



**Erkennung von Radfahrern mit einem bildgebenden  
Automobilradar**

# **DISSERTATION**

zur Erlangung des akademischen Grades eines

# **DOKTOR-INGENIEURS**

(Dr.-Ing.)

der Fakultät für Ingenieurwissenschaften  
und Informatik der Universität Ulm

von

**Martin Stolz**

**aus Ulm**

Gutachter: Prof. Dr.-Ing. Wolfgang Menzel

Prof. Dr.-Ing. Thomas Zwick

Amtierender Dekan: Prof. Dr.-Ing. Maurits Ortmanns

Ulm, 15. Juli 2019



# Abstract

Increasing urbanisation leads to higher utilisation of the existing transport infrastructure by motorised vehicles with frequent traffic jams. New environmentally friendly innovations such as electric motorization to overcome medium distances or the development of an own infrastructure have made the bicycle the preferred medium of transport for many people. The traffic between motorised vehicles and cyclists harbours a danger potential what can be proven by stagnating accident figures. To mitigate this problem, more and more driver assistance systems are being developed and used in vehicle fleets specifically for the protection of vulnerable road users. Radar sensors are increasingly being used to detect the vehicle environment in accident avoidance systems. This is convincing due to its robustness against environmental influences and its high-resolution detection of distance, speed and heading direction of an object in only one measurement cycle.

For future protection systems it is being investigated how cyclists can be identified, localised and classified by means of an automotive imaging radar. The basis for this is a prototype radar system that makes it possible to detect multidimensional detection point clouds of an object.

Starting with the generation of a model of a moving cyclist, based on elaborated radar simulations, the recognition of features and cyclist-specific signatures with radar sensor technology is investigated. These extracted features will then be validated with the prototype radar sensor. A further development of the sensor technology towards the possibility of detecting objects in three-dimensional space by designing a new antenna array will also be carried out. The required angle estimation will be developed in parallel.

The extracted characteristics serve as a basis for the localization, classification and motion prediction of a cyclist. Different combinations of measuring ranges and speed resolutions are used. An image of the combined distance and speed representation, the so-called range-Doppler Matrix, was used to determine the type of a detected object. Methods of machine learning are applied and allocation accuracies around 98 % are achieved. Methods from machine learning are also successfully utilized for localization, either directly in the radar images or in a representation of point clouds. The motion prediction is based on evaluations of the point cloud information. Based on this information the direction and speed of movement are predictable.



# Kurzfassung

Zunehmende Urbanisierung führt zu hoher Auslastung der vorhandenen Verkehrsinfrastruktur durch motorisierte Fahrzeuge mit häufigen Staus. Attraktiv durch neue umweltfreundliche Innovationen wie die Elektromotorisierung zur Überwindung von mittleren Entfernungen oder eigener Infrastruktur, ist das Fahrrad mittlerweile für viele das präferierte Transportmittel geworden. Das Verkehrsgeschehen zwischen motorisierten Fahrzeugen und Radlern birgt ein Gefahrenpotential, das sich durch stagnierende Unfallzahlen belegen lässt. Um dieses zu entschärfen werden vermehrt Fahrerassistenzsysteme, speziell für den Schutz von leicht verwundbaren Verkehrsteilnehmern, entwickelt und in den Fahrzeugflotten eingesetzt. Zur Erfassung des Fahrzeugumfelds bei Systemen zur Unfallvermeidung wird zunehmend Radarsensorik eingesetzt. Diese überzeugt durch Robustheit gegenüber Umwelteinflüssen und durch hochauflösende Erfassung von Entfernung, Geschwindigkeit und Richtung eines Objekt in einem Messzyklus.

Für zukünftige Schutzsysteme wird untersucht, wie anhand eines bildgebenden Automobilradar Radfahrer erkannt, lokalisiert und klassifiziert werden können. Grundlage dafür bildet ein prototypisches Radarsystem, das es ermöglicht mehrdimensionale Detektionswolken eines Objekts zu erfassen.

Beginnend mit der Generierung eines Modells des bewegten Radfahrers, für Radarsimulationen, wird die Erkennung von radfahrerspezifischen Merkmalen und Strukturen mit der Radarsensorik untersucht. Anschließend werden diese extrahierten Merkmale mit dem prototypischen Radarsensor messtechnisch validiert. Eine Weiterentwicklung der Sensorik hin zur Möglichkeit der Erfassung von Objekten im dreidimensionalen Raum, durch Entwurf eines neuen Antennenarray, wird ebenfalls durchgeführt. Die benötigte Winkelschätzung wird parallel dazu mitentwickelt.

Die somit extrahierten Merkmale dienen als Grundlage für die Lokalisierung, Klassifizierung und Bewegungsprädiktion eines Radfahrers. Dabei werden verschiedene Kombinationen der Messbereiche genutzt. Zur Feststellung der Objektart wird ein Bild aus der Kombination von Entfernung und Geschwindigkeit genutzt. Darauf können Methoden des maschinellen Lernens angewendet werden, mit denen Zuordnungsgenauigkeiten bis 98 % erzielt werden. Für die Lokalisierung werden ebenfalls Methoden aus dem maschinellen Lernen erfolgreich verwendet, unter anderem durch direkte Verwendung der Radarbilder oder auch in der Darstellungsform mit Punktwolken. Die Bewegungsprädiktion basiert auf den Auswertungen von Punktwolkeninformationen. Anhand dieser Information kann die Bewegungsrichtung und Bewegungsgeschwindigkeit prädiziert werden.



# Vorwort

Die vorliegende Arbeit entstand während meiner Zeit als Doktorand bei der Robert Bosch GmbH am Standort Leonberg in Kooperation mit der Universität Ulm. In der Voraufwicklung Sensor Systeme befasste ich mich mit Fahrerassistenzsystemen auf Basis von Radarsensoren.

Mein besonderer Dank gilt Prof. Dr.-Ing. Wolfgang Menzel für die wissenschaftliche Betreuung meiner Arbeit, für seine fachliche Unterstützung, den zugesprochenen Freiräumen in der Gestaltung der Arbeit, sowie die stets sehr angenehme Kooperation. Herrn Prof. Dr.-Ing. Thomas Zwick danke ich sehr für sein hohes Interesse an meiner Arbeit, der Übernahme des Koreferats sowie der Anfertigung des Zweitgutachtens.

Seitens der Robert Bosch GmbH gilt ein besonderer Dank meinem fachlichen Betreuer Dr.-Ing. Martin Kunert für die stets wertvolle fachliche und menschliche Unterstützung, sowie bei Dr.-Ing. Berthold Käferstein und Dr.-Ing. Lorenz Hagemeyer für das entgegen gebrachte Vertrauen und dem gewährten Freiraum in der Gestaltung und Bearbeitung meines Themas.

Darüber hinaus boten die freundliche und innovative Atmosphäre in der Voraufwicklung den geeigneten Nährboden zum Gelingen dieser Arbeit. In diesem Zusammenhang bedanke ich mich besonders bei Frank Meinl und Dr.-Ing. Eugen Schubert für die gemeinsame Entwicklung eines prototypischen hochauflösenden Radarsensors zum Aufnehmen von Messdaten. Beim gesamten Team möchte ich mich bedanken für die fachlichen Diskussionen und den inspirierenden Gedankenaustausch.

Ein weiterer Dank gilt allen Korrektoren, insbesondere Bettina Glanzer, für das Interesse an meiner Arbeit und ihren wertvollen Korrekturvorschlägen.

Ebenso gilt mein Dank den am öffentlich geförderten Projekt PROSPECT beteiligten Mitarbeitern der kooperierenden Forschungseinrichtungen und Firmen für die offene Zusammenarbeit und den inspirierenden fachlichen Austausch im Rahmen des Projekts.

Nicht zuletzt gebührt meiner Familie und meinen Freunden ein ganz besonderes Dankeschön, für ihre Unterstützung, Rücksichtnahme, Verzicht und den hochgeschätzten Rückhalt während der letzten Jahre.

Leonberg, im Juli 2019

Martin Stolz



# Inhaltsverzeichnis

|          |   |           |
|----------|---|-----------|
| <b>1</b> | <b>Einleitung</b>                                       | <b>1</b>  |
| 1.1      | Zielsetzung und Inhalt . . . . .                        | 3         |
| <b>2</b> | <b>Anforderungen an die Radarsensorik</b>               | <b>5</b>  |
| 2.1      | Analyse von Unfallstatistiken . . . . .                 | 6         |
| 2.2      | Kinematik und Dynamik von Verkehrsteilnehmern . . . . . | 7         |
| 2.2.1    | Kraftfahrzeug . . . . .                                 | 7         |
| 2.2.2    | Radfahrer . . . . .                                     | 9         |
| 2.2.3    | Fußgänger . . . . .                                     | 9         |
| 2.3      | Sensoranforderungen . . . . .                           | 10        |
| 2.3.1    | Erfassungsbereich . . . . .                             | 10        |
| 2.3.2    | Testszenarioszenarien . . . . .                         | 12        |
| 2.3.3    | Urbanes Umfeld . . . . .                                | 13        |
| <b>3</b> | <b>Automobile Radarsensorik</b>                         | <b>15</b> |
| 3.1      | Grundlagen der automobilen Radarsensorik . . . . .      | 16        |
| 3.1.1    | Radargleichung . . . . .                                | 17        |
| 3.1.2    | Radarrückstreuquerschnitt . . . . .                     | 19        |
| 3.1.3    | Entfernungsinformation . . . . .                        | 20        |
| 3.1.4    | Geschwindigkeit sinformation . . . . .                  | 20        |
| 3.2      | Sendsignalmodulation . . . . .                          | 20        |
| 3.2.1    | LFMCW-Radar . . . . .                                   | 21        |
| 3.2.2    | Chirp-Sequence-Radar . . . . .                          | 23        |
| 3.3      | Richtungserfassung . . . . .                            | 26        |
| 3.3.1    | Ausbreitung elektromagnetischer Wellen . . . . .        | 26        |
| 3.3.2    | Antennenarrays . . . . .                                | 28        |
| 3.4      | Radarsensor und Hardwareplattform . . . . .             | 33        |
| 3.5      | Radar Front-End Design . . . . .                        | 35        |
| 3.5.1    | Antennen . . . . .                                      | 36        |
| 3.5.2    | Antennenarray . . . . .                                 | 38        |
| 3.6      | Signalverarbeitung . . . . .                            | 43        |
| 3.6.1    | Spektralanalyse im Basisband . . . . .                  | 44        |
| 3.6.2    | Signaldetektion im Rauschen . . . . .                   | 46        |
| 3.6.3    | Winkelschätzung . . . . .                               | 48        |

|          |  |            |
|----------|--|------------|
| <b>4</b> | <b>Detektion von Radfahrern</b>                              | <b>57</b>  |
| 4.1      | Physikalische Attribute eines Radfahrers . . . . .           | 58         |
| 4.1.1    | Systembetrachtung . . . . .                                  | 58         |
| 4.1.2    | Bewegungsanalyse . . . . .                                   | 60         |
| 4.1.3    | Mikro-Doppler Effekt . . . . .                               | 66         |
| 4.1.4    | RCS . . . . .  | 66         |
| 4.2      | Modellierung eines Radfahrers . . . . .                      | 69         |
| 4.2.1    | Simulationsumgebung . . . . .                                | 69         |
| 4.2.2    | Radfahrermodell . . . . .                                    | 69         |
| 4.2.3    | Sensormodell . . . . .                                       | 71         |
| 4.2.4    | Validierung der Simulation . . . . .                         | 74         |
| 4.2.5    | Fußgängermodell . . . . .                                    | 77         |
| 4.3      | Extraktion von Merkmalen . . . . .                           | 79         |
| 4.3.1    | Objektausdehnung . . . . .                                   | 80         |
| 4.3.2    | Streuzentrengeschwindigkeit . . . . .                        | 81         |
| 4.3.3    | Räumliche Verteilung der Streuzentren . . . . .              | 82         |
| 4.3.4    | Eigengeschwindigkeit . . . . .                               | 89         |
| 4.3.5    | Erkennungsbereich . . . . .                                  | 90         |
| 4.4      | Anforderungen an einen artikulierte Radfahrerdummy . . . . . | 91         |
| <b>5</b> | <b>Klassifizierung von Radfahrern</b>                        | <b>95</b>  |
| 5.1      | Neuronale Netze . . . . .                                    | 96         |
| 5.1.1    | Aktivierungsfunktion . . . . .                               | 98         |
| 5.1.2    | Backpropagation . . . . .                                    | 101        |
| 5.1.3    | Faltende Neuronale Netze . . . . .                           | 103        |
| 5.2      | Bereichsdetektion . . . . .                                  | 105        |
| 5.2.1    | Clustering im Bildbereich . . . . .                          | 106        |
| 5.2.2    | Bereichsdetektionsnetzwerk . . . . .                         | 110        |
| 5.3      | Datenpräparation . . . . .                                   | 111        |
| 5.3.1    | Generierung von Trainings- und Testdaten . . . . .           | 112        |
| 5.4      | Klassifizierung . . . . .                                    | 114        |
| 5.4.1    | Faltendes Neuronales Netz . . . . .                          | 115        |
| 5.4.2    | Klassifizierungsnetz mit Bereichsdetektion . . . . .         | 118        |
| <b>6</b> | <b>Zusammenfassung</b>                                       | <b>123</b> |
| 6.1      | Ausblick . . . . .   | 124        |
|          | <b>Literatur</b>   | <b>127</b> |

# Abkürzungsverzeichnis

|        |  |
|--------|--|
| ABS    | Antiblockiersystem   |
| ACC    | Adaptive Cruise Control  |
| ADC    | Analog Digital Converter   |
| AEB    | Autonomous Emergency Braking   |
| CFAR   | Constant False Alarm Rate  |
| CNN    | Convolutional Neural Network   |
| CW     | Continuous Wave  |
| DBSCAN | Density-Based Algorithm for Discovering Clusters in Large Spatial Databases with Noise |
| DFT    | Diskrete Fourier Transformation  |
| DOM    | Direction of Movement  |
| ESP    | Elektronisches Stabilitätsprogramm   |
| FFT    | Fast Fourier Transformation  |
| FSK    | Frequency Shift Keying   |
| GPU    | Graphics Processing Unit   |
| LFMCW  | Linear Frequency Modulated Continuous Wave   |
| NMS    | Non-Maximum Suppression  |
| OFDM   | Orthogonal Frequency Division Multiplex  |
| QSFP   | Quad Small Form-factor Pluggable   |
| RANSAC | Random Sample Consensus  |
| RCS    | Radar Cross Section  |
| ReLU   | Rectified Linear Unit  |

## *Abkürzungsverzeichnis*

|     |                         |
|-----|-------------------------|
| ROI | Region of Interest      |
| RPN | Region Proposal Network |
| SNR | Signal-to-Noise Ratio   |
| SVM | Support Vector Machine  |
| ULA | Uniform Linear Array    |

# Symbolverzeichnis

|                                    |   |
|------------------------------------|---|
| $A$                                | Signalamplitude   |
| $\mathbf{A}_{BF}(\theta, \varphi)$ | Amplitudenspektrum aller lokalen Maxima                           |
| $A_B$                              | Beatsignalamplitude   |
| $A_R$                              | Empfangsamplitude   |
| $a_{gB}$                           | gleichförmige Beschleunigung                                      |
| $a_{gB_{max}}$                     | maximale gleichförmige Beschleunigung                             |
| $a_{gV}$                           | gleichförmige Verzögerung   |
| $a_{gV_{max}}$                     | maximale gleichförmige Verzögerung                                |
| $AA$                               | maximaler Abstand der Einzelemente in einem Antennenarray         |
| $\mathbf{A}(\theta, \varphi)$      | Steuerungsmatrix  |
| $\mathbf{A}_M(\theta, \varphi)$    | Array-Mannigfaltigkeitsmatrix                                     |
| $a_{gV_{min}}$                     | minimale gleichförmige Vollverzögerung                            |
| $A_{BF}$                           | räumliches Amplitudenspektrum des Bartlett-Beamformer             |
| $\vec{A}_{BF}$                     | Vektor des räumlichen Amplitudenspektrums des Bartlett-Beamformer |
| $A_T$                              | Sendeamplitude  |
| $\vec{a}$                          | idealer Steuerungsvektor  |
| $B$                                | Bandbreite  |
| $c_0$                              | Lichtgeschwindigkeit im Vakuum                                    |
| $d_p$                              | Distanz Punkt P zur Wellenfront                                   |
| $d$                                | Distanz Koordinatenursprung zur Wellenfront                       |
| $d_a$                              | Richtungsvektor der einfallenden ebenen Wellenfront               |
| $\vec{E}$                          | Vektor der elektrischen Feldstärke                                |
| $\vec{E}_0$                        | Vektor der elektrischen Feldstärke im Koordinatenursprung         |

## Symbolverzeichnis

|                        |   |
|------------------------|---|
| $\eta$                 | Eingabedaten an ein neuronales Netz   |
| $\vec{e}_x$            | Einheitsvektor in x-Richtung  |
| $f_A$                  | Kanalfrequenz   |
| $f_s$                  | Abtastfrequenz  |
| $f_B$                  | Basisbandfrequenz, Beatfrequenz   |
| $f_D$                  | Dopplerverschiebung   |
| $E_e$                  | eintreffende Feldstärke   |
| $\Delta f$             | Frequenzauflösung   |
| $f_{max}$              | maximal eindeutige Frequenz   |
| $f_R$                  | Rangefrequenz   |
| $E_r$                  | reflektierte Feldstärke   |
| $f_T$                  | Sendefrequenz   |
| $f_0$                  | Startfrequenz   |
| $g$                    | Gravitationskraft der Erde  |
| $G_R$                  | Empfangsantennengewinn  |
| $g(\theta, \varphi)$   | komplexwertige Antennenantwort  |
| $\gamma$               | komplexwertiger Korrekturfaktor für Phasen- und Amplitudenverzerrungen einer Antenne beim Empfang |
| $G_T$                  | Sendantennengewinn  |
| $GTR$                  | Unter- bzw. Übersetzungsverhältnis Pedal zu Radumdrehung  |
| $\vec{H}$              | Vektor der magnetischen Feldstärke  |
| $K$                    | Anzahl der Rampen   |
| $\varpi$               | Korrekturfaktor für die Leistungsverteilung einer Antenne   |
| $\vec{k}$              | Vektor der Wellenzahl   |
| $L$                    | Anzahl der lokalen Maxima   |
| $l_e(\theta, \varphi)$ | effektive Länge einer Antenne   |
| $\lambda_0$            | Wellenlänge des Sendesignals  |
| $\lambda_T$            | Wellenzahl  |
| $M$                    | Anzahl der Einzelantennen in einem Antennenarray  |

|                     |   |
|---------------------|---|
| $m$                 | Rampensteigung  |
| $\vec{\nabla}$      | Nabla-Operator $\nabla := \left( \frac{\partial}{\partial x_1}, \dots, \frac{\partial}{\partial x_N} \right)$ |
| $N$                 | Anzahl der Abtastwerte  |
| $\nu_j$             | Eingabe an die Aktivierungsfunktion eines Neuron  |
| $\vec{n}(t)$        | additiver Rauschanteil  |
| $o_j$               | Aktivierung eines künstlichen Neuron  |
| $O$                 | Anzahl eintreffender Wellenfronten  |
| $\omega_D$          | Kreisfrequenz des Doppler   |
| $\omega_R$          | Kreisfrequenz der Entfernung  |
| $\omega_T$          | Kreisfrequenz des Sendesignals  |
| $\vec{\omega}_p(t)$ | zeitabhängige Winkelgeschwindigkeit der Pedale  |
| $\vec{\omega}_w(t)$ | zeitabhängige Winkelgeschwindigkeit   |
| $P_R$               | Empfangsleistung  |
| $P_{BF}$            | räumliches Leistungsspektrum des Bartlett-Beamformer  |
| $P_T$               | Sendeleistung   |
| $\vec{p}$           | Position im dreidimensionalen Raum  |
| $\vec{r}$           | Kreisradius   |
| $\vec{r}_0$         | initialer Ortsvektor  |
| $R$                 | Range, Entfernung   |
| $\sigma$            | RCS-Wert  |
| $R_{max}$           | maximale eindeutige Entfernung  |
| $RMSE_{\theta,P}$   | Mittleres Abweichungsquadrat der Phasendifferenz in Azimut  |
| $RMSE_{\theta_V,W}$ | Mittleres Abweichungsquadrat der Winkeldifferenz für den virtuellen Azimut                                    |
| $RMSE_{\theta,W}$   | Mittleres Abweichungsquadrat der Winkeldifferenz in Azimut  |
| $RMSE_{vEgo,Mod1}$  | Mittleres Abweichungsquadrat der Eigengeschwindigkeitsschätzung eines Radfahrers mit Modulation 1             |

