnittpunkte kreuzen und damit die realen Ziele von den Geisterzielen separieren. Dieses wird in Abbildung 14 gezeigt.

Durch diese Erweiterung lassen sich zwei Ziele sicher detektieren, ohne die Geisterziele in Betracht ziehen zu müssen.




Abbildung 13: Mehrdeutigkeit in einer Zweizielsituation




Abbildung 14: Aufgelöste Mehrdeutigkeit in einer Zweizielsituation durch einen weiteren Chirp im Sendesignal (gestrichelt)

Wenn allerdings mehr als zwei Ziele vorhanden sind und auch Rauschen hinzukommt, kann die Situation schnell unübersichtlich werden, so dass auch Geisterziele in Betracht gezogen werden. Daher funktioniert diese Sendesignalform sehr gut bei Anwendungen, wo wenig Ziele vorhanden sind [Kro14].



Da in der Verkehrsbeobachtung jedoch meist sehr viele Fahrzeuge gleichzeitig detektiert werden sollen, ist diese Sendeform dafür in den meisten Fällen nicht geeignet. Weiter muss beachtet werden, dass die Beobachtungszeit durch das Senden von mehreren Chirps länger sein kann, als es die Beobachtungsbedingungen im Verkehrsbereich zulassen.

#### 5.2.4 Frequenzumtastendes Radar

Das frequenzumtastende Radar ist eine Weiterentwicklung eines CW-Radars, die genutzt wird, wenn zusätzlich zu der Geschwindigkeitsinformation auch gleichzeitig die Entfernung bestimmt werden soll, aber keine Trennung in Entfernung benötigt wird.

Bei einer Frequenzumtastung ändert sich die Frequenz des Sendesignals sprunghaft zwischen zwei Grundfrequenzen  $f_1$  und  $f_2$ , wie in Abbildung 15 gezeigt. Diese Signalform wird auch als *Frequency Shift Keying-Radar (FSK-Radar)* bezeichnet. Dabei werden zwei unmodulierte Signale mit ihren jeweiligen Grundfrequenzen abwechselnd gesendet, wobei der Frequenzabstand zwischen  $f_1$  und  $f_2$  als  $f_{shift}$  bezeichnet wird.

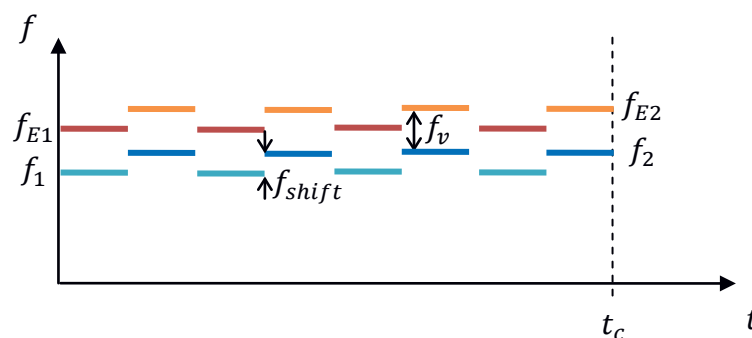


Abbildung 15: Sendesignal (blau) mit zwei unterschiedlichen Sendefrequenzen und Empfangssignal (rot) eines FSK-Radars



Zwischen Sende- und Empfangssignal entsteht so wiederum die Frequenzverschiebung  $f_v$ . In dieser Verschiebung ist ausschließlich der Doppleranteil vorhanden, da sich eine Laufzeitverschiebung nur bemerkbar macht, wenn frequenzmodulierte Rampen zur Messung verwendet werden. Daher kann die radiale Geschwindigkeit  $v_r$  mit der bekannten Gleichung für den Doppler-Effekt berechnet werden:

$$f_v = f_D = -\frac{2v_r}{\lambda} . \quad (5.33)$$

Diese Dopplerfrequenz hängt von der Wellenlänge ab. Solange die Differenz  $f_{shift}$  zwischen beiden Sendefrequenzen allerdings deutlich kleiner ist als die Sendefrequenz selber, ist der Unterschied in der Dopplerfrequenz  $f_D$  vernachlässigbar [Kro14]. Durch die eindeutige Dopplerfrequenz entstehen auch im Gegensatz zum linear frequenzmodulierten Signal keine Geisterziele.

Da in der Frequenzverschiebung kein Laufzeitanteil vorhanden ist, ist es nicht möglich, hieraus die Entfernung des Ziels zu bestimmen. Allerdings ändert sich durch den Wechsel der Frequenz von  $f_1$  zu  $f_2$  die Phase  $\phi$  des Empfangssignals von  $\phi_1$  auf  $\phi_2$ , wodurch sich ein messbarer Phasenunterschied  $\Delta\phi$  ergibt, der von der Laufzeit  $\tau$  des Signals abhängt:

$$\Delta\phi = \phi_1 - \phi_2 = 2\pi f_{shift}\tau . \quad (5.34)$$

Diese Phasendifferenz hängt von dem Frequenzsprung  $f_{shift}$  ab und von der Laufzeit  $\tau$  des Signals und damit auch von der Entfernung. Denn je länger das Signal unterwegs ist, desto mehr verändert sich die Phase aufgrund der leicht unterschiedlichen Frequenz. Mit dem Einsetzen der Entfernungsgleichung (5.2) ergibt sich für die Entfernung

$$r = \frac{c}{4\pi f_{shift}} \Delta\phi . \quad (5.35)$$

Dadurch ist auch die Eindeutigkeit der Entfernungsmessung gegeben. Denn sobald die Phasendifferenz größer wird als  $2\pi$ , also eine komplette Phasendrehung, ist nicht unterscheidbar, ob nicht doch nur eine geringe Phasendifferenz vorhanden ist. Dabei ist die maximale eindeutige Entfernung eines FSK-Radars gegeben durch





$$r_{max} = \frac{c}{2f_{shift}} . \quad (5.36)$$

Sobald zwei Ziele allerdings die gleiche radiale Geschwindigkeit haben, können sie nicht mehr voneinander separiert werden, da keine Trennung in der Entfernung möglich ist. Dieses gilt vor allem für stationäre Ziele.

### 5.2.5 Linear moduliertes frequenzumtastendes Radar

Um Ziele sowohl in Entfernung als auch der Geschwindigkeit auflösen zu können und zusätzlich Mehrdeutigkeitsprobleme in Mehrzielsituationen zu vermeiden, wurde eine Kombination aus verschiedenen Sendesignalen entwickelt [RM01]. Diese Kombination ergibt sich aus dem zuvor beschriebenen FSK- und LFM CW-Radar und wird als linear moduliertes frequenzumtastendes Radar oder *Multiple Frequency Shift Keying*-Radar (**MFSK-Radar**) bezeichnet.

Dieses vereint die Vorteile beider Sendesignalformen: Zum einen die Möglichkeit des FSK-Radars, Entfernung und Geschwindigkeit gleichzeitig in kurzer Zeit zu messen, und zum anderen die Eigenschaft des LFM CW-Radars, beide Größen aufzulösen. Dies hat zur Folge, dass auch Mehrzielsituationen mit vielen Zielen gut erkannt werden können.

In Abbildung 16 ist das Signal des MFSK-Radars aufgezeigt. Dabei werden die beiden Grundsendefrequenzen  $f_1$  und  $f_2$  stufenweise über eine Bandweite von  $f_{Hub}$  linear gesteigert. Die Sendedauer eines Chirps setzt sich dabei aus der Anzahl der Sendestufen und der Zeit pro Stufe  $t_b$  zusammen.

Die Frequenzverschiebung  $f_v$  setzt sich wie beim LFM CW-Radar aus den Frequenzverschiebungen für Dopplerfrequenz  $f_D$  und Laufzeitverschiebung  $f_\tau$  zusammen. Die Gleichung zur Berechnung der Geschwindigkeit entspricht Gleichung (5.26):

$$f_v = f_D - f_\tau = -\frac{2}{\lambda} v_r - \frac{2f_{Hub}}{ct_c} r . \quad (5.37)$$




Abbildung 16: Sendesignal (blau) mit stufenweise ansteigenden Sendefrequenzen und Empfangssignal (rot) eines MFSK-Radars

Um daraus die Information für Geschwindigkeit und Entfernung zu trennen, sind weitere Informationen nötig, die durch den FSK-Teil des Sendesignals zur Verfügung gestellt werden. Wie dort wird die Phasendifferenz  $\Delta\phi$  der Signale gemessen. Diese enthält dieselbe Information über die Entfernung, die in Gleichung (5.35) aufgezeigt wurde. Allerdings ist durch den Anstieg der Frequenz hier ein zweiter Anteil vorhanden, der durch die Doppler-Verschiebung zustande kommt und von der Dopplerfrequenz abhängt. Zusätzlich wird dieser Teil größer, je länger die einzelnen Stufen des MFSK-Sendesignals sind. Damit ergibt sich für den Phasenunterschied

$$\Delta\phi = -2\pi \left( f_D t_b + \frac{2f_{shift}}{c} r \right), \quad (5.38)$$

$$\Delta\phi = \frac{4\pi t_b}{\lambda} v_r - \frac{4\pi f_{shift}}{c} r. \quad (5.39)$$

Mit den beiden Gleichungen für die Frequenzverschiebung  $f_v$  (5.37) und den Phasenunterschied  $\Delta\phi$  (5.39) können die Informationen für die radiale Geschwindigkeit und die Entfernung gleichzeitig innerhalb eines Chirps gewonnen werden.



Diese beiden Informationen sind direkt im Spektrum verknüpft, so dass sie immer für dasselbe Ziel gelten und keinerlei Geisterziele auftreten können [Kro14], womit eine wichtige Voraussetzung für die Verkehrsbeobachtung vieler Fahrzeuge gleichzeitig gegeben ist.

Zusätzlich können die Ziele in Entfernung und radialer Geschwindigkeit aufgelöst werden. Die Entfernungsauflösung wird dabei besser, je größer die Bandbreite des Signals ist. Die unterschiedlichen Dopplerfrequenzen können besser getrennt werden, je länger der Messzyklus  $t_c$  dauert [Heu13]. Daraus ergeben sich die Entfernungsauflösung

$$\Delta r = \frac{c}{2f_{Hub}} \quad (5.40)$$

und die Geschwindigkeitsauflösung

$$\Delta v_r = -\frac{\lambda}{2t_c} . \quad (5.41)$$

Dieses MFSK-Sendesignal kann die Entfernung und die radiale Geschwindigkeit schnell und eindeutig messen und ebenso beide Größen auflösen. Zusätzlich entstehen keine Probleme mit Geisterzielen und die Messung erfolgt innerhalb einer kurzen Messspanne.

Die Genauigkeit der Phasendifferenzmessung kann erhöht werden, wenn dem Signal ein weiterer Downchirp hinzugefügt wird. Die Messung der Geschwindigkeit wird durch einen angehängten reinen FSK-Chirp noch genauer, da dort keine Entfernungsinformationen im reflektierten Signal vorhanden sind.

### 5.2.6 Weitere Sendesignalformen

Zusätzlich zu den bisher aufgezeigten Sendesignalen gibt es weitere Signalformen, die anstelle eines einzelnen Chirps aus mehreren Chirpsequenzen bestehen [Kro14]. Die einzelnen Chirps sind dabei sehr kurz und steil. Eine beispielhafte Darstellung einer solchen Chirpsequenz-Sendeform ist in Abbildung 17 gezeigt.




Abbildung 17: Sende- (blau) und Empfangssignal (rot) einer Sendesignalform mit Chirpsequenzen

Durch ein Heruntermischen des Signals und einer geeigneten Signalverarbeitung mit Fast-Fourier-Transformationen lassen sich die Geschwindigkeit und die Entfernung aus den Frequenzmessungen bestimmen.

### 5.3 Detektion

Es ist die Aufgabe der Zieldetektion, aus den empfangenen Signalen zu erkennen, wann es sich um eine Rauschsituation handelt und wann ein reales Ziel additiv überlagert mit dem Rauschsignal beobachtet wird. Starke Ziele lassen sich zumeist gut über dem Rauschen detektieren, während schwache Ziele von starken Rauschsignalen verdeckt werden. Deswegen ist ein guter Detektor notwendig, um auch diese Ziele erkennen zu können [Lud02]. Erst wenn ein Ziel als solches erkannt wurde, können die Messgrößen Entfernung, radiale Geschwindigkeit und Azimutwinkel bestimmt werden [Hud99].

Dazu ist es nötig, eine Entscheidung zu treffen, ob ein tatsächliches Ziel vorhanden ist oder nur Rauschen vorliegt. Diese Entscheidung wird mit Hilfe einer Detektionsschwelle  $S_D$  getroffen. Wenn die Signalamplitude über dieser Schwelle liegt, wird auf ein Ziel entschieden. Dabei kann es sein, dass das Rauschen so stark ist, dass es über diese



Schwelle kommt. Wenn dies passiert, wird fälschlicherweise auf ein Ziel entschieden und ein sogenannter Falschalarm ausgelöst. Dazu wird eine Falschalarmwahrscheinlichkeit

$$P_{Fa} = \frac{\text{Anzahl der Falschentscheidungen bei Rauschen}}{\text{Anzahl der möglichen Entscheidungen}} \quad (5.42)$$


definiert.

Den Gegenpol dazu bilden die Anzahl der richtigen Entscheidungen. Unter der Annahme, dass ein Ziel vorhanden ist, gibt die Detektionswahrscheinlichkeit  $P_D$  an, wie wahrscheinlich es ist, dass dieses Ziel entdeckt wird:

$$P_D = \frac{\text{Anzahl der korrekten Entscheidungen in Zielsituationen}}{\text{Anzahl der möglichen Entscheidungen}} \quad (5.43)$$

In einem Detektionsprozess wird die Falschalarmwahrscheinlichkeit vorgegeben. Mit dieser Festlegung als Voraussetzung wird anschließend die Detektionswahrscheinlichkeit maximiert. Dafür wird für diese Zielentscheidung die Detektionsschwelle  $S_D$  berechnet und fest eingestellt.

Um diese Entscheidungsschwelle zu ermitteln, soll zunächst der Aufbau des Empfängers beschrieben werden. Das reellwertige und hochfrequente Eingangssignal  $s_R(t)$  wird nach dem Empfang in einen Quadraturdemodulator gegeben, der in Abbildung 18 dargestellt ist.



**Abbildung 18: Quadraturdemodulator im Empfänger mit nachgeschaltetem Detektor**



Dieser Quadraturdemodulator teilt das Eingangssignal in einen Realteil  $I$  und einen Imaginäranteil  $Q$  auf. Wenn ausschließlich ein Rauschsignal am Eingang dieses Empfängers anliegt, können die beiden Anteile durch statistisch unabhängige und gleichverteilte Zufallsvariablen  $x_1$  und  $x_2$  beschrieben werden. Diese Zufallsvariablen folgen einer Gauß'schen Wahrscheinlichkeitsdichtefunktion mit dem Effektivwert des Rauschens  $\sigma_n$ :

$$p(x_1) = \frac{1}{\sigma_n \sqrt{2\pi}} e^{-\frac{x_1^2}{2\sigma_n^2}}, \quad (5.44)$$

$$p(x_2) = \frac{1}{\sigma_n \sqrt{2\pi}} e^{-\frac{x_2^2}{2\sigma_n^2}}. \quad (5.45)$$

Die Entscheidung im Detektor wird anhand der komplexen Einhüllenden  $r$  getroffen, so dass die Wahrscheinlichkeitsdichtefunktion von der Zufallsvariablen  $r$  benötigt wird. Die Berechnung dieser wird im Folgenden beschrieben.

Zunächst wird dafür die Verbundwahrscheinlichkeitsdichte  $p(x_1, x_2)$  von  $x_1$  und  $x_2$  benötigt, die sich wegen der statistischen Unabhängigkeit beider Größen durch das Produkt der Wahrscheinlichkeitsdichtefunktionen berechnen lässt:

$$p(x_1, x_2) = p(x_1) p(x_2) = \frac{1}{2\pi\sigma_n^2} e^{-\frac{(x_1^2+x_2^2)}{2\sigma_n^2}}. \quad (5.46)$$

Um auf die Einhüllende  $r$  und deren Wahrscheinlichkeitsdichtefunktion  $p(r)$  zu gelangen, wird eine Transformation in Polarkoordinaten vorgenommen, so dass gilt:

$$x_1 = r \cos(\varphi), \quad (5.47)$$

$$x_2 = r \sin(\varphi). \quad (5.48)$$

Die Transformation der Verbundwahrscheinlichkeit von  $p(x_1, x_2)$  zu  $p(r, \varphi)$  ergibt sich mit Hilfe der Jacobi-Determinanten:

$$p(x_1, x_2) = |J| p(r, \varphi). \quad (5.49)$$



Die Jacobi-Determinante  $|J|$  berechnet sich aus den Ableitungen der Transformationsgleichungen (5.47) und (5.48).

$$|J| = \begin{vmatrix} \frac{dx_1}{dr} & \frac{dx_2}{dr} \\ \frac{dx_1}{d\varphi} & \frac{dx_2}{d\varphi} \end{vmatrix} = \begin{vmatrix} \cos(\varphi) & \sin(\varphi) \\ -r \sin(\varphi) & r \cos(\varphi) \end{vmatrix} = r. \quad (5.50)$$

Damit folgt durch Einsetzen der Transformationsgleichungen in (5.46) und anschließender Multiplikation mit der Jacobi-Determinanten:

$$p(r, \varphi) = \frac{r}{2\pi \sigma_n^2} e^{-\frac{r^2}{2\sigma_n^2}}. \quad (5.51)$$

Durch die Integration über  $\varphi$  ergibt sich schlussendlich die gesuchte Wahrscheinlichkeitsdichtefunktion der Hüllkurve  $r$  für das angenommene Eingangssignal von reinem Rauschen:

$$p_R(r) = \int_0^{2\pi} p(r, \varphi) d\varphi = \frac{r}{\sigma_n^2} e^{-\frac{r^2}{2\sigma_n^2}}. \quad (5.52)$$

Diese Wahrscheinlichkeitsdichtefunktion  $p_R(r)$  von reinem Rauschen wird dabei als Rayleigh-Verteilung einer Zufallsvariablen  $r$  bezeichnet.

Wenn neben dem Rauschen auch ein Ziel im Empfangssignal vorhanden ist, weist die Wahrscheinlichkeitsdichtefunktion  $p_Z(r)$  eine Überlagerung von Nutzsignal und Rauschen auf. Dafür können, wie in [Lud02] gezeigt, dieselben Berechnungsschritte, wie zuvor für reines Rauschen gezeigt, wiederholt werden, so dass sich für die gesuchte Wahrscheinlichkeitsdichtefunktion der Hüllkurve  $r$  die folgende Gleichung ergibt:


$$p_Z(r) = \frac{r}{\sigma_n^2} e^{-\left(\frac{r^2+A^2}{2\sigma_n^2}\right)} I_0\left(\frac{rA}{\sigma_n^2}\right). \quad (5.53)$$

Diese Verteilung wird als Rice-Verteilung bezeichnet und ist zusätzlich zur Zufallsvariablen  $r$  abhängig von der Zielsignalamplitude  $A$  und wird durch die modifizierte Bessel-Funktion 1. Art [AWH13] und nullter Ordnung  $I_0$  beschrieben. Die Rayleigh-Verteilung



für reines Rauschen ist dabei eine Sonderform der Rice-Verteilung für den Fall, dass die Zielsignalamplitude  $A$  null ist und damit  $I_0(0) = 1$  gilt.

Beide Verteilungen werden in Abbildung 19 dargestellt. Die Detektionsschwelle zeigt den Wert an, über dem entschieden wird, dass das Signal von einem Ziel stammt. Es ist gut zu erkennen, dass unterhalb der Schwelle  $S_D$  nicht jedes Ziel erkannt wird.



**Abbildung 19:** Wahrscheinlichkeitsdichtefunktionen für Rauschen  $p_R(r)$  (blau) und von einem Ziel mit überlagertem Rauschen  $p_Z(r)$  (rot) mit der Detektionsschwelle  $S_D$

Die Detektionswahrscheinlichkeit  $P_D$  ist die Fläche oberhalb der Detektionsschwelle unter der Wahrscheinlichkeitsdichtefunktion  $p_Z(r)$  für ein Ziel im Rauschen und ergibt sich aus:

$$P_D = \int_{S_D}^{\infty} p_Z(r) dr . \quad (5.54)$$

Dort, wo die Verteilung für das reine Rauschen die Schwelle überschreitet, kommt es zu Falschalarmen. Die Wahrscheinlichkeit  $P_{Fa}$  dafür ergibt sich aus der Fläche oberhalb der Detektionsschwelle unter der Wahrscheinlichkeitsdichtefunktion des Rauschens  $p_R(r)$  und errechnet sich aus:





$$P_{Fa} = \int_{S_D}^{\infty} p_R(r) dr . \quad (5.55)$$

Diese Falschalarmwahrscheinlichkeit soll über die ganze Zeit konstant gehalten werden, damit jederzeit bekannt ist, mit wie vielen Fehldetektionen in etwa zu rechnen ist. Eine übliche Falschalarmwahrscheinlichkeit  $P_{Fa}$  bewegt sich dabei in einer Größenordnung von  $10^{-6}$  bis  $10^{-8}$ . Um dieses konstant zu gewährleisten, muss die Detektionsschwelle  $S_D$  adaptiv an das unbekannte Niveau des Rauschens angepasst werden, damit bei größerem Rauschen nicht mehr Fehlalarme zustande kommen und bei geringem Rauschen nicht unnötig viele Ziele nicht detektiert werden.

### 5.3.1 CFAR-Detektor

Ein *Constant False Alarm Rate (CFAR)-Detektor* wird, wie der Name andeutet, dafür genutzt, dass der Pegel des Rauschens geschätzt wird, um damit die Detektionsschwelle so anzupassen, dass die Falschalarmwahrscheinlichkeit konstant bleibt. Aus Gleichung (5.52) und (5.55) ergibt sich diese Falschalarmwahrscheinlichkeit  $P_{Fa}$  zu:

$$P_{Fa} = \int_{S_D}^{\infty} \frac{r}{\sigma_n^2} e^{-\frac{r^2}{2\sigma_n^2}} dr . \quad (5.56)$$

Hier ist gut zu erkennen, dass eine konstante Falschalarmwahrscheinlichkeit  $P_{Fa}$  nur von der Detektionsschwelle und dem Effektivwert des Rauschens  $\sigma_n$  abhängt. Ziel ist es demnach, die Detektionsschwelle  $S_D$  je nach Stärke des momentan vorherrschenden Rauschens adaptiv anzupassen.

Bei unbekannter Rauschleistung muss diese geschätzt werden, da sich Rauschen bei jeder Messung verändert und zusätzlich von Ort zu Ort unterschiedlich ist. Örtlich kann es Umwelteinflüsse geben, die das Rauschen verstärken, so dass die Schätzung des Rauschpegels von der Umgebung des Testpunktes abhängt. Deshalb wird eine örtliche Unterteilung in Zellen vorgenommen, so dass für jede Zelle der Rauschpegel der benachbarten Zellen überprüft werden kann, um eine passende Schwelle zu definieren. Zwei dieser Zellen haben dabei in etwa einen zeitlichen Abstand, welcher der



Signallaufzeit  $\tau$  entspricht und daher ungefähr die Größe einer Auflösungszelle im Entfernungsbereich [Lud02].

Ziel ist es, für jede Zelle eine adaptive Detektionsschwelle zu bestimmen. Deswegen werden die ermittelten Leistungen aller Zellen in eine Art Schieberegister der Länge  $l$  geschrieben. Eine Zelle ist dabei immer die Testzelle, in der die Leistung  $P_T$  aus dem quadratischen Empfänger gemessen wird. Für diese Testzelle wird dann im Folgenden ein eigener Schwellwert  $S_D$  bestimmt, um zu ermitteln ob sich in dieser Zelle ein Ziel befindet.

Dargestellt ist das Ganze in Abbildung 20, wo die Funktionsweise des *Cell-Averaging-CFAR (CA-CFAR)* gezeigt ist. Grundsätzlich ist der Standardaufbau bei den CFAR-Verfahren gleich, nur dass sich die Verarbeitung der Rauschwerte zwischen den Anwendungen unterscheidet. Die beiden Zellen direkt neben der markierten Testzelle werden nicht betrachtet, da diese Werte von einem eventuellen Ziel in der Testzelle beeinflusst sein könnten. Die übrigen Nachbarn werden in Betracht gezogen, um den Rauschpegel zu bestimmen.




Abbildung 20: Darstellung des CA-CFAR Funktionsprinzips

Beim CA-CFAR werden alle Werte der Nachbarzellen von  $P_1$  bis  $P_l$  addiert. Mit dieser Summe wird anschließend die mittlere Leistung ermittelt, da das arithmetische Mittel die beste Methode ist, um eine unbekannte Größe zu schätzen. Anschließend wird diese mit dem verfahrensspezifischen Schwellenfaktor  $\alpha_s$  multipliziert. Dieser Faktor wird dazu genutzt, die gewünschte Falschalarmwahrscheinlichkeit einzustellen, und er



ist für jedes CFAR-Verfahren unterschiedlich. Die Schwelle  $S_D$  ergibt sich dann im CA-CFAR aus:

$$S_D = \frac{\alpha_S}{l} \sum_{i=1}^l P_i . \quad (5.57)$$

Anschließend wird die Leistung in der Testzelle mit der errechneten Schwelle verglichen und es wird entschieden, ob ein Ziel vorliegt oder nicht. Eine Herausforderung ergibt sich dann, wenn die Testzelle auf dem Grenzgebiet zwischen zwei unterschiedlichen Rauschgebieten liegt. Dann könnte die Schwelle durch das niedrigere Rauschen auf einer Seite der Testzelle klein genug sein, so dass die Grenze zum stärkeren Rauschen als Ziel erkannt wird.

Abhilfe schafft hier ein *Cell-Averaging-Greatest-Of*-CFAR (**CAGO-CFAR**), welches in [Han73] beschrieben wird und in Abbildung 21 dargestellt ist. Bei diesem Verfahren werden die Werte der Nachbarzellen zu jeder Seite einzeln addiert. Anschließend wird der größere der beiden Mittelwerte genutzt, um wie zuvor die Schwelle zu errechnen.

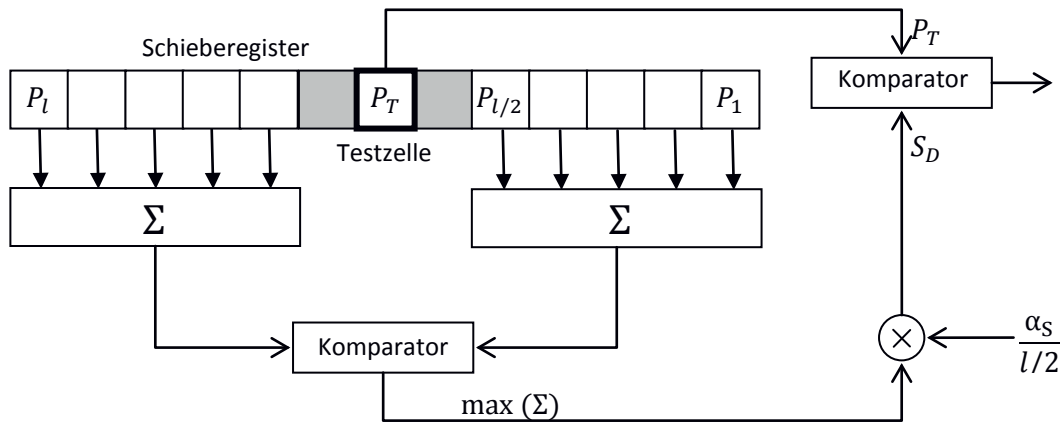


Abbildung 21: Darstellung des CAGO-CFAR Funktionsprinzips

Ein Nachteil der beiden CA-CFAR-Verfahren sind Probleme, die in Mehrzielsituationen auftreten können. Das liegt daran, dass ein Ziel, welches in den Nachbarzellen liegt, die



Detektionsschwelle für die Testzelle erhöhen würde, so dass hier das in der Testzelle befindliche Ziel nicht detektiert werden würde [Lud02].

In [Roh83] wird ein Verfahren vorgestellt, welches das Vorgehen in dieser Hinsicht verbessert. Das sogenannte *Ordered-Statistic*-CFAR (**OS-CFAR**) wird in Abbildung 22 dargestellt. Hierbei werden die Werte der Nachbarzellen der Größe nach geordnet und anschließend wird ein zuvor bestimmtes Element mit Rang  $k$  ausgewählt und als Referenz benutzt.

Nachbarzellen, welche ein Ziel enthalten, beinhalten eine große Leistung, die beim CA-CFAR durch einen Anstieg des Mittelwertes ein mögliches Ziel in der Testzelle maskieren kann. Beim OS-CFAR würde diese Nachbarzelle durch die Sortierung nach Signalgröße ganz oben landen. Diese Zelle hätte dann keinen weiteren Einfluss auf die Schwellenberechnung, da ein tieferliegendes Element als Referenzwert genommen wird.

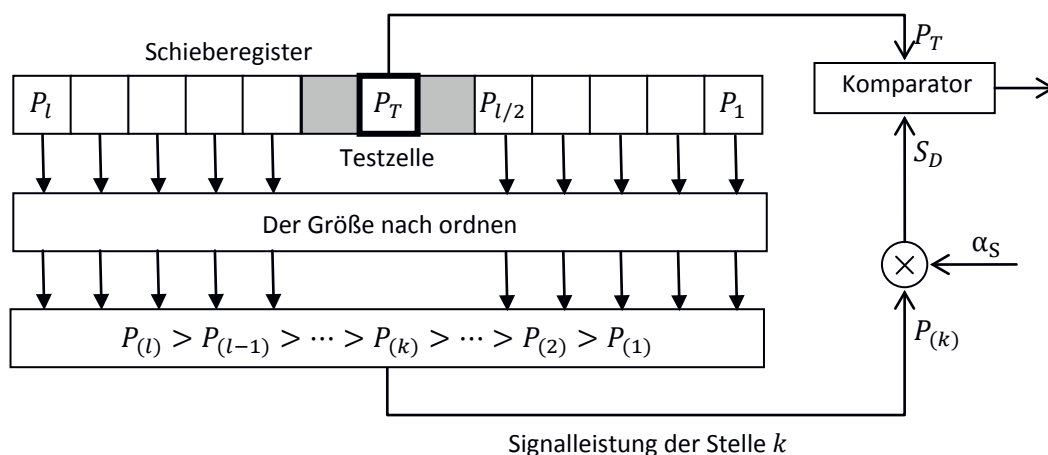


Abbildung 22: Darstellung des OS-CFAR Funktionsprinzips

Der Referenzwert des  $k$ -ten Elements gilt dann als gute Schätzung für das mittlere Rauschen der Umgebung. Damit ergibt sich die Detektionsschwelle zu

$$S_D = \alpha_S P_{(k)} . \quad (5.58)$$



In Mehrzielsituationen, wie sie in der Verkehrsüberwachung hauptsächlich vorkommen, ist das OS-CFAR den zuvor genannten Verfahren überlegen.

Wenn sich allerdings die Testzelle genau an der Grenze von verschiedenen Rauschgebieten befindet, also eine Seite stark verrauscht und die andere weniger verrauscht ist, kann die Rauschkante dann oft fälschlicherweise als Ziel erkannt werden, da der  $k$ -te Rang in diesem Sonderfall eine falsche Referenz darstellt.

Abhilfe schafft hier das *Ordered-Statistic-Greatest-Of*-CFAR (**OSGO-CFAR**), welches in Abbildung 23 dargestellt ist. Hier wird ebenso wie beim CAGO-CFAR der Bereich in zwei Teile vor und nach der Testzelle geteilt. In beiden Teilen werden die Werte getrennt voneinander der Größe nach sortiert und das  $k$ -te Element wird ausgewählt. Anschließend werden die gewählten Elemente beider Seiten miteinander verglichen und das größere von beiden für die Schwellenberechnung benutzt.

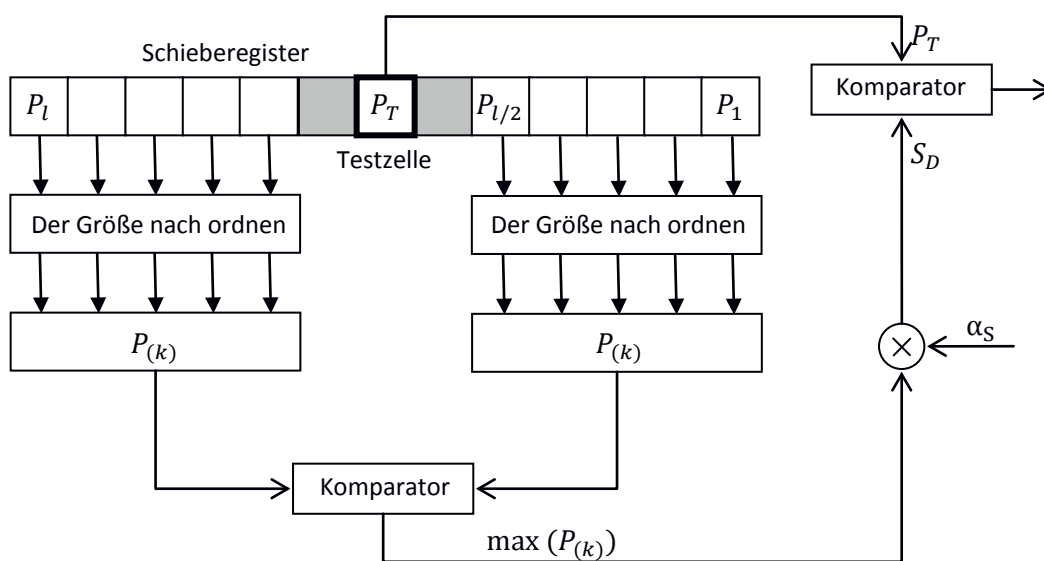


Abbildung 23: Darstellung des OSGO-CFAR Funktionsprinzips

Weitere Details und Berechnungen zu den genannten CFAR-Verfahren sowie Berechnungen zum CFAR-Verlust befinden sich in [Lud02].

## 6 Tracking

Der Radarsensor führt wie beschrieben in jedem Messzyklus, basierend auf einer Schwellwertabfrage, die Zieldetektion durch. Wenn der Radarsensor eine Straßenkreuzung beobachtet, dann befinden sich dort viele Fahrzeuge, in diesem Fall die sogenannten Radarobjekte, gleichzeitig im Sichtbereich des Sensors. In einer solchen Mehrzielsituation werden in jedem Messzyklus, welcher einige Millisekunden dauert, mehrere Ziele detektiert.

Von allen Radarzielen werden in jedem Messzyklus die individuellen Eigenschaften – die Entfernung  $r$ , der Azimutwinkel  $\varphi$  und die radiale Geschwindigkeit  $v_r$  – ermittelt und im Messvektor  $z_{mess}$  zusammengefasst. Zusätzlich wird durch ein stochastisches Modell die Messgenauigkeit der einzelnen Zieleigenschaften durch die Standardabweichung  $\sigma_{mess}$  beschrieben. Diese Standardabweichung wird gemeinsam mit dem dazugehörigen Messvektor des Ziels in einer Zielliste abgelegt, welche in jedem Messzyklus aktualisiert wird. Nach jedem Zyklus ergibt sich demnach mit der Zielliste eine Momentaufnahme sämtlicher Radarziele, die zu einem gegebenen Zeitpunkt im Beobachtungsbereich detektiert wurden.

Die Aufgabe eines Trackingalgorithmus besteht darin, zu jedem realen Radarobjekt einen sogenannten Track anzulegen und zu berechnen. Diese pro Objekt individuelle Zielspur entsteht durch die zeitliche Folge detektierter Radarziele und der dazugehörigen Berechnung der Zielkoordinaten. Dabei werden die in einem Zyklus berechneten Messvektoren mit den Zieleigenschaften der bereits in der Vergangenheit angelegten



Tracks in Verbindung gebracht. Diese Aufgabe wird als Objektverfolgung, Zielspurberechnung oder allgemein als Tracking bezeichnet.

Erschwerend für die Objektverfolgung ist, dass sich die Radarobjekte in eine nicht bekannte Richtung bewegen und sich individuell verhalten. Außerdem ändert sich ihr Verhalten abhängig von äußeren Einflüssen, wie unter anderem im Bereich von Lichtsignalanlagen.

In der Beobachtungshistorie ist bereits eine Vielzahl von Tracks vorhanden, womit eine genaue Kenntnis über das beobachtete Szenario vorliegt. Die Beschreibung eines Tracks erfolgt pro Zyklus ähnlich wie bei den Zielen durch einen Vektor, dem sogenannten Zustandsvektor  $t$ , in dem die Position sowie Informationen über die bisherige Bewegung des Tracks enthalten sind.

Äquivalent zur Zielliste gibt es eine Trackliste, welche durch den Trackingalgorithmus mit jedem Messzyklus aktualisiert wird. Diese Liste ist eine Ausgabe des Radarsensors. Sie gibt dem Beobachter einen genauen Überblick über das beobachtete Szenario und die dazugehörigen Radarobjekte, welche sich im Sichtbereich des Sensors befinden.

Durch das Tracking werden in jedem Zyklus die Informationen über die Vergangenheit aus der Trackliste mit den aktuellen Messungen aus der Zielliste verglichen, so dass einem Track ein detektiertes Ziel aus diesem Messzyklus zugewiesen wird. Die Tracks werden anschließend durch diese zugeordneten Ziele aktualisiert. Dabei wird ein zeitlicher Zusammenhang zwischen der Vergangenheit eines Tracks und einer aktuellen Zielmessung hergestellt, um die Trackliste zu aktualisieren.

Der Trackingalgorithmus lässt sich in vier Teilbereiche unterteilen, welche im Folgenden erläutert werden.

Zu Beginn der Radarmessung wird ein Track initialisiert und ein neuer Zustandsvektor  $t$  angelegt, wenn die Zieleigenschaften eines detektierten Ziels zu keinem bereits bestehenden Track passen. Es wird angenommen, dass hier ein neuer Track für ein bis dahin nicht beobachtetes Radarobjekt angelegt werden muss. Dieser Vorgang, einen neuen Track anzulegen und in die Trackliste zu integrieren, wird als **Initialisierung** bezeichnet.



Wenn ein vergangener Zustand eines Objektes bekannt ist, kann prognostiziert werden, wo im nächsten Messzyklus ein Ziel zu erwarten ist. Dieser Schritt der Vorhersage wird als **Prädiktion** bezeichnet und bildet den ersten wichtigen Schritt eines Trackingfilters. Diese Prädiktion wird anhand eines bestimmten Bewegungsmodells durchgeführt.

Im Anschluss an die Prädiktion wird der Messvektor eines Ziels aus der aktuellen Zielliste dieses Messzyklus gesucht, welcher zu einem bereits etablierten Track passt. Diese Aufgabe nennt man **Assoziation**, wo die detektierten Ziele mit den bereits vorhandenen Tracks abgeglichen werden, um eine richtige Zuordnung zu erreichen.

Wenn ein Messvektor zum Track assoziiert wurde, kann anschließend der zweite wichtige Filterschritt, ein sogenanntes **Update**, gerechnet werden. Dieses ist die Korrekturphase, in welcher der zuvor geschätzte Zustand mit dem assoziierten Ziel verglichen wird. Anschließend wird der Zustand, der nach der Prädiktion erwartet wurde, in die Richtung des Ziels korrigiert. Dies sorgt dafür, dass die Tracks durch die detektierten Ziele beeinflusst werden und nicht ausschließlich der in der Prädiktion erwarteten Bewegungsrichtung folgen.

Der Ablauf eines solchen Trackingverfahrens wird in Abbildung 24 beschrieben. Hier werden die vier wichtigen Schritte der Objektverfolgung mit Initialisierung, Prädiktion, Assoziation und Update in dem Zeitverlauf von jeweils einem Messzyklus dargestellt.



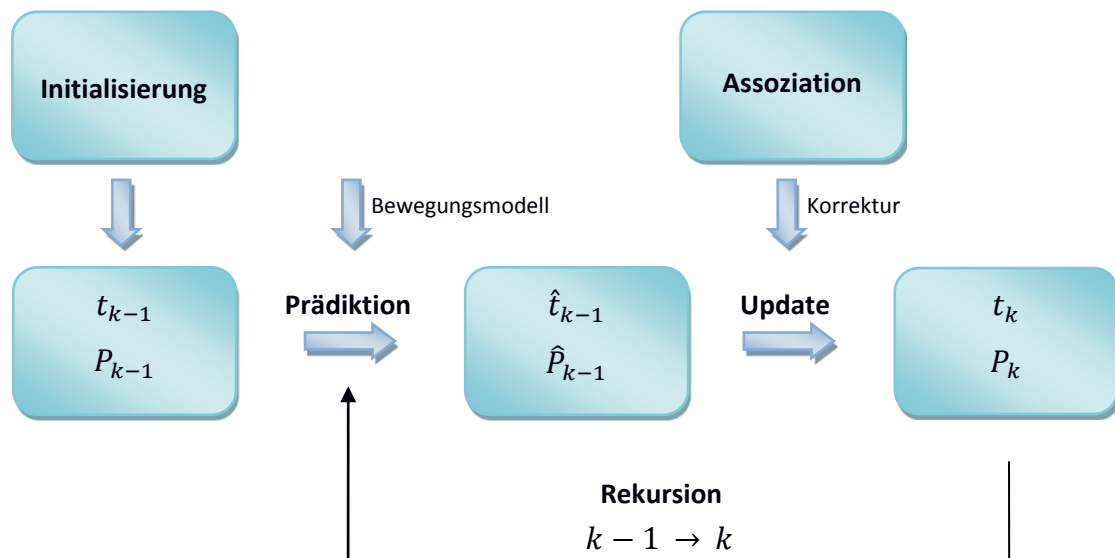


Abbildung 24: Ablauf eines Filterzyklus, in dem der Zustandsvektor  $t$  und die dazugehörige Kovarianzmatrix  $P$  geschätzt werden

## 6.1 Bewegungsmodelle

In einem vom Radarsensor beobachteten Szenario bewegen sich die Objekte in beliebige und zunächst nicht bekannte Richtungen. Die Herausforderung für das Trackingverfahren besteht darin, die Bewegungsrichtung sowie insbesondere die Änderungen dieser Bewegungsrichtung zu erkennen und entsprechend zu reagieren, damit der Zustandsvektor  $t$  passend geschätzt werden kann.

Die Bewegung der Radarobjekte wird daher durch geeignete Bewegungsmodelle erfasst. Diese Bewegungsmodelle beinhalten Annahmen über die Art der Bewegung, beispielweise ob sich die Objekte in einer Geradeaus- oder in einer Kreisfahrt befinden, eine konstante Geschwindigkeit fahren oder abbremesen beziehungsweise beschleunigen.

Diese unterschiedlichen Bewegungsmodelle werden genutzt, um in der Prädiktionsphase die Position und Bewegung der beobachteten Objekte vorherzusagen. Durch die



Dynamik der Modelle wird angegeben, welche Erwartung an die Bewegung des Objektes geknüpft ist. Aus dem Bewegungsmodell werden auch die Form und die Struktur des dazugehörigen Zustandsvektors  $t$  bestimmt.

Das erste in dieser Arbeit betrachtete Bewegungsmodell ist eine Geradeausfahrt mit konstanter Geschwindigkeit. Dort wird erwartet, dass das beobachtete Objekt sich in die gleiche Richtung wie zuvor mit gleichbleibender Geschwindigkeit bewegt. Hier hat der Zustandsvektor  $t$  die folgende Form:

$$t = \begin{pmatrix} x \\ y \\ v_x \\ v_y \end{pmatrix}. \quad (6.1)$$

Dieser Zustandsvektor  $t$  beschreibt den Zustand des Tracks in kartesischen Koordinaten. Dabei steht  $x$  für die Position in  $x$ -Richtung,  $y$  für die Position in  $y$ -Richtung und  $v_x$  und  $v_y$  stehen für die Geschwindigkeiten in ebendiese Richtungen.

Bei einer Geradeausfahrt mit konstanter Geschwindigkeit verändern sich die beiden Geschwindigkeitskomponenten  $v_x$  und  $v_y$  nicht und werden folglich in dem Bewegungsmodell einer Geradeausfahrt als konstant angenommen. Damit ist die Annahme dieses Bewegungsmodells implizit, dass sich weder Geschwindigkeit noch Fahrtrichtung des Objektes ändern. Die einzelnen Komponenten dieses **Geradeaus-Bewegungsmodells** werden in Abbildung 25(a) dargestellt.

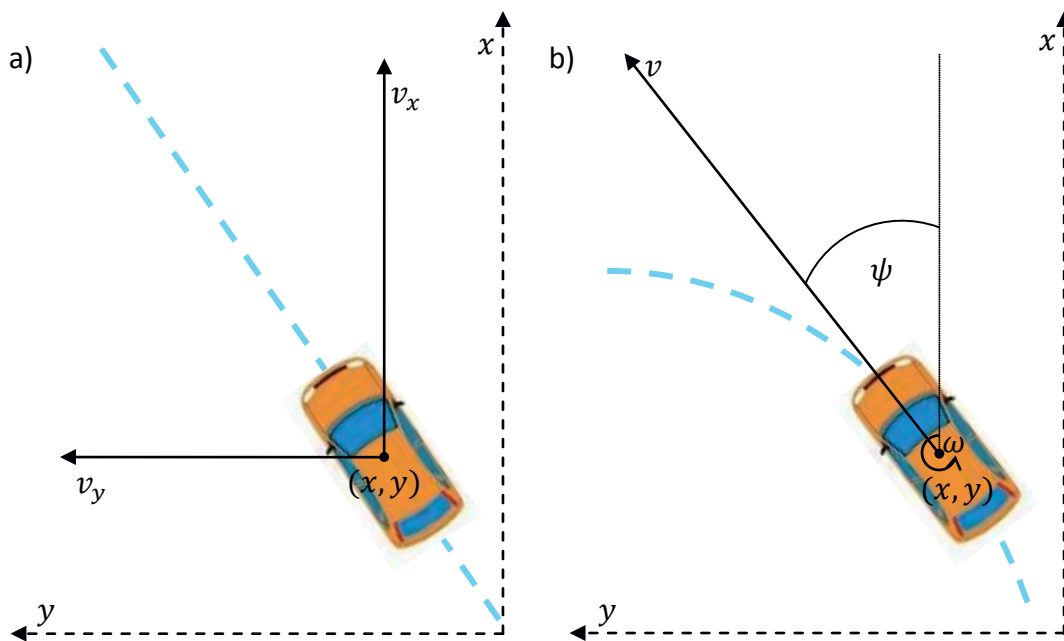
Ein zweites häufig genutztes Bewegungsmodell nimmt anstelle der Geradeausfahrt an, dass sich das Objekt in einer Kreisbewegung befindet. Die Annahme des Bewegungsmodells ist, dass sich das Objekt mit konstanter Geschwindigkeit auf einer Kreisbahn mit gleichbleibendem Radius bewegt. Auf einer solchen Kreisbahn ändert sich der Ausrichtungswinkel des Objektes gleichmäßig mit dessen Drehgeschwindigkeit. Diese Drehgeschwindigkeit  $\omega$  wird als konstant angenommen [MG05] und somit ändert sich der Ausrichtungswinkel  $\psi$ . Dieses in Abbildung 25(b) dargestellte **Kreisfahrt-Bewegungsmodell** nutzt den folgenden Zustandsvektor:



$$t = \begin{pmatrix} x \\ y \\ v \\ \psi \\ \omega \end{pmatrix}. \quad (6.2)$$

Das Geradeaus-Bewegungsmodell eignet sich besonders gut, wenn die beobachteten Objekte sich entlang einer Geraden bewegen, wohingegen das Kreisfahrt-Bewegungsmodell seine Stärken bei gleichmäßig gekrümmten Fahrbahnen hat. Die meisten Szenarien im Straßenverkehr setzen sich stückweise aus Geraden und Kreissegmenten zusammen.

Je nachdem, wie sich ein reales Objekt tatsächlich bewegt, muss untersucht werden, wie geeignet die beiden Bewegungsmodelle in unterschiedlichen Szenarien sind.



**Abbildung 25:** a) Komponenten des Bewegungsmodells der Geradeausfahrt mit  $x$ ,  $y$ ,  $v_x$  und  $v_y$   
 b) Komponenten des Bewegungsmodells einer Kreisfahrt mit  $x$ ,  $y$ ,  $v$ ,  $\psi$  und  $\omega$



## 6.2 Initialisierung

Um den ersten Filterdurchlauf zu starten, ist zunächst eine Initialisierung notwendig. Die Berechnung der Initialisierung hängt dabei vom gewählten Bewegungsmodell ab. In diesem Kapitel wird das Geradeaus-Modell betrachtet, wobei die Gleichungen für andere Bewegungsmodelle dementsprechend modifiziert werden können.

Die Initialisierung beginnt mit der Detektion eines Ziels, dessen Messvektor zu keinem bestehenden Track passt. Aus dem Messvektor, der aus der Entfernung  $r$ , dem azimutalen Winkel  $\varphi$  und der radialen Geschwindigkeit  $v_r$  besteht und die folgende Form hat

$$z_{mess} = \begin{pmatrix} r \\ \varphi \\ v_r \end{pmatrix}, \quad (6.3)$$

wird der in Gleichung (6.1) beschriebene Zustandsvektor mit Hilfe der folgenden Gleichungen berechnet:

$$x = r \cos(\varphi), \quad (6.4)$$

$$y = r \sin(\varphi), \quad (6.5)$$

$$v_x = \cos(\psi) \frac{v_r}{\cos(\varphi - \psi)}, \quad (6.6)$$

$$v_y = \sin(\psi) \frac{v_r}{\cos(\varphi - \psi)}. \quad (6.7)$$

Dabei sind alle Größen aus dem Messvektor  $z_{mess}$  bekannt bis auf den Ausrichtungswinkel  $\psi$ , der die zunächst unbekannte Bewegungsrichtung des Objektes beschreibt.

Diese Bewegungsrichtung ist unbekannt, weil noch keine Vergangenheit über die Bewegung des Objekts vorhanden ist. Der Ausrichtungswinkel  $\psi$  muss daher bei der Initialisierung eines Tracks geeignet gewählt werden. Durch eine Annahme für den Ausrichtungswinkel  $\psi$  wird es erst möglich, dass aus einem Messvektor  $z_{mess}$  mit drei Koordinaten ein Zustandsvektor  $t$  bestimmt wird, welcher vier Koordinaten beinhaltet.



Die Annahme für die Bewegungsrichtung wird meist mit Vorwissen über das beobachtete Szenario getätigt. Wenn nur ankommende Objekte erwartet werden, kann der Ausrichtungswinkel  $\psi$  entsprechend dieser Bewegungsrichtung gewählt werden. Mit einem angenommenen Ausrichtungswinkel, lässt sich anschließend der erste Zustandsvektor  $t$  für den Track des beobachteten Radarobjektes berechnen.

Zusätzlich ist für einige Trackingfilter die Berechnung der Kovarianzmatrix  $P$  wichtig, mit der die Genauigkeit der einzelnen Zustände quantitativ beschrieben wird. Hierbei wird die Kenntnis der Messgenauigkeit durch Angabe der Standardabweichungen  $\sigma_r$ ,  $\sigma_\varphi$  und  $\sigma_{v_r}$  genutzt. Zusätzlich ist eine angenommene Unsicherheit für den geschätzten Ausrichtungswinkel  $\psi$  nötig:

$$\sigma_{mess}^2 = \begin{pmatrix} \sigma_r^2 \\ \sigma_\varphi^2 \\ \sigma_{v_r}^2 \\ \sigma_\psi^2 \end{pmatrix}. \quad (6.8)$$

Die jeweilige erreichbare Messgenauigkeit ist spezifisch für jeden Radarsensor und gibt an, wie sehr dem gemessenen Wert vertraut werden kann. Die Unsicherheit für den Ausrichtungswinkel  $\psi$  wird als beliebig angenommen, je nachdem wie viel Vorwissen in der Schätzung vorhanden ist.

Diese Unsicherheiten  $\sigma_{mess}$  aus Gleichung (6.8) bilden die Hauptdiagonale der Matrix  $\Sigma$ , während alle anderen Elemente dieser Matrix gleich 0 sind. Anschließend wird zusätzlich die Jacobi-Matrix  $J$  benötigt, in der die partiellen Ableitungen des Zustandsvektors

$$t = \begin{pmatrix} x \\ y \\ v_x \\ v_y \end{pmatrix} = \begin{pmatrix} r \cos(\varphi) \\ r \sin(\varphi) \\ \cos(\psi) \frac{v_r}{\cos(\varphi - \psi)} \\ \sin(\psi) \frac{v_r}{\cos(\varphi - \psi)} \end{pmatrix} \quad (6.9)$$

nach den Messgrößen  $r$ ,  $\varphi$  und  $v_r$  und zusätzlich des geschätzten Ausrichtungswinkels  $\psi$  in Spalten angeordnet werden. Damit ergibt sich die Jacobi-Matrix



$$J = \begin{bmatrix} \cos(\varphi) & -r \sin(\varphi) & 0 & 0 \\ \sin(\varphi) & r \cos(\varphi) & 0 & 0 \\ 0 & \frac{v_r \cos(\psi) \sin(\varphi - \psi)}{\cos^2(\varphi - \psi)} & \frac{\cos(\psi)}{\cos(\varphi - \psi)} & -v_r \frac{(\sin(\psi) \cos(\varphi - \psi) + \cos(\psi) \sin(\varphi - \psi))}{\cos^2(\varphi - \psi)} \\ 0 & \frac{v_r \sin(\psi) \sin(\varphi - \psi)}{\cos^2(\varphi - \psi)} & \frac{\sin(\psi)}{\cos(\varphi - \psi)} & v_r \frac{(\cos(\psi) \cos(\varphi - \psi) - \sin(\psi) \sin(\varphi - \psi))}{\cos^2(\varphi - \psi)} \end{bmatrix}, \quad (6.10)$$

aus der anschließend die Kovarianzmatrix  $P$  mit Hilfe der Hauptdiagonalmatrix  $\Sigma$ , die die Unsicherheiten der Messwerte beinhaltet, berechnet werden kann:

$$P = J \Sigma J^T. \quad (6.11)$$

Die hierbei entstehende Kovarianzmatrix  $P$  ist symmetrisch und positiv definit.

Damit ist die Initialisierung abgeschlossen und der eigentliche rekursive Ablauf kann mit dem erstmalig berechneten Zustandsvektor  $t$  begonnen werden.

## 6.3 Filterung mit Prädiktion und Update

Im vorherigen Abschnitt wurde dargestellt, wie der Messvektor eines Ziels genutzt wird, um den ersten Zustandsvektor eines Tracks zu erzeugen. Nun soll erklärt werden, wie dieser Zustandsvektor in den Filtern genutzt wird. Im Folgenden werden einige häufig eingesetzte Filter mit ihren entsprechenden Stärken und Schwächen dargestellt.