## Symbolverzeichnis

|                       |   |
|-----------------------|---|
| $RMSE_{v_{Ego,Mod2}}$ | Mittleres Abweichungsquadrat der Eigengeschwindigkeitsschätzung eines Radfahrers mit Modulation 1         |
| $RMSE_{\varphi,P}$    | Mittleres Abweichungsquadrat der Phasendifferenz in Elevation   |
| $\Delta\varphi$       | Auflösung des Elevationwinkel   |
| $RMSE_{\varphi_V,W}$  | Mittleres Abweichungsquadrat der Winkeldifferenz für die virtuelle Elevation                              |
| $RMSE_{\varphi,W}$    | Mittleres Abweichungsquadrat der Winkeldifferenz in Elevation   |
| $\varrho$             | Ausgabedaten eines neuronalen Netz  |
| $\vec{r}$             | Ortsvektor im dreidimensionalen Raum  |
| $\Delta R$            | Entfernungsauflösung  |
| $\vec{r}(t)$          | zeitabhängiger Ortsvektor   |
| $\Delta r$            | räumliche Tiefe   |
| $s$                   | Wegstrecke  |
| $s_B$                 | Basisbandsignal   |
| $s_B(t)$              | Beatsignal  |
| $s_{Brems}$           | Bremsweg  |
| $s_R(t)$              | Empfangssignal  |
| $s_R$                 | Empfangssignal  |
| $s(t)$                | zeitkontinuierliches sinusförmiges Signal   |
| $s_{max}$             | maximale zurückgelegte Wegstrecke   |
| $s_T(t)$              | Sendesignal   |
| $s_T$                 | Sendesignal   |
| $t$                   | Zeit  |
| $t_s$                 | Abtastzeit  |
| $t_B$                 | Bremsdauer  |
| $\tau$                | Laufzeit  |
| $t_p$                 | Eintreffzeitpunkt der ebenen Welle an der Antenne   |
| $t_0$                 | Eintreffzeitpunkt der ebenen Welle im Koordinatenursprung   |
| $T$                   | Periodendauer   |
| $T_{RRI}$             | Rampen zu Rampen Intervall  |
| $\Delta t$            | zeitliche Differenz zwischen dem Eintreffen der ebenen Wellenfront am Koordinatenursprung und der Antenne |

|                    |   |
|--------------------|---|
| $u_m$              | Modulationsterm   |
| $\bar{v}$          | mittlere gleichförmige Geschwindigkeit  |
| $\vec{v}_{EGO}(t)$ | zeitabhängige Bahngeschwindigkeit   |
| $\Delta v_r$       | Geschwindigkeitsauflösung   |
| $v_{g,max}$        | maximale gleichförmige Geschwindigkeit  |
| $v_{max}$          | maximale eindeutige Geschwindigkeit   |
| $V$                | Volumen   |
| $v_r$              | Radialgeschwindigkeit   |
| $\vec{v}_r$        | relativer radialer Geschwindigkeitsvektor   |
| $\vec{v}_T(t)$     | zeitabhängige Tangentialgeschwindigkeit   |
| $\Delta\theta$     | Auflösung des Azimutwinkel  |
| $\theta_{3dB}$     | 3dB Azimutöffnungswinkel  |
| $\theta_V$         | virtueller Azimutwinkel   |
| $\varphi_{3dB}$    | 3dB Elevationsöffnungswinkel  |
| $\varphi_V$        | virtueller Elevationswinkel   |
| $w$                | Gewichtung Eingabewerte eines Neuron  |
| $\theta$           | horizontaler Winkel, Azimut   |
| $\varphi$          | vertikaler Winkel, Elevation  |
| $\delta\theta$     | Winkeltrennfähigkeit für Azimut in Grad   |
| $\delta\varphi$    | Winkeltrennfähigkeit für Elevation in Grad  |
| $\lambda_{Med}$    | Wellenlänge im Medium, charakterisiert durch die relative Permittivität und die magnetische Permeabilität |
| $\psi$             | Neigungswinkel Radfahrer in der Vertikalen  |
| $y(t)$             | Empfangssignal  |
| $\vec{y}(t)$       | Vektor mit den $m$ Empfangskanälen  |
| $\mathbf{Y}(t)$    | Matrix aller Empfangsvektoren der $L$ lokalen Maxima  |



# 1 Einleitung

Der zunehmende Bevölkerungsstrom in urbane Gebiete und Ballungszentren stellt Kommunen und Metropolen vor neue Herausforderungen in der Bereitstellung von Infrastruktur für die zukünftige Mobilität. Mit der Bezeichnung Berufsverkehr verbinden die allermeisten Arbeitnehmer und Bewohner in bevölkerungsreichen Regionen ein Synonym von Stau, verstopften Straßen und überfüllten öffentlichen Verkehrsmitteln wie Bus und Bahn. Diese Entwicklung führte in den letzten Jahren zu einer Renaissance des weltweit weit verbreitetsten Fortbewegungsmittels, dem Fahrrad. Für das Zurücklegen von kurzen Strecken etabliert sich parallel dazu auch noch zusätzlich der Weg zu Fuß. Vor allem das Fahrrad ist für kurze bis mittellange Strecken, wie sie im urbanen Bereich zumeist vorkommen, prädestiniert. Dies haben auch die Städteplaner und Kommunen entdeckt, welche durch den Ausbau von Fuß- und Radwegen, Kampagnen für das Radfahren, sowie das teilweise Aussperren von mit fossilem Brennstoff betriebenen motorisierten Verkehr aus den Innenstadtbereichen diese Art der Mobilität fördern. Dadurch wird nicht nur die Verkehrslast auf den Straßen und die Lärmbelästigung gesenkt, sondern es ist durch den verminderten CO<sub>2</sub> Ausstoß eben auch eine umweltfreundliche und klimaschonende Fortbewegungsalternative [1, 2]. Diese positiven Effekte tragen dazu bei, dass die Zunahme des Radverkehrs, auch beflügelt durch die Marktreife der e-Bikes, in den nächsten Jahren ungebrochen weiter gehen wird [3]. Selbst für die bekannten fahrradfreundlichen Metropolen wie Amsterdam, Kopenhagen, Strassburg, Sevilla und Münster, stellt dieses Wachstum eine große infrastrukturelle Herausforderung dar. Zudem wird es nicht gänzlich möglich sein, den Rad- und Fußgängerverkehr vom Kraftfahrzeugverkehr durch individuelle Fahrwege komplett zu trennen.

Die gemeinsam genutzten Verkehrsflächen bergen dabei das größte Gefährdungspotential durch Unfälle mit fatalen Folgen für die schwächeren Verkehrsteilnehmer, allen voran Radfahrer und Fußgänger. Für Deutschland ist den aktuellen Unfallzahlen zufolge ein Kraftfahrzeug in 75 % der registrierten Unfälle mit Radfahrerbeteiligung involviert [4]. Jeder achte Verkehrstote und jeder fünfte Verletzte war im Jahr 2017 eine Radlerin oder ein Radler. Der allgemeine Rückgang von Verkehrstoten in Deutschland konnte im Bereich der Radfahrer nicht nachvollzogen werden und hält sich seit Jahren auf einem stagnierenden Niveau. Für das Ziel der Europäischen Union, bis 2050 keine Verkehrstoten mehr auf Europas Straßen zu erreichen [5], sind diese sich stabilisierenden Unfallzahlen kontraproduktiv. Wie jedoch lassen sich diese weiter senken und letztendlich ganz auf Null reduzieren?

Speziell bei den ungeschützten Verkehrsteilnehmern wie Radfahrer und Fuß-

## 1 Einleitung

gänger sind sich die Experten einig. Der Selbstschutz dieser Gruppe durch geeignete Schutzausrüstung wie Helm, reflektierende Bekleidung und Beleuchtung sind keine ausreichenden Maßnahmen. Es kristallisiert sich ganz klar heraus, dass ohne einen aktiven Schutz in Kraftfahrzeugen für Fußgänger und Radfahrer die ehrgeizigen EU-Ziele nicht erreichbar sind.

Diese Erkenntnis ist ebenfalls bis zu den Fahrzeugherstellern und Zulieferern gelangt. Eine Vielzahl an Fahrerassistenzsystemen befindet sich im Laufe der letzten Jahre in der Entwicklung und findet immer mehr Durchdringung am Markt. Zu nennen sind hierbei unter anderem der Türöffnungswarner, der Totwinkelassistent beim Rechtsabbiegen an Kreuzungen und die automatische Gefahrenbremsung (AEB) auf querende Verkehrsteilnehmer. Treiber dieser Bemühungen sind mitunter Verbraucherschutzorganisationen wie Euro NCAP, die vermehrt Test-szenarien mit Augenmerk auf Fußgänger- und Radfahrerschutz in ihre Prüfprotokolle einbinden [6, 7]. Begonnen hat dies mit der Einführung der Testszenarien für Fußgänger im Jahr 2016, und angelehnt an diese Anforderungen für eine höhere Verkehrssicherheit, wurden diese in 2018 um Radfahrertests erweitert.

Um die gestiegenen Anforderungen zu erfüllen, ist die Weiterentwicklung der Sicherheitsfunktionen im Kraftfahrzeug eine beschäftigungsintensive Aufgabe. Die Leistungsfähigkeit der Systeme hängt essentiell von der exakten hochaufgelösten Erfassung des Fahrzeugumfelds mit Hilfe der Umfeldsensorik ab. In diesem Bereich haben sich zur Umgebungspertzeption Kamerasysteme als auch automobiler Radarsensoren etabliert.

In den Fokus rückt dabei immer mehr die Radarsensorik zur Erfassung der Fahrzeugumgebung. Die Beliebtheit erschließt sich aus mehreren vorteilhaften Merkmalen. Unter anderem aus der Selbstbeleuchtung des Messbereichs durch einen aktiven Sensor, die Robustheit gegenüber Umwelteinflüssen wie Schnee, Regen, Nebel, Staub und tiefstehender Sonne, sowie die Möglichkeit eines verdeckten Einbaus im Fahrzeug.

Im Gegensatz zu Kamera-basierten Systemen liefert die Radarsensorik kein visuelles Abbild der Umgebung, wie es der Anwender vom menschlichen Auge gewohnt ist. Dies erfordert im ersten Moment eine etwas gewöhnungsbedürftige Interpretation der Messergebnisse. Bei geeigneter Auslegung der Messgrößen Entfernung, Geschwindigkeit und Richtung lassen sich Darstellungen wählen, die dem Informationsgehalt einer visuellen Abbildung in nichts nachstehen bzw. sogar einen Mehrwert an Information über die sich im Blickfeld befindlichen Objekte bieten. Ein gerade für zeitkritische Anwendungen wie die Unfallvermeidung und Verhinderung höchst exquisiter Vorteil ist durch die Bestimmung aller Messgrößen in einem einzigen Aufnahmezyklus gegeben.

Heutige Radarsensorgenerationen ermöglichen zudem eine sehr hochauflösende Erkennung des Fahrzeugumfelds. Damit geht die Möglichkeit einher, sehr viele Punkte von einem physikalischen Objekt gleichzeitig zu erfassen. Durch die lokal nahe beieinander liegenden Punkte, zurückgestrahlt von einem Objekt, können diese einander zugeordnet werden. Mit einer solchen Gruppierung dienen die einzelnen Punkte als ein Parametersatz, anhand dessen es möglich ist, Rück-

schlüsse auf die Art des physikalischen Objekts zu ziehen. Je nach Objektart ist es sinnvoll verschiedene adaptive Verhaltensmuster der Fahrerassistenzsysteme zu implementieren.

### 1.1 Zielsetzung und Inhalt

Zur Erhöhung der Sicherheit von ungeschützten Verkehrsteilnehmern, speziell von Radfahrern, im Straßenverkehr, soll die Fähigkeit von bildgebenden Automobilradaren zur Lokalisierung und Identifizierung dieser untersucht werden.

Dazu gehören die Erarbeitung von Anforderungen an die Radarsensorik aus Bewegungsmustern von Radfahrern und Fahrzeugen, um den benötigten Überwachungsbereich und die Parametrisierung zu ermitteln. Hierzu werden in Kapitel 2 Auswertungen von Unfallstatistiken und Bewegungsmustern von Verkehrsteilnehmern vorgestellt, aus denen Anforderungen an die Radarsensorik abgeleitet werden.

Eine ganzheitliche Betrachtung des Systems Radfahrer mit algebraischer Definition soll entwickelt werden um in einer Modellbeschreibung zur Nutzung in einer Simulationsumgebung eingesetzt zu werden. Dadurch werden reproduzierbare Testszenarien ohne Verletzungsrisiko von Verkehrsteilnehmern ermöglicht. Hierfür entstand ein Punktmodell eines Radfahrers, mit Augenmerk auf die mit einem Radar messbaren Parametern, eingebettet in einer Simulationsumgebung für Radardaten, dargelegt in Abschnitt 4.2.

Aus den synthetisch erzeugten Daten und den unter realen Bedingungen aufgezeichneten Messdaten sollen einzigartige Merkmale im Radarsignal von Radfahrern extrahiert werden. Auf Basis dieser Kennzeichen sollen Methoden entwickelt und angewendet werden zur Klassifizierung der im allgemeinen mit der Radarsensorik detektierten physikalischen Objekte. Ebenso wird untersucht, ob die einzigartigen Charakteristika des Radfahrer ausreichend sind, um eine zuverlässige Lokalisierung zu gewährleisten. In Abschnitt 4.3 sind die extrahierten Merkmale aufgezeigt und darüber hinaus zusätzliche generierbare Information aus diesen. Es konnte in Kapitel 5 gezeigt werden, dass die einzigartigen dem Signal entnommenen Radfahrermerkmale ausreichend sind um mit neuronalen Netzen eine Lokalisierung und Klassifizierung durchzuführen.

Zusätzlich soll betrachtet werden, ob ein Informationszugewinn durch die Objekthöhe in der Klassifikation, Lokalisierung und Sicherheitssystemperformance einen Mehrwert bietet. Hiermit verbunden ist das Design einer aus mehreren Antennen bestehenden Anordnung zur Erfassung und Auswertung der Höheninformation. Die Beschreibung des neu entwickelten Antennenarray ist in Abschnitt 3.5 gegeben und die zugehörige, an das Array angepasste, Winkelschätzung in Unterabschnitt 3.6.3.

Allgemein steht die Verbesserung bestehender Algorithmen und Methoden im Fokus, sowie die Entwicklung neuer Verfahren und deren Implementierung zur Auswertung und Nutzung der enthaltenen Information im Radarsignal. Beispiele

## *1 Einleitung*

dafür sind in Unterabschnitt 5.2.1 anhand einer im Radarkontext neuartigen Methode des Clustering, sowie in Unterabschnitt 4.3.3 mit der Neuentwicklung eines Verfahrens zur Prädiktion der Bewegungsrichtung mit integrierter Indikation einer Kurvenfahrt des Radfahrers gezeigt.

# 2 Anforderungen an die Radarsensorik

## Inhalt

---

|            |  |           |
|------------|--|-----------|
| <b>2.1</b> | <b>Analyse von Unfallstatistiken</b>                 | <b>6</b>  |
| <b>2.2</b> | <b>Kinematik und Dynamik von Verkehrsteilnehmern</b> | <b>7</b>  |
| 2.2.1      | Kraftfahrzeug  | 7         |
| 2.2.2      | Radfahrer  | 9         |
| 2.2.3      | Fußgänger  | 9         |
| <b>2.3</b> | <b>Sensoranforderungen</b>                           | <b>10</b> |
| 2.3.1      | Erfassungsbereich                                    | 10        |
| 2.3.2      | Testszenarios  | 12        |
| 2.3.3      | Urbanes Umfeld                                       | 13        |

---

## Überblick

Für die Entwicklung von Systemen zur aktiven Unterstützung des Fahrers eines Kraftfahrzeuges, zur Vermeidung oder maximalen Abschwächung von Unfällen ist die Definition der Rahmenbedingungen im Einsatzbereich von großer Bedeutung. Die Fragen nach der infrastrukturellen Umgebung im Anwendungsfall, der Dynamik der involvierten Akteure, sowie die erreichbare Erhöhung der Sicherheit durch das System müssen vorab beantwortet werden.

Durch Analyse von relevanten Unfallstatistiken wird ein aufschlussreicher Überblick über das Unfallgeschehen und die Unfallursachen gewonnen. Sie dienen als Indikatoren für die Notwendigkeit und den Nutzen eines solchen Systems. Ebenfalls ermöglicht deren Auswertung die Feststellung von Unfallhäufungen in bestimmten Verkehrssituationen oder durch äußere Einflüsse wie z.B. die Straßenrandbebauung. Bekannte Gefahrenbereiche und Unfallursachen können damit detaillierter in Betracht gezogen werden.

Die Definition der technischen Anforderungen an die Sensorik wird zum Teil von der Unfallanalyse abgedeckt. Ein nicht unerheblicher Teil der Sensorkriterien hängt zusätzlich von der Dynamik der beteiligten Straßennutzer ab. Dabei werden die am schlechtesten anzunehmenden Fälle, die in einer Gefahrensituation auftreten können, analysiert.

Als Abgleich zu den identifizierten Leistungsanforderungen werden bekannte Testszenarien von Verbraucherschutzorganisationen wie Euro NCAP herangezogen. Darüber hinaus werden durch Beobachtung und Teilnahme im laufenden Verkehr kritische Situationen erkannt und den Anforderungen hinzugefügt.

### 2.1 Analyse von Unfallstatistiken

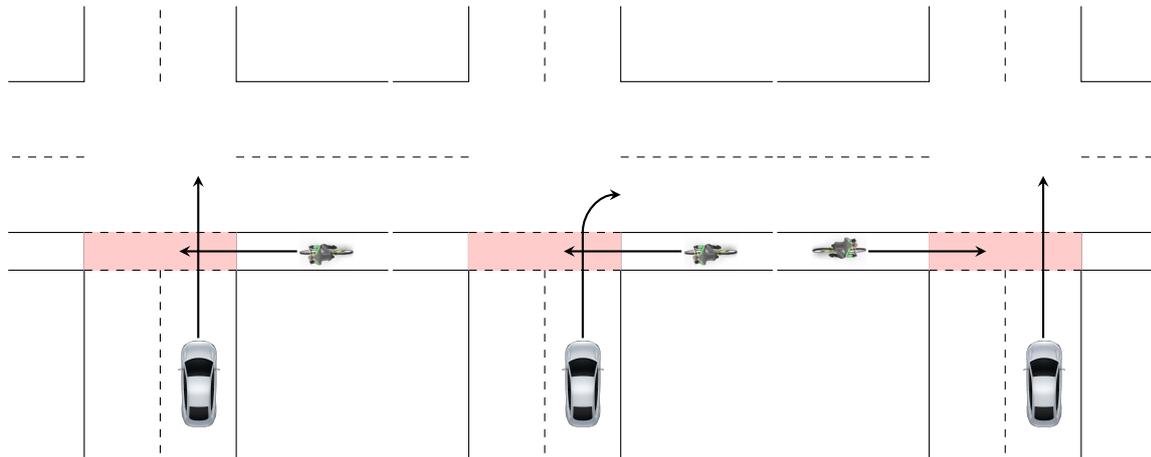
Im Rahmen des Forschungskonsortiums PROactive Safety for PEdestrians and CyclisTs (PROSPECT) [8] mit europäischer Förderung im Eighth Framework Programm Horizon 2020 [9] bestand die Möglichkeit des Zugriffs auf große Datenbanken mit Unfallstatistiken. Darunter befinden sich Daten der „Initiative for the Global Harmonisation of Accident Data“ (IGLAD) der Jahre 2007-2015 und der „German In-Depth Accident Study“ (GIDAS) von 2000-2013. Ebenfalls zurückgegriffen werden konnte auf die Veröffentlichungen des Statistischen Bundesamtes (DESTATIS) zur Unfallentwicklung von 2017 [4].