### 6.3.1 $\alpha$ - $\beta$ -Filter

Dieses Trackingfilter soll zunächst dazu dienen, eine Grundidee über die Funktionsweise der Filterung zu geben, indem hier ein einfacher Fall betrachtet wird. Für das  $\alpha$ - $\beta$ -Filter wird ein Geradeaus-Modell als Bewegungsmodell gewählt. Als Annahme soll davon ausgegangen werden, dass die Initialisierung bereits erfolgt ist und ein Zustandsvektor  $t_{k-1}$  des Filters zum Zyklus  $k - 1$  bekannt ist und folgende Form hat:



$$t_{k-1} = \begin{pmatrix} x_{k-1} \\ y_{k-1} \\ v_{x_{k-1}} \\ v_{y_{k-1}} \end{pmatrix}. \quad (6.12)$$

Im ersten Schritt der **Prädiktion** wird geprüft, an welchem Ort das Objekt nach der nächsten Messung erwartet wird. Dafür wird zumeist eine konstante Geschwindigkeit angenommen. Die Position des Objektes würde sich demnach abhängig von der bekannten Geschwindigkeit und der Zykluszeit  $\Delta t$  ändern. Dies führt zu einem Geradeaus-Bewegungsmodell und damit zu dem prädizierten Zustand  $\hat{t}_k$ :

$$\hat{t}_k = \begin{pmatrix} \hat{x}_k \\ \hat{y}_k \\ \hat{v}_{x_k} \\ \hat{v}_{y_k} \end{pmatrix} = \begin{pmatrix} x_{k-1} + v_{x_{k-1}} \Delta t \\ y_{k-1} + v_{y_{k-1}} \Delta t \\ v_{x_{k-1}} \\ v_{y_{k-1}} \end{pmatrix}. \quad (6.13)$$

Anschließend wird betrachtet, an welcher Position  $x_{mess}$  und  $y_{mess}$  das Objekt im nächsten Zyklus wieder detektiert wird, und der Zustand wird dementsprechend korrigiert, so dass der Zustand nach dem **Update** folgende Form annimmt:

$$t_k = \begin{pmatrix} x_k \\ y_k \\ v_{x_k} \\ v_{y_k} \end{pmatrix} = \begin{pmatrix} \hat{x}_k + \alpha (x_{mess} - \hat{x}_k) \\ \hat{y}_k + \alpha (y_{mess} - \hat{y}_k) \\ \hat{v}_{x_k} + \beta \left( \frac{x_{mess} - \hat{x}_k}{\Delta t} \right) \\ \hat{v}_{y_k} + \beta \left( \frac{y_{mess} - \hat{y}_k}{\Delta t} \right) \end{pmatrix}. \quad (6.14)$$

Die Faktoren  $\alpha$  und  $\beta$ , welche hier als Update-Faktoren angenommen werden, geben dem Filter seinen Namen [Bro98] und sorgen für die entsprechende Filterung, da den Messwerten aufgrund von Messunsicherheiten nicht exakt vertraut werden kann.

Dazu wird ein kurzes eindimensionales Zahlenbeispiel aufgezeigt, welches durch Abbildung 26 verdeutlicht werden soll. Die Bewegung in  $y$ -Richtung wird dabei vernachlässigt. Zunächst existiert ein Objekt in 50 m Entfernung, welches sich mit 10 m/s vom Betrachter in  $x$ -Richtung entfernt. Einen Messzyklus später, welcher ungefähr 100 ms dauert, würde ein Ziel aufgrund der angenommenen Geschwindigkeit in 51 m Entfernung erwartet werden. Gemessen wird das Objekt nach dieser Zeit



allerdings bei 51,2 m, daher sollte es ungefähr mit einer Geschwindigkeit von 12 m/s gefahren sein.




Abbildung 26: Schematische Darstellung des Filterzyklus eines  $\alpha$ - $\beta$ -Filters

Daraus ergibt sich, dass entweder die erwartete Geschwindigkeit fehlerbehaftet ist und diese sich zwischendurch geändert hat oder aber, dass die Entfernungsmessung sehr ungenau ist. Da die Sicherheit der Messung nicht gewährleistet ist, wird die Geschwindigkeit nicht einfach auf den neuen Wert geändert, sondern nur um einen gewissen Anteil in Richtung der 12 m/s erhöht. Ebenso wird die neue Position nicht auf 51,2 m geändert, sondern nur etwas von dem angenommenen Wert der 51 m erhöht. Um welchen Anteil diese Größen jeweils erhöht werden, hängt von den Filterfaktoren  $\alpha$  und  $\beta$  ab.

Nachdem ein Zyklus abgeschlossen ist, startet der nächste wieder mit einer Prädiktion des aktuellen Zustands und der Vorgang wiederholt sich in rekursiver Form.

Wie groß die Filterfaktoren  $\alpha$  und  $\beta$  gewählt werden, hängt von der Messgenauigkeit des Radarsensors ab. Wenn die Messungen sehr genau sind, dann wird stärker in Richtung der Messung korrigiert. Wenn sie eine große Unsicherheit besitzen, wird dem bis dahin gefilterten Zustand des Tracks mehr vertraut. Werden feste Korrekturfaktoren  $\alpha$  und  $\beta$  genutzt, ist das Filter solange stabil und gut, wie das Objekt sich nach der Annahme des Bewegungsmodells bewegt. Sobald die Annahme der konstanten Geschwindigkeit nicht mehr gültig ist, wird der Trackingfehler mit der Zeit größer.





### 6.3.2 Kalman-Filter

Das 1960 von R.E. Kalman [Kal60] vorgestellte Kalman-Filter vermeidet das in Abschnitt 6.3.1 aufgezeigte Problem der konstanten Filterfaktoren, indem die Filterfaktoren von Zyklus zu Zyklus angepasst werden. Dabei werden sowohl die Unsicherheit der jeweiligen Messung als auch die Unsicherheit des bis dahin gefilterten Tracks bedacht. Diese Trackunsicherheit wird durch die Kovarianzmatrix  $P$  des Tracks beschrieben. Sie wird in jedem Zyklus zusätzlich zum Zustandsvektor  $t$  gefiltert und an die Gegebenheiten angepasst.

Eine Übersicht des Ablaufs wurde in Kapitel 6 in Form von Abbildung 24 dargestellt. Dort sind die bereits kurz beschriebenen Abschnitte von Initialisierung, Prädiktion und Update einzeln dargestellt. Anschließend wird detailliert auf den Ablauf eingegangen. Das gesamte Verfahren wird in [WB06] und [Gel74] hergeleitet und soll im Folgenden anhand eines Beispiels aus dem Tracking-Bereich erläutert werden.

Dazu wird der in der Initialisierung in Kapitel 6.2 errechnete Zustandsvektor  $t$  genutzt, der auch hier mit dem Geradeaus-Bewegungsmodell beschrieben wird. Über den Ablauf verändert sich der Zustandsvektor  $t$  mit der Zeit, daher hängt der Zustandsvektor  $t_k$  zum Zeitpunkt  $k$  vom vorherigen Zustand  $t_{k-1}$  ab, da sich das beobachtete Objekt in einer kontinuierlichen Bewegung befindet.

Diese Bewegung wird durch physikalische Zusammenhänge mit der Transformationsmatrix  $\Phi$  beschrieben. Zusätzlich hängt die Bewegung von dem Eingangssignal  $u_k$  multipliziert mit der Matrix  $B$  ab. Dieses Eingangssignal nimmt aktiv Einfluss auf die Bewegung, so wie bei einem Fahrzeug die Eingabe die Lenkung ist, welche bestimmt, in welche Richtung gefahren wird. Zusätzlich wird das Prozessrauschen  $r_k$  hinzuaddiert. Dies führt zu folgendem Modell für den Zustandsvektor:

$$t_k = \Phi t_{k-1} + B u_k + r_k . \quad (6.15)$$

Da durch das Verkehrsbeobachtungssystem kein Einfluss auf die betrachteten Fahrzeuge genommen werden kann und damit das Eingangssignal unbekannt ist, vereinfacht sich die Gleichung zu



$$t_k = \Phi t_{k-1} + r_k . \quad (6.16)$$

Das Prozessrauschen steht für die Unsicherheit der angenommenen Bewegung. Dieser Term ist nötig, da sich das beobachtete Fahrzeug nicht nur nach voraussehbaren physikalischen Regeln bewegt, sondern ebenfalls Beschleunigungen und Lenkmanöver durchführen kann, die für den Beobachter zunächst unbekannt sind. Dieses Prozessrauschen wird als weiß und normalverteilt angenommen und hat die Kovarianzmatrix  $Q_k$ .

$$r_k \sim N(0, Q_k) . \quad (6.17)$$

Um die Transformationsmatrix  $\Phi$  zu ermitteln, werden zunächst die physikalischen Zusammenhänge dargestellt. Die einzelnen Komponenten des Zustandsvektors  $t_k$  zum Zeitpunkt  $k$  hängen ebenso wie in Gleichung (6.13) von den Zuständen des vorherigen Zyklus ab:

$$t_k = \begin{pmatrix} x_k \\ y_k \\ v_{x_k} \\ v_{y_k} \end{pmatrix} = \begin{pmatrix} x_{k-1} + v_{x_{k-1}} \Delta t \\ y_{k-1} + v_{y_{k-1}} \Delta t \\ v_{x_{k-1}} \\ v_{y_{k-1}} \end{pmatrix} . \quad (6.18)$$

Die Transformationsmatrix  $\Phi$  drückt dabei genau jene Abhängigkeit der Zustände zwischen den Zyklen aus. Um die Matrix zu ermitteln, wird der in Gleichung (6.18) aufgeschlüsselte Zustandsvektor nach seinen eigenen Komponenten abgeleitet. D. h., zunächst werden alle Zeilen nach  $x$ ,  $y$ ,  $v_x$  und  $v_y$  abgeleitet und die einzelnen Ableitungen werden in die Spalten der Matrix geschrieben, so dass sich die Transformationsmatrix  $\Phi$  für das Geradeaus-Modell zu

$$\Phi = \begin{bmatrix} 1 & 0 & \Delta t & 0 \\ 0 & 1 & 0 & \Delta t \\ 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 1 \end{bmatrix} \quad (6.19)$$

ergibt.

Mit Hilfe dieser Matrix wird nun die **Prädiktion** durchgeführt, so dass die Vorhersage



$$\hat{t}_k = \Phi t_{k-1} \quad (6.20)$$

durch Anwendung des physikalischen Modells erlangt wird. Im Prädiktionsschritt wird auch die dazugehörige Kovarianzmatrix  $P_k$  dementsprechend aus der Kovarianzmatrix des vergangenen Zyklus  $P_{k-1}$  geschätzt:

$$\hat{P}_k = \Phi P_{k-1} \Phi^T + Q_k . \quad (6.21)$$

Die Kovarianzmatrix  $P_k$  gibt die Unsicherheit des Tracks zum Zeitpunkt  $k$  an. Nach einer Prädiktion wird der Zustand des Tracks unsicherer, da dieser Zwischenschritt geschätzt wird. Zusätzlich wird daher der Kovarianzmatrix ein weiterer Unsicherheits-term  $Q_k$  hinzugefügt, um eventuelle Widersprüche der Bewegung zum gewählten Bewegungsmodell zu beachten. Dieser Term wird im Allgemeinen als Prozessrauschmatrix bezeichnet und kommt durch das Prozessrauschen  $r_k$  zustande, das die Bewegung wie in Gleichung (6.16) beeinflusst. Mit ihm können Situationen ausgeglichen werden, die im Modell nicht vorgesehen sind, wie im Geradeaus-Modell beispielsweise jede Art von Beschleunigungen und Verzögerungen. Die Wahl und Einstellung der Prozessrauschmatrix ist eine der wichtigsten Stellschrauben für die Filterperformance.

Es gibt keine festen Regeln, nach denen die Systemrauschmatrix  $Q_k$  berechnet wird, da die Rauschmatrix eine der besten Stellgrößen ist, um die Empfindlichkeit des Filters zu beeinflussen. Eine einfache Möglichkeit ist es, die Unsicherheit einer Beschleunigung des Objektes zu berücksichtigen. Diese Unsicherheit wird zu der prädizierten Kovarianzmatrix addiert, um  $\hat{P}_k$  zu erhalten und damit eine mögliche Beschleunigung der Objekte zu berücksichtigen, obwohl sie nicht im Modell enthalten ist. Die Systemrauschmatrix gibt dem Modell damit mehr Flexibilität.

Mit Gleichungen (6.20) und (6.21) wird der Prädiktionsschritt komplett gerechnet. Im Anschluss soll diese Vorhersage durch einen Messvektor  $z_{mess}$  korrigiert werden. Dieses geschieht im sogenannten **Update**.

Bei einem Radarsensor hat der Messvektor normalerweise die in Gleichung (6.3) angegebene Form. Er beinhaltet die Entfernung  $r$ , den Azimutwinkel  $\varphi$  und die radiale Geschwindigkeit  $v_r$  eines Ziels. Die Messung hängt dabei mit dem Zustandsvektor über die Messmatrix  $H$  zusammen und beinhaltet zusätzlich das Messrauschen  $m_k$  [Bla86]:



$$z_{mess} = H t_k + m_k . \quad (6.22)$$

Das Messrauschen ist unabhängig vom Prozessrauschen, wird aber ebenfalls als weiß und normalverteilt angenommen und hat die Kovarianzmatrix  $R_k$ .

$$m_k \sim N(0, R_k) . \quad (6.23)$$

Um im Folgenden den prädizierten Zustandsvektor mit der Messung  $z_{mess}$  vergleichen zu können, muss er in Radarkoordinaten überführt werden. Dazu werden die folgenden Gleichungen genutzt. Um die Übersicht zu wahren, wird der Zeitpunkt  $k$  ab jetzt nicht mehr dargestellt.

$$r = \sqrt{x^2 + y^2} , \quad (6.24)$$

$$\varphi = \arctan\left(\frac{y}{x}\right) , \quad (6.25)$$

$$v_r = \frac{xv_x + yv_y}{\sqrt{x^2 + y^2}} . \quad (6.26)$$

Aus dem prädizierten Zustandsvektor

$$\hat{t} = \begin{pmatrix} \hat{x} \\ \hat{y} \\ \hat{v}_x \\ \hat{v}_y \end{pmatrix} \quad (6.27)$$

wird mit Hilfe der Gleichungen (6.24), (6.25) und (6.26) der prädizierte Zustandsvektor in Radarkoordinaten

$$\hat{z} = \begin{pmatrix} \hat{r} \\ \hat{\varphi} \\ \hat{v}_r \end{pmatrix} = \begin{pmatrix} \sqrt{\hat{x}^2 + \hat{y}^2} \\ \arctan\left(\frac{\hat{y}}{\hat{x}}\right) \\ \frac{\hat{x}\hat{v}_x + \hat{y}\hat{v}_y}{\sqrt{\hat{x}^2 + \hat{y}^2}} \end{pmatrix} . \quad (6.28)$$

Um auf die Kovarianzmatrix  $P$  ebenfalls diese Koordinatentransformation anzuwenden, wird die Messmatrix  $H$  benötigt. Diese kann berechnet werden, in dem der prädizierte Messvektor  $\hat{z}$  nach den Variablen des prädizierten Zustandsvektors



abgeleitet wird. Die einzelnen Ableitungen nach  $\hat{x}$ ,  $\hat{y}$ ,  $\hat{v}_x$  und  $\hat{v}_y$  bilden anschließend die Spalten der Messmatrix

$$H = \begin{bmatrix} \frac{\hat{x}}{\hat{r}} & \frac{\hat{y}}{\hat{r}} & 0 & 0 \\ -\frac{\hat{y}}{\hat{r}^2} & \frac{\hat{x}}{\hat{r}^2} & 0 & 0 \\ -\frac{\hat{y}(\hat{x}\hat{v}_y - \hat{y}\hat{v}_x)}{\hat{r}^3} & \frac{\hat{x}(\hat{x}\hat{v}_y - \hat{y}\hat{v}_x)}{\hat{r}^3} & \frac{\hat{x}}{\hat{r}} & \frac{\hat{y}}{\hat{r}} \end{bmatrix}, \quad (6.29)$$

wobei  $\hat{r}$  nach Gleichung (6.24) eingesetzt wurde.

Anschließend kann eine Innovation  $z_{inno}$  berechnet werden. Sie gibt die Differenz zwischen dem gemessenen und dem prädizierten Messvektor an, sie zeigt demnach, wie weit die Prädiktion von dem Messwert entfernt liegt.

$$z_{inno} = z_{mess} - \hat{z}. \quad (6.30)$$

Zusätzlich wird dann die Innovationskovarianzmatrix  $\hat{S}$  aus der prädizierten Kovarianzmatrix des Zustands  $\hat{P}$  errechnet:

$$\hat{S} = H \hat{P} H^T + R. \quad (6.31)$$

Im Anschluss wird zur Umrechnung der Kovarianzmatrix mittels Messmatrix  $H$  die Messrauschmatrix  $R$  dazuaddiert. Diese Hauptdiagonalmatrix  $R$  ist abhängig vom Sensor, durch den die entsprechende Messung durchgeführt wird, und ist während der Messung bekannt. Auf der Diagonale der Messrauschmatrix stehen die Messunsicherheiten von Entfernung, Winkel und radialer Geschwindigkeit des Ziels, mit welchem der Track korrigiert werden soll.

Mit Hilfe der prädizierten Kovarianzmatrix  $\hat{P}$ , der Messmatrix  $H$  und der Innovationskovarianzmatrix  $\hat{S}$  kann nun die Verstärkungsmatrix des Filters, die sogenannte Kalman-Matrix  $K$ , berechnet werden:

$$K = \hat{P} H^T \hat{S}^{-1}. \quad (6.32)$$

Diese Kalman-Matrix beinhaltet das Äquivalent der Filterfaktoren [Bla86], welche beim  $\alpha$ - $\beta$ -Filter aus Kapitel 6.3 mit den gleichbleibenden Faktoren  $\alpha$  und  $\beta$  beschrieben



werden. Entgegengesetzt dazu, wird die Verstärkungsmatrix in einem Kalman-Filter in jedem Zyklus neu berechnet und ist von der Unsicherheit des aktuellen Zustands und der Messung abhängig. Hier wird in jedem Zyklus neu entschieden, wie sehr der Prädiktion des Zustandsvektors und dem aktuellen Messwert vertraut wird, so dass eine Adaption zum laufenden Prozess vorgenommen wird.

Der neue, durch das Update korrigierte Zustand ergibt sich aus dem prädizierten Messvektor und der Innovation  $z_{inno}$  wie folgt:

$$t_k = \hat{t}_k + K z_{inno} . \quad (6.33)$$

Die dazugehörige Kovarianzmatrix hängt äquivalent von ihrem prädizierten Pendant und der Innovationskovarianzmatrix  $\hat{S}_k$  ab:

$$P_k = \hat{P}_k - K \hat{S} K^T . \quad (6.34)$$

Der Zustand eines Kalman-Filters wird normalerweise durch die Bestätigung eines Updates und die Korrektur in Richtung des Ziels sicherer, was sich auch in der Kovarianzmatrix niederschlägt. Durch Gleichung (6.33) und (6.34) wurde mittels eines Filterdurchlaufes ein neuer Zustandsvektor samt zugehöriger Kovarianzmatrix gebildet. Dieser kann als Startwert für einen erneuten Durchlauf, beginnend mit einer neuen Prädiktion, genutzt werden, so dass ein rekursiver Prozess durchlaufen wird.

Falls in einem Zeitschritt keine Messungen vorhanden sind, kann kein Korrekturschritt ausgeführt werden. In dem Fall wird nur der Vorhersageschritt durchgeführt und die Unsicherheit in der Kovarianzmatrix  $P_k$  erhöht sich um das Prozessrauschen  $Q_k$ .

Dieses Kalman-Filter geht davon aus, dass die Verteilungen jederzeit durch Mittelwert und Kovarianzmatrix beschrieben werden können. Das setzt voraus, dass das Modell aus Gleichung (6.16) linear ist, dass die Rauschgrößen wie angenommen normalverteilt sowie in Mittelwert und Kovarianz bekannt sind und dass Zustandsvektor und Messvektor in einem linearen Zusammenhang stehen.



### 6.3.3 Extended-Kalman-Filter

Um das Kalman-Filter auch bei nichtlinearen Aufgabestellungen einsetzen zu können, wurde es erweitert. Das oben genannte Tracking-Beispiel besteht aus einem solchen nichtlinearen Fall, da der Zustandsvektor in kartesischen Koordinaten vorliegt und der Messvektor aber Polarkoordinaten liefert und zwischen diesen kein linearer Zusammenhang besteht. Die Messmatrix  $H$  besteht dann nicht mehr aus linearen Faktoren, so dass sich das Zustandsraummodell aus den Gleichungen (6.16) und (6.22) ändert in

$$t_k = \Phi t_{k-1} + r_k , \quad (6.35)$$

$$z_{mess_k} = h(t_k) + m_k . \quad (6.36)$$

Das Extended-Kalman-Filter linearisiert die Messfunktion  $h$ , um die Messmatrix  $H$  zu erhalten. Diese Linearisierung findet zum Zeitpunkt  $k$  der Vorhersage  $\hat{t}_k$  statt und ist nur in einem begrenzten Umfeld des Zustandes gültig [Hay01]. Um diese durchzuführen, muss die Messfunktion, wie bei der Berechnung von  $H$  gezeigt, differenzierbar sein, da die Messmatrix  $H$  sich wie folgt durch die Ableitung der Messfunktion  $h$  nach dem Zustand  $t_k$  ergibt:

$$H = \left. \frac{\partial h(t_k)}{\partial t_k} \right|_{t_k = \hat{t}_k} . \quad (6.37)$$

Die Approximation ist eine Taylornäherung der ersten Ordnung und bringt somit einen Fehler in das System, so dass die Prädiktion von Zustand und Kovarianzmatrix ungenau wird. Dieses geschieht verstärkt, sobald sich der Zustand in nichtlinearer Weise ändert und somit der Fehler durch die Linearisierung größer wird. In diesem Fall kann es zur Divergenz kommen, so dass das beobachtete Objekt nicht mehr verfolgt werden kann.

Dieses kann in Tracking-Situationen dann geschehen, wenn die Annahme des gewählten Bewegungsmodells so stark verletzt wird, dass die Bewegung nicht durch den Filterprozess ausgeglichen werden kann. Beim Geradeaus-Bewegungsmodell tritt diese Situation dann ein, wenn Objekte stark beschleunigen, abbremsen oder wenn sie sich nicht konstant in eine Richtung bewegen.



#### 6.3.4 Unscented-Kalman-Filter

Um auch in nichtlinearen Situationen ein gutes Tracking zu erhalten, wurde 1997 das Unscented-Kalman-Filter vorgestellt [JU97]. Dieses Filter hat bei solchen nichtlinearen Verhaltensweisen eine bessere Performance als das Extended-Kalman-Filter bei gleichem Rechenaufwand.

Dieses Filter umgeht die Transformation mit der Nichtlinearität, indem Zustandsvektor und Kovarianzmatrix nicht direkt transformiert werden. Stattdessen wird der Zustandsvektor als mehrdimensionale Zufallsvariable  $t$  mit Mittelwert  $\bar{t}$  und Kovarianz  $P$  gesehen. Um diese Information über Mittelwert und Kovarianz zu transformieren, werden passend gewichtete Punkte ausgewählt, durch die die beiden Größen entsprechend parametrisiert werden.

Diese Punkte werden zu jedem Zeitpunkt  $k$  so ausgewählt, dass ihr Mittelwert durch den Zustandsvektor  $t_k$  und ihre Kovarianz durch die entsprechende Kovarianzmatrix  $P_k$  ausgedrückt werden. Auf diese sogenannten Sigma-Punkte wird dann einzeln die nichtlineare Koordinatentransformation angewendet, wie in Abbildung 27 schematisch dargestellt ist.



**Abbildung 27: Schematische Darstellung des Prinzips der nichtlinearen Unscented-Transformation**

Die Berechnung der gewichteten Sigma-Punkte erfolgt abhängig von der Dimension  $L$  des Zustandsvektors  $t_k$  und wird inklusive Gewichte nach den folgenden Gleichungen berechnet [WvdM00]:





$$\chi_0 = \bar{t} , \quad W_0^{(t)} = \frac{\kappa}{L + \kappa} , \quad (6.38)$$

$$\chi_i = \bar{t} + \left( \sqrt{(L + \kappa)P} \right)_i , \quad i = 1 \dots L, \quad W_0^{(P)} = \frac{\kappa}{L + \kappa} + (1 - \alpha^2 + \beta) , \quad (6.39)$$

$$\chi_{i+L} = \bar{t} - \left( \sqrt{(L + \kappa)P} \right)_i , \quad i = 1 \dots L, \quad W_i = \frac{1}{2(L + \kappa)} , \quad i = 1 \dots 2L , \quad (6.40)$$

wobei  $\bar{t}$  den Mittelwert des Zustandsvektors und  $P$  die dazugehörige Kovarianzmatrix darstellt. Für die Berechnung des  $i$ . Sigma-Punktes  $\chi_i$  wird dabei der Mittelwert jeweils mit der  $i$ . Spalte der Matrixwurzel aus  $(L + \kappa)P$  addiert oder subtrahiert. Die Gewichtung des 0. Sigma-Punktes ist unterschiedlich, je nachdem ob dieses Gewicht  $W_0$  für die Berechnung des Mittelwertes ( $t$ ) oder der Kovarianzmatrix ( $P$ ) genutzt wird.

Mit den Parametern  $\alpha$ ,  $\beta$  und  $\kappa$  können die Gewichte der Sigma-Punkte  $W_i$  variiert werden, wobei  $\kappa$  auch die Punkte an sich beeinflusst. Während sich mittels  $\alpha$  bestimmen lässt, wie die Sigma-Punkte um den Mittelwert verteilt sind, kann mit  $\beta$  Vorwissen über die Verteilung hinzugerechnet werden. Durch die reelle Zahl  $\kappa$  ergibt sich ein weiterer Freiheitsgrad zum Anpassen der Sigma-Punkte an das Modell, um eine bessere Prädiktion zu erreichen. Für diese Zahl  $\kappa$  gilt:

$$\kappa = \alpha^2(L + \nu) - L . \quad (6.41)$$

Dabei ist  $\nu$  eine zusätzliche, sekundäre Stellvariable. Vorschläge, wie die angegebenen Parameter gewählt werden können, finden sich zum Beispiel in [WvdM00] und [JU97].

Die durch Gleichungen (6.38) bis (6.40) errechneten Sigma-Punkte werden alle einzeln, wie zuvor für den Zustandsvektor in Gleichung (6.20) gezeigt, prognostiziert und ergeben damit die prädizierten Sigma-Punkte  $\hat{\chi}_i$ . Mit Hilfe dieser prädizierten Sigma-Punkte können, wie in [WvdM00] gezeigt, der prognostizierte Mittelwert  $\bar{\hat{t}}$  und die Kovarianzmatrix  $\hat{P}$  berechnet werden:

$$\bar{\hat{t}} = \sum_{i=0}^{2L} W_i^{(t)} \hat{\chi}_i , \quad (6.42)$$



$$\hat{P} = \sum_{i=0}^{2L} W_i^{(P)} [\hat{\chi}_i - \bar{t}][\hat{\chi}_i - \bar{t}]^T + Q_k . \quad (6.43)$$

Anschließend wird auf die prädizierten Sigma-Punkte  $\hat{\chi}_i$  die nichtlineare Transformation angewendet, wodurch sich die mit der Messfunktion transformierten Sigma-Punkte  $\hat{Y}_i$  ergeben:

$$\hat{Y}_i = h(\hat{\chi}_i) . \quad (6.44)$$

Mit diesen ausgewählten Punkten ist es möglich, den Mittelwert nach der Transformation zu bestimmen, so dass sich der Mittelwert des prädizierten Zustandsvektors  $\bar{z}$  in Polarkoordinaten ergibt:

$$\bar{z} = \sum_{i=0}^{2L} W_i^{(t)} \hat{Y}_i . \quad (6.45)$$

Mit diesem Wert und der dem Zyklus zugeordneten Messung  $z_{mess}$  kann, wie zuvor für das Extended-Kalman-Filter in Gleichung (6.30) beschrieben, eine Innovation  $z_{inno}$  ermittelt werden. Ebenso ist es möglich, die transformierte Innovationskovarianzmatrix

$$\hat{S} = \sum_{i=0}^{2L} W_i^{(P)} [\hat{Y}_i - \bar{z}][\hat{Y}_i - \bar{z}]^T + R \quad (6.46)$$

und die Kreuzkovarianzmatrix

$$P_{tz} = \sum_{i=0}^{2L} W_i^{(P)} [\hat{\chi}_i - \bar{t}][\hat{Y}_i - \bar{z}]^T \quad (6.47)$$

zu bestimmen.