In Betracht gezogen wurden nur die Daten, bei denen Kraftfahrzeuge und Radfahrer als Unfallgegner fungierten. Das waren in Deutschland im Jahr 2017, von der Gesamtzahl der Unfälle mit Radfahrerbeteiligung, 75 % oder 46 153 dokumentierte Fälle und somit der größte Anteil. Bezogen auf die Ortslage der Unfälle (Innerorts, Landstraßen, Autobahnen) ereigneten sich 91 % der Radfahrerunfälle innerhalb von Ortschaften. Dabei lag die Zahl der leichtverletzten Radler bei 92 %, die der Schwerverletzten bei 83 % und die der Getöteten innerhalb geschlossener Ortschaften bei 66 %. Die verunglückten schwerverletzten Radfahrer auf Landstraßen machten 17 % aus, der Anteil der Getöteten lag bei 34 %. Daraus lässt sich ein großes Bedürfnis an aktiven Schutzsystemen in Fahrzeugen bei Fahrten innerorts ableiten, wodurch ein Großteil der Unfälle verhindert werden kann. Daher wird der Fokus im Folgenden ohne Beschränkung der Allgemeinheit auf den Bereich „innerorts“ gelegt.

Für eine detailliertere Analyse der Unfälle und deren Häufung innerhalb von Ortschaften wurden die Ergebnisse aus [10–12] verwendet. Aus diesen geht hervor, dass an einer Kreuzung oder einer Kreuzung ähnlichen (Ein- und Ausfahrt, Parkbucht) Verkehrsführung das größte Unfallrisiko besteht.

Nach Herunterbrechen auf die relevanten Bewegungsmuster der einzelnen Unfallszenarien bilden sich drei Szenarien aus, die 42 % aller Unfälle abdecken. Dazu gehören ein geradeaus fahrendes Kraftfahrzeug und ein von rechts kreuzendes Fahrrad (15 %), ein rechts abbiegendes Fahrzeug und ein von rechts kreuzender Radfahrer (15 %) sowie ein geradeaus fahrender PKW und ein von links querender Radler (12 %). Die als Muster gewählten Szenarien sind in Abbildung 2.1 grafisch visualisiert. Sie dienen als Orientierungshilfe und zur groben Abschätzung des benötigten Sensor-Sichtbereichs zur Erfassung der Gefahrenzone und der unmittelbaren Umgebung.

Auf eine separate Auswertung der Kollisionsgeschwindigkeiten der gewählten Muster wird an dieser Stelle verzichtet. Zur Beschreibung der Sensorauslegung



(a) Geradeaus fahrendes Fahrzeug mit von rechts kreuzendem Radfahrer  
 (b) Rechts abbiegendes Fahrzeug mit von rechts kreuzendem Radfahrer  
 (c) Geradeaus fahrendes Fahrzeug mit von links kreuzendem Radfahrer

Abbildung 2.1: Bewegungsmuster der drei häufigsten Unfallszenarien von Radfahrern mit Kraftfahrzeugen

sind die Maximalwerte der auftretenden Geschwindigkeiten von Interesse. Dabei überschreiten die Kollisionsgeschwindigkeiten der Fahrzeuge nicht die zulässige Maximalgeschwindigkeit von 50 km/h (Straßenverkehrsordnung StVO § 3) innerhalb geschlossener Ortschaften in Deutschland. Im Detail können die Aufprallgeschwindigkeiten in [11] eingesehen werden.

## 2.2 Kinematik und Dynamik von Verkehrsteilnehmern

Zur Beschreibung der Kinematik und Dynamik werden Personenkraftwagen und Radfahrer detailliert untersucht. In einer kurzen Nebenbetrachtung werden die diesbezüglichen Eigenheiten und Unterschiede von Fußgängern aufgezeigt. In Betracht gezogen werden überwiegend auftretende Bewegungen innerorts, da diese, wie in Abschnitt 2.1 beschrieben, die größte Relevanz in der Vermeidung oder Verminderung der Schwere von Unfällen besitzen.

### 2.2.1 Kraftfahrzeug

Moderne Personenkraftwagen verfügen über eine mehr als ausreichende Motorisierung um die maximal zulässige Fahrgeschwindigkeit in Ortschaften spielend zu erreichen. Dies verleitet den Fahrer gelegentlich zur Überschreitung dieser Grenzen, ob bewusst oder unbewusst. Dies ist ein erster Ansatzpunkt für ein

## 2 Anforderungen an die Radarsensorik

System zur Unfallvermeidung: Die Geschwindigkeit auf die zulässige Höchstgeschwindigkeit einzugrenzen. Technisch ist dies heutzutage leicht realisierbar und in vielen Neuwagen als Speedlimiter oder Geschwindigkeitsbegrenzer [13] verfügbar bzw. bereits als Serienausstattung vorhanden. Da diese Begrenzer durch den Fahrer selbstbestimmt ein- und ausgeschaltet werden können, besteht jedoch weiterhin die Möglichkeit einer Fortbewegung mit überhöhter Geschwindigkeit. Dies erschwert die exakte Definition der maximalen Bewegungsgeschwindigkeit des Fahrzeugs mit entsprechenden Sicherheitssystemen an Bord. Aus den gesamten Unfalldaten in [11] geht hervor, dass die maximale Geschwindigkeit eines Fahrzeuges im Gefahrenbereich bei  $v_{g,max} = 75 \text{ km/h}$  lag. Für die weitere Definition der Anforderungen wird mit diesem extrahierten Maximum gearbeitet.

Für die Dynamik eines Fahrzeugs ist die positive und negative Beschleunigung (Verzögerung) ein Maß zur Beschreibung der Fahrzeugagilität. Bei den positiven Beschleunigungswerten liefern sich die Automobilhersteller, vor allem im Sportwagensegment, einen erbitterten Wettkampf. Der aktuelle Beschleunigungsrekord von 0 auf 100 km/h für straßenzugelassene Fahrzeuge liegt bei  $t = 2,6 \text{ s}$  [14]. Dabei wird der Sportwagen mit einer maximalen gleichmäßigen Beschleunigung von  $a_{gB,max} = 10,7 \text{ m/s}^2$  auf Tempo 100 km/h angetrieben. Für ein Durchschnittsfahrzeug mit 111,3 kW Durchschnittsantriebsleistung der Neuzulassungen im Jahr 2017 [15] werden im mittel gleichmäßige Beschleunigungswerte von  $a_{gB} = 3,4 \text{ m/s}^2$  erreicht. Die positive Beschleunigung ist für die Sensorauslegung von geringerer Relevanz, da diese bisher nur in seltenen Fällen zur Unfallvermeidung eingesetzt werden kann.

Einen weitaus größeren Einfluss hat dagegen die Verzögerung auf die Sensorparametrisierung. Von ihr leitet sich zum größten Teil die benötigte maximale detektierbare Entfernung ab. Mit Bremsregelsystemen wie dem Antiblockiersystem (ABS) [16] und dem elektronischen Stabilitätsprogramm (ESP) [17] wird eine zuverlässige und hohe Bremsverzögerung bei voller Manövrierfähigkeit erreicht. Wiederum im Sportwagensegment werden die technisch erreichbaren maximalen gleichmäßigen Verzögerungen von  $a_{gV,max} = 12,3 \text{ m/s}^2$  erzielt. Bei den gewöhnlichen Fahrzeugen aller Klassen variiert die gleichmäßige Verzögerung von  $a_{gV} = 8,0 \text{ m/s}^2$  bis  $11,8 \text{ m/s}^2$  bei idealen Fahrbahnbedingungen (trockener Untergrund) [18]. Eine deutliche Verschlechterung der Bremsverzögerung kommt bei nasser, schneebedeckter oder eisglatter Fahrbahn zustande. Schneebedeckte oder eisglatte Fahrbahnverhältnisse werden an dieser Stelle vernachlässigt, da angenommen wird, dass sich bei diesen Witterungsbedingungen nur wenige erfahrene Radfahrer auf den Straßen befinden. Für nasse Fahrbahnen werden Richtwerte von  $a_{gV,min} = 5,0 \text{ m/s}^2$  bis  $6,5 \text{ m/s}^2$  angenommen.

Auf eine Auswertung der Lenkdynamik wird verzichtet, da der Sensorüberwachungsbereich bis zum möglichen Stillstand des Fahrzeugs definiert wird. Ein Lenkeingriff ist dadurch weiterhin möglich, benötigt aber keine zusätzlichen Anforderungen an die Sensorik.

### 2.2.2 Radfahrer

Bei der Untersuchung der Kinematik von Radfahrern wurden Studienergebnisse aus [19–21] verwendet. Für die Studien sind Radfahrer unterschiedlichen Alters und Geschlechts mit Messeinrichtungen ausgerüstet worden, um die Geschwindigkeit und die zurückgelegte Strecke aufzuzeichnen. Die Probanden waren in Chemnitz, Göteborg und in der Hauptstadtregion Australiens mit unterschiedlichen Fahrradmodellen (Konventionell, Pedelec und S-Pedelec<sup>1</sup>) unterwegs.

Innerhalb geschlossener Ortschaften wurde dabei trotz motorisierter Unterstützung keine höhere Geschwindigkeit als  $v_{g,max} = 42,9$  km/h gemessen. Die mittlere Fortbewegungsgeschwindigkeit lag für die verschiedenen Typen konventioneller Radfahrer, Pedelec und S-Pedelec bei  $\bar{v} = 15$  km/h,  $\bar{v} = 17,4$  km/h und  $\bar{v} = 24,5$  km/h. Wiederum ist der maximale Geschwindigkeitswert von Interesse für die Definition der Anforderungen an die Radarsensorik.

Aus [21] ist zusätzlich die Beschleunigung aus dem Stand aufgeführt. Dabei wurde eine gleichmäßige Beschleunigung von maximal  $a_{gB,max} = 1,4$  m/s<sup>2</sup> ermittelt. Angaben über die Beschaffenheit und den witterungsbedingten Zustand der Fahrbahn wurden dabei nicht gemacht.

Zur Ermittlung der erreichbaren Verzögerungen eines Radfahrers konnte auf [22] zurückgegriffen werden. Es wurde sehr detailliert untersucht, welche Verzögerungen abhängig von der Fahrradart (Mountainbike, Trekkingrad, Cityrad, Rennrad und älteres Straßenrad) mit variierenden Bremstypen (hydraulische Scheibenbremse, Seilzug Scheibenbremse, V-Brake, hydraulische Felgenbremse, Rücktrittbremse und Seitenzugbremse) auf trockener und nasser Fahrbahn erreicht werden können. Als maximale gleichmäßige Verzögerung wurde  $a_{gV,max} = 6,8$  m/s<sup>2</sup> gemessen. Die geringste gleichmäßige Vollverzögerung wurde in der Kombination eines älteren Straßenrads mit Seitenzugbremse zu  $a_{gV,min} = 4,2$  m/s<sup>2</sup> bestimmt. Dabei beeinflusst eine nasse Fahrbahn die Verzögerungswerte um bis zu 60 % was dazu führt, dass die geringste Vollverzögerung auf  $a_{gV,min} = 1,7$  m/s<sup>2</sup> absinkt.

### 2.2.3 Fußgänger

Bewegungsmuster von Fußgängern wurden in den Arbeiten [23–25] detailliert untersucht, in [25] ebenfalls im Kontext Detektion mit Automobilradar. Daher werden diese in Kurzform beschrieben.

Die Geschwindigkeiten werden für Fußgänger in verschiedene Klassen unterteilt: wie Gehen, schnelles Gehen, Laufen und Rennen. Beim Rennen wurde die höchste gemessene Geschwindigkeit festgestellt mit  $v_{g,max} = 24,5$  km/h. Im Mittel lagen die Geschwindigkeiten deutlich tiefer und erstreckten sich vom Gehen mit  $\bar{v} = 5,2$  km/h, über schnelles Gehen  $\bar{v} = 7,2$  km/h, Laufen  $\bar{v} = 11,5$  km/h und Rennen  $\bar{v} = 18$  km/h.

---

<sup>1</sup>Pedelec: Pedal Electric Cycle, Fahrrad mit Elektroantrieb mit Unterstützung bis 25 km/h bei gleichzeitigem tritt der Pedale.

S-Pedelec: elektrobetriebenes Kleinkraftrad mit Unterstützung bis zu 45 km/h

## 2 Anforderungen an die Radarsensorik

Ebenfalls untersucht wurde die Beschleunigung für die unterschiedlichen Gangarten. Aufgeführt werden die maximalen gleichmäßigen Beschleunigungen für Gehen  $a_{gB_{max}} = 3,0 \text{ m/s}^2$ , schnelles Gehen  $a_{gB_{max}} = 5,0 \text{ m/s}^2$ , Laufen  $a_{gB_{max}} = 2,3 \text{ m/s}^2$  und Rennen mit  $a_{gB_{max}} = 5,0 \text{ m/s}^2$ .

Zur Verzögerung wird keine Angabe in den Ausarbeitungen gemacht. Aus eigenen Beobachtungen jedoch liegt die maximale gleichmäßige Verzögerung mindestens auf dem Niveau der maximalen gleichmäßigen Beschleunigung. Tendenziell ist diese eher noch höher anzunehmen.

Für die Sensorparametrisierung liegen die maximalen Geschwindigkeiten unter dem Niveau der Radfahrer. Lediglich die Beschleunigungswerte sind höher und werden gegebenenfalls in die Parametrisierung mit einfließen.

### 2.3 Sensoranforderungen

Die Anforderungen an die Radarsensorik leiten sich aus den vorangegangenen Untersuchungen der Unfallstatistiken und Bewegungsmuster der Verkehrsteilnehmer ab. Dabei beziehen sich die meisten Anforderungen auf das Hardware-design des Sensors. Im Folgenden sollen die Einsatzbereiche des Radars für die Entfernung und Geschwindigkeit sowie die Beschreibung des benötigten Sichtfeldes definiert werden. Dafür wird der jeweils am schlechtesten anzunehmende Fall zugrunde gelegt. Die so ermittelten Anforderungen werden mit den bekannten Prüfvorschriften von Verbraucherschutzorganisationen wie Euro NCAP verglichen und gegebenenfalls dementsprechend erweitert bzw. angepasst. Ebenso wird der urbane Raum als primärer Einsatzort beleuchtet und die sich daraus ergebenden, zusätzlichen Kriterien mit aufgenommen.

#### 2.3.1 Erfassungsbereich

Zur Beschreibung des maximalen Erfassungsbereiches der Sensorik, und im speziellen der Radarsensorik, wird der am schlechtesten anzunehmende Fall untersucht. Die Bereiche werden eingeteilt in erfassbare Messgrößen des Radars wie die Entfernung und die Geschwindigkeit. Ebenso betrachtet wird das Sichtfeld und die benötigte Zykluszeit.

Die maximale benötigte Entfernung um die Gefahrensituation zu detektieren ist in Abbildung 2.2a skizziert. Es wird angenommen, dass lediglich der PKW mit minimaler Vollverzögerung  $a_{gV_{min}} = 5,0 \text{ m/s}^2$  bremst und sich der Radfahrer unvermindert weiter bewegt. Dafür berechnet sich ein Bremsweg für das Fahrzeug ohne Reaktionszeit von  $s_{Brems} = 43,4 \text{ m}$  bei einer Bremsdauer von  $t_B = 4,2 \text{ s}$ . In dieser Zeit legt der Radfahrer einen Weg von  $s = 49,8 \text{ m}$  zurück. Die Summe der beiden ermittelten Strecken  $s_{max} = 93,2 \text{ m}$  liefert den maximalen Entfernungsbereich, den die Sensorik unter schlechtesten Randbedingungen abdecken muss. Um das komplette Fahrrad zu sehen, ist es sinnvoll noch zwei Meter zur maximalen Entfernung hinzuzunehmen was zu einem  $s_{max} = 95,2 \text{ m}$  führt.

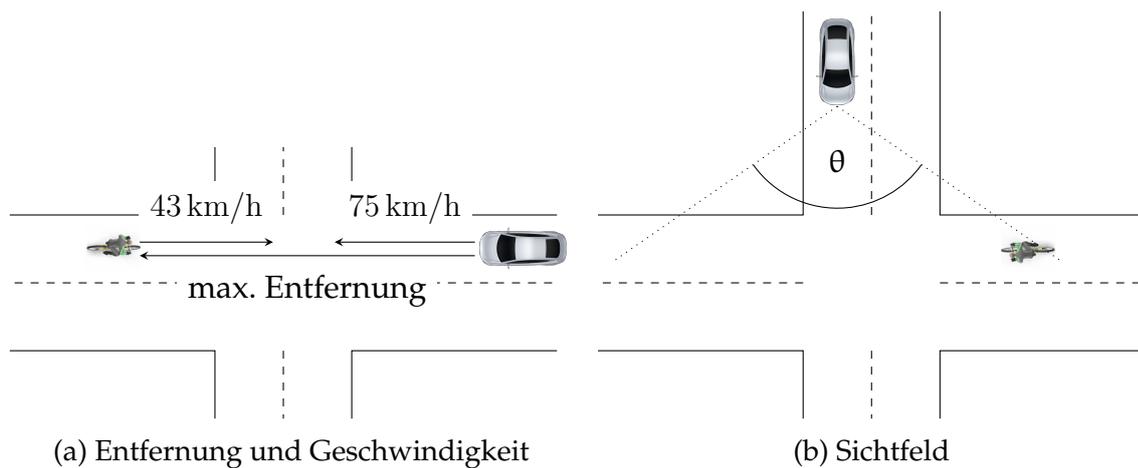


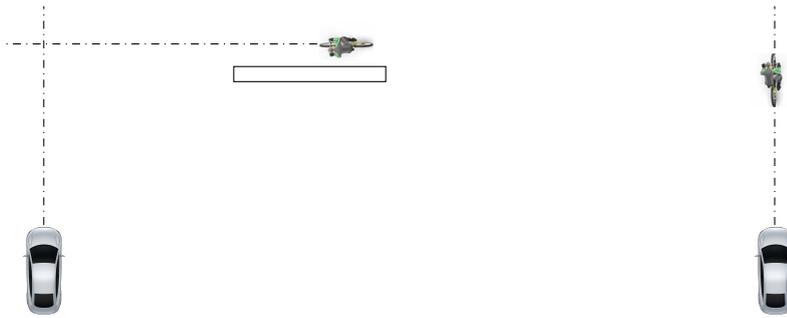
Abbildung 2.2: Skizzen für die am schlechtesten anzunehmenden Fälle zur Bestimmung der benötigten maximalen Grenzbereiche der Sensorik

Um den Eindeutigkeitsbereich der Geschwindigkeit zu bestimmen muss beachtet werden, dass ein Radarsensor die relative Geschwindigkeit zwischen Objekt und Sensor misst. Visualisiert ist der schlechteste anzunehmende Fall ebenfalls in Abbildung 2.2a. Der Zusammenhang aus maximaler Entfernung und Geschwindigkeit erschließt sich aus der grundlegenden physikalischen Definition der Geschwindigkeit. Für den abgebildeten Fall leitet sich die maximale relative Geschwindigkeit von 118,0 km/h unter den schlechtesten Bedingungen ab.

Für die Festlegung des benötigten Sichtfeldes, wird der in Abbildung 2.2b dargestellte ungünstigste Fall zugrunde gelegt. Dabei bewegt sich das Fahrzeug mit Sensorik an Bord mit 75,0 km/h und führt eine Notbremsung bis zum Stillstand aus, ohne den querenden Radfahrer mit kontinuierlicher Geschwindigkeit von 43,0 km/h zu berühren. Der Bremsweg des Fahrzeugs und die zurückgelegte Strecke des Radfahrers sind bereits aus der Betrachtung zur maximalen Entfernung bekannt. Der Fahrweg des Radfahrers wird wiederum um 2,0 m verlängert um das gesamte Fahrrad zu erfassen. Der Öffnungswinkel in der Horizontalen für die Sensorik, mit Verbau in der Front des Fahrzeuges, ergibt sich zu  $\theta = 102^\circ$  mittig zentriert. In der Vertikalen ist ebenso ein Öffnungswinkel zu definieren. Hierfür wird vorausgesetzt, dass ein Radfahrer in 1 m Entfernung in voller Höhenausdehnung durch die Sensorik erfasst wird. Mit einer Höhe von 1,5 m berechnet sich für den vertikalen Sichtwinkel  $\varphi = 57^\circ$ .

Diese Parameter sind rein aus der Unfallstatistik und der Analyse der Dynamik und Kinematik abgeleitet. Es wird an dieser Stelle keinerlei Überprüfung auf Realisierbarkeit durchgeführt. Die theoretisch und praktisch erreichbaren Parameter werden in den folgenden Kapiteln genau betrachtet.