Die Kalman-Matrix berechnet sich anschließend aus diesen beiden Größen:

$$K = P_{tz} \hat{S}^{-1} . \quad (6.48)$$



Sobald die Kalman-Matrix  $K$  bekannt ist, kann mit ihr der Updateschritt des Filters berechnet werden:

$$t_k = \bar{t} + K z_{inno} , \quad (6.49)$$

$$P_k = \hat{P} - K \hat{S} K^T . \quad (6.50)$$

Damit ergibt sich wie zuvor beim Extended-Kalman-Filter mit den Gleichungen (6.33) und (6.34) der neue Initialzustand für einen weiteren Filterdurchlauf.

Im Gegensatz zum Extended-Kalman-Filter ist der Ablauf nicht von der Wahl des Zustandsvektors abhängig und damit ist es nicht nötig, spezifische Jacobi-Matrizen mit Ableitungen des Modellzustandes zu bilden. Das bedeutet, dass beim Nutzen eines anderen Bewegungsmodells nicht das Filter an sich geändert werden muss. Das Filter kann als Blackbox genutzt werden, welches für jedes Bewegungsmodell dieselben Berechnungen ausführt. So kann hier einfach das Kreis-Bewegungsmodell genutzt werden, ohne dass neue Matrizen berechnet werden müssen.

## 6.4 Assoziation

Im Assoziationsschritt wird ausgewählt, welches der detektierten Radarziele dieses Zyklus am besten zu dem Track passt. Dadurch wird entschieden, welcher Messvektor  $z_{mess}$  zur Berechnung der Innovation  $z_{inno}$  im Updateschritt zur Korrektur benutzt wird. Um das richtige Ziel auszuwählen, wird überprüft, ob die Position und die Geschwindigkeit, die von dem vorhandenen Track erwartet werden, zu einem der neu detektierten Ziele passen.

Dafür werden zunächst die Ziele ausgeschlossen, welche sich weit außerhalb eines bestimmten Sicherheitsbereichs um den Track befinden. Deren Messvektor passt in einer oder mehreren der drei Koordinaten nicht zu dem prädizierten Zustand des verfolgten Objektes.


Welche Form der Sicherheitsbereich hat, hängt zumeist von der Anwendung ab. Üblich ist es im verkehrstechnischen Bereich rechteckige sogenannte Gates für die Position



anzunehmen, in denen die Ziele liegen müssen, um überhaupt für die genauere Assoziation in Betracht gezogen zu werden.

Eine der am häufigsten angewendeten Assoziationsmethoden ist die Methode, möglichst viele Kombinationen aus Track und Ziel zu finden, die zusammen die geringste Differenz in Position und Geschwindigkeit zueinander haben [BP99]. Dieses ist bekannt unter dem englischen Namen **Global Nearest Neighbor Method**.

Diese Zuordnung kann dann zu einem Konflikt führen, wenn dasselbe Ziel zu mehreren bestehenden Tracks passt oder mehrere Ziele gut zu einem einzelnen Track passen. Solch eine Konfliktsituation ist in Abbildung 28 dargestellt, wobei die Ziele als orangefarbene Kreise, die Tracks als rote Quadrate und die Sicherheitsbereiche als schwarze Kreise um die Tracks dargestellt sind.



**Abbildung 28:** Schematische Abbildung einer Konfliktsituation, wo ein Ziel (oranger Kreis) zu mehreren Tracks (rote Quadrate) passen würde und ein Track mehrere Ziele im Sicherheitsbereich (Kreis) hat



Um diese Mehrdeutigkeiten aufzulösen, wird eine Zuordnungstabelle angelegt. In diese werden mittels einer normierten Entfernungsfunktion Distanzen eingetragen, die angeben, wie gut das Ziel zum jeweiligen Track passt [Bla86]. Je besser diese zusammen passen, desto geringer ist die eingetragene Distanz. Dort wo Track und Ziel schon aufgrund des Sicherheitsbereichs nicht zueinander passen, wird ein *X* eingetragen, da diese Kombination ausgeschlossen ist.

Für das in Abbildung 28 dargestellte Beispiel würde sich eine Zuordnungstabelle wie Tabelle 4 ergeben. Im Allgemeinen hat die Zuordnung durch diese Matrix das Ziel, möglichst viele Kombinationen zwischen Zielen und Tracks zu ermitteln, damit möglichst alle Tracks Informationen für ihre Korrekturphase bekommen. Wenn dieses vorausgesetzt wird, dann muss eine Kombination aus Ziel 3 und Track 1 gebildet werden, da Ziel 3 bei keinem anderen bestehenden Track im Sicherheitsbereich liegt, auch wenn Track 1 und Ziel 2 besser zueinander passen.

Ziel 1 und 2 passen beide zu den jeweils verbleibenden Tracks 2 und 3, wobei Ziel 2 zu beiden Tracks die kleinere Distanz aufweist. Hier wird dann geschaut, bei welchen Kombinationsmöglichkeiten die geringere Gesamtdistanz zustande kommt. Dieses ist der Fall, wenn Ziel 1 zu Track 2 zugeordnet wird und dementsprechend Ziel 2 zu Track 3. Dabei ergibt sich die Gesamtdistanz zu 8, während sie im anderen Fall die Distanz 11 ergäbe. Ziel 4 liegt außerhalb sämtlicher Sicherheitsbereiche und wird deshalb im Assoziationsschritt ausgeschlossen.

	Ziel 1	Ziel 2	Ziel 3	Ziel 4
Track 1	<i>X</i>	7	<b>9</b>	<i>X</i>
Track 2	<b>5</b>	4	<i>X</i>	<i>X</i>
Track 3	7	<b>3</b>	<i>X</i>	<i>X</i>

**Tabelle 4: Zuordnungstabelle zur Konfliktlösung in mehrdeutigen Assoziationssituationen**



## 6.5 Vergleichende Untersuchung der Kalman-Filter

Im Folgenden werden das Extended-Kalman-Filter aus Kapitel 6.3.3 mit einem Geradeaus-Bewegungsmodell mit dem Zustandsvektor

$$t = \begin{pmatrix} x \\ y \\ v_x \\ v_y \end{pmatrix} \quad (6.51)$$

und das Unscented-Kalman-Filter aus Kapitel 6.3.4 mit einem Kreis-Bewegungsmodell mit Zustandsvektor

$$t = \begin{pmatrix} x \\ y \\ v \\ \psi \\ \omega \end{pmatrix} \quad (6.52)$$

miteinander verglichen. Diese Kombinationen aus Filter und Zustandsvektor werden in der Praxis häufig benutzt und bleiben für den Verlauf des Kapitels erhalten. Für beide Filter werden in diesem Abschnitt dieselben Parameter und die gleiche Variabilität für die Berechnung der Systemrauschmatrix  $Q$  verwendet, da diese eine der wichtigsten Einstellmöglichkeiten zu Beeinflussung der Filterperformance ist. Der Ausrichtungswinkel, welcher bei beiden Filtern zur Initialisierung angenommen werden muss, wird in allen Szenarien mit  $\psi = 0^\circ$  gewählt.

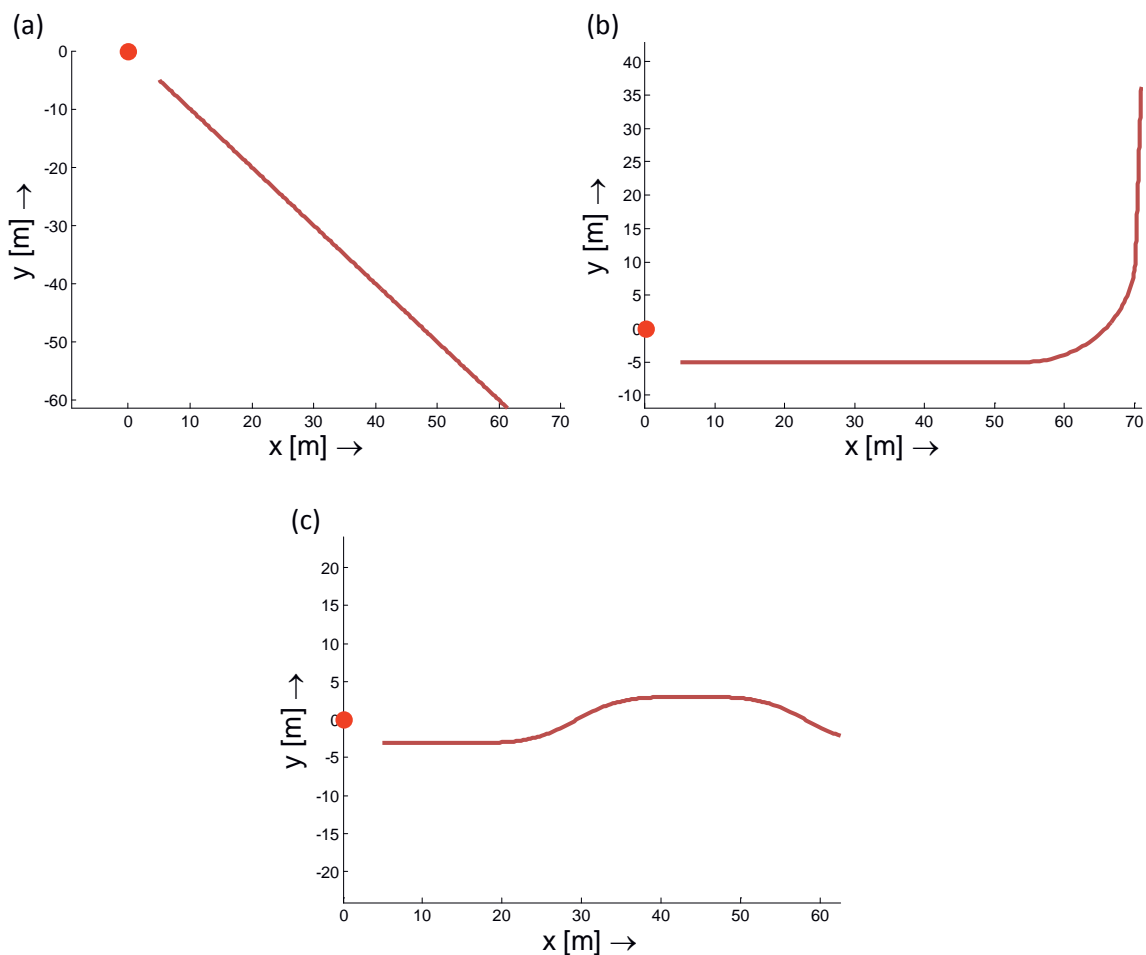
Für den Vergleich werden drei verschiedene häufig vorkommende Straßenszenarien, aus denen sich die meisten Straßenverläufe kombinieren lassen, mit diesen Filtern verarbeitet und analysiert.

Dazu wird eine Simulation von Radarzielen basierend auf den betrachteten Straßenszenarien durchgeführt. Diese drei Szenarien sind in Abbildung 29 in einem  $x$ - $y$ -Plot dargestellt, wo der Verlauf der simulierten Fahrspur örtlich aufgetragen ist. Zu sehen sind eine diagonale Geradeausfahrt (a), eine Kurvenfahrt (b) und ein Spurwechsel (c). Diese Szenarien setzen sich jeweils stückweise aus verschiedenen Geraden- und Kreissegmenten zusammen. In jedem dieser Szenarien wird die dargestellte Strecke von einem Objekt innerhalb von 200 Messzyklen zurückgelegt, so dass beispielsweise



bei der Kurvenfahrt in Abbildung 29(b) bei Zyklus 100 die Kurve beginnt. Um einen aussagekräftigen Vergleich zu erhalten, werden für jedes Straßenszenario 500 Objektdurchfahrten simuliert.

Die drei Straßenszenarien sollen für die folgenden Auswertungen als in der Verkehrsbeobachtung charakteristische Straßenverläufe genutzt werden, um die Leistungsfähigkeit der beiden Filter mit ihrem jeweiligen Bewegungsmodell zu ermitteln. Der rote Punkt stellt dabei den Aufstellungsort des Radarsensors im Koordinatensprung dar. Die angenommene Geschwindigkeit der Objekte in den Szenarien ist konstant und beträgt 36 km/h bei der Geradeausfahrt, 30 km/h bei der Kurvenfahrt und 22 km/h bei dem Spurwechsel.



**Abbildung 29: Drei Straßenszenarien: (a) Geradeausfahrt, (b) Kurvenfahrt und (c) Spurwechsel**



Basierend auf den obigen Straßenszenarien werden in der Simulation Radarziele mit fehlerbehafteten Messvektoren erzeugt. Für einen quantitativen Vergleich werden Abweichungen in Position, Geschwindigkeit und Ausrichtungswinkel zwischen dem gefilterten Track und den drei Straßenszenarien ermittelt. Zur Auswertung wird die Wurzel der mittleren Fehlerquadratsumme (*Root-Mean-Square-Error (RMSE)*) zwischen dem von den Filtern errechneten Track und dem vorgegebenen Szenario in den drei Fehlergrößen Position, Geschwindigkeit und Ausrichtungswinkel in jedem Zyklus berechnet. Dieser Fehler zeigt an, wie weit die gefilterten Werte von den gezeigten Straßenszenarien abweichen. Es wird dabei überprüft, welches Filter in welchem Szenario besser geeignet ist und zu geringeren Abweichungen führt.

Zusätzlich wird ermittelt, wie viele der simulierten Radarobjekte durchgehend spurgetreu verfolgt werden können. Wenn ein Track einem simulierten Objekt nicht folgen kann oder der Track sich zu weit vom vorgegebenen Szenario entfernt, führt dies zu dem sogenannten Abreißen eines Tracks. Dieses Abreißen der Tracks ist in der Verkehrsbeobachtung möglichst immer zu vermeiden, da solche Tracks beispielsweise nicht gezählt, oder von einer Lichtsignalanlagensteuerung übersehen werden, da sie nicht mehr existieren oder sich auf der falschen Fahrspur befinden.

Während das RMSE eine Übersicht bietet, wie genau die Tracks im Mittel am Szenario entlang verfolgt werden können, betrachtet die Anzahl der abreißenden Tracks die Performance von jedem einzelnen Track.

Zunächst soll die diagonale **Geradeausfahrt** aus Abbildung 29(a) betrachtet werden. Hier wird eine konstante Bewegung mit einem konstanten Ausrichtungswinkel simuliert. Das Ergebnis ist in Abbildung 30 gezeigt, wobei der rote Graph die Abweichung des Extended-Kalman-Filters anzeigt und der blaue diese für das Unscented-Kalman-Filter darstellt.

Insgesamt ist der Unterschied zwischen den beiden Filtertypen gering. Es fällt auf, dass die Abweichung des Extended-Kalman-Filters in allen drei Messgrößen etwas kleiner ist als die des Unscented-Kalman-Filter. Das Extended-Kalman adaptiert sich schneller in Position sowie Ausrichtung und Geschwindigkeit, so dass der Initialisierungsfehler des unkorrekt angenommenen Ausrichtungswinkels schneller kompensiert werden kann.



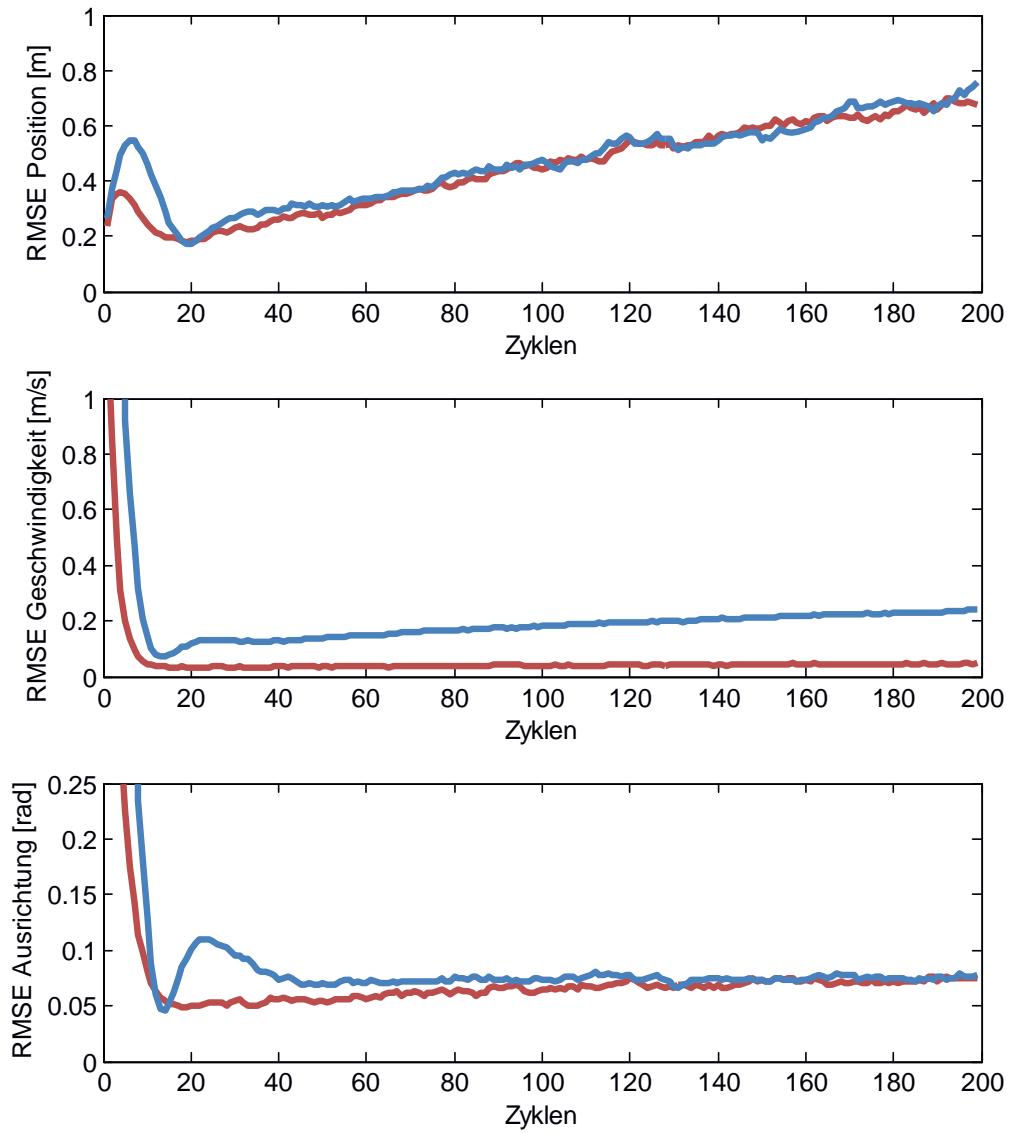


Abbildung 30: RMSE in Position, Geschwindigkeit und Ausrichtung vom Extended-Kalman-Filter (rot) und Unscented-Kalman-Filter (blau) für eine Geradeausfahrt



Da sich die simulierten Fahrzeuge im Ablauf der Simulation vom Radarsensor entfernen, bedingt sich der Anstieg des Positionsfehlers über die Zyklen in dem zunehmenden Winkelfehler.

Von der Leistungsfähigkeit über alle Objekte gemittelt sind beide Filter mit ihrem geringen Fehler für die Benutzung auf einer Geradeausfahrt geeignet. Das Extended-Kalman-Filter kann sich aufgrund des Bewegungsmodells für die Geradeausfahrt schneller an den zu Beginn fehlerhaften Ausrichtungswinkel anpassen.

Die Anzahl der abreißenden Tracks liegt beim Extended-Kalman-Filter bei 2,6 % und beim Unscented-Kalman-Filter bei 2,4 %. Damit ist der mittlere Fehler zwar klein, aber einzelne Tracks entfernen sich weit vom vorgegebenen Straßenszenario und würden so abreißen. Das Abreißen auf der Geradeausfahrt geschieht erst in großer Entfernung zum Radarsensor, wo die gemessenen Zielkoordinaten aufgrund der ungenaueren Winkelmessung unsicherer sind.

Als nächstes wird das Straßenszenario der **Kurvenfahrt** aus Abbildung 29(b) betrachtet. Diese Kurvenfahrt besteht stückweise aus geraden Elementen, so wie auch aus einem Kreisabschnitt zwischen Zyklus 100 und 150. Das Ergebnis der beiden Filter für eine Kurvenfahrt ist in Abbildung 31 dargestellt.

Im Gegensatz zu der schrägen Geradeausfahrt passt beim Kurvenszenario der in der Trackinitialisierung geschätzte Ausrichtungswinkel. Daher gibt es hier zu Beginn des Tracks kaum Einschwingverhalten der Filter.

Bei beiden Filtern steigt der Fehler in der Kurve an. Dabei zeigt das Unscented-Kalman-Filter in Blau innerhalb der Kurve ein besseres Verhalten. Durch die Kurve wird hauptsächlich nur ein Fehler in der Ausrichtung und der Geschwindigkeit hinzugefügt. Die Position passt trotz Eintritt in die Kurve immer noch gut zum vorgegebenen Szenario und der Fehler in dieser Größe erfährt keinen sprunghaften Anstieg durch die Änderung der Bewegung. Erst nachdem das Straßenszenario nach 150 Zyklen wieder von einem Geradensegment bestimmt ist, wird der Fehler im Unscented-Kalman-Filter größer. Allgemein kommt das Unscented-Kalman-Filter in einer variablen Kurvensituation zu einem besseren Ergebnis.

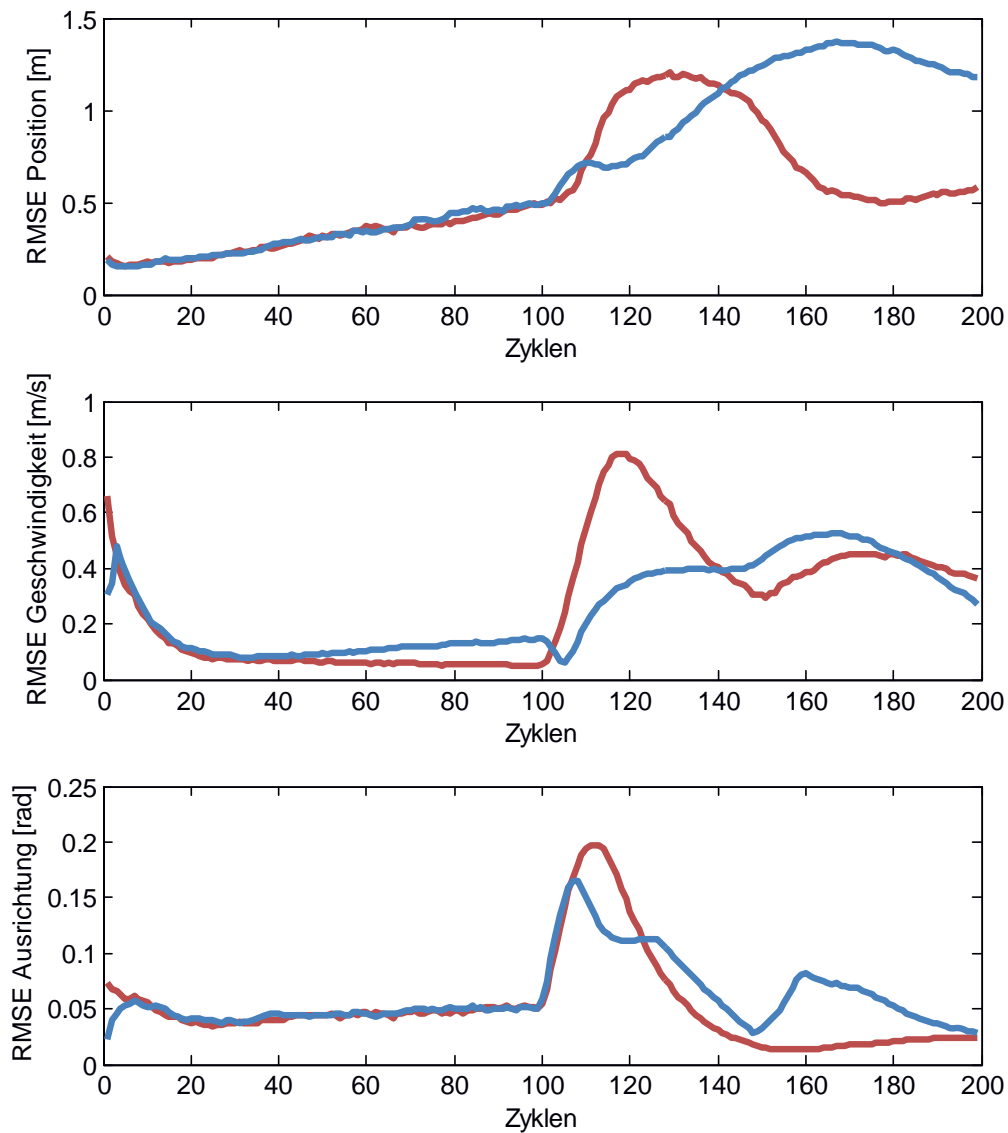


Abbildung 31: RMSE in Position, Geschwindigkeit und Ausrichtung vom Extended-Kalman-Filter (rot) und Unscented-Kalman-Filter (blau) für eine Kurvenfahrt



Obwohl dieser mittlere Fehler bei beiden Filtern relativ gering ist, gibt es einige Objekte, die nicht durch Tracks durchgehend verfolgt werden können, so dass in dem dargestellten Kurvenszenario beim Extended-Kalman-Filter ungefähr 5,8 % der Tracks abreißen und beim Unscented-Kalman-Filter ungefähr 5 % der Tracks verloren gehen. Dieses ist für die Verkehrsbeobachtung ungünstig, da Kurven häufig vorkommen und dann zu viele Tracks abreißen, die durchgehend beobachtet werden sollen.

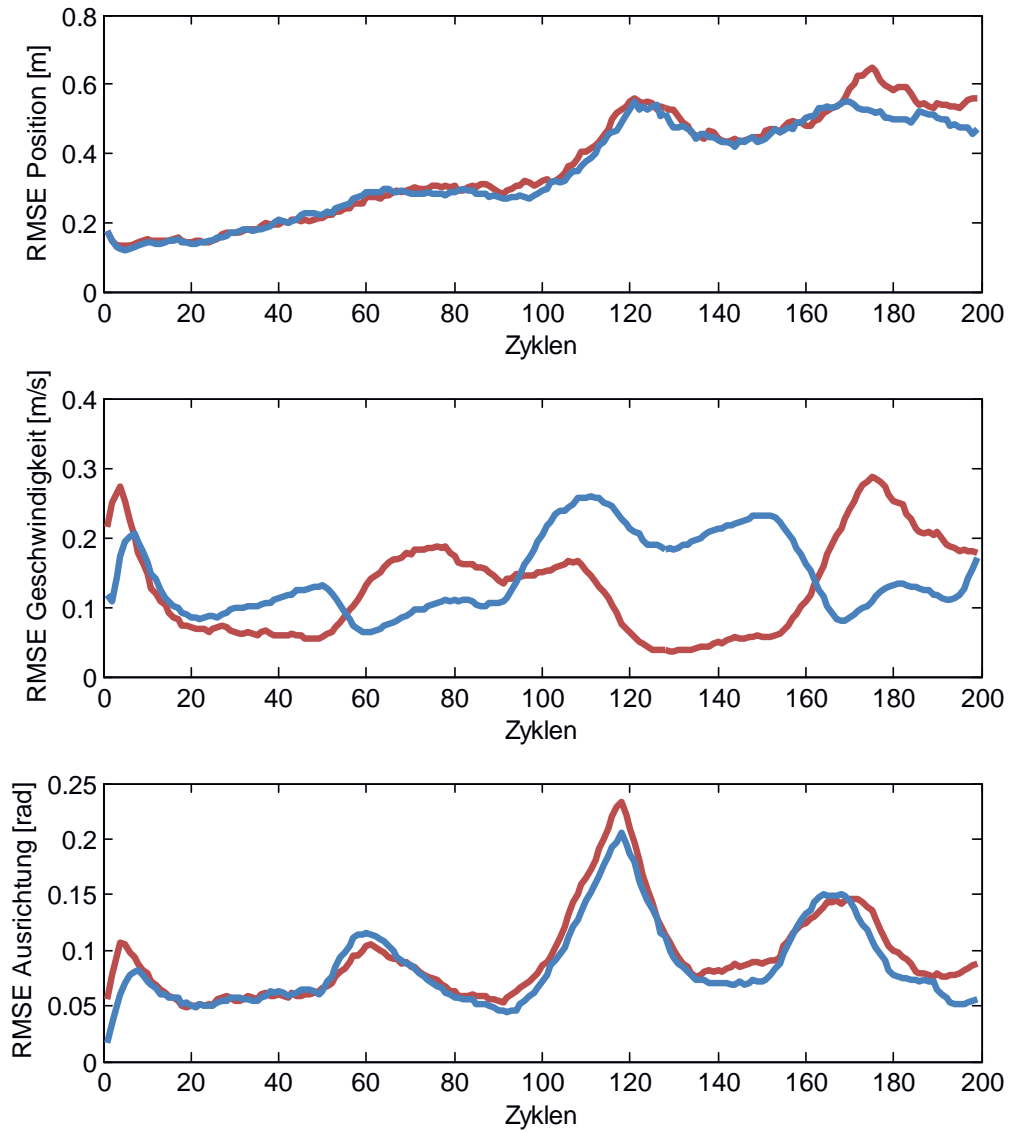
Zum weiteren Vergleich zwischen dem Extended-Kalman-Filter und dem Unscented-Kalman-Filter soll anschließend das letzte gewählte Szenario, der in Abbildung 29(c) gezeigt **Spurwechsel**, ausgewertet werden. Die Ergebnisse sind in Abbildung 32 dargestellt.