## 2 Anforderungen an die Radarsensorik



- (a) Kreuzender Radfahrer von der Beifahrerseite kommend hinter einer Verdeckung  
(b) Longitudinal bewegter Radfahrer vor dem Testfahrzeug

Abbildung 2.3: Schematische Darstellung der Testszenarien aus dem Euro NCAP Testprotokoll [26]

### 2.3.2 Testszenarien

Als Orientierung und zur richtigen Einordnung der in Unterabschnitt 2.3.1 abgeleiteten Parameter werden Testszenarien von Verbraucherschutzorganisationen herangezogen. Im aktuellen Testprotokoll von Euro NCAP [26] sind zwei Prüf-szenarien aufgeführt. Diese sind schematisch in Abbildung 2.3 dargestellt.

Die Testvorgaben für das Szenario aus Abbildung 2.3a bezüglich der Geschwindigkeiten für die Versuchsteilnehmer sind für den Radfahrer fixiert bei 15 km/h und variieren für das zu testende Fahrzeug von 20 km/h bis 60 km/h.

Für das longitudinale Szenario aus Abbildung 2.3b werden für den Radfahrer 15 km/h bis 20 km/h und für das Testfahrzeug 25 km/h bis 80 km/h angenommen.

Die Startpositionen der Versuche sind nicht explizit vorgegeben. Der Test ist jedoch so aufgebaut, dass sich der Radfahrer, beim Testvorgang ein Dummy, und das Fahrzeug ohne einen aktiven Eingriff in Form von Bremsen in der Mitte der vorderen Stoßstange kontaktieren. Der Dummy ist adaptiv so gesteuert, dass er zur jeweiligen Fahrgeschwindigkeit des Fahrzeuges exakt immer den definierten Aufprallpunkt trifft.

Zur Einordnung der Anforderungen an die Sensorik aus den Testvorgaben bleibt festzuhalten, dass die Geschwindigkeiten für das Fahrzeug sich auf einem ähnlichen Niveau befinden, die für den Radfahrer jedoch deutlich geringer sind als der Maximalwert aus Unterabschnitt 2.2.2. Daraus ist abzuleiten, dass die benötigten Maxima in Entfernung und Sichtfeld ebenfalls geringer sind. Sie liegen jedoch noch in einem Bereich, der die Parameter aus Unterabschnitt 2.3.1 bestätigt und als nicht überbewertet einzustufen ist.



(a) Euro NCAP Testszenario kreuzender Radfahrer mit Fahrzeug Notbremsung (b) Urbanes Umfeld in dem sich Fahrzeuge, Fußgänger und Radler die Infrastruktur teilen

Abbildung 2.4: Beispiele für den Kontrast zwischen Testszenario und Verkehrsnutzung im urbanem Umfeld

### 2.3.3 Urbanes Umfeld

Im Kontrast zu den klar definierten Testszenarien steht der tägliche Verkehr im urbanen Umfeld. In Abbildung 2.4 ist dies durch zwei Beispiele verdeutlicht. Die Beschreibung „chaotisch“ für die Verkehrsszenarie im städtischen Bereich ist zuweilen keine Untertreibung. Der größte Teil an Verkehrsteilnehmern hält sich an die geltenden Regeln und Vorgaben. Ausreißer sind aber nicht auszuschließen. Um ein System einsatzbereit im Großstadtdschungel zu entwickeln, ergeben sich noch aus der Einsatzumgebung spezifische Anforderungen.

Es kann generell nicht davon ausgegangen werden, dass alle Verkehrsregeln und Geschwindigkeitsbegrenzungen eingehalten werden. Dies bedingt eine adaptive situationsabhängige Reaktionsweise.

Ebenso ist es nicht möglich, die genaue Anzahl an Verkehrsteilnehmern a priori zu bestimmen. Hierfür ist es wiederum notwendig adaptiv zu reagieren. Als Anforderung an die Sensorik leitet sich daraus ab, dass diese mehrere Objekte detektieren und erkennen muss, um die jeweilige Situation in geeigneter Weise zu interpretieren und angepasst zu agieren.

Im bebauten Bereich der Stadt kann es zu Verdeckungen und schlecht einsehbaren Bereichen für die Sensorik und den Fahrer kommen. Daraus ergeben sich höchst zeitkritische Gefahrensituationen, in denen teilweise eine Verminderung der Unfallschwere als einzige Option übrig bleibt. An die Sensorik leitet sich daraus Echtzeitfähigkeit und eine sehr kurze Zykluszeit ab. Auch bei der Detektion und Zuordnung von Objekten ist es essenziell, dies innerhalb eines Messzyklus zu gewährleisten. Um eine kleinere Reaktionszeit als der Fahrer, und somit eine Verbesserung durch das System zu erhalten, ist die Reaktionszeit (auch Schrecksekunde genannt) und damit die Zykluszeit deutlich unter der des Fahrzeugführers anzusetzen. Ein gewöhnlicher Fahrer reagiert bei einem unerwarteten Ereignis in-

## 2 Anforderungen an die Radarsensorik

nerhalb von 0,7 s bis 1,5 s [27–29]. Das System sollte eine möglichst kurze Reaktion ermöglichen. Dies ist eine direkte Anforderung an die Zyklusrate der Sensorik und wird im weiteren Verlauf betrachtet.

### Zusammenfassung

Anhand von Unfallstatistiken und Untersuchung der Bewegungsmuster von beteiligten Verkehrsteilnehmern wurden die essentiellen Anforderungen an die Sensorik und das Radfahrerunfallvermeidungssystem abgeleitet. Durch eine signifikant höhere Anzahl an Zusammenstößen von Fahrzeugen und Radfahrern im urbanen Raum ist diese Konstellation fokussiert betrachtet worden.

Spezifisch angepasst an die Radarsensorik, wurden Entfernungs- und Geschwindigkeitsbereiche definiert, deren maximaler Abdeckungsbereich bei  $s_{max} = 96$  m bzw.  $v_{g,max} = 118$  km/h liegt. Zur Beschreibung des Sichtfeldes ist der Azimutwinkel  $\theta = 102^\circ$  als horizontaler und der Elevationswinkel  $\varphi = 57^\circ$  als vertikaler Öffnungswinkel bestimmt worden. Die Dynamik der Verkehrsteilnehmer floss nur für das Fahrzeug in die Anforderung an den Erfassungsbereich mit ein, da lediglich diese in der kritischen Verkehrssituation von einem System beeinflusst werden kann.

Des Weiteren wurde eine hochdynamische Umgebung erkannt, in der das System eingesetzt wird, wodurch es nötig ist eine unbekannt Anzahl an Objekten zu detektieren und einzuordnen. Auch sind Anforderungen an die Zykluszeit beschrieben worden, um in zeitkritischen Situationen schneller als ein menschlicher Fahrer agieren zu können.

Als mögliche Szenarien kann prinzipiell nichts ausgeschlossen werden, was physikalisch auch realisierbar ist, da Verkehrsregeln nur bedingt in Gänze eingehalten werden. Dadurch kommt es gelegentlich zu abstrusen Situationen im täglichen Verkehrsaufkommen.

# 3 Automobile Radarsensorik

## Inhalt

---

|   |           |
|---|-----------|
| <b>3.1 Grundlagen der automobilen Radarsensorik</b> | <b>16</b> |
| 3.1.1 Radargleichung                                | 17        |
| 3.1.1.1 Punktziele                                  | 17        |
| 3.1.1.2 Flächenziele                                | 18        |
| 3.1.1.3 Volumenziele                                | 18        |
| 3.1.2 Radarrückstreuquerschnitt                     | 19        |
| 3.1.3 Entfernungsinformation                        | 20        |
| 3.1.4 Geschwindigkeitsinformation                   | 20        |
| <b>3.2 Sendesignalmodulation</b>                    | <b>20</b> |
| 3.2.1 LFM CW-Radar                                  | 21        |
| 3.2.2 Chirp-Sequence-Radar                          | 23        |
| <b>3.3 Richtungserfassung</b>                       | <b>26</b> |
| 3.3.1 Ausbreitung elektromagnetischer Wellen        | 26        |
| 3.3.2 Antennenarrays                                | 28        |
| 3.3.2.1 Lineares Array                              | 32        |
| 3.3.2.2 Planares Array                              | 32        |
| <b>3.4 Radarsensor und Hardwareplattform</b>        | <b>33</b> |
| <b>3.5 Radar Front-End Design</b>                   | <b>35</b> |
| 3.5.1 Antennen                                      | 36        |
| 3.5.2 Antennenarray                                 | 38        |
| <b>3.6 Signalverarbeitung</b>                       | <b>43</b> |
| 3.6.1 Spektralanalyse im Basisband                  | 44        |
| 3.6.2 Signaldetektion im Rauschen                   | 46        |
| 3.6.3 Winkelschätzung                               | 48        |

---

## Überblick

Mit der Einführung des Abstandsregeltempomat (Adaptive Cruise Control (ACC)) als erstes radarbasiertes Fahrerassistenzsystem, mit erstem Serieneinsatz im Jahre 1998, hat sich die Radarsensorik im Fahrzeug etabliert [29, 30]. Die herausragenden Eigenschaften, welche auf dem Grundprinzip des Radars beruhen, wie die Unabhängigkeit von externer Beleuchtung und die Robustheit gegenüber Umwelteinflüssen wie Schnee, Regen, Nebel und Staub [31, 32], machen es zu einem wichtigen Partner des Sensorverbunds im Fahrzeug. Mit dem Erfolg des ACC wurden weitere Fahrerassistenzsysteme auf Basis eines Radarsensors entwickelt. Im Jahr 2005 kamen erste Vorgängervarianten der automatischen Notbremsysteme (Autonomous Emergency Braking (AEB)) in Fahrzeugen serienmäßig zum Einsatz [33]. Diese werden bis heute ständig weiterentwickelt und in ihrem Umfang erweitert, beispielsweise zum Schutz von Fußgängern und Radfahrern. Dabei ging auch eine Weiterentwicklung der Sensorik einher [34]. Diese ist mittlerweile in der Lage hochauflösend die Distanz, Geschwindigkeit und Richtung in der Vertikalen und Horizontalen eines Objekts im Sichtbereich des Sensor zu bestimmen. Die Bestimmung dieser Größen ist innerhalb eines einzigen Messzyklus möglich, was ein großer Vorteil, vor allem beim Einsatz in zeitkritischen Anwendungen wie der Unfallvermeidung ist. Unter anderem die sofortige Verfügbarkeit aller Messgrößen in einem Messzyklus prognostiziert für diese Sensortechnologie eine Schlüsselrolle im Bereich des automatisierten Fahrens [35].

In diesem Kapitel soll zunächst eine grundlegende Einführung in die Theorie der automobilen Radarsensorik gegeben werden. Darauf aufbauend wird der in dieser Arbeit verwendete Radarsensor bzw. die Hardwareplattform vorgestellt. Anschließend wird das neu entwickelte Radarfrontend, vom Design bis zur Validierung in der Antennenmesskammer, mit der Möglichkeit zur zweidimensionalen Richtungsbestimmung (vertikal und horizontal), beschrieben. Im letzten Abschnitt folgen die Ausführungen zur digitalen Signalverarbeitung von den Radarrohdaten bis hin zu Detektionspunktlisten.

### 3.1 Grundlagen der automobilen Radarsensorik

Ein Radarsensor ist in der Lage gleichzeitig elektromagnetische Wellen auszusenden und zu empfangen. Dabei ist er so konstruiert, dass er die Information wie die Lage, die Geschwindigkeit und den Radarrückstreuquerschnitts (Radar Cross Section (RCS)) eines Objekts aus den reflektierten elektromagnetischen Wellen gewinnen kann [31, 32].

Der prinzipielle Aufbau eines Radarsystems ist in Abbildung 3.1 gezeigt. Das Sendesignal  $s_T$  wird mittels einer Sendeantenne abgestrahlt und über einen Ausbreitungskanal der Länge  $R$  übertragen. Das ausgesendete Signal wird an Objekten, die sich im Umfeld des Radars befinden, reflektiert und zur Empfangsantenne zurückgestrahlt. Über den Empfänger wird das Empfangssignal  $s_R$  zur weiteren

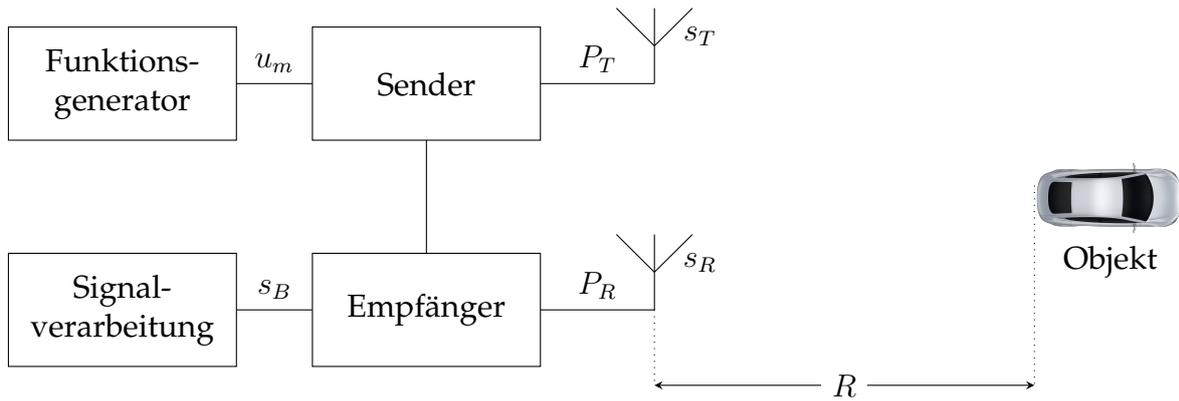


Abbildung 3.1: Schematischer Aufbau eines Radarsystems

Signalverarbeitung ins Basisband  $s_B$  heruntergemischt, in dem dann die beschriebenen Parameter der detektierten Objekte ermittelt werden.

Je nach Einsatzzweck werden verschiedene Modulationen  $u_m$  verwendet. Das Repertoire reicht dabei von einfachen Dauerstrichsignalen bis zu Puls-, Frequenz- und Codemodulationen [29]. Aktuelle automotiv Sensorgenerationen basieren hauptsächlich auf frequenzmodulierten Dauerstrichradaren [36]. Deren Trägerfrequenz liegt dabei typischerweise im Millimeterwellenbereich bei 24 GHz und 77 GHz.

#### 3.1.1 Radargleichung

Die Radargleichung wird zur Beschreibung der Empfangsleistung  $P_R$  angewendet [37]. Es gibt sie in unterschiedlicher Ausprägung, abhängig davon, ob sich das Objekt vollständig im 3 dB Öffnungswinkel der Antenne befindet oder nur teilweise. Historisch bedingt werden Objekte im Radarkontext auch als Ziele bezeichnet. Um konform mit der Standardliteratur [31, 32, 37, 38] zu bleiben wird diese Begrifflichkeit ebenfalls genutzt. Dabei wird zwischen Punktzielen, unendlich ausgedehnten Flächenzielen und verteilten Zielen (Volumenzielen) unterschieden. In der Praxis liegt die Konstellation oft dazwischen.

##### 3.1.1.1 Punktziele

Voraussetzung der Radargleichung für Punktziele ist die vollständige Lage der Objekte in der Hauptkeule der Antenne. Dies ist meist erfüllt, wenn die Objekte sehr klein sind oder sich in großer Entfernung befinden.

$$P_R = \frac{P_T G_T}{4\pi R^2} \sigma \frac{G_R \lambda_0^2}{(4\pi)^2 R^2} \quad (3.1)$$

Die Sendeleistung  $P_T$ , die Wellenlänge der Trägerfrequenz  $\lambda_0$ , die Sende- und Empfangsgewinne der Antennen  $G_T$  und  $G_R$ , die Entfernung  $R$  und der RCS-Wert  $\sigma$  beeinflussen die Empfangsleistung  $P_R$ . Außerdem ist der Radarrückstreuquerschnitt abhängig von der Lage und der geometrischen Struktur des Objekts sowie vom Einfallswinkel der elektromagnetischen Welle. Prägnant für Punktziele ist die Proportionalität der empfangenen Leistung  $P_R$  zu  $1/R^4$ .

#### 3.1.1.2 Flächenziele

Zur mathematischen Beschreibung von sehr groß ausgedehnten Flächenzielen wird die Spiegelungsmethode angesetzt. Dafür wird eine komplette Spiegelung der Welle am Objekt angenommen. Dadurch ergibt sich das Äquivalent von Sender und Empfänger am gleichen Ort zu einem virtuellen Empfänger hinter der Spiegelfläche mit der Entfernung  $R$ . Damit ergibt sich für  $P_R$  von ausgedehnten Flächenzielen

$$P_R = \frac{P_T G_T G_R \lambda_0^2}{(4\pi)^2 (2R)^2}. \quad (3.2)$$

Bedingt durch die komplette Spiegelung der ausgesendeten Welle am Objekt, reduziert sich das Verhältnis der Empfangsleistung  $P_R$  zu  $1/R^2$ .

#### 3.1.1.3 Volumenziele

Die Beschreibung der Radargleichung für Volumenziele findet klassischerweise Anwendung im Bereich der Wetterradare, beispielsweise bei Regentropfen, Schneeflocken, Hagel und Graupel. Das Volumen wird approximiert durch die entfernungsabhängige illuminierte Fläche mit der räumlichen Tiefe  $\Delta r$  unter der Annahme eines Zylinders [39, 40].

$$V = \pi \sin\left(\frac{\theta_{3dB}}{2}\right) \sin\left(\frac{\varphi_{3dB}}{2}\right) R^2 \Delta r \varpi \quad (3.3)$$

Die Grundfläche des Zylinders wird mit dem 3 dB Öffnungswinkel in Azimut  $\theta_{3dB}$  und Elevation  $\varphi_{3dB}$  und der mittleren Entfernung  $R$  des Volumens berechnet. Abhängig vom verwendeten Antennentyp ist ein Korrekturfaktor für die Leistungsverteilung  $\varpi$  berücksichtigt.

Die Summe aller zufällig verteilten Ziele bezogen auf ein Einheitsvolumen  $V_{ol}$  wird als Reflexionsvermögen bezeichnet und als  $\sum_{V_{ol}} \sigma_i$  definiert, mit der Einheit  $[1/m]$ . Kombiniert mit dem ausgeleuchteten Volumen des Radars ist die Reflexionseigenschaft eines Objekts beschrieben [40–42].

$$\sigma = V \sum_{V_{ol}} \sigma_i \quad (3.4)$$

Tabelle 3.1: Exemplarische RCS Werte von Verkehrsteilnehmern

| Verkehrsteilnehmer | RCS Wert [m <sup>2</sup> ] | RCS Wert [dBsm] |
|--------------------|----------------------------|-----------------|
| Fußgänger          | 0.05 - 0.4                 | -13 - -4        |
| Radfahrer          | 0.05 - 1.0                 | -13 - 0         |
| PKW                | 3.2 - 31.6                 | 5 - 15          |

Basierend auf Gleichung 3.1 lässt sich die Radargleichung für Volumenziele definieren.

$$P_R = \frac{P_T G_T}{4\pi R^2} V \sum_{Vol} \sigma_i \frac{G_R \lambda_0^2}{(4\pi)^2 R^2} \quad (3.5)$$

Substitution von Gleichung 3.3 in Gleichung 3.5 liefert

$$P_R = \frac{P_T G_T G_R \lambda_0^2}{64\pi^2 R^2} \sin\left(\frac{\theta_{3dB}}{2}\right) \sin\left(\frac{\varphi_{3dB}}{2}\right) \Delta r \varpi \sum_{Vol} \sigma_i \quad (3.6)$$

Wiederum reduziert sich die Proportionalität der Empfangsleistung  $P_R$  zu  $1/R^2$ . Dieses Verhalten zeigt sich allgemein, wenn ein Ziel die gesamte Beambreite des Radarsystems ausfüllt.

### 3.1.2 Radarrückstreuquerschnitt

Der Radarrückstreuquerschnitt  $\sigma$  (Radar Cross Section (RCS)) beschreibt die Reflexionseigenschaft eines Objekts. Er ist definiert als der Quotient aus reflektierter  $E_r$  zu eintreffender  $E_e$  Feldstärke am Objekt, abgeleitet aus der Radargleichung für Punktziele [32].

$$\sigma = \lim_{R \rightarrow \infty} 4\pi R^2 \frac{|E_r|^2}{|E_e|^2} \quad (3.7)$$

In Gleichung 3.7 gilt, dass die Objektentfernung ausreichend ist um eine eintreffende ebene Wellenfront anzunehmen. Beeinflusst wird der RCS unter anderem vom Material, der Geometrie, der Größe und der Orientierung des Objekts. Mit dieser Vielzahl an Einflüssen ist es schwierig einen exakten Wert für ein bestimmtes Objekt anzugeben. Es wird oft ein gemittelter Wert bzw. ein Wertebereich in der Literatur dafür verwendet [25, 32, 43, 44]. In Tabelle 3.1 sind exemplarisch RCS Werte für Verkehrsteilnehmer aufgeführt. Daraus ist zu entnehmen, dass der Rückstreuquerschnitt sich nicht proportional zur physikalischen Größe der Objekte verhält und deutlich größer oder auch kleiner sein kann. Zusätzlich aufgeführt ist die weit verbreitete normierte Angabe auf einen Quadratmeter in Dezibel (dBsm).

### 3.1.3 Entfernungsinformation

Die Information der Entfernung  $R$  eines Objekts zum Radarsensor wird indirekt über die Zeitspanne  $\tau$  zwischen senden und empfangen des Signals ermittelt [32].

$$R = \frac{c_0 \tau}{2} \quad (3.8)$$

Die Ausbreitungsgeschwindigkeit elektromagnetischer Wellen im Vakuum entspricht exakt der Lichtgeschwindigkeit  $c_0 = 299\,792\,458$  m/s. In Materie verlangsamt sich die Bewegungsgeschwindigkeit in Abhängigkeit eines Brechungsindex. In bodennaher Luft verringert sich  $c_0$  um etwa 0,28 ‰. Für praktische Anwendungen wird meist  $c_0 = 3 \cdot 10^8$  m/s verwendet.

Aufgrund der hin- und rücklaufenden Welle vom Radar zum Objekt entspricht die Laufzeit der doppelten Entfernung. Für Gleichung 3.8 wird angenommen, dass zwischen Sender und Empfänger keine großen Abstände bestehen, was bei Radarsensoren im Automobilbereich anhand der Bauform gegeben ist.

### 3.1.4 Geschwindigkeitsinformation

Mit einem Radar lässt sich die Dopplerverschiebung  $f_D$  des empfangenen Signals gegenüber dem gesendeten Signal bestimmen. Daraus ist die auf das Radar gerichtete radiale Geschwindigkeitskomponente  $v_r$  des Objekts ermittelbar [31]. Per Definition hat dabei ein sich entfernendes Objekt eine positive radiale Geschwindigkeit und ein sich näherndes eine negative.

$$f_D = -\frac{2v_r}{\lambda_0} \quad (3.9)$$

Der Quotient aus doppelter radialer Geschwindigkeitskomponente  $v_r$  und der Wellenlänge des Sendesignals  $\lambda_0$  beschreibt die Dopplerefrequenz  $f_D$ .

## 3.2 Sendesignalmodulation

Die Modulation des Sendesignals eines automobilen Radarsystems ist ein großer Bereich in der Forschung und Entwicklung von Radaren. Dabei wurden in den zurückliegenden Dekaden mehrere Modulationsformen eingesetzt und vorgestellt.

Eine der ersten eingesetzten Arten war die Pulsmodulation [29], die bereits eine Auswertung der Entfernung und Geschwindigkeit ermöglicht. Es werden jedoch Pausen zwischen den einzelnen Sendeimpulsen benötigt, um die Laufzeiten der reflektierten Echosignale messen zu können.

Zur Vermeidung dieser Pausenzeiten wurden Dauerstrichmodulationen (CW-Radar) eingeführt, die ein kontinuierliches Sendesignal ausstrahlen. Es ermöglicht ausschließlich eine Geschwindigkeitsmessung und wird häufig in der Verkehrsüberwachung eingesetzt.

Um die Entfernungsinformation ebenfalls mit Continuous Wave (CW)-Radaren zu ermitteln, ist diese um die Frequency Shift Keying (FSK) Modulation erweitert worden. Dabei werden mindestens zwei unterschiedliche CW-Signale ausgesendet. Durch deren Phasenunterschiede am Empfänger ist eine Detektion der Entfernung möglich. Jedoch ist es nicht möglich, mehrere Ziele in der selben Entfernung aufzulösen [45, 46].

Als Verbesserung des FSK-CW-Radar wurde das Linear Frequency Modulated Continuous Wave (LFMCW) Verfahren entwickelt. Dieses sendet meist mehrere unterschiedliche linear ansteigende Frequenzrampen aus, wodurch eine Bestimmung der Entfernung und Geschwindigkeit für mehrere Ziele möglich wird [47].

Die Chirp-Sequence Modulation ist eine abgewandelte Form des LFMCW Verfahrens. Durch kürzere Zeiten der Frequenzrampen sind die verschiedenen Steigungen nicht mehr nötig [48–51].

Für zusätzliche Funktionen eines Radars, wie beispielsweise Informationsübertragung zwischen Sensoren oder die Steigerung der Robustheit gegenüber Interferenz, wird die Orthogonal Frequency Division Multiplex (OFDM) Modulation in ersten Prototypen verwendet [52–54].

Das in dieser Arbeit verwendete Radarsystem arbeitet mit der aktuell im Fahrzeug am weitesten verbreiteten Chirp-Sequence Modulation. Die relativ einfache Signalauswertung und die Verfügbarkeit von hochintegrierten Baugruppen, führte zu dieser Wahl. Die Beschreibung des LFMCW-Radar als Grundlage für das Chirp-Sequence-Radar folgt in Unterabschnitt 3.2.1. Anschließend wird das Chirp-Sequence Verfahren detailliert in Unterabschnitt 3.2.2 vorgestellt.

### 3.2.1 LFMCW-Radar

Wie in der Bezeichnung bereits beschrieben, gehören lineare frequenzmodulierte Dauerstrichradare zu den kontinuierlich Signal aussendenden Radarsystemen. Die Modulation kann als Sägezahn oder Dreieck ausgeführt sein [47, 55, 56]. Im Radarkontext wird ein solch modulierte Signal auch als Rampe bezeichnet.

Wie in Abbildung 3.2b dargestellt, wird das Sendesignal mit dem Empfangssignal gemischt und anschließend tiefpassgefiltert. Um die Entfernung eines Objekts zu bestimmen, wird mittels der Frequenz des Basisbandsignals  $f_B$ , im Radar auch Beatsignal genannt, indirekt die Laufzeit  $\tau$  bestimmt. Ebenfalls in der Beatfrequenz enthalten ist die Dopplerverschiebung  $f_D$ , welche durch bewegte Objekte generiert wird.

Zur Beschreibung des Sendesignals  $s_T(t)$  wird folgende Modellgleichung angewendet.

$$s_T(t) = A_T \cos(\phi_T(t)) \quad (3.10)$$

$$\text{mit } \phi_T(t) = 2\pi \int_0^t f_T(\hat{t}) d\hat{t} \quad (3.11)$$

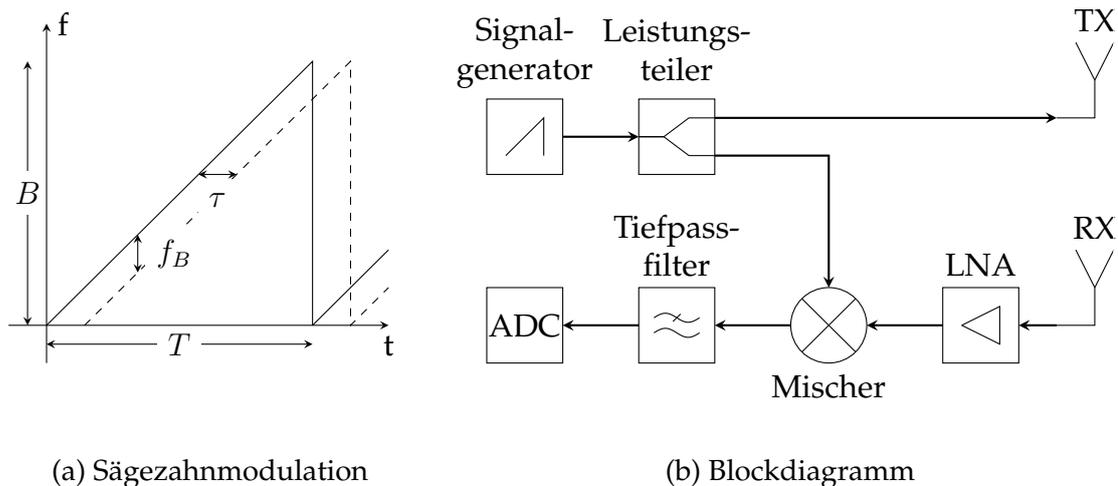


Abbildung 3.2: Rampen und Blockschaltbild eines LFMCW-Radar

Für eine Sägezahnmodulation ist die Sendefrequenz  $f_T(t)$  definiert mit der Startfrequenz  $f_0$ , der Bandbreite  $B$  sowie der Periodendauer  $T$ . Das Verhältnis  $\frac{B}{T}$  entspricht der Rampensteigung  $m$ .

$$f_T = f_0 + \frac{B}{T}t = f_0 + mt \quad (3.12)$$

Nach Einsetzen von Gleichung 3.12 in Gleichung 3.11 entsteht das Sendesignal für ein LFMCW-Radar.

$$\phi_T(t) = 2\pi \int_0^t f_0 + m\hat{t} \, d\hat{t} = 2\pi f_0 t + \pi m t^2 + \phi_0 \quad (3.13)$$

$$s_T(t) = A_T \cos(\phi_T(t)) = A_T \cos(2\pi f_0 t + \pi m t^2 + \phi_0) \quad (3.14)$$

Der Radarsensor strahlt das Sendesignal  $s_T(t)$  ab und empfängt eine am Objekt reflektierte zeitverzögerte Kopie  $s_R(t)$ .

$$s_R(t) = A_R \cos(2\pi f_0 (t - \tau) + \pi m (t - \tau)^2 + \phi_0) \quad (3.15)$$

Die Laufzeit  $\tau$ , bekannt aus Unterabschnitt 3.1.3, hängt von der Entfernung des Objekts ab. Aus Abbildung 3.2a wird die Abhängigkeit der Beatfrequenz  $f_B$  von der Laufzeit  $\tau$  ersichtlich. Diese Proportionalität kann sehr elegant im Empfänger durch Bestimmung der Beatfrequenz genutzt werden. Praktisch realisiert wird dies, wie in Abbildung 3.2b gezeigt, mit einem Mischer und anschließender Tiefpassfilterung, welcher direkt die der Beatfrequenz entsprechenden Frequenzdifferenz zwischen Sende- und Empfangssignal liefert.

Die Laufzeit  $\tau$  bleibt konstant, solange das Objekt und der Sensor während der

Messung stationär sind. Bewegt sich einer der beiden, bekommt die Laufzeit eine zeitliche Abhängigkeit  $\tau(t)$  und es entsteht ein zusätzlicher Frequenzversatz durch den Doppler Effekt. Unter Annahme eines Objekts mit konstanter Bewegung  $v_r$  lässt sich  $\tau(t)$  ausdrücken zu:

$$\tau(t) = \frac{2R}{c_0} + \frac{2v_r t}{c_0} \quad (3.16)$$

Das Beatsignal  $s_B(t)$  lässt sich aus der Multiplikation von Gleichung 3.14 mit Gleichung 3.15 und einsetzen von Gleichung 3.16 unter Weglassen von vernachlässigbaren Termen beschreiben.

$$s_B(t) = s_T(t)s_R(t) = A_B \cos \left( \frac{4\pi f_0 R}{c_0} + \underbrace{\frac{4\pi f_0 v_r}{c_0} t}_{=\omega_D} + \underbrace{\frac{4\pi m R}{c_0} t}_{=\omega_R} \right) \quad (3.17)$$

Die Beatfrequenz  $f_B$  besteht aus zwei Frequenztermen  $f_R$  und  $f_D$ , die entfernungs- und geschwindigkeitsabhängig sind.

$$f_B = f_R + f_D = \frac{2mR}{c_0} + \frac{2v_r}{\lambda_0} \quad (3.18)$$

In Gleichung 3.18 sind zwei Unbekannte,  $R$  und  $v_r$ . Diese lassen sich nicht eindeutig mit einer Frequenzmessung bestimmen. Dafür werden mehrere Messungen, mit variierenden Rampensteigungen, benötigt, mit denen anschließend durch ein mit Matching bezeichnetes Verfahren die Mehrdeutigkeiten durch ein lineares Gleichungssystem zu lösen [57, 58] sind.

### 3.2.2 Chirp-Sequence-Radar

Basierend auf den Grundprinzipien der LFMCW Modulation ist die Chirp-Sequence Modulation [48, 49, 59] eine Weiterentwicklung, die den steigenden Anforderungen im automobilen Umfeld gerecht wird. Die unbekannte Anzahl an Objekten, verteilt im Radarsichtfeld, stellt eine große Herausforderung an die Detektion dar. Dabei ist nicht die absolute Anzahl an endlichen physikalischen Objekten der limitierende Faktor. Durch hochauflösende Radarsensoren ist es möglich, mehrere Streuzentren an einem Objekt zu unterscheiden. Dadurch entsteht eine hohe Anzahl an Einzeldetektionen, die mittels Signalverarbeitung getrennt werden müssen. Mit einem LFMCW-Radar ist dies sehr aufwendig, da eine separate Rampensteigung benötigt wird, um jede Einzeldetektion unterscheiden zu können.

Abhilfe schafft die Chirp-Sequence Modulation, die auch als schnelle Rampen Modulation beschrieben werden könnte. In diesem Zusammenhang wird Chirp synonym zu Rampe verwendet. Im Unterschied zu den langsamen Chirps beim LFMCW-Radar mit Rampendauern von bis zu 100 ms wird bei der Chirp-Sequence

Variante eine Serie an schnellen Rampen mit gleicher Steigung generiert und ausgesendet. Typische Chirpdauern sind  $10 \mu\text{s}$  bis  $50 \mu\text{s}$ . Die Rampenform und das Blockschaltbild aus Abbildung 3.2 werden unverändert übernommen.

Durch die hohe Rampensteilheit bei gleichbleibender Laufzeit des Signals zwischen Radar und Objekt/Streuzentrum steigt die Beatfrequenz deutlich. Diese Steigerung hängt allein von der Entfernung der Objekte ab. Die Dopplerverschiebung der Frequenz, generiert durch die Geschwindigkeit eines Objekts, bleibt gleich wie beim LFM CW-Radar und ist im Vergleich zur entfernungsabhängigen Komponente nun vernachlässigbar klein. Damit entspricht  $f_B \approx f_R$ .

Die Ermittlung der Geschwindigkeit eines Objekts unterscheidet sich jedoch sehr deutlich zum LFM CW Verfahren. Der Schlüssel zur Bestimmung der Geschwindigkeit liegt in der Auswertung der Phase zwischen den einzelnen schnellen Rampen einer Sendesequenz. Durch die kurzen Zeitabstände  $T_{RRI}$  zwischen den einzelnen gesendeten Rampen erfolgt nur eine sehr geringe Objektbewegung von Rampe zu Rampe. Damit tastet jede Rampe eine leicht veränderte Entfernung zum Objekt ab.

Zur Auswertung der Entfernung werden die digitalisierten Abtastwerte nach Mischen und Tiefpassfiltern einer jeden Rampe verwendet. Mittels einer Fast Fourier Transformation (FFT) beschleunigten Diskrete Fourier Transformation (DFT), wird das Spektrum jeder Rampe berechnet und die Proportionalität von Beatfrequenz und Entfernung ausgenutzt.

Es wird davon ausgegangen, dass die Bewegung eines Objekts für eine Messsequenz innerhalb einer solchen Entfernungszelle bleibt. Der Fall einer Überschreitung in eine nebenliegende Zelle wird als Range-Migration bezeichnet und benötigt zusätzliche Korrekturen, wie beispielsweise in [60] beschrieben. Für den angenommenen Fall ohne Range-Migration, wird für jede ausgewertete Rampe das Objekt in der selben Entfernungszelle detektiert. Einziges Unterscheidungsmerkmal bietet die Phasenlage des Objekts für jede ausgewertete Rampe. Mit einer zweiten DFT über alle Rampen ist es möglich die Dopplerfrequenz auszuwerten.

Für die Beschreibung in analytischer Form ist Gleichung 3.17 als Startpunkt bekannt. Die Veränderung der Entfernung für jede der  $K$ -Rampen wird durch

$$R = R_0 + v_r k T_{RRI} \quad (3.19)$$

mit dem Rampenindex  $k$  modelliert.

Einsetzen von Gleichung 3.19 in Gleichung 3.17 und Streichen vernachlässigbarer Terme liefert das Beatsignal für die Chirp-Sequence Modulation.

$$s_B(t) = A_B \cos \left( \frac{4\pi f_0 R_0}{c_0} + \underbrace{\frac{4\pi f_0 v_r}{c_0} T_{RRI} k}_{=\omega_D} + \underbrace{\frac{4\pi m R_0}{c_0} t}_{=\omega_R} \right) \quad (3.20)$$

Aus Gleichung 3.20 ist die Auflösung, abhängig von den verwendeten Parame-

tern der Entfernung und Geschwindigkeit, bestimmbar.

Unter Anwendung der DFT lässt sich die Beatfrequenz berechnen. Dabei gilt weiterhin  $f_B \approx f_R$ .

$$f_B \approx f_R = \frac{2mR}{c_0} = \frac{2BR}{c_0T} \quad (3.21)$$

Die Auflösung ist von der DFT und deren Frequenzzellenbreite  $\Delta f = \frac{1}{T}$  bestimmt.

$$\Delta f_R = \frac{2B\Delta R}{c_0T} \Rightarrow \Delta R = \frac{c_0}{2B} \quad (3.22)$$

Mit Hilfe der Entfernungsauflösung in Gleichung 3.22, der Anzahl der Abtastwerte  $N$  und dem Abtasttheorem nach Nyquist-Shannon [61]  $t_s \leq \frac{1}{2f_{max}}$ , lässt sich die maximale eindeutige detektierbare Entfernung  $R_{max}$  bestimmen.

$$R_{max} = \frac{N}{2}\Delta R = N\frac{c_0}{4B} \quad (3.23)$$

Um die Geschwindigkeit des Objekts zu ermitteln, wird eine zweite DFT über  $K$ -Rampen berechnet. Wiederum aus Gleichung 3.20 leitet sich  $f_D$  ab.

$$f_D = \frac{2f_0v_r}{c_0} \quad (3.24)$$

Die Dopplerfrequenz  $f_D$  ist proportional zur Geschwindigkeitskomponente  $v_r$ . Mit demselben Schema wie für die Entfernung begrenzt die DFT die Auflösung. Jedoch ist die Periodendauer  $T = KT_{RRI}$ .

$$\Delta f_D = \frac{2f_0\Delta v_r}{c_0} \Rightarrow \Delta v_r = \frac{c_0}{2f_0KT_{RRI}} \quad (3.25)$$

Zur Bestimmung der maximalen eindeutigen Geschwindigkeit  $v_{max}$  ist das Vorgehen identisch zur maximalen eindeutigen Entfernung  $R_{max}$ . Anstelle der Abtastzeit  $t_s$  ist die Rampenwiederholrate  $T_{RRI}$  relevant.

$$\pm v_{max} = \frac{K}{2}\Delta v_r = \frac{c_0}{4f_0T_{RRI}} \quad (3.26)$$

Im Unterschied zur Entfernung sind negative relative Geschwindigkeiten im Radar möglich. Ein Objekt, welches sich auf das Radar zu bewegt, hat eine negative relative Geschwindigkeit und ein sich entfernendes eine positive.

### 3.3 Richtungserfassung

Die Erfassung der Entfernung und Geschwindigkeit eines Objekts wurde in den vorangegangenen Abschnitten vorgestellt und hinreichend erläutert. Darüber hinaus besteht die Möglichkeit mit einem Radarsensor die Richtung, in der sich ein Objekt zum Radar befindet, zu lokalisieren. Dies ist mit verschiedenen technischen Realisierungsformen möglich. Allen gemeinsam ist dabei die Verwendung einer oder mehrerer Antenne.

Im automobilen Einsatzbereich hat sich eine Realisierung mit mehreren Empfangsantennen durchgesetzt. Die Gründe dafür sind in der möglichst kleinen Bauform und im unter der Karosserie verdeckten Verbau zu finden, wofür beispielsweise eine sich drehende stark gebündelte Richtantenne unpraktikabel ist.

Die meisten Sensoren verwenden aktuell seriell über Mikrostreifenleitungen gespeiste Patch Array Antennen. Deren Vorteil liegt in der kleinen Abmessung und der kostengünstigen Fertigung aus leichten Materialien. Meist sind diese so ausgelegt, dass die Hauptstrahlrichtung in der vertikalen Ebene gebündelt ist. Eine solche Anordnung fungiert wiederum als Einzelelement eines Antennenarrays, welches dafür verwendet wird, um die Richtung zu schätzen.