Dabei zeigt sich, dass sich beide genannten Filtertypen in der Position und der Ausrichtung ähnlich verhalten. Lediglich in der Geschwindigkeit gibt es deutliche Unterschiede. Dabei fällt das schon zuvor in den beiden anderen Straßenszenarien gezeigte Verhalten auf, dass das Extended-Kalman-Filter einen größeren Fehler in den Kurvenfahrten ausweist, während das Unscented-Kalman-Filter dort seine Stärken hat, aber auf den Geraden einen größeren Fehler erzeugt.

Dahingegen ist die Anzahl der abreißenden Tracks mit 0,4 % beim Extended-Kalman-Filter und 0,8 % beim Unscented-Kalman-Filter sehr gering. Das Szenario weist weder so starke Kurven auf wie das Kurvenszenario noch erreicht es eine hohe Entfernung, so dass die größten Fehlerquellen, welche zum Abreißen der Tracks führen, wegfallen. Zusätzlich ist die Geschwindigkeit der simulierten Objekte geringer.

Gerade in der Analyse der Kurvenfahrt wurde jedoch gezeigt, dass keines der bisher betrachteten Filter ideal für die Überwachung des Straßenverkehrs geeignet ist, da in solchen Kurvensituationen deutlich zu viele der Tracks abreißen und die beobachteten Objekte nicht gut genug verfolgt werden können. Aktuell werden diese Filter zwar genutzt, aber das Ergebnis ist nicht immer ausreichend.

Oft kann das Tracking Objekte nicht in Kurvenfahrten verfolgen. Der Anteil der abgerissenen Tracks pro Anzahl der simulierten Objekte wird in Tabelle 5 dargestellt.



**Abbildung 32:** RMSE in Position, Geschwindigkeit und Ausrichtung vom Extended-Kalman-Filter (rot) und Unscented-Kalman-Filter (blau) für einen Spurwechsel



	Geradeausfahrt	Kurvenfahrt	Spurwechsel
EKF	2,6 %	5,8 %	0,4 %
UKF	2,4 %	5,0 %	0,8 %

**Tabelle 5: Prozentzahl der abreißenden Tracks pro Straßenszenario mit Extended-Kalman-Filter (EKF) und Unscented-Kalman-Filter (UKF)**

Diese Prozentzahl ist für eine gute Verkehrsüberwachung zu hoch, da verlorene oder nicht der korrekten Fahrspur zugeordnete Tracks nicht gezählt oder detektiert werden. Um dennoch eine gute Filterperformance zu erreichen, reicht es nicht, die Filter besser abzustimmen, deshalb soll im Folgenden ein anderer Weg gewählt werden.

Ein gutes Filter soll sowohl in Kurven als auch auf Geraden nur einen geringen Fehler im Tracking aufweisen. Dabei hat die Wahl des Filters selbst nur einen geringen Einfluss auf die Ergebnisse, auch der Anteil der abreißenden Tracks aus Tabelle 5 ist für beide untersuchten Varianten sehr ähnlich.

Für die Trackingfilter sind Informationen über den lokalen Straßenverlauf für die Fehlerminimierung von großem Nutzen. Dann wäre bekannt, wo sich eine Straße befindet, welchen Verlauf sie nimmt und wo eine Kurve beginnt. Dieses Vorwissen über den Straßenverlauf kann im Filter berücksichtigt werden. Für Aufgaben der Verkehrsbeobachtung könnte dieses Wissen bereitgestellt oder ermittelt werden.

Im folgenden Kapitel wird deshalb ein Bewegungsmodell entwickelt, welches dieses Vorwissen berücksichtigt. Dieses wird dann in einem Extended-Kalman-Filter genutzt, da dieser durch das Vorwissen eine deutlichere Leistungssteigerung erfahren kann.





## 7 Tracking anhand von bekannten Umgebungsdaten

Im vorangegangenen Kapitel wurde gezeigt, dass ein Trackingfilter immer dann vor technischen Herausforderungen steht, wenn sich das Fahrverhalten der verfolgten Objekte abrupt ändert oder diese Fahrmanöver durchführen. In einem solchen Fall passt die Annahme des Bewegungsmodells nicht zum Verhalten des Objektes. Dadurch kann ein großer Fehler entstehen und der Track kann abreißen und verloren gehen, wenn die Ziele aufgrund dieser Bewegungsannahme nicht mehr assoziiert werden können.

Da der Radarsensor in der Verkehrsbeobachtung stationär ist, kann er Vorwissen über seine gleichbleibende Umgebung erhalten oder erlernen und mit einer festen Umgebungskarte arbeiten. Hierdurch enthält das Trackingfilter im Radarsensor Informationen über die Straßenverläufe.

In diesem Kapitel wird gezeigt, dass die bisher betrachteten Filterverfahren deutlich verbessert werden können, wenn dieses Vorwissen über die Straßenverläufe in der Umgebung des Radarsensors bekannt ist. Der resultierende Fehler des Trackingfilters ist in diesem Fall wesentlich kleiner und die Anzahl der abreißenden Tracks wird deutlich reduziert.

Hierbei ist das vorhandene Vorwissen von großer Wichtigkeit. Durch eine Umgebungskarte ist bekannt, entlang welcher Straße sich das verfolgte Objekt bewegt





und welche Fahrmanöver es durchführen wird. Demnach kann in die richtige Richtung entlang einer so bekannten Kurve prädiziert werden und die Annahme des Bewegungsmodells stimmt mit der Objektbewegung überein. Damit wird ein größerer Fehler durch eine Abweichung vom erwarteten Bewegungsmodell vermieden.

### 7.1 Vorwissen über den Ausrichtungswinkel

Wenn die lokale Umgebungskarte ermittelt wurde, können daraus für den Trackingalgorithmus verwertbare Informationen gewonnen werden. Dazu gehört die Position der Straßen, sowie deren Ausrichtungswinkel und die mittlere Geschwindigkeit, mit der auf diesen Straßen gefahren wird.

Die Geschwindigkeit vorbeifahrender Fahrzeuge eignet sich nicht gut als Vorwissen, da einzelne Fahrzeuggeschwindigkeiten weit von dieser mittleren Geschwindigkeit abweichen. Die Position hingegen kann sich für die Filterung eignen, allerdings soll diese nicht berücksichtigt werden. Dieses ist darin begründet, dass nicht bekannt ist, ob sich die Objekte immer an ihre aktuelle Fahrspur halten. Wenn die Position des Tracks auf die Straßenposition beschränkt ist, fehlt den Tracks die nötige Flexibilität und sie können sich nicht mehr von der vorgegebenen Fahrspur absetzen. Dieses würde einen Spurwechsel und den Wechsel auf Abbiegespuren unmöglich machen.

Daher soll im Folgenden nur der Ausrichtungswinkel  $\psi$  als Vorwissen benutzt werden, um zu ermitteln, in welche Richtung sich ein Track bewegt. Damit können Kurven erkannt und Spurwechselmanöver trotzdem ermöglicht werden, da der Ausrichtungswinkel in solchen Szenarien nur wenig von der Ausrichtung der Straße abweicht. Zusätzlich sind Situationen für das Trackingfilter am kritischsten, wo Fahrmanöver durchgeführt werden, da dort der Ausrichtungswinkel die größte Änderung erfährt und hier der größte Mehrwert durch die Anwendung des Vorwissens vorhanden ist.

Wenn der Ausrichtungswinkel durch Vorwissen zur Verfügung gestellt wird, können Fehler deutlich verringert werden. Vor allem der Fehler, der durch die Annahme des falschen Ausrichtungswinkels  $\psi$  bei der Initialisierung eines Tracks entsteht, würde durch dieses Vorwissen nicht vorkommen. Der Ort der Initialisierung ist durch die Position des ersten gemessenen Ziels bekannt und da auch der Straßenverlauf bekannt




ist, kann der Track mit dem dann bekannten Ausrichtungswinkel  $\psi$  der nächstgelegenen Straße initialisiert werden. Damit muss nicht wie im bisher betrachteten Trackingverfahren ein beliebiger Ausrichtungswinkel in der Initialisierung angenommen werden.

Anschließend wird der Track an seiner Position parallel zum Straßenverlauf präzisiert und ihm wird so die korrekte Ausrichtung vorgegeben. Die Position selbst wird nur anhand der gemessenen Ziele gefiltert.

Zur Analyse und zur Darstellung, wie das Vorwissen genutzt wird, wird zunächst angenommen, dass die Informationen über die Straßenverläufe in der nahen Umgebung im Sichtbereich des Sensors bereits bekannt sind. Das heißt, jeder Track hat zu jedem Zeitpunkt die Information, auf welcher Straße er sich befindet und in welche Richtung er dementsprechend präzisiert werden müsste, wenn er dieser Straße folgen soll. Wie die Integration dieses Vorwissens über die Straßenverläufe in der lokalen Umgebung des Radarsensors in das Verfahren technisch realisiert ist, wird im nächsten Kapitel erläutert.

Zunächst wird davon ausgegangen, dass dieses Vorwissen in einer landkartenförmigen Art vorhanden ist. Dabei ist die Lage der Fahrspuren bekannt und zu jedem Punkt auf einer Fahrbahnmitte existiert ein Ausrichtungswinkel  $\psi$ , welcher die Ausrichtung der Straße an dieser Stelle beschreibt. Eine solche vorgegebene Umgebungskarte ist beispielhaft in Abbildung 33 dargestellt. Die hellblau gestrichelte Linie beschreibt die Fahrbahnmitte.

Im Folgenden ist die räumliche Position eines Tracks durch seinen Zustandsvektor beschrieben. Mittels dieser rot gekennzeichneten Objektposition wird eine Verbindung zu dem Punkt auf der Fahrbahnmitte hergestellt, der einen minimalen Abstand zum Objekt aufweist. Dieser mit einem dunkelblauen Kreuz gekennzeichnete Punkt auf der Fahrbahnmitte ist der Referenzpunkt, von dem die Informationen und das Vorwissen des Straßenverlaufs ermittelt werden und aus dem der zum Track gehörige Ausrichtungswinkel der Fahrbahnmitte erfasst wird.



**Abbildung 33:** Eine vom Radarsensor beobachtete Straße (schwarz). Die Tracks (rot) werden der Fahrbahnmitte (hellblau) zugeordnet und übernehmen den Ausrichtungswinkel der Straße am Referenzpunkt (dunkelblaues Kreuz).

Im Folgenden wird aus diesem Referenzpunkt der gespeicherte Ausrichtungswinkel  $\psi$  an den Track übergeben, so dass dieser als Vorwissen dem Trackingverfahren zur Verfügung steht. Damit wird angenommen, dass sich der Track in dieselbe Richtung bewegt, wie der Ausrichtungswinkel des Straßenverlaufs das an dieser Stelle vorgibt.

Um den Tracks in der Position ihre Flexibilität zu erhalten, wird wie beschrieben nur der Ausrichtungswinkel aus dem Vorwissen übernommen, nicht jedoch die jeweilige Straßenposition.

Da der Track durch das bekannte Vorwissen einen Ausrichtungswinkel  $\psi$  zugeordnet bekommt, muss dieser im Trackingfilter nicht mehr gefiltert werden. Dies ist von großem Vorteil, da mit der Ausrichtung ein Freiheitsgrad in der Filterung wegfällt, der nicht direkt durch die detektierten Ziele korrigiert werden konnte. Zusätzlich wird die Größe des Zustandsvektors reduziert und somit Speicherplatz und Rechenzeit im Trackingalgorithmus eingespart. Durch das Weglassen des Ausrichtungswinkels im Zustandsvektor ändert sich, wie in [Beh15] beschrieben, der Zustandsvektor des Filters zu:

$$t = \begin{pmatrix} x \\ y \\ v \end{pmatrix}. \quad (7.1)$$



Die Geschwindigkeit  $v$  stellt die absolute Geschwindigkeit des beobachteten Tracks dar und ist nicht mehr in getrennten Richtungskomponenten  $v_x$  und  $v_y$  dargestellt, wie es beim Geradeaus-Bewegungsmodell der Fall war, da diese die Richtungsinformation beinhaltet haben. Das heißt, die Geschwindigkeit enthält nun keinerlei Richtungsinformation, da diese durch das Vorwissen zur Verfügung gestellt wird.

Dadurch, dass der Ausrichtungswinkel  $\psi$  nicht mehr gefiltert werden muss, fehlt ein Freiheitsgrad im Zustandsvektor, was zu einer großen Steigerung der Genauigkeit führt.

Zunächst erfolgt der Initialisierungsprozess dieses Filters mit den aus dem vorherigen Kapitel bekannten Gleichungen (6.4) bis (6.7). Der Ausrichtungswinkel  $\psi$  basiert auf dem Vorwissen der Ausrichtung der Fahrbahnmitte. Dafür wird zu jedem Zeitpunkt  $k$  der dichteste Punkt zu einer benachbarten Fahrbahnmitte ermittelt und der entsprechende Ausrichtungswinkel  $\psi$  von diesem Referenzpunkt genutzt. Dieses ist möglich, da angenommen wird, dass das Objekt, welches mit dem zu initialisierenden Track verfolgt werden soll, die nächstgelegene Straße benutzt und daher den Ausrichtungswinkel der relevanten Fahrbahnmitte kennt.

Auch die Berechnung der Kovarianzmatrix in den Gleichungen (6.9) bis (6.11) wird mit dem bekannten Ausrichtungswinkel  $\psi_k$  ermittelt. Anschließend wird der Zustandsvektor  $\hat{t}_k$  wie folgt aus dem letzten Zustandsvektor  $t_{k-1}$  prädiziert:

$$\hat{t}_k = \begin{pmatrix} \hat{x}_k \\ \hat{y}_k \\ \hat{v}_k \end{pmatrix} = \begin{pmatrix} x_{k-1} + v_{k-1} \cos(\psi_k) \Delta t \\ y_{k-1} + v_{k-1} \sin(\psi_k) \Delta t \\ v_{k-1} \end{pmatrix}. \quad (7.2)$$

Die Besonderheit ist, dass der in der Prädiktion genutzte Ausrichtungswinkel  $\psi_k$  nicht im Zustandsvektor enthalten ist, sondern aus dem genutzten Vorwissen stammt. Mit Gleichung (7.2) ergibt sich analog zum vorherigen Kapitel die Transformationsmatrix

$$\Phi = \begin{bmatrix} 1 & 0 & \cos(\psi_k) \Delta t \\ 0 & 1 & \sin(\psi_k) \Delta t \\ 0 & 0 & 1 \end{bmatrix}. \quad (7.3)$$

Mit dieser und der zusätzlich angepassten Messmatrix  $H$  lässt sich die Berechnung des Extended-Kalman-Filters identisch, wie in Kapitel 6.3.2 gezeigt, durchführen:

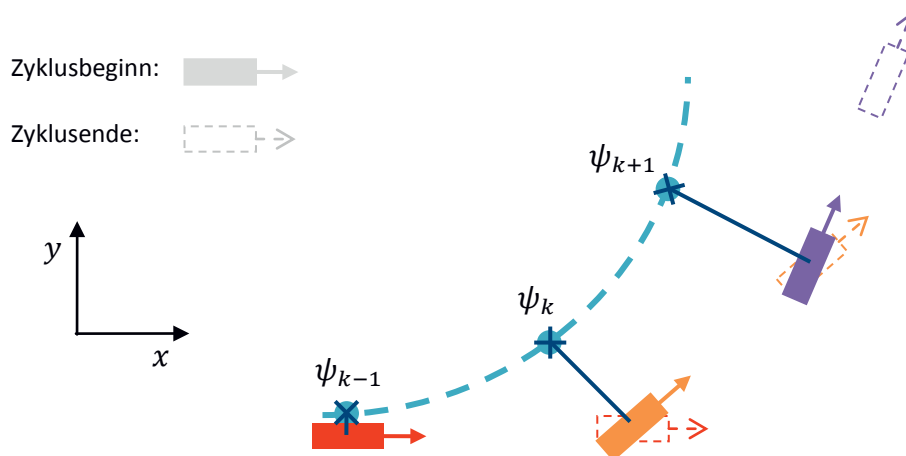


$$H = \begin{bmatrix} \frac{x}{r} & \frac{y}{r} & 0 \\ -\frac{y}{r^2} & \frac{x}{r^2} & 0 \\ \frac{vy(y \cos(\psi) - x \sin(\psi))}{r^3} & \frac{vx(x \sin(\psi) - y \cos(\psi))}{r^3} & \frac{(x \cos(\psi) + y \sin(\psi))}{r} \end{bmatrix}. \quad (7.4)$$

Hier wurde der Zeitpunkt  $k$  auf Grund der Übersichtlichkeit weggelassen. Dennoch wird diese Matrix mit den aktuellen Werten in jedem Zyklus erneut berechnet.

Zu Beginn des Zyklus wird der Ausrichtungswinkel  $\psi$  vor der Prädiktion von der zugehörigen Fahrbahnmitte gewonnen, um den Zustandsvektor möglichst gut präzisieren zu können, und in die Transformationsmatrix  $\Phi$  aus Gleichung (7.2) eingesetzt.

Diese Prädiktion würde in einem Kurvenverlauf zunächst jedoch vom Straßenverlauf und damit auch vom vorgegebenen Szenario wegführen, ebenso wie auch ein Geradeaus-Modell eine Geradeausfahrt präzisieren würde. Dieses Verhalten ist in Abbildung 34 dargestellt. Durch das anschließende Update ändert sich die Position zwar wieder etwas in Richtung des detektierten Ziels, aber grob entfernt sich der Track mit jedem Zyklus weiter von der Straße, obwohl er in jedem Zyklus vor der Prädiktion den richtigen Ausrichtungswinkel aus der Fahrbahnmitte übernimmt.



**Abbildung 34: Steigender Entfernungsfehler bei der Benutzung des Filters mit Vorwissen der Fahrbahnmitte (hellblau) mit jedem Zyklus**




Deswegen wird der Ausrichtungswinkel nach der Prädiktion erneut aus dem Vorwissen vom Referenzpunkt der Fahrbahnmitte bezogen. Wenn der Ausrichtungswinkel  $\psi$  zusätzlich nach der Prädiktion noch einmal an der prädizierten Position in Erfahrung gebracht wird, unterscheidet sich die Ausrichtung von der zuvor in der Prädiktion genutzten, da der Track sich an einer anderen Stelle auf der Fahrbahn befindet. Mit dem neuen Ausrichtungswinkel  $\psi$  nach der Prädiktion wird dann für das Update die Messmatrix  $H$  wie in Gleichung (7.4) berechnet. Damit passt der prädizierte Messvektor besser zum Szenario und der entstehende Fehler wird verringert.

Zusätzlich wird eine weitere Maßnahme ergriffen, damit die Tracks besser entlang der Fahrbahnmitte prädiziert werden. Dazu wird die Änderung des Ausrichtungswinkels zwischen zwei aufeinanderfolgenden Zyklen betrachtet. Der in Abbildung 34 systematische Prädiktionsfehler wird deutlich verringert, da keine konstante Ausrichtung mehr angenommen wird, sondern es wird die Ausrichtungsänderung  $d\psi$  zwischen zwei Zyklen betrachtet und diese wird als konstant angenommen. Um die Ausrichtungsänderung  $d\psi$  zu berechnen, wird der Ausrichtungswinkel vor der Prädiktion des vergangenen Zyklus  $\psi_{k-1}$  gespeichert.

Im aktuellen Zyklus vor der Prädiktion  $\psi_k$  ergibt sich wieder der Ausrichtungswinkel aus dem Vorwissen, so dass aus diesen beiden Werten anschließend eine Ausrichtungsänderung  $d\psi$  berechnet werden kann, die zwischen dem aktuellen und dem vorherigen Zyklus stattgefunden hat:

$$d\psi_k = \psi_k - \psi_{k-1} . \quad (7.5)$$

Es wird angenommen, dass sich diese Ausrichtungsänderung, die im letzten Zyklus stattgefunden hat, im aktuellen Zyklus wiederholt. Statt also den Ausrichtungswinkel der Fahrbahnmitte direkt zu übernehmen, wird auf diesem die errechnete Ausrichtungsänderung addiert. Demnach wird eine konstante Ausrichtungsänderung  $d\psi$  angenommen. Durch diese Maßnahme ändert sich das vorherige Verhalten zu dem in Abbildung 35 dargestellten. Hier wird der Track immer wieder näher an die Fahrbahnmitte prädiziert und der Fehler wird stark reduziert.



**Abbildung 35:** Berücksichtigung der Ausrichtungswinkeländerung  $d\psi_k$  zwischen zwei Zyklen. Es wird nicht mehr direkt mit dem Ausrichtungswinkel  $\psi_k$  der Fahrbahnmitte prädiziert, sondern mit dem addierten Winkel  $\check{\psi}_k$ .

Der neue Ausrichtungswinkel vor der Prädiktion  $\check{\psi}_k$  wird wie folgt bestimmt:

$$\check{\psi}_k = \psi_k + d\psi_k . \quad (7.6)$$

Damit wird die Prädiktion wie in Gleichung (7.2) berechnet. Anschließend wird wie zuvor ein neuer Ausrichtungswinkel vor dem Update bestimmt.

Dieses neue Filter bezieht seine neue Ausrichtung damit von der Fahrbahnmitte der bekannten Straßenverläufe im aktuellen und aus dem vergangenen Zyklus. Zusätzlich wird die Geschwindigkeit im Bewegungsmodell weiterhin als konstant angenommen. Demnach unterscheidet sich das Bewegungsmodell hier vom Geradeaus-Modell nur dadurch, dass der Ausrichtungswinkel  $\psi$  nicht mehr mit gefiltert wird, sondern als Vorwissen verfügbar ist. Um beide Varianten mit und ohne Vorwissen aus den Umgebungsdaten zu vergleichen, wird für beide ein Extended-Kalman-Filter gewählt,



so dass ausschließlich das Vorwissen den Unterschied im Vergleich ausmacht. Die Ergebnisse hierfür sind in Abbildung 36 für eine Geradeausfahrt dargestellt.

In diesem Fall ist zu sehen, dass der RMSE in allen drei Prüfgrößen von Position, Geschwindigkeit und Ausrichtung von dem neuen in Dunkelblau dargestellten Filter mit Vorwissen geringer ist als bei dem zuvor genutzten Extended-Kalman-Filter mit Geradeaus-Modell ohne Vorwissen, welches in Rot dargestellt wird. Der Fehler in der Position steigt nicht annähernd so stark an, da das Bewegungsmodell auch dann der Ausrichtung des vorgegebenen Szenarios folgt, wenn die Größen des Zielmessvektors durch Rauscheinflüsse davon abweichen.

Das Filter ohne Vorwissen filtert den Ausrichtungswinkel in jedem Zyklus mit, so dass auch in der Position eine erhöhte Unsicherheit mit größerer Entfernung und unsicheren Zielen hinzukommt. Das Extended-Kalman-Filter mit Vorwissen nutzt dahingegen den bekannten Ausrichtungswinkel und weicht so in Einzelfällen nicht so weit vom Szenario ab, wodurch der Fehler kontinuierlich gering bleibt.

Auch die anderen beiden Fehlergrößen sind mit diesem neuen Bewegungsmodell, welches das Vorwissen über die Umgebung nutzt, deutlich geringer. Damit ist die Performance dieses neuen Bewegungsmodells auf einer Geradeausfahrt deutlich größer als die üblicherweise genutzten Modelle, die ohne Vorwissen auskommen müssen.

Anschließend wird das Szenario einer Kurvenfahrt betrachtet. Auch hier werden zwei Extended-Kalman-Filter jeweils ohne sowie mit Vorwissen miteinander verglichen. Die Ergebnisse sind in Abbildung 37 dargestellt. Es ist zu erkennen, dass das neue Bewegungsmodell mit Vorwissen bessere Ergebnisse und geringere Fehler beinhaltet.

Sobald die Kurvenfahrt in Zyklus 100 beginnt, steigt der Fehler in allen drei Fehlergrößen zwar immer noch an, aber es ist zu erkennen, dass der maximale mittlere Fehler deutlich unter dem des Filters mit Geradeaus-Bewegungsmodell ohne Vorwissen ist. Ein Fehler ist nur dort vorhanden, wo die Annahme der konstanten Ausrichtungsänderung  $d\psi$  nicht zutreffend ist, wie am Ein- und Ausgang der Kurve.



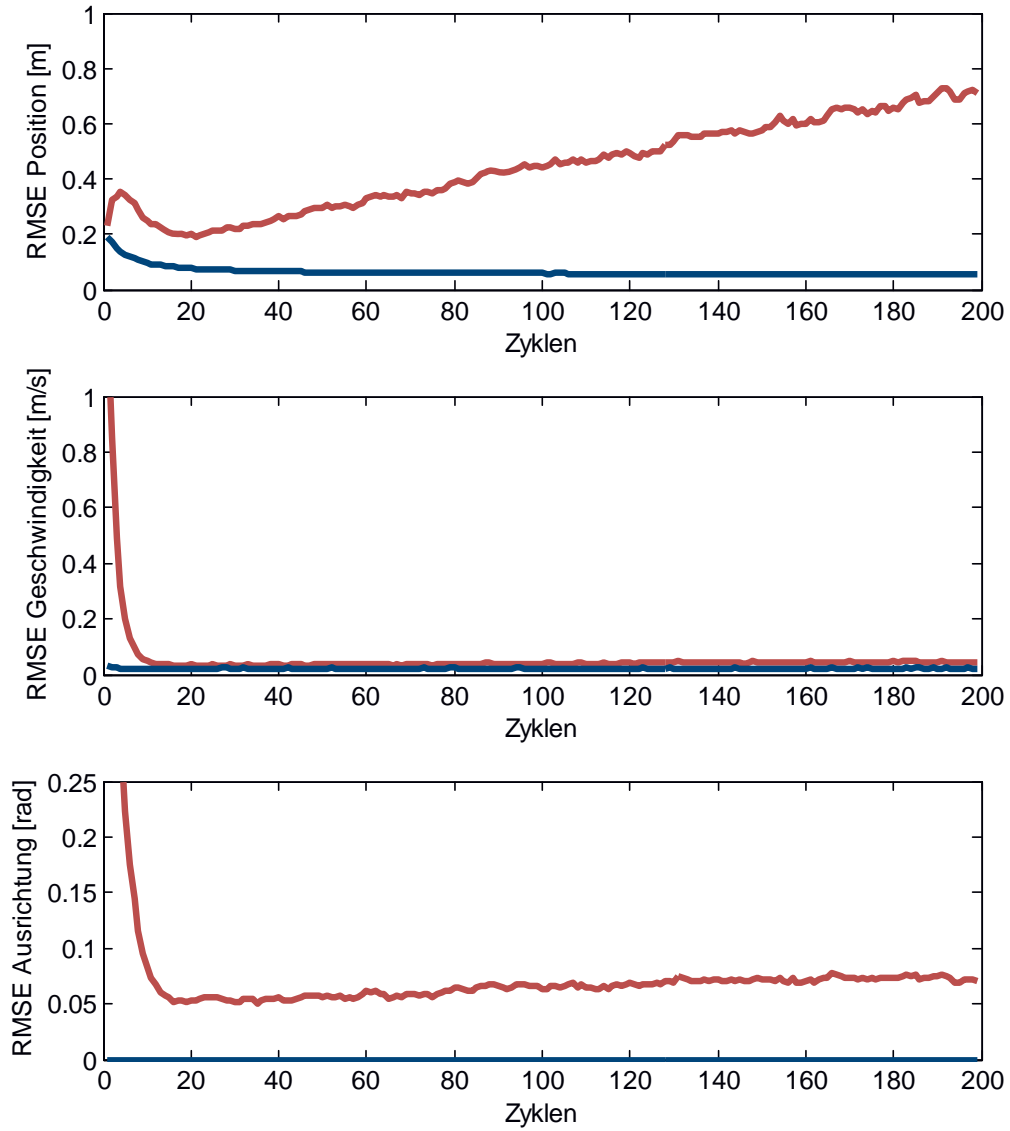
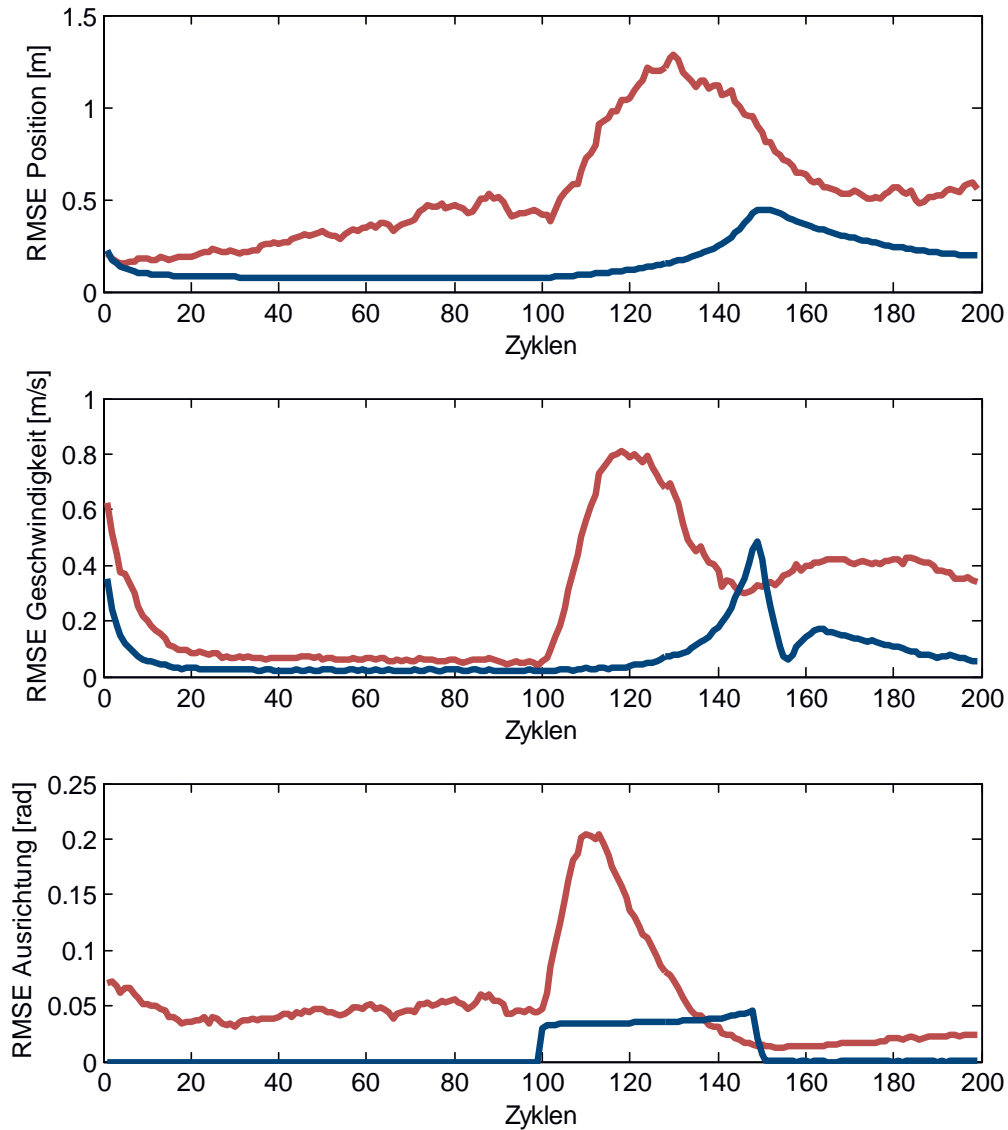


Abbildung 36: RMSE in Position, Geschwindigkeit und Ausrichtung von Extended-Kalman-Filtern ohne Vorwissen (rot) und mit Vorwissen (dunkelblau) für eine Geradeausfahrt



**Abbildung 37:** RMSE in Position, Geschwindigkeit und Ausrichtung von Extended-Kalman-Filtern ohne Vorwissen (rot) und mit Vorwissen (dunkelblau) für eine Kurvenfahrt



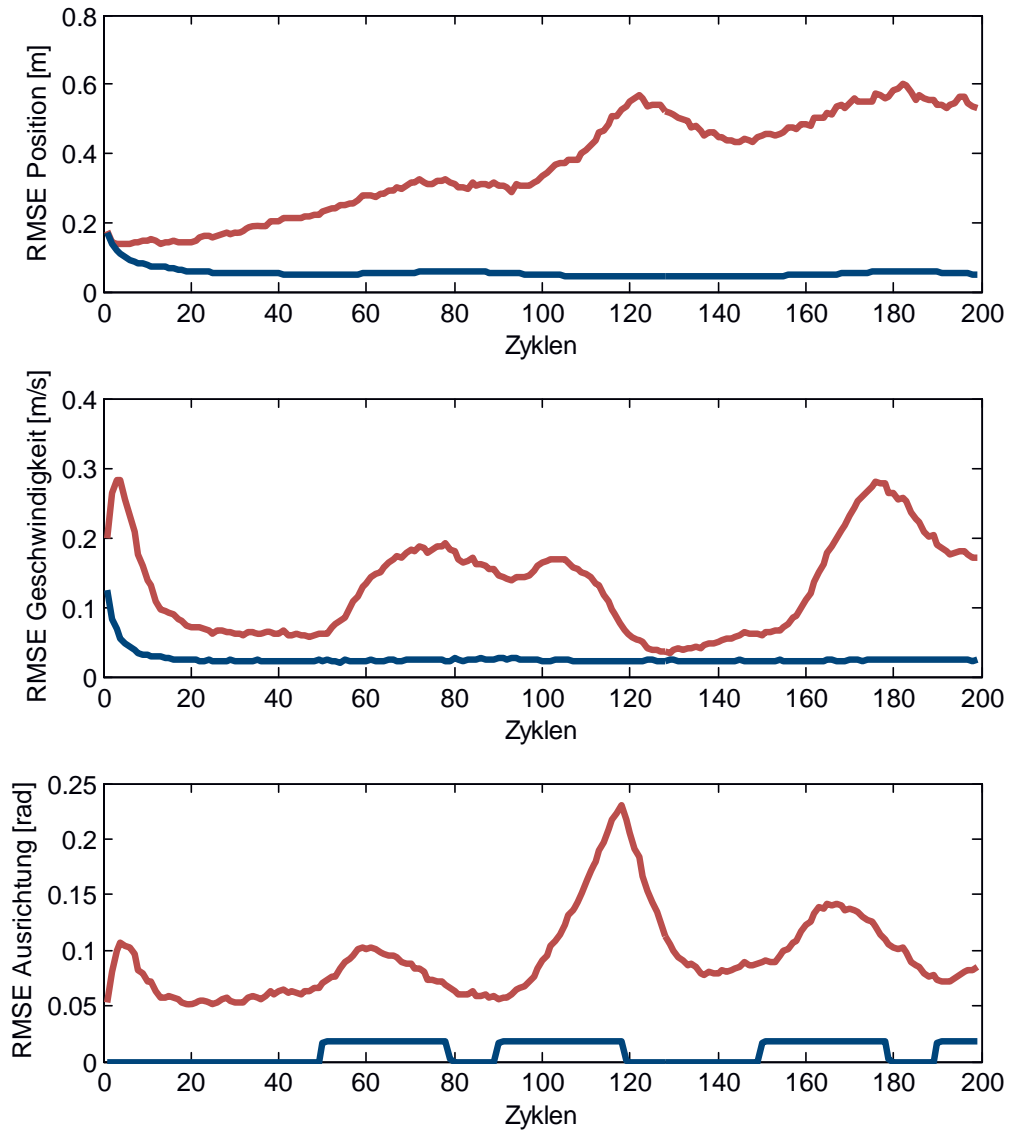
Dennoch ist deutlich zu erkennen, dass das maximale RMSE des Filters mit genutztem Vorwissen in allen drei Messgrößen mit den angewendeten Maßnahmen geringer ist als beim vergleichend gezeigten Extended-Kalman-Filter mit Geradeaus-Modell.

Zwar erzeugt die Kurvenfahrt immer noch einen kleinen Fehler, aber dieser Fehler ist so gering, dass ein gutes Tracking ohne weiteres möglich ist und auch in den Kurven keine Tracks abreißen. Beim Filter ohne Vorwissen hingegen reißen, wie in Kapitel 6.5 beschrieben, mehr als 5 % der Tracks in der Kurve ab. Daher wird hier eine sehr deutliche Verbesserung in der Gesamtperformance erzeugt.

Damit bestätigt sich die Annahme, dass durch Vorwissen über die Umgebung das Tracking signifikant verbessert werden kann. Deutlich wird das bei abschließender Betrachtung eines anschaulichen Spurwechselszenarios, wie in Abbildung 38 gezeigt. Auch hier kommt nur ein Fehler zustande, wenn sich in den kleinen Kurven des Spurwechselszenarios der Ausrichtungswinkel nicht wie angenommen ändert.

Dieser Fehler ist jedoch gering, so dass bei dem kleinen RMSE in Position und Geschwindigkeit eine sehr gute Assoziation und folglich ein stark verbessertes Tracking mit diesem Filter mit Vorwissen entsteht.

Zusammenfassend lässt sich feststellen, dass mit dem Vorwissen die Abweichungen vom Szenario deutlich verringert und die Genauigkeit im Extended-Kalman-Filter verbessert sowie abreißende Tracks in den gezeigten Szenarien komplett vermieden werden.



**Abbildung 38:** RMSE in Position, Geschwindigkeit und Ausrichtung von Extended-Kalman-Filtern ohne Vorwissen (rot) und mit Vorwissen (dunkelblau) während eines Spurwechsels



## 7.2 Schätzen der Beschleunigung mit Vorwissen

Wie im vorherigen Kapitel gezeigt, bringt das Filter mit Vorwissen bereits eine deutliche Verbesserung gegenüber den konventionellen Bewegungsmodellen. Zusätzlich zu dieser Leistungssteigerung durch das Vorwissen wird etwas betrachtet, das bisher sämtliche betrachteten Filter und Modelle gemeinsam hatten – die Annahme einer konstanten Geschwindigkeit.

Sämtliche Fahrmanöver variieren normalerweise auch die Geschwindigkeit des Fahrzeugs. Das ist der Grund dafür, dass im folgenden Ansatz zusätzlich die Beschleunigung  $a$  im Zustandsvektor berücksichtigt wird. Infolgedessen wird nicht mehr eine konstante Geschwindigkeit in der Prädiktion angenommen, sondern eine konstante Beschleunigung, so dass für beschleunigende Fahrzeuge angenommen wird, dass sie weiterhin schneller werden.

Dazu wird der Zustandsvektor aus Gleichung (7.1) um die Größe der Beschleunigung  $a$  erweitert, so dass nicht mehr von einer konstanten Geschwindigkeit, sondern von einer konstanten Beschleunigung entlang des Straßenverlaufs ausgegangen wird.

$$t = \begin{pmatrix} x \\ y \\ v \\ a \end{pmatrix}. \quad (7.7)$$

In der Initialisierung wird dabei zunächst ein nicht beschleunigtes Fahrzeug angenommen. Anschließend wird für die Prädiktion die gefilterte Beschleunigung aus dem Zustandsvektor hinzugezogen sowie der aus dem Referenzpunkt der Fahrbahnmittte gewonnene Ausrichtungswinkel  $\psi$  aus dem Vorwissen. Damit ergibt sich folgende Transformationsmatrix

$$\Phi = \begin{bmatrix} 1 & 0 & \cos(\psi) \Delta t & \frac{1}{2} \cos(\psi) \Delta t^2 \\ 0 & 1 & \sin(\psi) \Delta t & \frac{1}{2} \sin(\psi) \Delta t^2 \\ 0 & 0 & 1 & \Delta t \\ 0 & 0 & 0 & 1 \end{bmatrix}. \quad (7.8)$$

Die Messmatrix  $H$ , welche im vorherigen Kapitel in Gleichung (7.4) beschrieben ist, kann wie gewohnt im Extended-Kalman-Filter genutzt werden.



Um die Leistungssteigerung dieser Erweiterung darzustellen, sollen im Folgenden zwei Extended-Kalman-Filter mit Vorwissen miteinander verglichen werden. Der eine nutzt den Zustandsvektor aus Gleichung (7.1) mit konstanter Geschwindigkeit und der zweite nutzt den Zustandsvektor aus Gleichung (7.7) mit konstanter Beschleunigung. Beide benutzen, wie in Kapitel 7.1 beschrieben, das Vorwissen aus der Umgebungskarte.


Zunächst wird das Straßenszenario der Geradeausfahrt betrachtet. Im angenommenen Szenario ist die Geschwindigkeit der simulierten Objekte konstant. In Abbildung 39 wird das RMSE über die Größen von Position, Geschwindigkeit und Ausrichtungswinkel aufgezeigt. Das Filter mit konstanter Beschleunigung wird in Orange und das Filter aus dem vorherigen Unterkapitel mit konstanter Geschwindigkeit weiterhin in Dunkelblau dargestellt.

Das RMSE ist für beide Bewegungsmodelle in allen Messgrößen sehr gering und sorgt in beiden Fällen für ein stabiles Tracking. Lediglich der Geschwindigkeitsfehler beider Filter unterscheidet sich geringfügig. Durch die zusätzlich geschätzte Beschleunigung lässt sich der Fehler in der Geschwindigkeit weiter reduzieren.

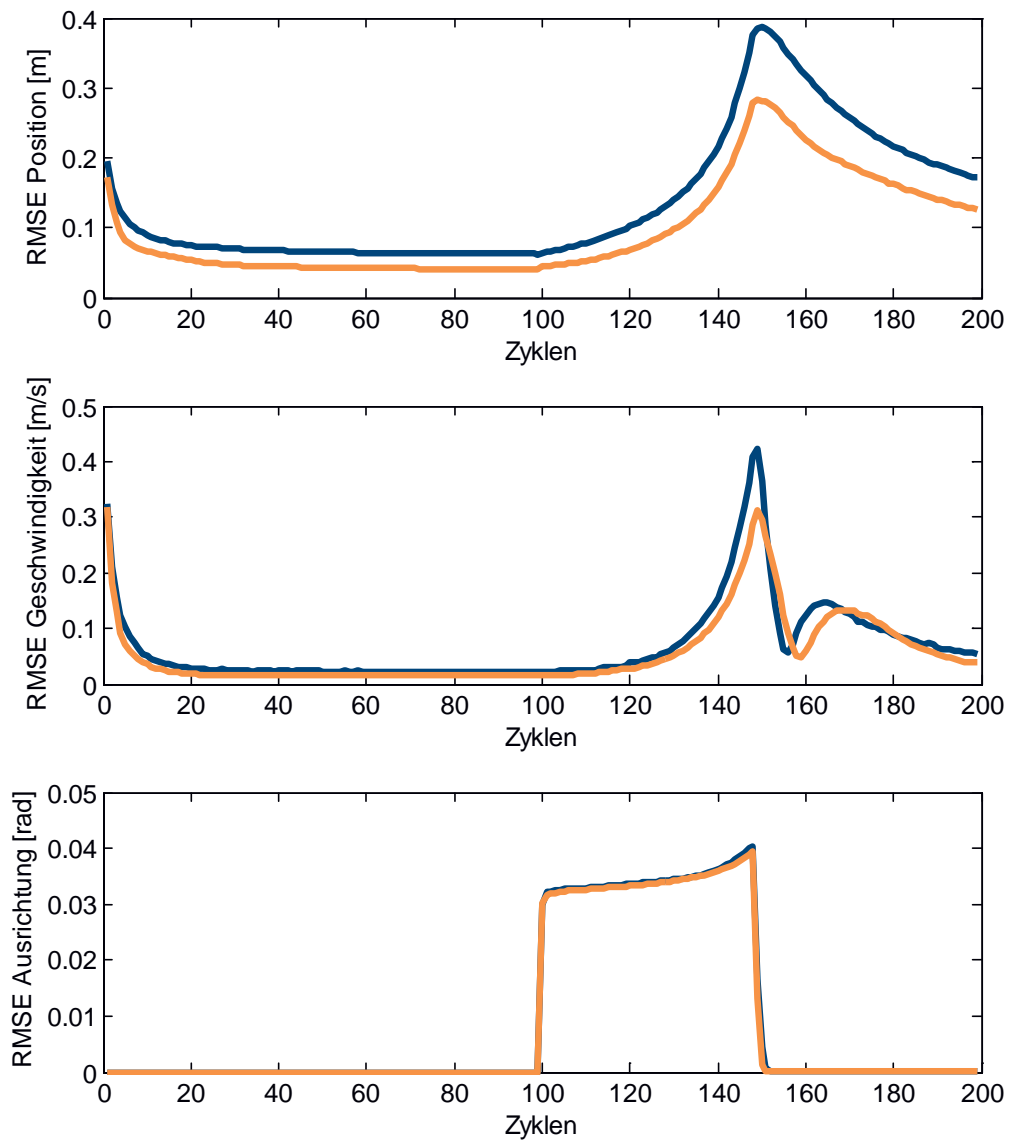
Als nächstes wird die Kurvenfahrt betrachtet, deren Ergebnisse in Abbildung 40 zu sehen sind. Hier bietet sich ein ähnliches Bild wie schon bei der Geradeausfahrt, auch hier wird der resultierende Fehler weiter verringert.

Beide Filter bekommen auf Grund der in der Kurve nicht konstanten Kurswinkeländerung den gleichen Fehler im Ausrichtungswinkel. Die Fehler in Geschwindigkeit und Position sind mit Beachtung der Beschleunigung geringer, da diese Abweichungen besser ausgeglichen werden können.

Trotz dieser kleinen Fehler haben beide hier gezeigten Filter eine durchweg bessere Performance als die Filter mit konventionellen Bewegungsmodellen, da sie Vorwissen über die Straßenverläufe in der Umgebung nutzen können. Hier reißen keine Tracks mehr ab und Objekte können in allen Fällen in einer Kurvensituation verfolgt werden.



**Abbildung 39:** RMSE in Position, Geschwindigkeit und Ausrichtung für zwei Extended-Kalman-Filter mit Vorwissen (dunkelblau) und zusätzlich mit konstanter Beschleunigung (orange) für eine Geradeausfahrt



**Abbildung 40:** RMSE in Position, Geschwindigkeit und Ausrichtung für zwei Extended-Kalman-Filter mit Vorwissen (dunkelblau) und zusätzlich mit konstanter Beschleunigung (orange) für eine Kurvenfahrt





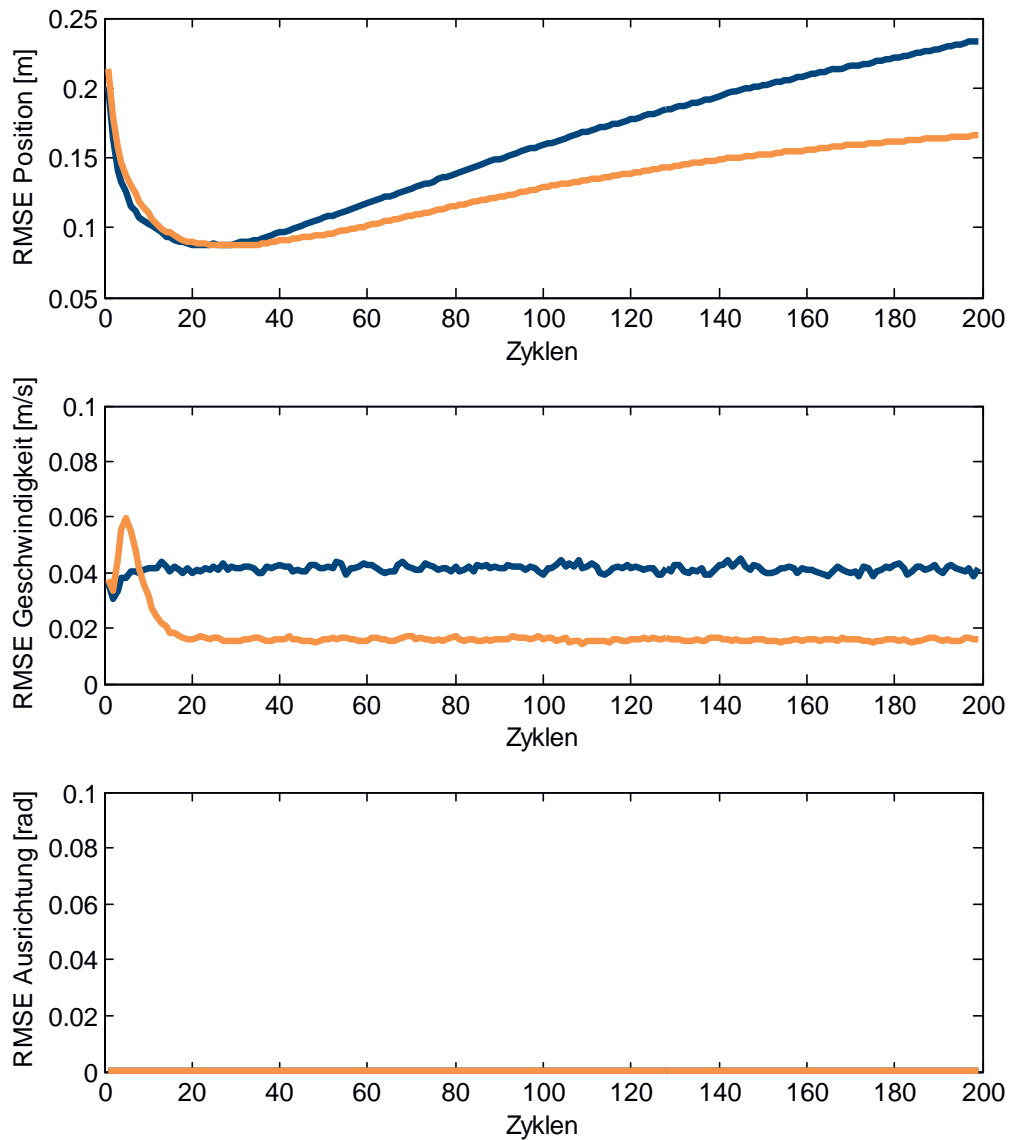
Der Vorteil des Filters mit der konstanten Beschleunigung gegenüber der konstanten Geschwindigkeit zeigt sich erst dann deutlich, wenn in einem Straßenszenario Fahrzeuge mit Beschleunigungen simuliert werden. Dazu wird das Szenario der Geradeausfahrt so verändert, dass entlang der Geraden mit einer konstanten Beschleunigung gefahren wird. Hierbei werden die Fahrzeuge konstant von einer Anfangsgeschwindigkeit von 30 km/h bis zum Ende des Szenarios auf eine Endgeschwindigkeit von 65 km/h beschleunigt, um damit einen Vorgang im Stadtverkehr zu simulieren.

Im ursprünglichen Filter mit Vorwissen ist eine solche Beschleunigung nicht vorgesehen, da die Geschwindigkeit als konstant angenommen wird. Um den Zielen folgen zu können, muss das Filter eine hohe Flexibilität aufweisen. Falls diese nicht vorhanden ist, kann der gefilterte Track dem vorgegebenen Szenario nur schwer folgen.

Dieses Verhalten ist in Abbildung 41 dargestellt. Hier wird gezeigt, wie der Fehler in der Position beim Filter mit Vorwissen stärker ansteigt als dort, wo die konstante Beschleunigung zusätzlich zum Vorwissen angenommen wird. Letzteres kann den beschleunigten Objekten besser folgen.

Der verbleibende Fehler zu Beginn des Szenarios entsteht durch die fehlerhafte Wahl der Beschleunigung in der Initialisierung. Da anschließend durch die Informationen in den Radarzielen keine Korrektur der Beschleunigung erfolgen kann, sondern dies nur über die Zeit gefiltert werden kann, dauert es etwas länger, bis sich das Filter auf die korrekte konstante Beschleunigung eingependelt hat. Dann ergibt sich allerdings ein deutlich kleineres RMSE vor allem in der Geschwindigkeit.

Beschleunigte Bewegungen sind mittels eines Radarsensors allgemein nicht einfach zu filtern, da es, wie bereits erwähnt, kein direktes Messergebnis für diese Schätzgröße gibt. Aber durch die neuen Filter, die das Vorwissen über den Ausrichtungswinkel nutzen, wird die Möglichkeit eröffnet, solche Szenarien zu verfolgen, die innerhalb des Straßenverkehrs sehr üblich sind, da die Fahrzeuge oft beschleunigen und bremsen.