Die folgenden Unterkapitel orientieren sich stark an den Ausführungen der Arbeiten von [62, 63].

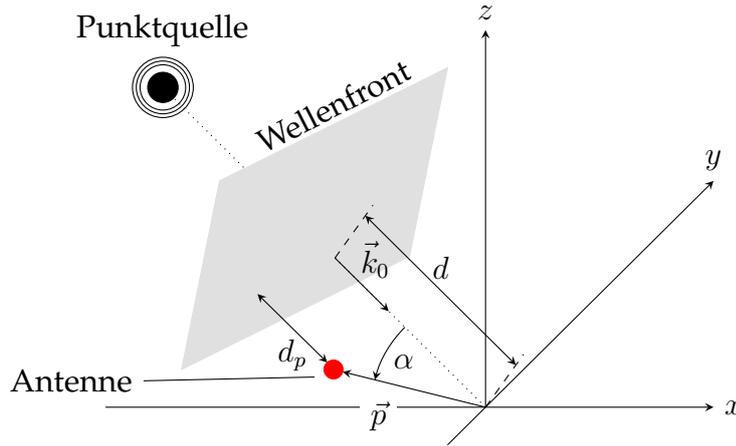
#### 3.3.1 Ausbreitung elektromagnetischer Wellen

Die Ausbreitung der elektromagnetischen Wellen eines automotiven Radarsensors geschieht im Freiraum. Dabei zeichnet sich der Freiraum nach Maxwell durch Quellenfreiheit aus. Unter Anwendung des Nabla-Operators  $\vec{\nabla}$  auf die zweite Maxwellsche Gleichung ergibt sich nach einigen Umformungen die homogene Form der Wellengleichung [62].

$$\vec{\nabla}^2 \vec{E} - \frac{1}{c^2} \frac{\partial^2}{\partial t^2} \vec{E} = 0 \quad (3.27)$$

Beschrieben als partielle Differentialgleichung zweiter Ordnung mit dem Vektor der elektrischen Feldstärke  $\vec{E}$ . Durch Quellenfreiheit im Freiraum gilt Gleichung 3.27 synchron zur magnetischen Feldstärke  $\vec{H}$ . Mit der Konstanten  $c = \sqrt{\frac{1}{\mu\varepsilon}}$  wird die Ausbreitungsgeschwindigkeit der Welle im Medium durch die Permeabilität  $\mu$  und die Permittivität  $\varepsilon$  charakterisiert. Für Luft wird diese mit der Lichtgeschwindigkeit im Vakuum  $c_0$  angenähert.

Die Wellendifferentialgleichung ist lösbar mit der ebenen Welle, deren Wellenfronten bei gleicher Phase als Ebenen ausgeprägt sind [64]. Die Existenz einer solchen Welle wird es in der Realität nie geben, jedoch ist es bei genügend großem Abstand zwischen Quelle und Beobachter möglich, diese als lokale Näherung zu verwenden. Eine solche Approximation gilt insbesondere bei Punktquellen in aus-


 Abbildung 3.3: Empfang einer ebenen Welle mit Punktquelle am Punkt  $\vec{p}$  nach [62]

reichend großer Entfernung, die eine Kugelwelle abstrahlen, und als Fernfeldnäherung bezeichnet wird.

Unter Annahme von Homogenität der Welle mit konstanter Amplitude und Kreisfrequenz  $\omega_T = 2\pi f_T$  gilt für die Feldstärke am Ort  $\vec{r} = [x, y, z]^T$  zum Zeitpunkt  $t$  nach [65] folgende Beziehung.

$$\vec{E}(\vec{r}, t) = \vec{E}_0 e^{j(2\pi f_T t - \vec{k}^T \vec{r})} \quad (3.28)$$

Der Wellenvektor  $\vec{k} = [k_x, k_y, k_z]^T$  zeigt in Ausbreitungsrichtung. Der Betrag des Wellenvektors heißt Wellenzahl und ist abhängig von der Wellenlänge  $\lambda_T$ .

$$\|\vec{k}\|_2 = \frac{2\pi}{\lambda_0} = \frac{2\pi f_T}{c_0} \quad (3.29)$$

In Abbildung 3.3 ist der Empfang einer ebenen Welle, erzeugt durch eine Punktquelle in ausreichendem Abstand, illustriert. Zur Beschreibung des Abstands  $d$  zwischen der ebenen Wellenfront und dem Ursprung, wird die Normalenform der Ebenengleichung herangezogen.

$$d = -\vec{k}_0^T \vec{r} \quad (3.30)$$

Dabei ist  $\vec{k}_0 = \frac{\vec{k}}{\|\vec{k}\|_2}$  der Normalenvektor der Wellenfront und  $\vec{r}$  ein beliebiger Punkt auf der Wellenfront [63]. Die Ausbreitungsrichtung bedingt das negative Vorzeichen von  $\vec{k}$ . Die Distanz der Wellenfront zur Antenne am Punkt  $\vec{p}$  beträgt

$$d_p = d + \vec{k}_0^T \vec{p}. \quad (3.31)$$

Zum Zeitpunkt  $t_p$  erreicht die Welle mit der Ausbreitungsgeschwindigkeit  $c_0$  die

Antenne.

$$t_p = \frac{d_p}{c_0} = t_0 + \frac{\vec{k}_0^T \vec{p}}{c_0} \quad (3.32)$$

$$\text{mit } t_0 = \frac{d}{c_0} \quad (3.33)$$

Der Zeitpunkt  $t_0$  fungiert als Referenz, an der die Wellenfront den Koordinatenursprung erreicht. Damit lässt sich eine zeitliche Differenz  $\Delta t$  zwischen  $t_p$  und  $t_0$  bestimmen [62, 63].

$$\Delta t = t_p - t_0 = \frac{\vec{k}_0^T \vec{p}}{c_0} = \frac{1}{c_0} \|\vec{p}\|_2 \cos(\alpha) \quad (3.34)$$

Die Wellennormale und der Ortsvektor  $\vec{p}$  umschließen den Winkel  $\alpha$ . Daraus leitet sich eine Abhängigkeit des Zeitversatzes beim Eintreffen einer Wellenfront von der Beobachtersposition ab. Diese Eigenschaft wird bei Antennenarrays ausgenutzt, wobei Beobachter an mindestens zwei unterschiedlichen Orten zur Erfassung der Einfallrichtung der Wellenfront notwendig sind. In der Signalverarbeitung ist dieser Vorgang als Winkel- oder Richtungsschätzung bekannt.

In Radaranwendungen ist der ebenen Welle zusätzliche Information in Form einer Modulation  $u_m(t)$  aufgeprägt. Beispielsweise die aus Unterabschnitt 3.2.2 bekannte Chirp-Sequence Modellierung. Die Wellengleichung erweitert sich dementsprechend.

$$\vec{E}_{mod}(\vec{r}, t) = u_m(t) \vec{E}(\vec{r}, t) = \vec{E}_0 u_m(t) e^{j(2\pi f_T t - \vec{k}_0^T \vec{r})} \quad (3.35)$$

Der zeitliche Verlauf der elektrischen Feldstärke im Koordinatenursprung  $\vec{r} = \vec{0}$  wird als Referenz definiert.

$$\vec{E}_{mod,0}(t) = \vec{E}_{mod}(\vec{r} = \vec{0}, t) = \vec{E}_0 u_m(t) e^{j2\pi f_T t} \quad (3.36)$$

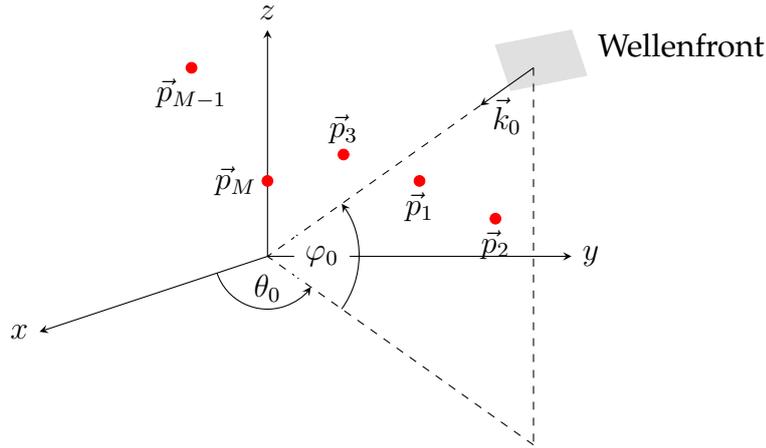
Im Bezug dazu kann nun der zeitliche Verlauf der elektrischen Feldstärke am Antennenpunkt  $\vec{p}$  angegeben werden. Dabei gilt der Zeitversatz gemäß Gleichung 3.34.

$$\vec{E}_{mod}(\vec{p}, t) = \vec{E}_{mod,0}(t - \Delta t) = \vec{E}_0 u_m(t - \Delta t) e^{j(2\pi f_T (t - \Delta t))} \quad (3.37)$$

Auf Gleichung 3.37 basiert die Array-Signalverarbeitung [62].

### 3.3.2 Antennenarrays

Eine beliebige Anordnung von mehreren einzelnen Antennen an unterschiedlichen Positionen im Raum wird als Antennenarray bezeichnet. Ohne Beschränkung der Allgemeinheit wird angenommen, dass alle  $M$  Sensoren identisch sind, die gleiche räumliche Ausrichtung aufweisen und keine Wechselwirkung zwi-


 Abbildung 3.4: Empfang einer ebenen Welle mit  $M$  Einzelementen

schen den Sensoren besteht.

Eine eintreffende ebene Wellenfront wird am Antennenarray detektiert. Die Ausbreitungsrichtung ist durch den Wellennormalenvektor  $\vec{k}_0$  beschrieben [66].

$$\vec{k}_0 = -\frac{2\pi}{\lambda_0} d_a = -\frac{2\pi}{\lambda_0} \begin{bmatrix} \cos(\theta) \cos(\varphi) \\ \sin(\theta) \cos(\varphi) \\ \sin(\varphi) \end{bmatrix} \quad (3.38)$$

Die Koordinaten beziehen sich dabei auf das Fahrzeugkoordinatensystem nach DIN 70000. Dabei verläuft die x-Achse entlang der Fahrzeuglängsachse und zeigt in Fahrtrichtung.

Bekannt aus Gleichung 3.33 trifft die Wellenfront zu unterschiedlichen Zeitpunkten an den jeweiligen Einzelementen  $\vec{p}_M$  ein. Per Definition erreicht die Wellenfront zum Zeitpunkt  $t_0 = 0$  den Koordinatenursprung. Damit gilt für die elektrische Feldstärke des  $m$ -ten Elements beim Zeitpunkt des Auftreffens

$$\begin{aligned} \vec{E}_{mod}(\vec{p}_m, t) &= \vec{E}_{mod,0}(t - \Delta t_{p_m}) \\ &= \vec{E}_0 u_m(t - \Delta t_{p_m}) e^{-j2\pi f_T \Delta t_{p_m}} e^{j2\pi f_T t}, \quad m = 1 \dots M, \end{aligned} \quad (3.39)$$

mit  $\Delta t_{p_m} = \vec{k}_0^T \vec{p}_m / c_0$ .

Unter Annahme von Gültigkeit der Schmalbandnäherung für das Modulationssignal  $u_m(t)$  ist folgende Näherung für alle  $M$  Einzelemente legitim.

$$u_m(t - \Delta t_{p_m}) \approx u_m(t) \quad (3.40)$$

Schmalbandigkeit im Antennenarraykontext bedeutet, dass sich das Modulationssignal während der benötigten Passierzeit der Wellenfront durch das Array nur

### 3 Automobile Radarsensorik

geringfügig ändert [66, 67]. Bezogen auf die Signalbandbreite  $B$  muss gelten

$$B \ll \frac{c_0}{AA}, \quad (3.41)$$

wobei  $AA$  den maximalen Abstand der Einzelelemente in einem Antennenarray beschreibt.

Mit Gleichung 3.40 und Gleichung 3.34 ist Gleichung 3.39 reformuliert zu

$$\vec{E}_{mod}(\vec{p}_m, t) = \vec{E}_0 u_m(t) e^{-j\vec{p}_m^T \vec{k}_0} e^{j2\pi f_T t}, \quad m = 1 \dots M. \quad (3.42)$$

Die Fernfeldnäherung für ein Antennenarray ist nach [65] für Objekte mit einem Abstand von

$$r \gg \frac{2AA^2}{\lambda_0} \quad (3.43)$$

erfüllt. Für ein Automobilradar mit 77 GHz Trägerfrequenz und einer maximalen Arraydimension von wenigen Zentimetern ist die Näherung schon ab wenigen Metern gültig.

Die bisherigen Betrachtungen beziehen sich auf die Beschreibung der Phase der Empfangssignale. Beim Übergang von einer Raumwelle zu einer Leitungswelle wird die elektrische Feldstärke in eine induzierte Spannung gewandelt. Die Empfangsspannung  $y(t)$  ist in Kombination mit der effektiven Länge der Antenne  $l_e(\theta, \varphi)$  beschreibbar [65].

$$y_m(t) = \vec{E}_{mod}(\vec{p}_m, t) l_e(\theta, \varphi) \quad (3.44)$$

Die effektive Länge hängt vom Einfallswinkel des Signals auf die Antenne ab. Damit korrespondiert sie mit der Richtcharakteristik in ihrer Ausgangsspannungsstärke. Unter Berücksichtigung der komplexwertigen Antennenantwort  $g(\theta, \varphi)$  wird das Empfangssignal am  $m$ -ten Element wie folgt formuliert.

$$y_m(t) = g(\theta, \varphi) \gamma u_m(t) e^{-j\vec{p}_m^T \vec{k}_0} e^{j2\pi f_T t} \quad (3.45)$$

Phasen- und Amplitudenverzerrungen beim Empfang mit einer Antenne werden mit  $\gamma$  berücksichtigt.

Beim Mischen ins Basisband mit Tiefpassfilterung entsteht der Empfangsvektor  $\vec{y}(t)$ .

$$\vec{y}(t) = \gamma u_m(t) \begin{bmatrix} g(\theta, \varphi) e^{-j\vec{p}_1^T \vec{k}_0} \\ \vdots \\ g(\theta, \varphi) e^{-j\vec{p}_M^T \vec{k}_0} \end{bmatrix} = s(t) \begin{bmatrix} g(\theta, \varphi) e^{-j\vec{p}_1^T \vec{k}_0} \\ \vdots \\ g(\theta, \varphi) e^{-j\vec{p}_M^T \vec{k}_0} \end{bmatrix} \quad (3.46)$$

Daraus ist ersichtlich, dass die  $M$  Empfangskanäle identische Modulationsanteile

und richtungsspezifische Anteile beinhalten.

Die Systemantwort des Antennenarrays auf eine richtungsabhängige einfallende ebene Welle wird durch

$$\vec{a}(\theta, \varphi) = g(\theta, \varphi) \begin{bmatrix} g(\theta, \varphi) e^{-j\vec{p}_1^T \vec{k}_0} \\ \vdots \\ g(\theta, \varphi) e^{-j\vec{p}_M^T \vec{k}_0} \end{bmatrix} \quad (3.47)$$

charakterisiert und als Steuerungsvektor bezeichnet. Die Gesamtheit aller physikalisch möglichen Richtungen von Steuerungsvektoren wird als Array-Mannigfaltigkeit  $\mathbf{A}_M(\theta, \varphi)$  bezeichnet [62].

Mit der Annahme idealer Einzelantennen als isotrope Kugelstrahler, was zu  $g(\theta, \varphi) = 1$  führt, ist der ideale Steuerungsvektor:

$$\vec{a}(\theta, \varphi) = \begin{bmatrix} e^{-j\vec{p}_1^T \vec{k}_0} \\ \vdots \\ e^{-j\vec{p}_M^T \vec{k}_0} \end{bmatrix}. \quad (3.48)$$

Mit Superposition kann das Modell aus Gleichung 3.46 auf  $O$  eintreffende Wellenfronten erweitert werden.

$$\vec{y}(t)(\theta, \varphi) = \sum_{o=1}^O s_o(t) \begin{bmatrix} e^{-j\vec{p}_1^T \vec{k}_0} \\ \vdots \\ e^{-j\vec{p}_M^T \vec{k}_0} \end{bmatrix} = \mathbf{A}(\theta, \varphi) \vec{s}(t) \quad (3.49)$$

Dies ist legitim, da die Einzelelemente lineare Systeme sind und das Medium, in der sich die Welle ausbreitet, ebenfalls als linear angenommen werden darf. Es gilt  $\mathbf{A}(\theta, \varphi) = [\vec{a}(\theta_1, \varphi_1), \dots, \vec{a}(\theta_O, \varphi_O)]^T$  und  $\vec{s}(t) = [s_1(t), \dots, s_O(t)]$ . Um zusätzliche Einflüsse durch Rauschen und Modellungenauigkeiten zu beachten, wird ein additiver Rauschterm  $\vec{n}(t)$  eingeführt. Dies führt zum idealen Signalmodell für ein Antennenarray im Basisband [62].

$$\vec{y}(t) = \mathbf{A}(\theta, \varphi) \vec{s}(t) + \vec{n}(t) \quad (3.50)$$

Mit der allgemeinen Form ist die Beschreibung für ein Antennenarray ohne Einschränkungen gegeben. In der Praxis bei Radaren im automobilen Umfeld haben sich spezielle Antennenanordnungen durchgesetzt. Für gewöhnlich sind Antennen bei einem Automobilradar in einer Ebene verteilt, was dazu führt, dass die Freiheitsgrade um mindestens eine räumliche Dimension verkleinert werden. In der Literatur sind solche Arrays als lineare und planare Arrays bekannt. Bei einem linearen Array ist die Verteilung der einzelnen Elemente entlang einer Achse, bei einem planaren Array sind die Elemente auf einer Ebene verteilt [66].

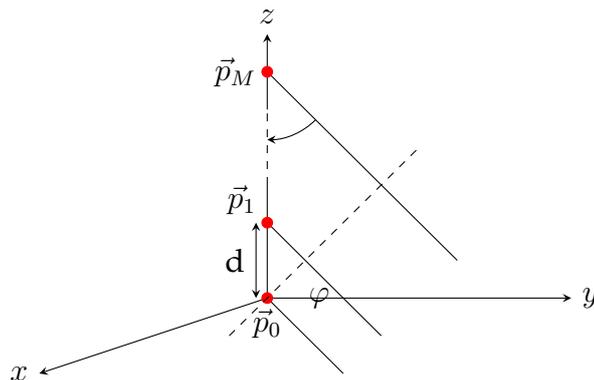


Abbildung 3.5: Lineares Antennenarray mit gleichförmigen Elementabständen  $d$

### 3.3.2.1 Lineares Array

Eine Anordnung der Einzelantennenelemente eines Arrays entlang einer Geraden wird als lineares Array bezeichnet [68]. Mit der Einschränkung der Ausdehnung in nur einer Dimension ist lediglich die direkte Detektion eines Raumwinkels möglich. Wie in Abbildung 3.5 dargestellt, ist in der verwendeten Konfiguration eine Verteilung der Elemente entlang der  $z$ -Achse zur Bestimmung des Elevationswinkels geeignet. Dabei ist die Position der Einzelemente gegeben durch

$$\vec{p}_m = [0, 0, p_{z,m}]^T, \quad m = 1, \dots, M. \quad (3.51)$$

Bei äquidistanten Abständen zwischen den Einzelementen spricht man von gleichförmigen linearen Arrays (Uniform Linear Array (ULA)). Für ein lineares Array vereinfacht sich der ideale Steuerungsvektor aus Gleichung 3.48 zu

$$\vec{a}(\varphi) = \left[ e^{j \frac{2\pi}{\lambda_0} p_{z,1} \sin(\varphi)}, \dots, e^{j \frac{2\pi}{\lambda_0} p_{z,M} \sin(\varphi)} \right]^T. \quad (3.52)$$

Weiter vereinfacht sich der Steuerungsvektor für ein ULA.

$$\vec{a}_{ULA}(\varphi) = \left[ e^{j \frac{2\pi}{\lambda_0} 0d \sin(\varphi)}, \dots, e^{j \frac{2\pi}{\lambda_0} (M-1)d \sin(\varphi)} \right]^T \quad (3.53)$$

### 3.3.2.2 Planares Array

Ein Antennenarray mit zwei Freiheitsgraden in der Positionierung der Einzelemente wird als planares Array bezeichnet [68]. Die Verteilung in einer Ebene ermöglicht die eindeutige Detektion der beiden Raumwinkel in Azimut und Elevation. Die Positionen  $\vec{p}_m$  der einzelnen Elemente haben eine  $y$ - und  $z$ -Komponente und liegen damit ausschließlich in der  $y$ - $z$ -Ebene.

$$\vec{p}_m = [0, p_{y,m}, p_{z,m}]^T, \quad 1, \dots, M. \quad (3.54)$$

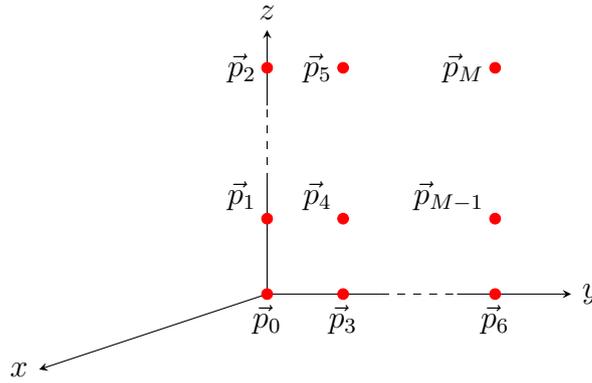


Abbildung 3.6: Exemplarische Darstellung eines planaren Antennenarrays

Der ideale Steuerungsvektor aus Gleichung 3.48 vereinfacht sich wiederum, jedoch im Vergleich zu einem linearen Array nur um eine Dimension.

$$\vec{a}(\theta, \varphi) = \left[ e^{j \frac{2\pi}{\lambda_0} (p_{y,1} \sin(\theta) \cos(\varphi) + p_{z,1} \sin(\varphi))}, \dots, e^{j \frac{2\pi}{\lambda_0} (p_{y,M} \sin(\theta) \cos(\varphi) + p_{z,M} \sin(\varphi))} \right]^T \quad (3.55)$$

### 3.4 Radarsensor und Hardwareplattform

Für die Generierung von Radardaten steht ein prototypisches Automobilradar im 77 GHz Band zur Verfügung. Im Detail beschrieben ist dieses in den Veröffentlichungen [69–71]. An dieser Stelle wird ein Überblick über die Sensorik und die Möglichkeiten in der Parametrisierung gegeben.