**Abbildung 41:** RMSE in Position, Geschwindigkeit und Ausrichtung für zwei Extended-Kalman-Filter mit Vorwissen (dunkelblau) und zusätzlich mit konstanter Beschleunigung (orange) für eine Geradeausfahrt mit konstanter Beschleunigung



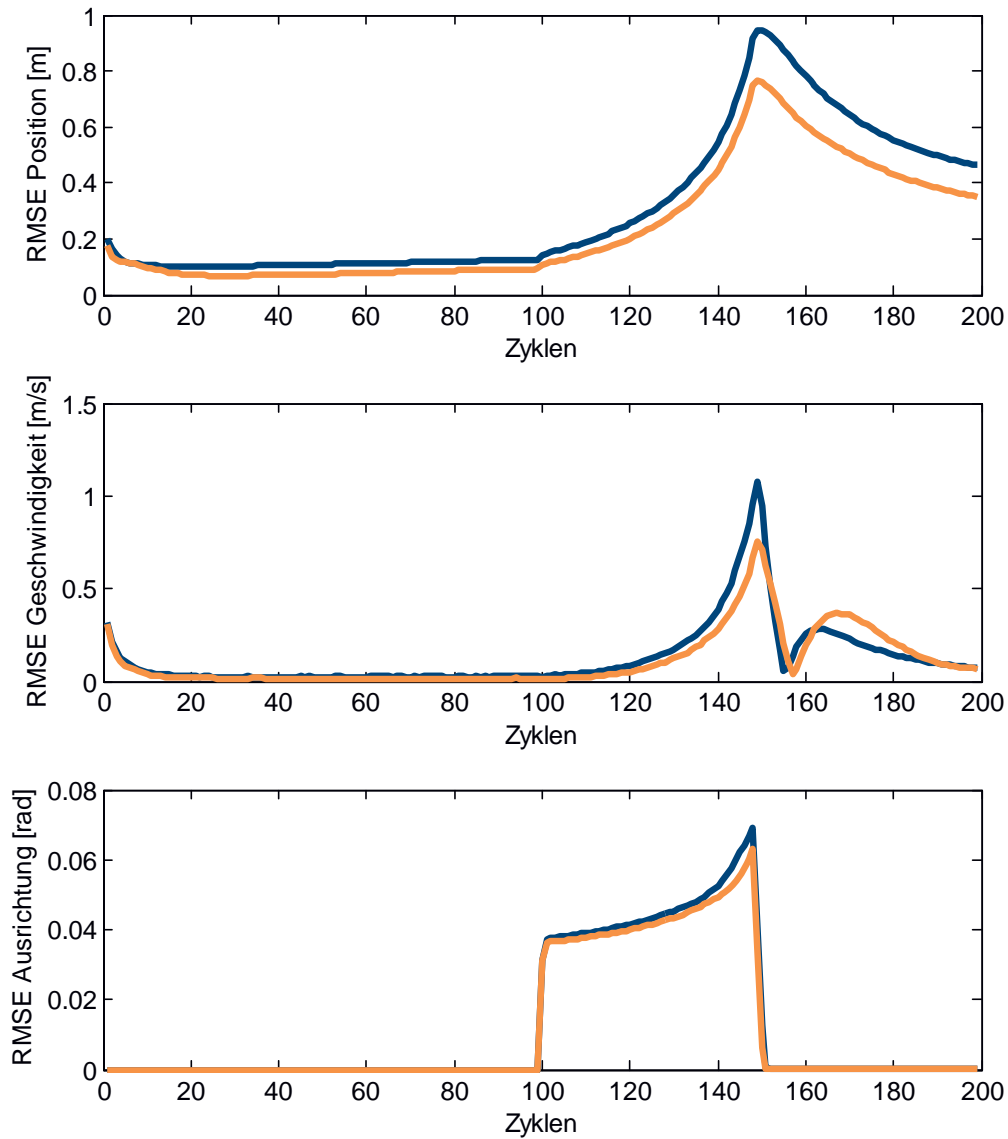
In einer Kurvenfahrt werden die Fahrzeuge konstant von einer Anfangsgeschwindigkeit von 30 km/h auf eine Endgeschwindigkeit von 45 km/h beschleunigt. Die Auswertung dazu wird in Abbildung 42 dargestellt. Hier zeigen sich die gleichen Eigenschaften wie zuvor bei der Geradeausfahrt. Das Filter mit zusätzlicher Beschleunigungsschätzung erzeugt einen geringeren Fehler. Beide erzeugen jedoch einen deutlich geringeren Fehler als die Bewegungsmodelle, welche kein Vorwissen aus der Umgebung nutzen. Dabei muss hervorgehoben werden, dass die Filter, welche kein Vorwissen über die Umgebung nutzen können, ein RMSE haben, welches deutlich über die hier genutzte Skala hinausgeht.

Um den Vergleich mit den ursprünglichen Bewegungsmodellen darzustellen, folgt in Abbildung 43 ein Beispiel mit veränderter Skala für dasselbe Szenario der beschleunigten Kurvenfahrt. Dieser vergleichsweise große mittlere RMSE, des hier zum Vergleich in Rot dargestellten Extended-Kalman-Filter mit Geradeaus-Bewegungsmodell bedeutet, dass dieses Filter mit der gewählten Einstellung bei fast vier Dritteln der Objekten nicht in der Lage sein würde, über die Gesamtdauer des Szenarios einen durchgehenden Track für diese Ziele zu bilden. Die Filter mit Vorwissen dagegen sind in allen Szenarien mit der bisherigen Einstellung deutlich besser und können daher universell eingesetzt werden.

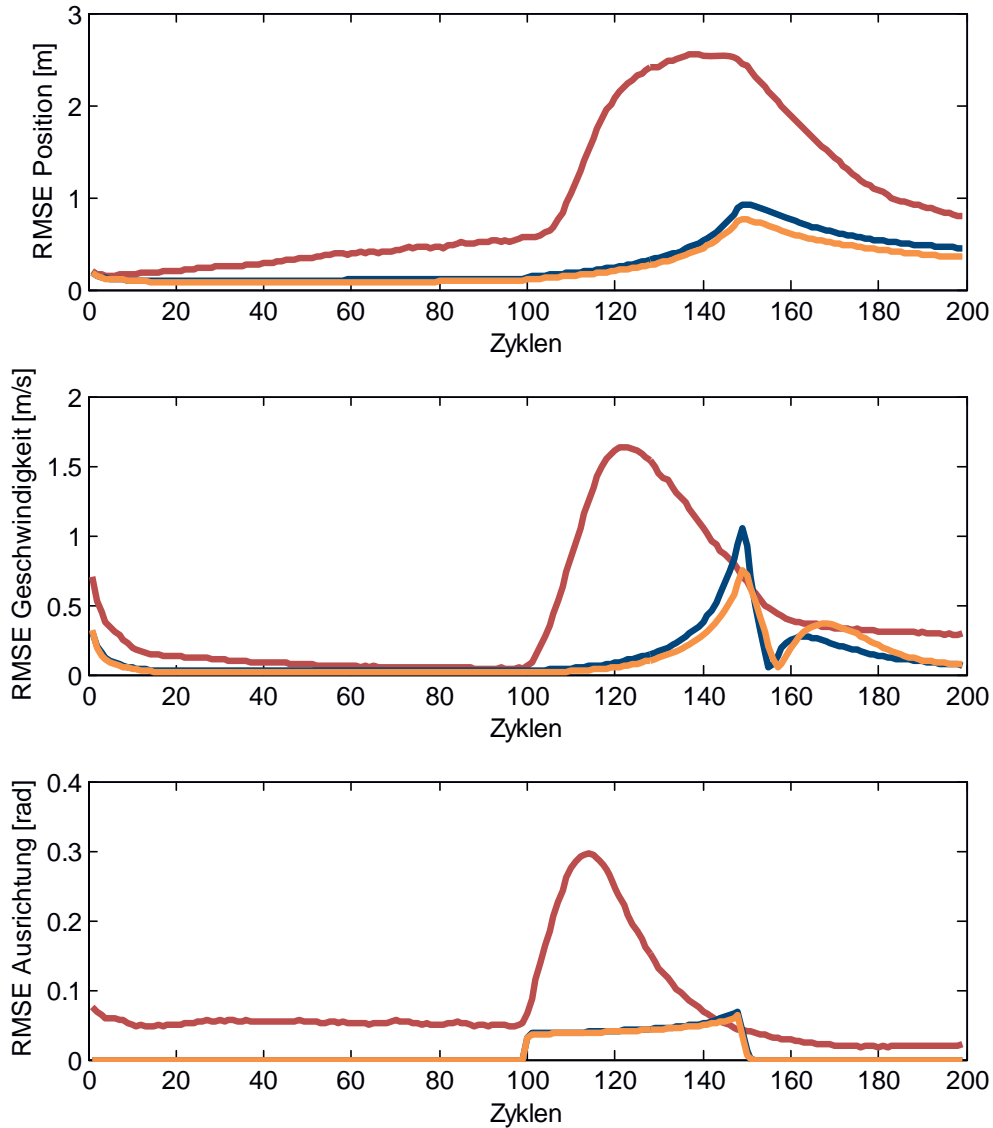
Zum Vergleich ist der Anteil der abreißenden Tracks in Tabelle 6 dargestellt. Hierbei wird deutlich, dass der Extended-Kalman-Filter ohne Vorwissen es in vielen Fällen nicht schafft, den beschleunigten Szenarien zu folgen. Die Filter mit Vorwissen erhalten dahingegen alle Tracks am Leben. Der Filter mit Beschleunigung erzeugt ein geringeres RMSE in Position und Geschwindigkeit und ist somit genauer.

	Beschleunigte Geradeausfahrt (30 - 65 km/h)	Beschleunigte Kurvenfahrt (30 - 45 km/h)
Kein Vorwissen	50,2 %	74 %
Vorwissen	0 %	0 %
Vorwissen mit $a$	0 %	0 %

**Tabelle 6: Anteil an abreißenden Tracks für die Filter mit und ohne Vorwissen sowie mit konstanter Beschleunigung  $a$**



**Abbildung 42:** RMSE in Position, Geschwindigkeit und Ausrichtung für zwei Extended-Kalman-Filter mit Vorwissen (dunkelblau) und zusätzlich mit konstanter Beschleunigung (orange) für eine Kurvenfahrt mit konstanter Beschleunigung



**Abbildung 43:** RMSE in Position, Geschwindigkeit und Ausrichtung für drei Extended-Kalman-Filter mit Vorwissen (dunkelblau) und zusätzlich mit konstanter Beschleunigung (orange) und einem Geradeaus-Modell ohne Vorwissen (rot) für eine Kurvenfahrt mit konstanter Beschleunigung



Der Hauptgrund, der für die Anwendung der Kalman-Filter mit Vorwissen aus der Umgebung spricht, ist, dass mit beiden Filtern mit Vorwissen keine Tracks mehr abreißen. Es ist eine der höchsten Prioritäten in der Verkehrsbeobachtung, dass aus einem Fahrzeug über die gesamte Beobachtungsdauer in allen Fahrsituationen ein Track erzeugt wird, der durchgehend vorhanden ist und nicht abreißt. Ansonsten könnte nach Abreißen des Tracks dieser in einer Verkehrszählung nicht berücksichtigt werden oder die Lichtsignalanlage könnte dem dazugehörigen Fahrzeug an einer Kreuzung das Signal nie auf Grün schalten.

Deswegen ist es eine wertvolle Verbesserung, den Weg über das Vorwissen aus der Umgebung zu wählen, weil mit beiden Filtern, sowohl mit konstanter Geschwindigkeit als auch Beschleunigung, eine deutliche Verbesserung durch das Vorwissen erreicht wird, so dass keine Tracks in herausfordernden Szenarien wie Kurven abreißen.





## 8 Umgebungsdaten für das Vorwissen

Im vorangegangenen Kapitel wurde gezeigt, wie sehr das Tracking in einem stationären Radarsensor davon profitieren kann, wenn Vorwissen über die Straßenverläufe in der Umgebung des Sensors vorhanden ist. Dieses Vorwissen wird in einer Umgebungskarte gespeichert.

Ziel ist es dabei, das Vorwissen aus den gemessenen Daten des Radarsensors mit dem im Folgenden vorgestellten Verfahren automatisch zu generieren. Dies ist möglich, da der stationäre Radarsensor selbst seine lokale Umgebung kontinuierlich beobachtet und so Informationen über die bewegten Fahrzeuge, die durch seinen Sichtbereich fahren, generiert. Um aus diesen Informationen Vorwissen zu extrahieren, sind keine externen Daten erforderlich, sondern nur die Daten, die der Radarsensor in seinem normalen Betrieb selbstständig ermittelt. Dazu gehören die Entfernung, der azimutale Winkel, damit also die Position, und die radiale Geschwindigkeit von detektierten Zielen.

In dem hier betrachteten Verfahren werden Daten über einen bestimmten Zeitraum der Installationsphase gemessen und anschließend so ausgewertet, dass die Fahrspuren in der lokalen Umgebung des Radarsensors nach einer Auswertung bestimmt werden können. An der Position, wo der Radarsensor Ziele von einem Fahrzeug detektiert, befindet sich eine Straße. Damit entsteht für das Verkehrsbeobachtungssystem eine landkartenähnliche Darstellung der Straßenverläufe in der lokalen Umgebung.





## 8.1 Umgebungsraster

Im ersten Schritt dieses Verfahrens wird ein Beobachtungsbereich festgelegt. Nur in diesem Bereich werden die detektierten Ziele genutzt, um Fahrspuren zu ermitteln und die Umgebung zu erkennen.

Dieser Beobachtungsbereich liegt innerhalb des Sichtbereichs des Radarsensors und wird in dem hier betrachteten Anwendungsfall als rechteckig angenommen. In dieser Arbeit werden in Blickrichtung des Sensors, die im Folgenden als  $x$ -Richtung definiert ist, 100 m betrachtet und zu den Seiten in  $y$ -Richtung jeweils 20 m nach links und rechts, so dass ein Bereich von 100 m mal 40 m entsteht.

Anschließend wird, wie in [Beh16] dargestellt, ein kartesisches Raster über diesen Bereich gelegt, so dass der Beobachtungsbereich in einzelne kartesische Zellen unterteilt wird. Dieser Sachverhalt ist in Abbildung 44 schematisch dargestellt.




Abbildung 44: Kartesisches Raster über dem Beobachtungsbereich des Radarsensors



Nachdem der Radarsensor in seiner endgültigen Position installiert ist, beginnt eine Initialisierungsphase, in der der Radarsensor möglichst viele Radarziele von passierenden Fahrzeugen detektiert und deren Position sowie deren radiale Geschwindigkeit ermittelt und speichert. Anschließend wird der Fahrspurverlauf ermittelt, aus dem der Ausrichtungswinkel extrahiert wird. Die Kenntnis des Ausrichtungswinkels wird später im Trackingverfahren als Vorwissen eingebracht. Diese Initialisierungsphase dauert entweder eine bestimmte Zeitspanne oder bricht ab, nachdem genügend Fahrzeuge am Radarsensor vorbeigefahren und ausreichend Daten erfasst worden sind.

In der Initialisierungsphase detektiert der Radarsensor in jedem Messzyklus neue Ziele in Polarkoordinaten im gesamten Beobachtungsbereich und ordnet jedem Ziel eine Position im kartesischen Raster zu. Anschließend wird für jede Zelle des Rasters die Anzahl der detektierten Radarziele ermittelt. Während der Initialisierungsphase entsteht ein immer detaillierteres Bild über die Lage der Straßenverläufe im Beobachtungsbereich des Radarsensors.

Zusätzlich wird über alle detektierten Ziele einer Zelle die mittlere radiale Geschwindigkeit berechnet. Beide Informationen, sowohl die Anzahl der in einer Zelle detektierten Ziele als auch ihre mittlere radiale Geschwindigkeit, werden in dem Umgebungsraster gespeichert.

Nach Durchfahrt von mindestens 20 Fahrzeugen ergibt sich eine Häufigkeitsverteilung der Ziele, die in Abbildung 45 zu sehen ist. Der Radarsensor befindet sich, hier dargestellt als roter Punkt, im Ursprung des Koordinatenrasters.

Dieses Beispiel zeigt die zuvor in Abbildung 44 dargestellte Linkskurve. Im Histogramm ist zu erkennen, wie sich die Zielpositionen in der Simulation bei einem solchen Szenario verteilen. Im Nahbereich des Sensors sind mehr Ziele pro Zelle vorhanden, da sich die Winkelunsicherheit in größerer Entfernung stärker auswirkt und die Ziele so über mehrere benachbarte Zellen verteilt werden.

Die Zellgröße wird so gewählt, dass ihre Größe die Breite einer Fahrspur nicht überschreitet, aber der Verarbeitungsaufwand limitiert wird. Als gutes Mittelmaß zwischen diesen beiden Voraussetzungen hat sich eine Zellengröße von 2 m mal 2 m ergeben, so dass der Beobachtungsbereich von 100 m mal 40 m mit dem Raster in 50 mal 20 quadratische Zellen unterteilt wird.




Abbildung 45: Histogramm über die Anzahl der Ziele, die in jeder Zelle des kartesischen Rasters detektiert worden sind



## 8.2 Erkennung der Fahrspuren

Aus diesem mit dem Raster erzeugten Histogramm werden nun die Fahrspur und die dazugehörige Fahrbahnmitte extrahiert. Die Position der Straßen befindet sich an den Stellen im Histogramm, an denen die meisten bewegten Radarziele detektiert wurden.

Um diese Fahrspur zu ermitteln, wird aus dem Histogramm eine Matrix erzeugt, wobei die Zellen des Histogramms die einzelnen Elemente der Matrix sind, welche mit den Indizes  $i$  und  $j$  angesprochen werden.

### 8.2.1 Spurfindungsalgorithmus

In diesem Spurfindungsalgorithmus werden die Matrixelemente, die große Werte beinhalten, mit einem gleitenden Fenster, wie in [Beh16] gezeigt, durchsucht.

Dieses Verfahren soll zunächst anhand eines einfachen Beispiels erläutert werden. Als Ausgangspunkt existiert eine Matrix mit der pro Zelle gezählten Anzahl der detektierten und bewegten Radarziele. Für dieses Beispiel sieht die Matrix wie folgt aus:

$$\begin{array}{c}
 \downarrow i \\
 \begin{bmatrix}
 0 & 0 & 0 & 0 & 0 & 1 & 9 & 1 \\
 0 & 0 & 0 & 0 & 0 & 0 & 9 & 2 \\
 0 & 0 & 0 & 0 & 0 & 1 & 10 & 0 \\
 0 & 0 & 0 & 0 & 1 & 2 & 7 & 1 \\
 1 & 1 & 0 & 1 & 2 & 6 & 4 & 0 \\
 8 & 10 & 13 & 11 & 10 & 4 & 2 & 0 \\
 0 & 2 & 0 & 1 & 0 & 1 & 0 & 0
 \end{bmatrix} \\
 \xrightarrow{j}
 \end{array}$$

Im Folgenden wird der komplette Ablauf des Algorithmus mit seinen einzelnen Phasen nachgestellt.



0	0	0	0	0	1	9	1
0	0	0	0	0	0	9	2
0	0	0	0	0	1	10	0
0	0	0	0	1	3	7	1
1	1	0	1	2	6	4	0
8	10	13	11	10	4	2	0
0	2	0	1	0	1	0	0

Zunächst wird die Zelle mit der höchsten Anzahl detektierter Ziele gesucht.

0	0	0	0	0	1	9	1
0	0	0	0	0	0	9	2
0	0	0	0	0	1	10	0
0	0	0	0	1	3	7	1
1	1	0	1	2	6	4	0
8	10	13	11	10	4	2	0
0	2	0	1	0	1	0	0

Alle Nachbarzellen der Startzelle werden in einem Fenster nach einer maximalen Anzahl durchsucht.

0	0	0	0	0	1	9	1
0	0	0	0	0	0	9	2
0	0	0	0	0	1	10	0
0	0	0	0	1	3	7	1
1	1	0	1	2	6	4	0
8	10	13	11	10	4	2	0
0	2	0	1	0	1	0	0

Der Nachbar mit dem höchsten Wert wird markiert und dessen Nachbarzellen in Grün nach dem höchsten Wert durchsucht.



0	0	0	0	0	1	9	1
0	0	0	0	0	0	9	2
0	0	0	0	0	1	10	0
0	0	0	0	1	3	7	1
1	1	0	1	2	6	4	0
8	10	13	11	10	4	2	0
0	2	0	1	0	1	0	0

Selbiges passiert im nächsten Schritt, dieses Mal markiert in Violett.

0	0	0	0	0	1	9	1
0	0	0	0	0	0	9	2
0	0	0	0	0	1	10	0
0	0	0	0	1	3	7	1
1	1	0	1	2	6	4	0
8	10	13	11	10	4	2	0
0	2	0	1	0	1	0	0

Wenn eine Ecke im Suchfelder den höchsten Wert hat, werden im nächsten Schritt fünf weitere Nachbarzellen nach dem höchsten Wert durchsucht, die hier in Orange markiert sind.

0	0	0	0	0	1	9	1
0	0	0	0	0	0	9	2
0	0	0	0	0	1	10	0
0	0	0	0	1	3	7	1
1	1	0	1	2	6	4	0
8	10	13	11	10	4	2	0
0	2	0	1	0	1	0	0

Dieses Verfahren wird solange fortgeführt, bis die Suche an einer Kante der Matrix endet.



0	0	0	0	0	1	9	1
0	0	0	0	0	0	9	2
0	0	0	0	0	1	10	0
0	0	0	0	1	3	7	1
1	1	0	1	2	6	4	0
8	10	13	11	10	4	2	0
0	2	0	1	0	1	0	0

Anschließend wird von der blau markierten Startzelle aus erneut gesucht, um das andere Ende der Fahrspur zu finden.

0	0	0	0	0	1	9	1
0	0	0	0	0	0	9	2
0	0	0	0	0	1	10	0
0	0	0	0	1	3	7	1
1	1	0	1	2	6	4	0
8	10	13	11	10	4	2	0
0	2	0	1	0	1	0	0


Auch hier wird die Suche dann entsprechend fortgeführt, bis der Rand der Matrix erreicht wurde.

0	0	0	0	0	1	9	1
0	0	0	0	0	0	9	2
0	0	0	0	0	1	10	0
0	0	0	0	1	3	7	1
1	1	0	1	2	6	4	0
8	10	13	11	10	4	2	0
0	2	0	1	0	1	0	0

So ergeben sich zusammenhängende Zellen, die sich bis zu den Rändern des Beobachtungsbereichs erstrecken.



Abschließend ist das Auswertungsergebnis des Algorithmus für das Beispiel in Abbildung 46 dargestellt. Die weiße Linie zeigt das Ergebnis des Algorithmus als Verbindungslinie aller gefundenen Zellen zwischen den Rändern des Sichtbereichs.



**Abbildung 46:** Häufigkeitsverteilung der detektierten Ziele und Ergebnis des Spurfindungsalgorithmus als weiße Linie für das zuvor erläuterte Beispiel


Für eine Simulation, wie als Histogramm in Abbildung 45 dargestellt, ergibt sich mit dem beschriebenen Algorithmus die folgende in Abbildung 47 dargestellte Fahrspur. Dabei ist das Ergebnis des Algorithmus als weiße Linie dargestellt.

Mit diesem Ergebnis sind, wie in Abbildung 47 gezeigt, nur Verbindungen möglich, welche eine Ausrichtung in 45°-Abschnitten haben, da nur die Mittelpunkte benachbarter Zellen miteinander verbunden werden. Da der Ausrichtungswinkel im Tracking





aber deutlich genauer ermittelt werden muss, um als Vorwissen dienen zu können, wird das Ergebnis mit einer Schwerpunktberechnung verfeinert.




**Abbildung 47: Häufigkeitsverteilung der detektierten Ziele mit dem Ergebnis des Spurfindungsalgorithmus in Weiß**

Bisher wird der nächste Punkt der Fahrbahn immer in der Mitte einer kartesischen Rasterzelle gefunden. Die Zelle, in der die meisten Ziele detektiert werden, gibt vor, welchen Zwischenpunkt der Algorithmus errechnet. Dabei werden die Werte der anderen Zellen, welche in der näheren Umgebung liegen, komplett außer Acht gelassen.


Dies wird nun geändert, indem der Algorithmus durch eine Schwerpunktberechnung auch die Nachbarzellen neben der gefundenen Zelle betrachtet. Hierbei werden während des Suchalgorithmus alle Nachbarn in Suchrichtung betrachtet, um einen gemittelten Wert zu finden und nicht nur auf die Mitte der Zellen beschränkt zu sein.

Der Schwerpunktalgorithmus führt zu folgendem in Abbildung 48 dargestellten Ergebnis. Hier ist zu sehen, wie die Fahrspur einen geglätteten Verlauf aufweist und nicht mehr in festen Winkelabschnitten vorliegt.



**Abbildung 48:** Ergebnis des Spurfindungsalgorithmus in Weiß mit zusätzlicher Schwerpunktbetrachtung

In einem weiteren Beispiel liegt die Fahrspur genau mittig zwischen zwei Rasterzellen, so dass bei reiner Betrachtung der Maximalwerte die gefundene Fahrbahn zwischen den Zellen schwanken würde. Mit Hilfe der Schwerpunktberechnung stellt sich das Ergebnis des in Abbildung 49 gezeigten Beispiels aber als gute Interpolation der Fahrspur heraus.



**Abbildung 49:** Ergebnis des Spurfindungsalgorithmus in Weiß mit zusätzlicher Schwerpunktbetrachtung, wenn die Fahrspur auf der Grenze zwischen zwei Zellen liegt



Durch den zusätzlichen Einsatz eines gleitenden Mittelwertfilters kann das Ergebnis noch weiter verfeinert und die Positionsgenauigkeit erhöht werden. Damit ergibt sich dann ein sehr genauer Verlauf der gefundenen Fahrspur, die so eine gute Basis für das Vorwissen im Trackingalgorithmus aus Kapitel 7 bildet. Eine gute Positionsgenauigkeit unterstützt dabei die Genauigkeit des Ausrichtungswinkels.

Dafür werden für jeden Rasterpunkt, der im Suchalgorithmus gefunden wurde, die gefilterten Koordinaten in einer Liste gespeichert. So sind bestimmte Zwischenpunkte der Fahrspur mit ihren Koordinaten bekannt. Es muss daher nicht das komplette Raster gespeichert werden, sondern nur die Liste der einzelnen Punktkoordinaten.

### 8.2.2 Spurfindungsverfahren von mehreren Fahrspuren

Um mehrere Fahrspuren gleichzeitig zu finden, muss der Algorithmus mehrmals durch das Raster laufen. Nachdem eine Fahrspur komplett zwischen den Rändern des Rasters gefunden worden ist, wird der Wert im Histogramm in allen bereits durchsuchten Feldern negiert. Damit ist die Information über die Anzahl der Ziele pro Zelle noch im absoluten Wert vorhanden, aber dennoch sind die entsprechenden Zellen durch das negative Vorzeichen markiert. So wird bei einem erneuten Durchsuchen des Rasters, startend von der Zelle mit der höchsten Zielanzahl, nicht noch einmal dieselbe Fahrspur gefunden, da der zuletzt gefundene maximale Wert sowie alle anderen Werte dieser Fahrspur nun negativ sind. Stattdessen gibt es einen neuen höchsten Wert, welcher als neuer Startwert für die nächste Fahrspur genutzt wird.


Nach Abschluss einer Fahrspur wird das Raster erneut nach einem Maximum durchsucht. Je nachdem, wie hoch dieses ist, wird angenommen, dass sich dort noch eine weitere Fahrspur befindet oder keine weitere Spur mehr vorhanden ist. Wenn die verschiedenen Spuren etwa gleich viel befahren werden, haben Simulationen ergeben, dass es reicht, wenn der neue Maximalwert größer als die Hälfte des ursprünglich größten Wertes im Histogramm ist, um anzunehmen, dass hier noch eine weitere Fahrspur existiert.



### 8.2.3 Erfassung der Fahrtrichtung

Für alle gefundenen Fahrspuren soll zusätzlich zur Position auch die Fahrtrichtung erkannt werden, damit eine definitive Ausrichtung ans Tracking übergeben werden kann. Dazu wird die zweite Information genutzt, die in der Initialisierungsphase in den einzelnen kartesischen Zellen des Rasters gespeichert wurde – die mittlere radiale Geschwindigkeit der Ziele.

Wenn eine Straße mit zwei Fahrspuren betrachtet wird, wovon jeweils eine zum Radarsensor hin und eine davon weg führt, dann ergibt sich zunächst im Histogramm gemeinsam mit dem Spurfindungsalgorithmus die folgende Abbildung 50. Anhand dieser Abbildung ließe sich nicht unterscheiden, welche der beiden Fahrspuren die des ankommenden Verkehrs ist und welche die der abfließenden Fahrzeuge.




**Abbildung 50:** Ergebnis des Spurfindungsalgorithmus bei einer zweispurigen Straße

Um dieses herauszufinden, wird die gespeicherte, mittlere radiale Geschwindigkeit der pro Zelle gefundenen Ziele genutzt. Diese gemittelten Geschwindigkeiten sind entsprechend ihrem Vorzeichen in Abbildung 51 dargestellt.

Die radiale Geschwindigkeit zeigt immer direkt zum Radarsensor hin oder davon weg und ist damit vorzeichenbehaftet. Wenn die Geschwindigkeit negativ ist, dann bewegt



sich das Fahrzeug auf den Radarsensor zu, was in Abbildung 51 in Grün dargestellt ist. Eine positive radiale Geschwindigkeit ist in Rot abgebildet. Demnach entfernen sich die Fahrzeuge auf dieser Fahrspur vom Radarsensor.