Das Gesamtsystem Radarsensor besteht aus einem Radar Frontend mit analoger Basisbandsignalverarbeitung bis zur Analog-Digital Umsetzung mittels eines 250 MHz Analog Digital Converters (ADCs). Diese Komponente wird außen am Versuchsfahrzeug verbaut. Über eine digitale Datenschnittstelle (Quad Small Form-factor Pluggable (QSFP)) werden die Rohdaten an ein Entwicklungskit von Xilinx mit einem Virtex-7 FPGA übertragen. Darauf werden erste digitale Signalverarbeitungsschritte durchgeführt. Die dabei ausgewerteten Detektionspunkte werden über eine 1 GBit/s Ethernetschnittstelle an einen PC übermittelt. Auf diesem PC wird das Softwareframework ADTF zur Steuerung des Radarsensors ausgeführt. Damit ist es möglich die Daten in Echtzeit anzuzeigen, für spätere Verarbeitung im Offlinemodus aufzuzeichnen und in ein Datenformat zu transformieren, das von Mathworks® Matlab/Simulink verarbeitet werden kann. Abbildung 3.7 zeigt den entwickelten Prototypsensor.

Als Modulationsform wird Chirp-Sequence verwendet. Die Parameter Bandbreite, Rampendauer, Anzahl der Abtastwerte für jede Rampe sowie die Anzahl der Rampen, im durch die Hardwarekonfiguration vorgegebenen limitierten Bereich, ist frei einstellbar. Bei maximaler Ausnutzung der zur Verfügung stehen-

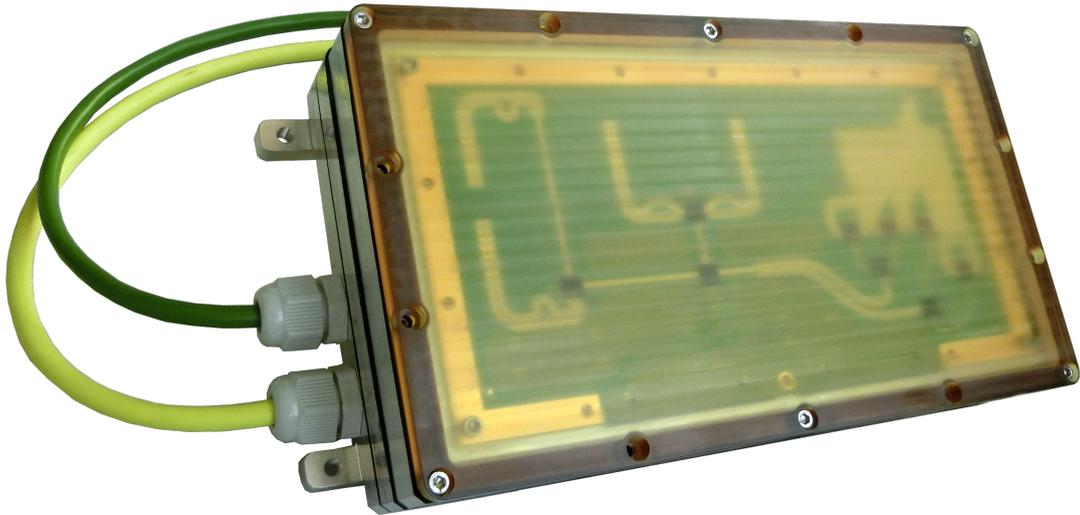


Abbildung 3.7: Prototypischer Radarsensor im 77 GHz Band für Vorentwicklungsaufgaben

den Ressourcen werden sehr hohe Messgenauigkeiten in der Distanz von wenigen Zentimetern ( $<10\text{ cm}$ ), in der Geschwindigkeit von geringen Zentimetern pro Sekunde ( $<10\text{ cm/s}$ ) und in der Richtung von Werten im Bereich kleiner als ein Grad möglich.

Als Modulationsparameterset für die Chirp-Sequence Modulation sind zwei Varianten zur näheren Untersuchung bezüglich der Eignung zur Detektion und Klassifikation von Radfahrern mittels eines Radars in Verwendung. In Tabelle 3.2 sind die Parametersets der beiden Versionen aufgeführt. Mit Modulation 2 sind die Anforderungen aus Unterabschnitt 2.3.1 bezüglich maximaler Entfernung mit  $104,6\text{ m}$  bei benötigten  $95,2\text{ m}$ , und relativer maximaler Geschwindigkeit von  $130,8\text{ km/h}$  bei geforderten  $118,0\text{ km/h}$ , erfüllt. Das Auflösungsvermögen in der

Tabelle 3.2: Modulationsparametersets der zwei zu untersuchenden Modulationsvarianten

| Parameter                          | Modulation 1      | Modulation 2      |
|------------------------------------|-------------------|-------------------|
| Trägerfrequenz $f_T$               | 76,94 GHz         | 76,41 GHz         |
| Abtastfrequenz $f_s$               | 125 MHz           | 125 MHz           |
| Bandbreite $B$                     | 2,37 GHz          | 1,47 GHz          |
| Rampe zu Rampe Intervall $T_{RRI}$ | $48\ \mu\text{s}$ | $27\ \mu\text{s}$ |
| # Abtastwerte pro Rampe $N$        | 4096              | 2048              |
| # Rampen $K$                       | 1024              | 2048              |

Entfernung ist bei 10,2 cm und für die Geschwindigkeit bei 12,8 cm/s.

Modulation 1 ist die hochauflösende Version, welche eine Entfernungsauflösung von 6,3 cm und eine Geschwindigkeitsauflösung von 4,0 cm/s erreicht. Damit einher geht eine deutliche Verminderung der Geschwindigkeitseindeutigkeit auf 73,1 km/h. Dies kommt vom längeren Rampen zu Rampen Intervall, welches aufgrund der endlichen Steigung der Rampe durch die Phasenregelschleife des spannungsgesteuerten Oszillator limitiert ist. In der Entfernungsreichweite stellt diese sogar noch eine Steigerung zur Modulation 2, die 104,6 m hat, auf 129,6 m dar.

Mit den beiden Modulationen wird untersucht, welchen Einfluss die Auflösung auf die Detektion und Klassifizierung von Radfahrern mit Radar hat. Die ausgewählten Modulationen ermöglichen eine Messzyklusrate von ca. 20 Hz.

## 3.5 Radar Front-End Design

Für den Radarsensor aus Abschnitt 3.4 wurde im Verlauf dieser Arbeit ein neues Hochfrequenz Front-End entwickelt, mit dem eine Erfassung der Winkel in Azimut und Elevation möglich ist. Während der Entwicklung entstand eine betreute Abschlussarbeit eines Masterstudenten über den Antennen- und Arrayentwurf [72]. Ebenfalls wurde das neue Antennenarray sowie begleitende Signalverarbeitung in einem Konferenzbeitrag veröffentlicht [73]. Das Design der Leiterplatte wurde in Kooperation mit dem Institut für Nachrichtentechnik und Hochfrequenzsysteme der Johannes Kepler Universität in Linz, Österreich erstellt.

Es gibt mehrere Anforderungen an das neue Radar Front-End.

Abhängig von der Anzahl der ADCs auf der Basisbandleiterplatte ist es maximal möglich 16 simultane Empfangskanäle zu realisieren.

Die Anordnung der Empfangsantennen soll eine Erfassung in Azimut und Elevation ermöglichen und dies mit einer möglichst hohen Winkeltrennfähigkeit, wobei der Fokus auf dem Azimutwinkel liegt.

Die Anforderung für den Öffnungswinkel einer Empfangsantenne in Azimut ist auf  $\theta = 120^\circ$  festgelegt. Dadurch besteht die Möglichkeit im städtischen Umfeld die eigene Fahrspur in 2 m Entfernung vollständig zu erfassen und die Vorgaben für den Erfassungsbereich aus Unterabschnitt 2.3.1 ebenfalls zu erfüllen. Für den Öffnungswinkel in der Elevation gibt es keine strikten Vorgaben. Um ein wenig Freiheit in der Auswahl der Antennen zu ermöglichen und von einem Antennengewinn durch Bündelung zu profitieren, wird als grobe Richtlinie ein Öffnungswinkel von  $\varphi = 20^\circ$  angestrebt.

Des Weiteren soll das Design keine Limitierungen in der Auswahl der verwendeten Winkelschätzverfahren auferlegen.

Der Entwurf ist nicht exklusiv für die Lokalisierung und Detektion von Radfahrern gestaltet, sondern sieht einen Einsatz in verschiedenen Anwendungsbereichen vor. Dadurch sind einige Kompromisse eingegangen worden, die an dieser Stelle aber nicht detaillierter beleuchtet werden müssen.

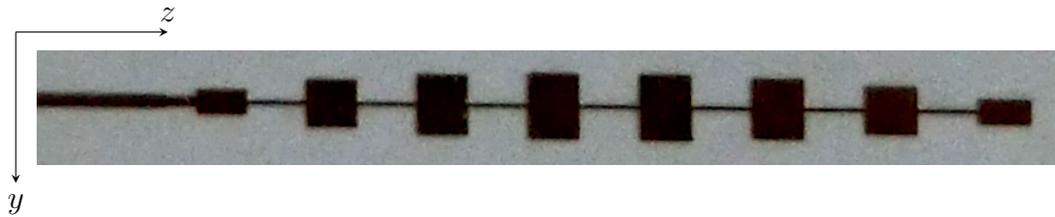


Abbildung 3.8: Antenne als seriell gespeistes Patch-Array zum Einsatz auf dem Radar Front-End

#### 3.5.1 Antennen

Bei der Wahl einer geeigneten Antenne konnte auf ein fertiges Design der Johannes Kepler Universität Linz zurückgegriffen werden. Diese Antenne ist ein seriell gespeistes Mikrostreifen Patch-Array, dargestellt in Abbildung 3.8. Sie besteht aus acht einzelnen Patches und bündelt das abgestrahlte elektrische Feld in Elevation. Die geringe Baugröße und einfache Realisierbarkeit auf einer Leiterplatte gaben letztendlich den Ausschlag für diese Variante.

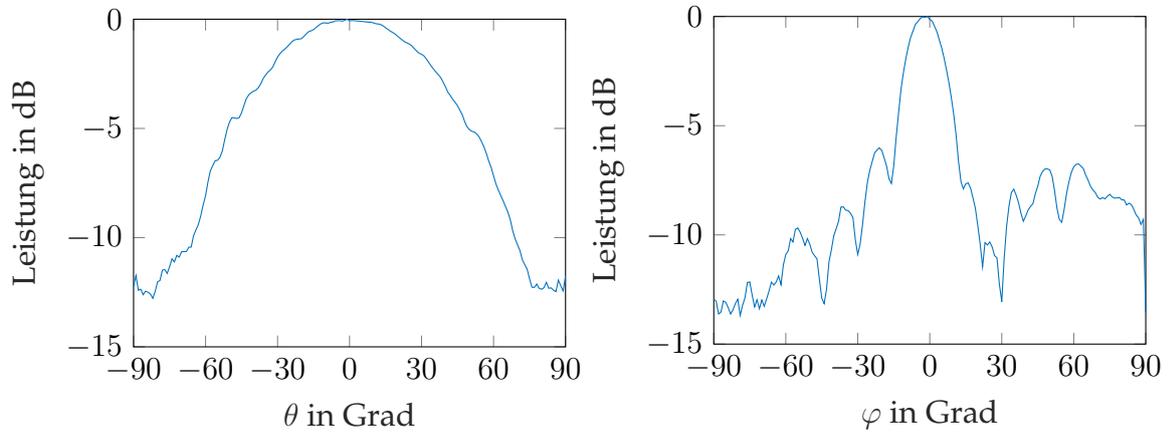
Der Entwurf ist nach [74] durchgeführt worden. Zur stärkeren Unterdrückung von Nebenkeulen wurde als Tapering ein  $-18$  dB Chebyshev-Fenster verwendet. Die Patchabstände der acht Einzelpatches beträgt  $0,5\lambda_{Med}$ .

Die Antenne wurde in der Antennenmesskammer an der Universität Linz zur Charakterisierung des Öffnungswinkels vermessen. Es wurden zwei Messungen durchgeführt, die das Einwegantennendiagramm im Fernfeld aufnehmen. Die Erste mit einem horizontalen Schwenk von  $-90^\circ$  bis  $90^\circ$  und Schrittweite  $1^\circ$  entlang der  $y$ -Achse. Die Antenne wurde dabei von links nach rechts gedreht. Die Zweite in der Vertikalen ebenfalls von  $-90^\circ$  bis  $90^\circ$  und Schrittweite  $1^\circ$  entlang der  $z$ -Achse. Geschwenkt wurde von unten nach oben. Die normierten korrespondierenden Einwegantennendiagramme sind in Abbildung 3.9 aufgetragen.

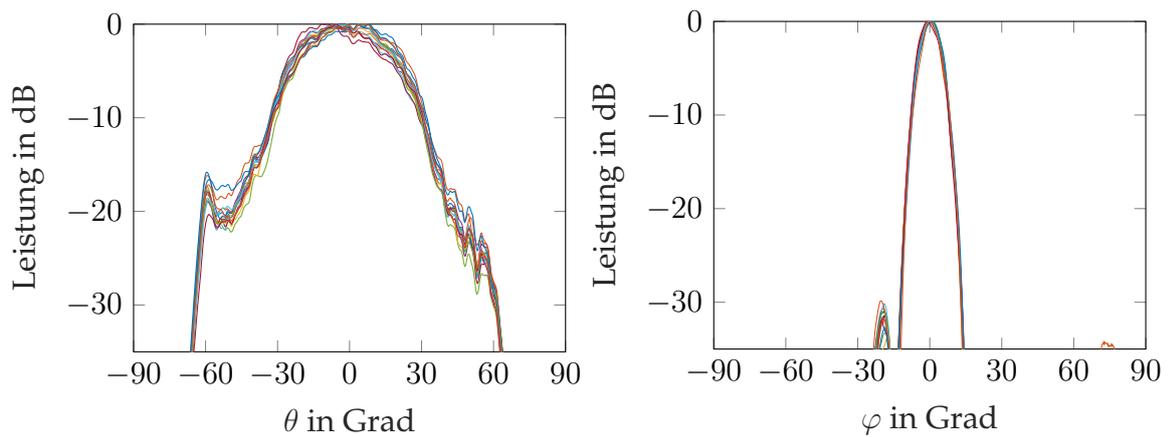
Gut zu erkennen ist dabei der breite Öffnungsbereich in Azimut, welcher die geforderten  $120^\circ$  mit einer maximalen Dämpfung von  $-10$  dB bezogen auf das Antennenmaximum erfüllt. In der Elevation werden ähnliche Werte für den grob vorgegebenen Öffnungsbereich von  $20^\circ$  mit einer maximalen Dämpfung von  $-5$  dB, wiederum bezogen auf das Antennenmaximum, erreicht.

Als Sendeantenne wurde eine stärker bündelnde Anordnung verwendet. Für diese liegt jedoch kein Einwegantennendiagramm, aufgezeichnet in der Messkammer, vor. Die Verifizierung der Kombination aus Sender und Empfänger im Zweiwegantennendiagramm erfolgt mit der entworfenen Hardware.

Nach Fertigstellung des HF-Front-Ends konnte in der Antennenmesskammer das Zweiwegantennendiagramm verifiziert werden. In Abbildung 3.9c und Abbildung 3.9d ist dies jeweils dargestellt. Für beide Diagramme wurden die 16 realisierten Kanäle synchron aufgezeichnet und dargestellt. Die größeren Dämpfungen sind auf die höhere Empfindlichkeit der Auswerteelektronik zurückzuführen. Die Labormessung der einzelnen Antenne liegt bei ungefähr  $-12$  dB über dem



(a) Einwegantennendiagramm für einen Empfangskanal in Azimut (b) Einwegantennendiagramm für einen Empfangskanal in Elevation



(c) Gemessenes Zweiwegantennendiagramm in Azimut (d) Gemessenes Zweiwegantennendiagramm in Elevation

Abbildung 3.9: Ein- und Zweiwegantennendiagramme normiert auf die maximale Leistung in Azimut und Elevation im Fernfeld

Rauschlevel. Bei der Messung mit dem Radarsensor liegt der Rauschlevel zirka  $-90$  dB unter dem Antennenmaximum. Aufgrund des großen Dynamikbereich ist ein Absinken der Empfangsleistung, normiert auf die maximale Empfangsleistung, auf  $-30$  dB in den Zweiwegantennendiagrammen, an den geforderten größten Öffnungswinkeln, zu akzeptieren. Dies gilt sowohl für den Azimut als auch für den Elevationswinkel. Die spezifizierten und validierten Antennen von Sender und Empfänger werden nachfolgend im Entwurf des Antennenarray als vorausgesetzt angenommen.

#### 3.5.2 Antennenarray

Für die Anordnung der Antennen zu einem Array sind die Anforderungen aus Abschnitt 3.5 zu beachten, wie auch die Bauform und Größe der einzelnen Antennen, die als Arrayelemente fungieren.

Um der Anforderung nach Erfassung von Azimut und Elevation Folge zu leisten, ist eine Verteilung der einzelnen Elemente in zwei Dimensionen mit der verwendeten Antennenkonfiguration (für die Elevation) zwingend erforderlich, was ein sogenanntes planares Array darstellt. Um ebenfalls die Einsetzbarkeit der gängigsten Winkelschätzalgorithmen zu ermöglichen, sollten die Elementabstände in der Vertikalen und Horizontalen möglichst äquidistant sein.

Als finales Design wurde eine Anordnung für das Empfangsarray gewählt, das 16 parallele Elemente angeordnet in der Horizontalen mit einem Abstand von  $0,7 \lambda_0$  vorsieht. 10 dieser Elemente liegen auf derselben Höhe und sind als ULA angeordnet. Die übrigen sechs Elemente sind in zwei Dreiergruppen jeweils im Abstand  $1,0 \lambda_0$  in der Vertikalen versetzt. In Abbildung 3.10 ist dies zur Verdeutlichung skizziert. Dabei wurden die Antennen zur besseren Übersichtlichkeit zu Phasenzentren in der Mitte des Patch-Array zusammengefasst.