**Abbildung 51:** Darstellung des Vorzeichens der mittleren radialen Geschwindigkeit pro Zelle bei einer zweispurigen Straße, wobei Rot eine positive und Grün eine negative radiale Geschwindigkeit markiert

Damit lässt sich die Richtung der einzelnen Fahrspuren direkt mit der Ausrichtung und dem Verlauf der Fahrspuren bestimmen und so als Information ins Tracking integrieren, um dieses zu verbessern.

#### 8.2.4 Kreuzende Fahrspuren

Eine besondere Herausforderung für den Spurfindungsalgorithmus sind kreuzende Fahrbahnen. Die Zielhäufigkeit in einer solchen Situation ist in Abbildung 52 dargestellt. Wie zu erwarten, befindet sich die Zelle mit dem maximalen Wert an der Stelle, wo sich die beiden Fahrspuren kreuzen.




Abbildung 52: Häufigkeitsverteilung der detektierten Ziele bei sich kreuzenden Fahrspuren

Von dieser Zelle ausgehend wird in die Richtung gesucht, in der sich die Nachbarzelle mit dem nächst höheren Wert befindet. Wenn der Rand erreicht ist, ist es wichtig, darauf zu achten, dass erneut von der Maximalzelle startend nun in die gegenüberliegende Richtung gesucht wird und nicht in einem rechten Winkel dazu. Dieses würde sonst dazu führen, dass zwei Hälften verschiedener Fahrspuren miteinander verbunden würden.

Nach Abschluss der ersten Fahrspur werden die Werte aller durchsuchten Zellen negiert. Deshalb liegt der nächste Maximalwert nicht mehr im Kreuzungspunkt, sondern auf einer bisher nicht gefundenen Position. Von diesem Punkt aus wird der Algorithmus erneut gestartet. Sobald die zuerst gefundene Fahrspur dabei geschnitten wird, wird über diese in gleichbleibender Richtung mit einem kleineren Suchbereich hinweggegangen und auf der anderen Seite der Algorithmus weitergeführt.

In der Simulation einer solchen Situation ist das Ergebnis in Abbildung 53 dargestellt.






Abbildung 53: Ergebnis des Spurfindungsalgorithmus bei sich kreuzenden Fahrbahnen

### 8.3 Extraktion des Vorwissens aus der gefundenen Fahrspur

Mit dem Ergebnis des Spurfindungsalgorithmus ergeben sich die Indizes der Zellen, in denen die Fahrspur liegt.

Um diese in kartesische Koordinaten zu überführen, muss das Wissen über die Größe des Rasters bekannt sein. Dazu gehört die Anfangsposition, an der das Raster startet. Diese Position wird im Folgenden als  $P_0$  bezeichnet und besteht aus dem kleinsten  $x$ - und  $y$ -Wert, welche jeweils als  $x_0$  und  $y_0$  beschrieben werden. In den bisher simulierten Beispielen war  $x_0 = 0m$  und  $y_0 = -20m$ .

Zusätzlich muss die Zellengröße bekannt sein, welche bisher mit  $x_z = 2m$  und  $y_z = 2m$  angenommen wurde. Um nun aus den Indizes  $i$  und  $j$  kartesische Koordinaten zu berechnen, können folgende Gleichungen genutzt werden:

$$x = x_0 + (i - 0,5) * x_z , \quad (8.9)$$


$$y = y_0 + (j - 0,5) * y_z . \quad (8.10)$$

Diese Position liegt auf dem Mittelpunkt der Zelle mit den Indizes  $i$  und  $j$ . Durch die angewandte Schwerpunktberechnung verschieben sich die Werte aus dem Mittelpunkt der Zelle heraus. Dennoch wird für jede gefundene Zelle eine kartesische Position



ermittelt. Damit ergibt sich eine Abfolge von Punkten im kartesischen Raum, also eine Liste aus Positionen, die auf der gefundenen Fahrbahn liegen. Diese Liste ist die gespeicherte Version der Fahrbahn, die für das Vorwissen genutzt wird.

Die Reihenfolge der Punkte in der Liste hängt von der Fahrtrichtung ab, die über die mittlere radiale Geschwindigkeit der Ziele, wie in Kapitel 8.2.3, ermittelt worden ist. Mit Hilfe der Punkte und deren Verbindungen lassen sich dann weitere Eigenschaften der Fahrbahnmitte berechnen wie beispielsweise der Ausrichtungswinkel. Zur Verdeutlichung der Berechnung wird Abbildung 54 genutzt. Ziel ist es, die Ausrichtung einzelner Segmente der Fahrbahnmitte  $\bar{\psi}_n$  zu berechnen. Dieses ist mit den Positionen der einzelnen gespeicherten Punkte der Fahrbahn, die aus den Indizes gewonnen und eventuell noch einmal gefiltert wurden, möglich.



**Abbildung 54:** Skizze zur Berechnung der Ausrichtung einzelner Fahrbahnsegmente, welche in Blau dargestellt sind

Um die Steigung eines Segments zwischen zwei Punkten zu berechnen, werden zunächst die Differenzen  $dx$  und  $dy$  der Koordinaten dieser Punkte gebildet:





$$dx_n = x_{n+1} - x_n \quad , \quad (8.11)$$

$$dy_n = y_{n+1} - y_n \quad . \quad (8.12)$$

Anschließend kann daraus der Ausrichtungswinkel des Segments  $\bar{\psi}_n$  berechnet werden:

$$\bar{\psi}_n = \tan^{-1} \left( \frac{dy_n}{dx_n} \right) \quad . \quad (8.13)$$

Diese Berechnung wird für alle Segmente der abgespeicherten Fahrbahnpositionen durchgeführt. Um den Ausrichtungswinkel  $\psi_n$  in einem der Zwischenpunkte zu erhalten, werden die Werte aus den beiden benachbarten Segmenten gemittelt:

$$\psi_n = \frac{\bar{\psi}_{n-1} + \bar{\psi}_n}{2} \quad . \quad (8.14)$$

Mit dem Anlegen dieser Liste, in der die Positionen der Fahrbahn sowie der zusätzliche in Gleichung (8.14) berechnete Ausrichtungswinkel für jeden Punkt abgespeichert werden, endet die Installationsphase des Radarsensors, in der das Vorwissen generiert wird. Die als Listen gespeicherten Fahrbahnen stehen danach im normalen Betrieb des Radarsensors dem Trackingalgorithmus als Vorwissen zur Verfügung.

#### 8.4 Integration des Vorwissens in das Tracking

Wenn der normale Betrieb des Sensors beginnt, muss der Trackingalgorithmus das Vorwissen aus den gefundenen Fahrbahnen auslesen. Von jeder beliebigen Position eines Tracks  $P_t$  muss daher der Punkt mit dem geringsten Abstand auf der gefundenen Fahrbahn ermittelt werden, so dass von dort der passende Ausrichtungswinkel in Erfahrung gebracht wird.

Eine wie in Kapitel 8.3 erläuterte Liste von Punkten beschreibt die Fahrbahnen in der Umgebungskarte, welche das Vorwissen für das Tracking liefern soll. Diese Fahrbahn wird in einzelnen, durchnummerierten Unterpunkten gespeichert. Für jeden dieser  $n$  Punkte existiert eine Position und ein Ausrichtungswinkel  $\psi_n$ .



Für jeden Track muss nun zu einem im Filter bestimmten Zeitpunkt und zu seiner Position  $P_t$  der Ausrichtungswinkel aus dem Vorwissen bezogen werden. Dazu wird die zur Position des Tracks passendste Fahrbahn ermittelt. Dieses ist die Fahrspur, welche dem Track am nächsten ist.

Anschließend werden die zwei dem Track nächsten Unterpunkte der Fahrbahn gesucht, in denen ein Ausrichtungswinkel abgespeichert wurde. Zwischen diesen beiden gespeicherten Punkten befindet sich der Referenzpunkt, aus dem das Vorwissen für das Tracking bezogen wird. Dieser Referenzpunkt ist der Lotpunkt  $P_L$  auf der Fahrbahn, an dem der Abstand zwischen Track und Fahrspur am geringsten ist, siehe den grünen Punkt in Abbildung 55.




Abbildung 55: Der Track (rot) bezieht den Ausrichtungswinkel aus dem Lotpunkt (grün) auf der Fahrbahn



Für diesen Referenzpunkt wird der Ausrichtungswinkel berechnet, da dieser nur in den angrenzenden Unterpunkten berechnet und gespeichert wurde. Dieses ist möglich, in dem die beiden Strecken  $s_1$  und  $s_2$  bestimmt werden.

Mit dem Verhältnis der Strecken können die Ausrichtungswinkel der gespeicherten Fahrbahnpositionen so gewichtet werden, dass der Winkel im Lotpunkt  $\psi_L$  approximiert wird. Dabei geht der Ausrichtungswinkel eines Punktes stärker in die Berechnung ein, je geringer der dazugehörige Abstand des Punktes zum Lotpunkt ist. Somit ergibt sich der Ausrichtungswinkel im Lotpunkt zu:

$$\psi_L = \frac{\psi_2 s_1 + \psi_1 s_2}{s_1 + s_2} . \quad (8.15)$$

Dieser im Lotpunkt errechnete Ausrichtungswinkel wird vom Referenzpunkt als Vorwissen an den Trackingalgorithmus übergeben. Damit erhöht sich die Genauigkeit der Prädiktion des Zustandsvektors, was die Assoziation verbessert und damit zur einer verbesserten Objektverfolgung führt.



## 9 Fazit

Durch wachsendes Verkehrsaufkommen werden Verkehrsbeobachtungssysteme immer stärker gefragt. In dieser Arbeit wird dargelegt, dass ein stationärer Radarsensor in vielen Beobachtungsszenarien vor allem auf Grund seiner Allwetterfähigkeit eine gute Wahl für diese Aufgabe ist. Zusätzlich bietet die direkte Geschwindigkeitsmessung des Radarverfahrens einen großen Vorteil in vielen Straßenszenarien.

Für die meisten Anwendungsfälle der Verkehrsbeobachtung ist ein Radarsensor mit einem leistungsstarken Tracking vonnöten. Mittels dieses Trackingalgorithmus können einzelne Zielmessungen zu Objekten kombiniert werden, so dass Aussagen über den Fahrweg und die Vergangenheit einzelner Objekte möglich sind. Da die Beobachtungsszenarien komplexer werden, wird auch das Tracking mit immer komplexeren Herausforderungen konfrontiert.

Im Rahmen dieser Arbeit wird dargestellt, wie in den häufigsten Anwendungen ein solches Tracking durchgeführt wird. Dabei werden Kalman-Filter angewendet, welche die Zustände der Objekte filtern.

Zusätzlich werden hier neue Bewegungsmodelle vorgeschlagen, die darauf basieren, dass dem Radarsensor Vorwissen über seine Umgebung bekannt ist. Es wird mittels Simulationen gezeigt, wie groß der Vorteil dieser Bewegungsmodelle mit Vorwissen gegenüber den ursprünglich genutzten ist. Dieses Vorwissen unterstützt das Tracking, indem es vorgibt, in welcher Ausrichtung und Lage sich Fahrbahnen im Sichtbereich



des Sensors befinden. Damit kann die einfache Annahme getätigt werden, dass sich die Fahrzeuge auf den bekannten Fahrbahnen bewegen und damit ihre Bewegungsrichtung abhängig von ihrer Position vorab bekannt ist.

In komplexeren Straßenszenarien, wie in Kurvenfahrten oder bei Spurwechseln, wird durch das Vorwissen eine deutliche Reduzierung des Trackingfehlers erreicht, so dass die Objekte besser verfolgt werden können. Des Weiteren wird ein Bewegungsmodell vorgeschlagen, welches die Beschleunigung der Objekte zusätzlich schätzt und filtert, so dass Beschleunigungs- und Anhaltvorgänge besonders an Kreuzungen besser und stabiler verfolgt werden können. Somit ist auch eine bessere Verkehrsbeobachtung mit diesem Vorwissen und den vorgeschlagenen Bewegungsmodellen möglich.

Im Anschluss wird dargestellt, wie das erforderliche Vorwissen für diese Anwendung aus den Radardaten selbst gewonnen werden kann. Dabei sammelt der Radarsensor selbst in einer Initialisierungsphase Informationen über seine Umgebung. Diese Informationen werden in einem Raster gespeichert und mittels eines Spurfindungsalgorithmus extrahiert.

Dieser Algorithmus macht es sich zunutze, dass die bewegten Radarziele von den Fahrzeugen, die sich auf der Fahrbahnmitte befinden, reflektiert werden. Die Ziele werden dazu ausgewertet und mittels eines Suchalgorithmus werden Fahrspuren gefunden, so dass diese extrahierten Informationen im Anschluss der Initialisierungsphase dem Tracking zur Verfügung stehen. Damit können die vorgeschlagenen Bewegungsmodelle mit Vorwissen verwendet werden, um damit ein besseres Trackingergebnis zu erzielen. Dieser Algorithmus ist leicht anpassbar, so dass viele Sonderfälle in der Verkehrsführung damit gelöst werden können.

Abschließend lässt sich feststellen, dass sich durch die vom Radarsensor selbst ermittelten Informationen eine wesentliche Verbesserung im Tracking erzielen lässt.



## 10 Symbole und Abkürzungen

$\alpha$	Faktor im $\alpha$ - $\beta$ -Filter und im Unscented-Kalman-Filter
$\alpha_S$	Schwellwertfaktor
$\beta$	Faktor im $\alpha$ - $\beta$ -Filter und im Unscented-Kalman-Filter
$\kappa$	Faktor im Unscented-Kalman-Filter
$\lambda$	Wellenlänge
$\nu$	Faktor im Unscented-Kalman-Filter
$\sigma$	Standardabweichung
$\sigma_n$	Effektivwert des Rauschens
$\sigma_n^2$	Varianz des Rauschens
$\Sigma$	Hauptdiagonalmatrix mit den Unsicherheiten des Messvektors
$\tau$	Laufzeit
$Y_i$	Transformierter $i$ . Sigma-Punkt
$\varphi$	Azimutwinkel
$\Phi$	Transformationsmatrix
$\phi$	Phasenverschiebung
$\Delta\phi$	Phasenunterschied, -differenz
$\phi_E$	Phasenverschiebung im Empfangssignal
$\chi_i$	$i$ . Sigma-Punkt
$\psi$	Ausrichtungswinkel



$\check{\psi}$	Durch die Ausrichtungswinkeländerung korrigierter Ausrichtungswinkel
$\bar{\psi}$	Ausrichtungswinkel der Segmente der ermittelten Fahrspur
$\psi_L$	Ausrichtungswinkel im Lotpunkt
$\omega$	Drehgeschwindigkeit, Gierrate
$A$	Signalamplitude
$A_S$	Signalamplitude des Sendesignals
$A_E$	Signalamplitude des Empfangssignals
$B$	Multiplikationsmatrix zum Eingangssignal
$c$	Lichtgeschwindigkeit
$d$	Abstand
$d\psi$	Ausrichtungswinkeländerung
$f$	Frequenz
$f_0$	Grundfrequenz eines Dauerstrichradars
$f_a$	Frequenzverschiebung im Upchirp
$f_b$	Frequenzverschiebung im Downchirp
$f_D$	Dopplerfrequenz
$\Delta f_D$	Auflösung der Dopplerfrequenz
$f_E$	Empfangsfrequenz
$f_{Hub}$	Bandbreite, Frequenzhub
$f_{PF}$	Pulswiederholungsfrequenz eines Pulsradars
$f_{shift}$	Frequenzabstand der beiden Sendefrequenzen eines FSK Radars



$f_S$	Sendefrequenz
$f_v$	Frequenzverschiebung, -unterschied
$f_\tau$	Frequenzverschiebung durch den Laufzeitunterschied
$h(t)$	Messfunktion
$H$	Messmatrix
$i,j$	Matrix-Indizes
$I$	Realanteil des Eingangssignals
$I_0$	Modifizierte Bessel-Funktion 1. Art und nullter Ordnung
$J$	Jacobi-Matrix
$k$	Zyklus, diskreter Zeitpunkt z. B. im Kalman-Filter
$K$	Kalman-Matrix, Verstärkungsmatrix
$l$	Länge des Schieberegisters des CFAR-Detektors
$L$	Dimension des Zustandsvektors
$m_k$	Messrauschen zum Zeitpunkt $k$
$n$	Unterpunktnummer der ermittelten Fahrspur
$N$	Rauschleistung
$p(x)$	Wahrscheinlichkeitsdichtefunktion
$p(x_1, x_2)$	Verbundwahrscheinlichkeitsdichte
$P$	Sendeleistung
$P_0$	Ursprung des Rasters für den Spurfindungsalgorithmus
$P_D$	Detektionswahrscheinlichkeit





$P_{Fa}$	Falschalarmwahrscheinlichkeit
$P_k$	Kovarianzmatrix zum Zeitpunkt $k$
$\hat{P}_k$	Prädizierte Kovarianzmatrix zum Zeitpunkt $k$
$P_L$	Lotpunkt, Referenzpunkt
$P_T$	Leistung in der Testzelle in einem CFAR-Detektor
$P_t$	Trackmittelpunkt
$P_{tz}$	Kreuzkovarianzmatrix
$Q$	Imaginärteil des Eingangssignals
$Q_k$	Systemrauschmatrix zum Zeitpunkt $k$
$r$	Entfernung
$r_{max}$	Entfernungseindeutigkeit
$r_k$	Prozessrauschen zum Zeitpunkt $k$
$\Delta r$	Entfernungsauflösung
$R$	Messrauschmatrix
$s$	Streckenabschnitt
$s_E$	Empfangssignal
$s_S$	Sendesignal
$\Delta s$	Gangunterschied
$S$	Signalleistung
$S/N$	Signal-zu-Rausch-Verhältnis
$\hat{S}$	Innovationskovarianzmatrix



$S_D$	Detektionsschwelle
$t$	Zeit
$\bar{t}$	Mittelwert einer Zufallsvariablen $t$
$t_b$	Zeit einer Sendestufe im MFSK-Radar
$t_k$	Zustandsvektor zum Zeitpunkt $k$
$\hat{t}_k$	Prädizierter Zustandsvektor zum Zeitpunkt $k$
$t_C$	Chirpdauer eines Dauerstrichradars, Beobachtungsdauer
$t_E$	Empfangszeit eines Pulsradars
$t_S$	Sendezeit eines Pulsradars, Pulsdauer
$t_{PI}$	Pulswiederholungsintervall eines Pulsradars
$\Delta t$	Zykluszeit
$u_k$	Eingangssignal zum Zeitpunkt $k$
$v$	Geschwindigkeit
$v_r$	Radiale Geschwindigkeit
$v_t$	Tangentiale Geschwindigkeit
$v_x$	Geschwindigkeit in $x$ -Richtung
$v_y$	Geschwindigkeit in $y$ -Richtung
$\Delta v_r$	Auflösung der radialen Geschwindigkeit
$W_i$	Gewicht des $i$ . Sigma-Punktes
$x, y$	Positionskordinaten
$x_0, y_0$	Ursprung des Rasters für den Spurfindungsalgorithmus



$x_1, x_2$	Zufallsvariablen
$x_Z, y_Z$	Größe einer Rasterzelle
$\hat{z}$	Prädizierter Zustandsvektor in Radarkoordinaten
$z_{inno}$	Innovation
$z_{mess}$	Radarmessvektor



CW-Radar	<i>Continuous Wave-Radar</i> Dauerstrichradar
FSK-Radar	<i>Frequency Shift Keying-Radar</i> Frequenzumtastendes Radar
LFMCW-Radar	<i>Linear Frequency Modulated Continuous Wave-Radar</i> Linear frequenzmoduliertes Radar
MFSK-Radar	<i>Multiple Frequency Shift Keying-Radar</i> Linear moduliertes frequenzumtastendes Radar
CFAR	<i>Constant False Alarm Rate</i> Konstante Falschalarmwahrscheinlichkeit
CA-CFAR	<i>Cell-Averaging-CFAR</i> "Mittelwert"-CFAR
CAGO-CFAR	<i>Cell-Averaging-Greatest-Of-CFAR</i> "Größter Mittelwert"-CFAR
OS-CFAR	<i>Ordered-Statistic-CFAR</i> "Geordnete Statistik"-CFAR
OSGO-CFAR	<i>Ordered-Statistic-Greatest-Of-CFAR</i> "Größte geordnete Statistik"-CFAR
Kfz	Kraftfahrzeug
Lkw	Lastkraftwagen
Pkw	Personenkraftwagen
RMSE	<i>Root Mean Square Error</i> Wurzel der mittleren Fehlerquadratsumme





## 11 Literaturverzeichnis

- [ADA17] ADAC, *Staubilanz 2016*, Januar 2017.
- [AWH13] George B. Arfken, Hans J. Weber und Frank E. Harris, *Mathematical Methods for Physicists*, 7. Edition, Academic Press, Boston, 2013.
- [Beh15] Ramona Behrendt, *A Priori Information to Improve Tracking for Traffic Monitoring*, 16th International Radar Symposium (IRS) Dresden, Seiten 357 – 362, 2015.
- [Beh16] Ramona Behrendt, *Traffic Monitoring Radar for Road Map Calculation*, 17th International Radar Symposium (IRS) Krakau, 2016.
- [Bel95] John S. Belrose, *Fessenden and Marconi: Their Differing Technologies and Transatlantic Experiments During the First Decade of this Century*, International Conference on 100 Years of Radio, September 1995.
- [Bla86] Samuel S. Blackman, *Multiple-Target Tracking with Radar Applications*, Artech House, 1986.
- [BP99] Samuel Blackman und Robert Popoli, *Design and Analysis of Modern Tracking Systems*, Artech House, 1999.
- [Bro98] Eli Brookner, *Tracking and Kalman Filtering Made Easy*, John Wiley & Sons, Inc., 1998.
- [Bun15] Bundesministerium für Verkehr und digitale Infrastruktur, *Verkehr in Zahlen 2014/2015*, 2015.
- [Bun16] Bundesanstalt für Straßenwesen, *Voraussichtliche Entwicklung von Unfallanzahlen und Jahresfahrleistungen in Deutschland - Ergebnisse 2016*, Dezember 2016.
- [Dög13] Klaus-Peter Döge, *Videodetektion im Straßenverkehr*, Oldenbourg Verlag München, 2013.



- [Dop42] Christian Doppler, *Ueber das farbige Licht der Doppelsterne und einiger anderer Gestirne des Himmels.*, Abhandlungen der königlichen böhmischen Gesellschaft der Wissenschaften, Seiten 465 – 482, 1842.
- [Eur14] European Commission, *EU transport in figures*, 2014.
- [FN12] Arnd Fitschen und Hartwig Nordmann, *Verkehrsentwicklung auf Bundesfernstraßen 2012*, Bundesanstalt für Straßenwesen, 2012.
- [Föl97] Albrecht Fölsing, *Heinrich Hertz: Eine Biographie*, Hoffmann und Campe Verlag, 1997.
- [For10] Forschungsgesellschaft für Straßen- und Verkehrsplanung, *Hinweise zur kurzzeitigen automatischen Erfassung von Daten des Straßenverkehrs*, 2010.
- [Gel74] Arthur Gelb, *Applied Optimal Estimation*, MIT Press, 1974.
- [Göb00] Jürgen Göbel, *Radartechnik*, VDE Verlag, 2000.
- [Han73] V. Gregers Hansen, *Constant False Alarm Rate Processing in Search Radars*, IEE International Conference on Radar - Present and Future, Seiten 325 – 332, Oktober 1973.
- [Hay01] Simon Haykin, *Kalman Filtering and Neural Networks*, John Wiley & Sons, Inc., 2001.
- [Heu13] Steffen Heuel, *Fußgängererkennung im Straßenverkehr mit 24GHz Radarsensoren*, Dissertation, Technische Universität Hamburg-Harburg, 2013.
- [Hud99] Bernhard Huder, *Einführung in die Radartechnik*, B. G. Teubner, 1999.
- [Hül04a] Christian Hülsmeier, *Verfahren um entfernte metallische Gegenstände mittels elektrischer Wellen einem Beobachter zu melden.*, Patentschrift Nr. 165546, Kaiserliches Patentamt, April 1904.



- [Hül04b] Christian Hülsmeier, *Verfahren zur Bestimmung der Entfernung von metallischen Gegenständen (Schiffen o. dgl.), deren Gegenwart durch das Verfahren nach Patent 165546 festgestellt wird.*, Patentschrift Nr. 169154, Kaiserliches Patentamt, November 1904.
- [JU97] Simon J. Julier und Jeffrey K. Uhlmann, *A New Extension of the Kalman Filter to Nonlinear Systems*, The Robotics Research Group, Department of Engineering Science, The University of Oxford, 1997.
- [Kal60] Rudolf E. Kalman, *A New Approach to Linear Filtering and Prediction Problems*, Transactions of the ASME - Journal of Basic Engineering, 82 (Series D), Seiten 35 – 45, 1960.
- [Klo02] Michael Klotz, *An Automotive Short Range High Resolution Pulse Radar Network*, Dissertation, Technische Universität Hamburg-Harburg, Januar 2002.
- [Kro14] Matthias Kronauge, *Waveform Design for Continuous Wave Radars*, Dissertation, Technische Universität Hamburg-Harburg, 2014.
- [Lüb05] Urs Lübbert, *Target Position Estimation with a Continuous Wave Radar Network*, Dissertation, Technische Universität Hamburg-Harburg, 2005.
- [Lud02] Albrecht Ludloff, *Praxiswissen Radar und Radarsignalverarbeitung*, Vieweg Verlag, März 2002.
- [Max65] James C. Maxwell, *A Dynamical Theory of the Electromagnetic Field*, Philosophical Transactions of the Royal Society of London (155), Seiten 459 – 512, 1865.
- [MG05] Mark R. Morelande und Neil J. Gordon, *Target Tracking through a Coordinated Turn*, IEEE International Conference on Acoustics, Speech and Signal Processing, 2005.
- [RFR07] Hermann Rohling, Florian Fölster, und Henning Ritter, *Lateral Velocity Estimation for Automotive Radar Applications*, IET International Conference on Radar Systems, 2007.





- [Rit13] Henning Ritter, *Fußgängererkennung und Situationsanalyse mit 24GHz Radarsensoren*, Dissertation, Technische Universität Hamburg-Harburg, 2013.
- [RM01] Hermann Rohling und Marc-Michael Meinecke, *Waveform Design Principles for Automotive Radar Systems*, CIE International Conference on Radar Proceedings, 2001.
- [Roh83] Hermann Rohling, *Radar CFAR Thresholding in Clutter and Multiple Target Situations*, IEEE Transactions on Aerospace and Electronic Systems AES-19, Nr. 4, Seiten 608 – 621, Juli 1983.
- [RSH10] Mark A. Richards, James A. Scheer, und William A. Holm, *Principles of Modern Radar - Basic Principles*, SciTech Publishing, 2010.
- [She85] Samuel M. Sherman, *Monopulse Principles and Techniques*, Artech House, Dedham, 1985.
- [SL11] Werner Schnabel und Dieter Lohse, *Grundlagen der Straßenverkehrstechnik und der Verkehrsplanung, Band 1*, 3. Auflage, Beuth Verlag, 2011.
- [Sta17] Statistisches Bundesamt, *Verkehr - Verkehr aktuell*, Fachserie 8 Reihe 1.1, Februar 2017.
- [Tor84] Don J. Torrieri, *Statistical Theory of Passive Location Systems*, IEEE Transactions on Aerospace and Electronic Systems AES-20, Nr. 2, Seiten 183 – 198, 1984.
- [WB06] Greg Welch und Gary Bishop, *An Introduction to the Kalman Filter*, UNC-Chapel Hill, TR 95-041, Juli 2006.
- [WvdM00] Eric A. Wan und Rudolph van der Merwe, *The Unscented Kalman Filter for Nonlinear Estimation*, 2000.