Die Abweichung von einem eindeutigen ULA mit  $0,5 \lambda_0$  wurde als Kompromiss gewählt, um die Apertur zu vergrößern und die Beeinflussung der einzelnen Elemente untereinander zu verringern. Die Abstände in  $z$ -Richtung sind ebenfalls so gewählt, dass es zu einer Vergrößerung der Apertur kommt.

Um die Eindeutigkeit der Phasenbeziehungen zwischen den einzelnen Elementen für ein Antennenarray zu bestimmen, eignet sich die Mehrdeutigkeitsfunktion (Ambiguity Function), welche die Phasenbeziehungen der Steuervektoren für jede Einfallswinkelkombination korreliert [75].

$$\rho(\theta_1, \theta_2) = \left| \frac{\vec{a}^H(\theta_1)\vec{a}(\theta_2)}{\sqrt{\vec{a}^H(\theta_1)\vec{a}(\theta_1) \vec{a}^H(\theta_2)\vec{a}(\theta_2)}} \right| \quad (3.56)$$

Diese Funktion kann als dreidimensionales Flächendiagramm dargestellt werden, wobei die  $x$ -Achse den ersten Winkel, die  $y$ -Achse den zweiten Winkel und die  $z$ -Achse den Korrelationskoeffizient trägt. Der Korrelationskoeffizient nimmt nur Werte zwischen 0 und 1 an. 0 bedeutet eine orthogonale Arrayantwort, wodurch

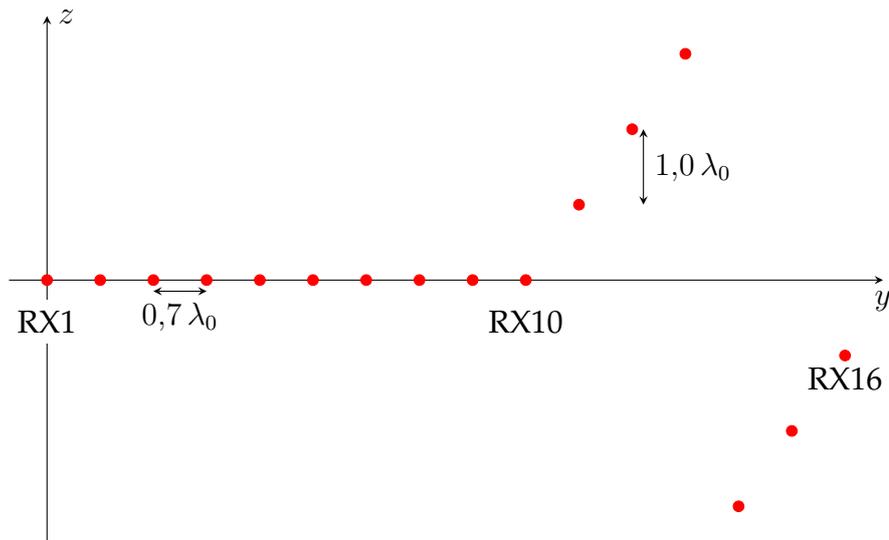


Abbildung 3.10: Empfangsantennenarray mit punktförmig zusammengefassten Antennenelementen

die beiden Steuervektoren problemlos voneinander unterschieden werden können. Für den Wert 1 sind die Antworten identisch und es ist keine Unterscheidung möglich. Dabei spricht man von Mehrdeutigkeiten eines Antennenarrays.

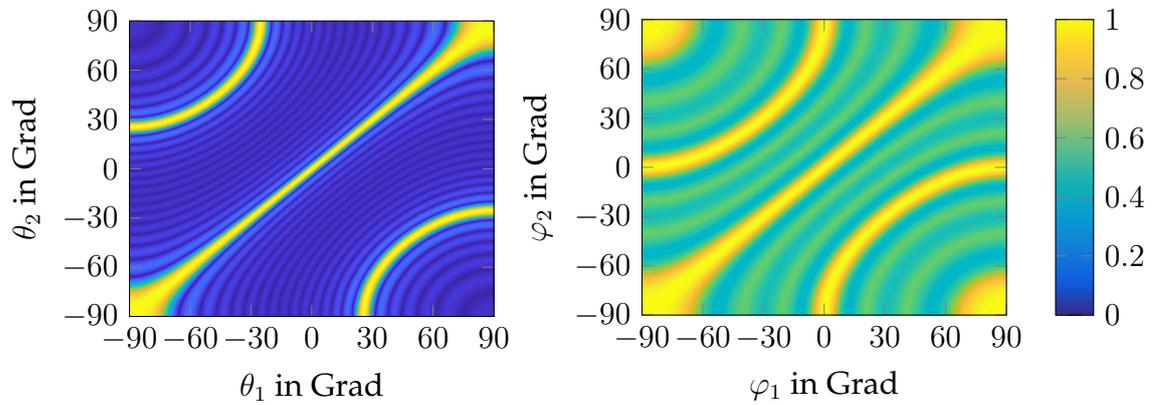
In Abbildung 3.11 ist die Mehrdeutigkeitsfunktion für den Arrayentwurf dargestellt. Für den Vergleich wurden die beiden Raumwinkel separat ausgewertet. Dies ist nur mit Fixierung des zweiten Raumwinkel auf  $0^\circ$  möglich.

Zwischen der theoretischen Betrachtung und der messtechnisch validierten tatsächlichen Realisierung gibt es für den Azimutwinkel keine nennenswerten Abweichungen. Die Diskrepanz im Elevationswinkel dagegen ist verhältnismäßig groß. Dieser Unterschied ist jedoch bewusst herbeigeführt. Er ist erklärbar unter Berücksichtigung des Antennendiagramms in Elevation. Der starke Abfall führt dazu, dass außerhalb des Öffnungsbereichs größtenteils Rauschen detektiert wird. Da dieses Rauschen als unkorreliert angenommen werden darf, sind die Korrelationskoeffizienten außerhalb des Öffnungsbereichs sehr klein (nahezu 0).

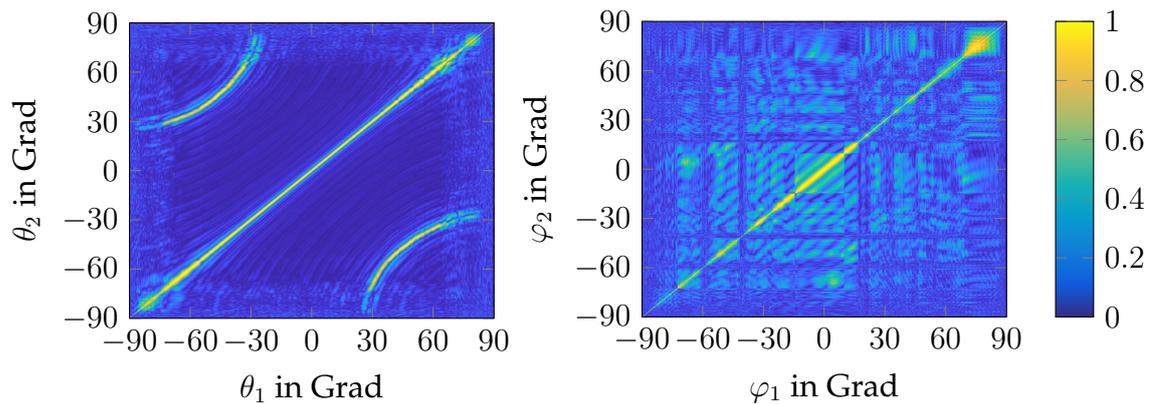
Aus den Betrachtungen lässt sich ein Eindeutigkeitsbereich in Azimut von  $\pm 30^\circ$  und in Elevation von  $\pm 15^\circ$  ableiten. Zur Verbesserung des Eindeutigkeitsbereichs, wurde ein weiterer Entwurf mit einem MIMO-Ansatz gestaltet, hat aber für diese Arbeit keine Relevanz und wird daher nicht genutzt.

Zur Beschreibung der Trennfähigkeit eines Antennenarrays wird das Rayleighkriterium herangezogen.

$$\begin{aligned} \delta\theta &= \arcsin\left(1,22 \frac{\lambda_0}{\text{AzimutArrayApertur}}\right) = 10^\circ \\ \delta\varphi &= \arcsin\left(1,22 \frac{\lambda_0}{\text{ElevationArrayApertur}}\right) = 14,1^\circ \end{aligned} \quad (3.57)$$

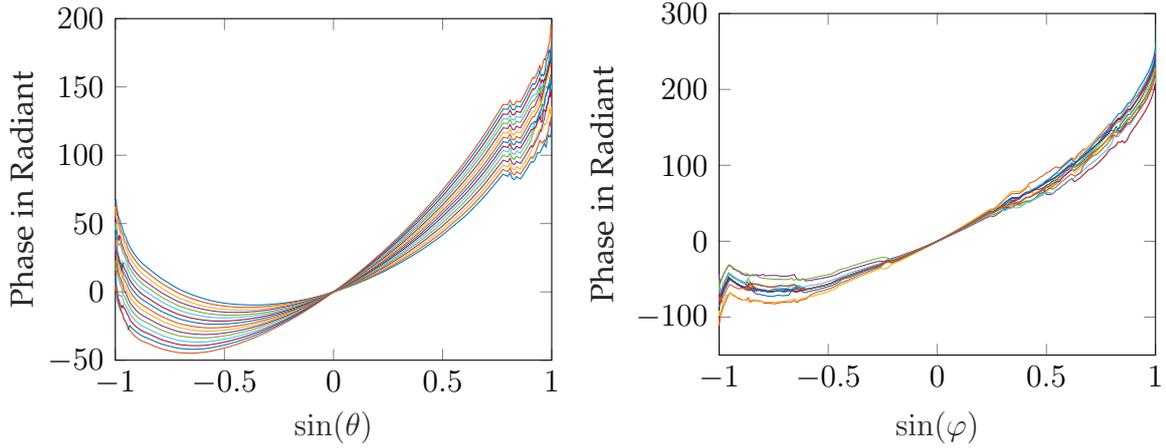


(a) Theoretische Steuerungsvektoren in Azimut mit Elevationsschnitt bei  $0^\circ$       (b) Theoretische Steuerungsvektoren in Elevation mit Azimutschnitt bei  $0^\circ$



(c) Gemessene Steuerungsvektoren in Azimut mit Elevationsschnitt bei  $0^\circ$       (d) Gemessene Steuerungsvektoren in Elevation mit Azimutschnitt bei  $0^\circ$

Abbildung 3.11: Mehrdeutigkeitsfunktionen für beide Raumwinkel, Azimut und Elevation, theoretisch und messtechnisch generiert



(a) Phasenverlauf in Azimut aller 16 RX      (b) Phasenverlauf in Elevation aller 16 RX

Abbildung 3.12: Phasenverläufe der einzelnen Kanäle in Azimut und Elevation über einen kompletten Schwenk von  $-90^\circ$  bis  $90^\circ$

Die Auflösung wird maßgeblich vom verwendeten Winkelschätzalgorithmus bestimmt und im Unterabschnitt 3.6.3 detailliert erläutert.

Die gemessenen komplexen Amplitudenwerte der 16 Kanäle über einen horizontalen oder vertikalen Schwenk von  $-90^\circ$  bis  $90^\circ$  dienen zusätzlich der Validierung der Elementpositionen im Array. Dafür wird der Phasenverlauf eines jeden Kanals mit einer Geraden approximiert und über folgende Beziehung ausgewertet. Die Beschreibung der Phase für jeden Kanal ist bekannt aus Gleichung 3.55.

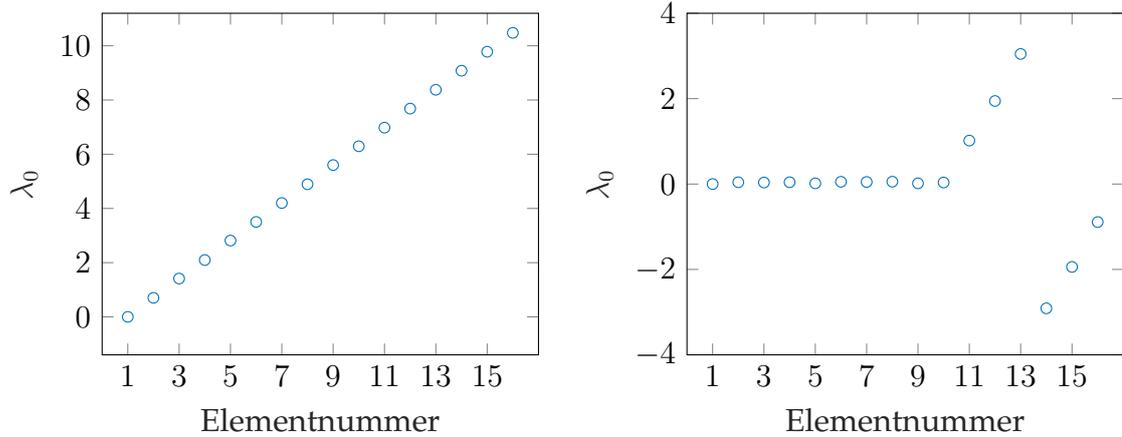
$$\phi_m = \left| \vec{k}_0 \right| (y_m \sin(\theta) \cos(\varphi) + z_m \sin(\varphi)) \quad (3.58)$$

Bei einem Schwenk in Azimut respektive in Elevation, vereinfacht sich die Phase durch das jeweilige Festsetzen auf  $0^\circ$  des nicht untersuchten Winkels.

$$\begin{aligned} \phi_{m,Az} &= \left| \vec{k}_0 \right| y_m \sin(\theta) \quad \varphi \stackrel{!}{=} 0 \\ \phi_{m,El} &= \left| \vec{k}_0 \right| z_m \sin(\varphi) \quad \theta \stackrel{!}{=} 0 \end{aligned} \quad (3.59)$$

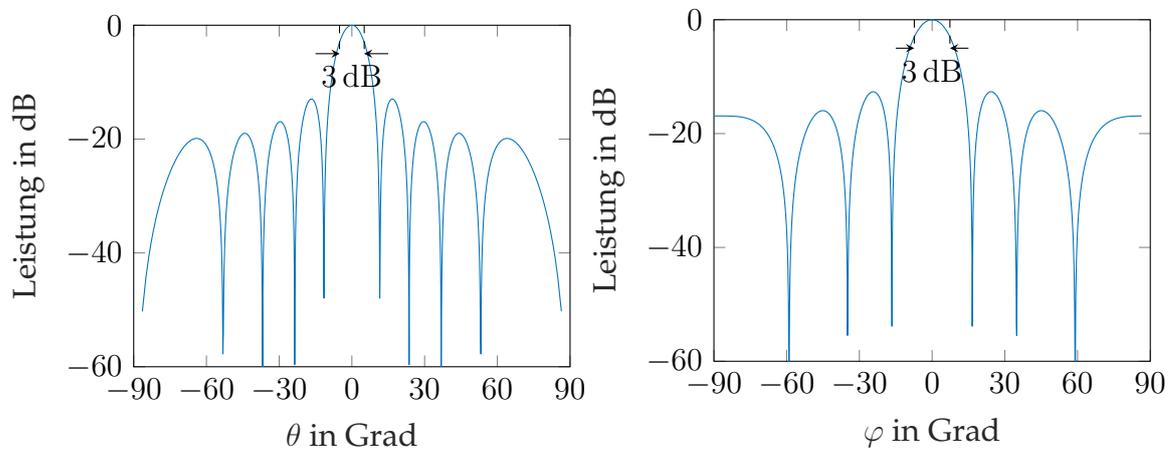
Gleichung 3.59 ist als Ursprungsgeradengleichung interpretierbar mit dem Phasenwert als Ordinate und dem Sinus des Winkels als Abszisse. Die Elementpositionen in  $y$  bzw. in  $z$  sind kombiniert mit dem Betrag der Wellenzahl in der Steigung der Geraden abgebildet. Abbildung 3.12 zeigt die Phasenverläufe für die jeweiligen Winkel über den gesamten Schwenk. Mit der Methode der kleinsten Quadrate wurden die Steigungen der Geraden, in den relevanten Winkelbereichen via Ausgleichsrechnung bestimmt. Dargestellt in Abbildung 3.13 sind die Positionen der Antennenelemente in  $y$  bzw.  $z$  bezogen auf das erste Element. Die somit ermittelten Positionen stimmen sehr gut mit dem Entwurf überein und er-

### 3 Automobile Radarsensorik



(a) Distanz zwischen den Arrayelementen in  $y$  bezogen auf das erste Element (b) Distanz zwischen den Arrayelementen in  $z$  bezogen auf das erste Element

Abbildung 3.13: Elementpositionen in  $y$  und  $z$  mit Bezug auf das erste Arrayelement



(a) Richtdiagramm des Antennenarray in Azimut mit Elevation  $0^\circ$  (b) Richtdiagramm des Antennenarray in Elevation mit Azimut  $0^\circ$

Abbildung 3.14: Arrayrichtdiagramme in Azimut und Elevation mit normierten Leistungswerten

bringen den Nachweis der gewünschten Funktionalität des Antennenarrays. Zur Vervollständigung ist in Abbildung 3.14 das Arrayrichtdiagramm für Azimut und Elevation dargestellt.

Die 3 dB Hauptkeulenbreite beträgt in Azimut  $10,2^\circ$  und in Elevation  $14,7^\circ$ , was sehr gut mit den ermittelten Werten aus Gleichung 3.57 übereinstimmt. Die erste Nebenkeule ist um  $-13$  dB gedämpft, was aus gleicher Strombelegung der Einzel-elemente resultiert und eine räumliche Rechteckfensterung abbildet.

## 3.6 Signalverarbeitung

Zur Extraktion der im Radarsignal enthaltenen Informationen bedarf es mehrerer Schritte der Signalverarbeitung. Es gibt verschiedene Möglichkeiten das Zeitsignal im Basisband zu verarbeiten um Detektionspunkte, welche ein Streuzentrum auf einem Objekt repräsentieren, mit den Parametern Entfernung, Geschwindigkeit, Winkel in Azimut und Elevation zu erhalten. Nachfolgend werden die angewendeten Methoden und Verfahren in dieser Arbeit vorgestellt. Ein grober Überblick über die einzelnen Schritte stellt das Blockdiagramm in Abbildung 3.15 dar, an dessen Verlauf sich die Unterkapitel orientieren.

Die Beschreibung der Signalverarbeitung ist als Nachbearbeitung der aufgenommenen Messdaten im Zeitbereich mit Mathworks® Matlab/Simulink aufbereitet, um eine geschlossene Kette darzustellen. Teile davon sind bereits auf der FPGA-Entwicklungsplattform implementiert und erlauben eine Darstellung und Aufnahme von vorverarbeiteten Radardaten in Echtzeit. Durch die Vorverarbeitung kann der notwendig Datendurchsatz und Speicherbedarf stark gesenkt werden. Bei allen Signalverarbeitungsschritten, die vor der Übertragung der Messdaten bereits durchgeführt werden, gibt es im Folgenden einen entsprechenden Hinweis.

Die aufgenommenen Daten werden pro Messzyklus gespeichert. Ein solcher Zyklus besteht aus  $K$ -Rampen mit jeweils  $N$ -Abtastwerten für jeden der  $M$ -Empfangskanäle. Abgelegt ist ein einzelner Messzyklus in einer dreidimensionalen Matrix. Dabei finden in der ersten Dimension die Abtastwerte, in der zweiten Dimension die Rampen und in der dritten Dimension die Empfangskanäle Platz. In Abbildung 3.16 ist die Struktur der abgetasteten Zeitsignale eines Messzyklus zusätzlich verdeutlicht.



Abbildung 3.15: Blockdiagramm der digitalen Signalverarbeitung beginnend beim Zeitsignal im Basisband bis zu den Detektionspunkten, welche die Objektstreuzentren repräsentieren

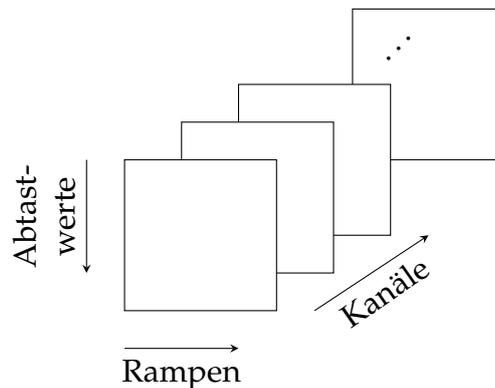


Abbildung 3.16: 3D Datenstruktur der Radarrohdaten für einen Messzyklus

#### 3.6.1 Spektralanalyse im Basisband

Wie in Unterabschnitt 3.2.2 bereits angemerkt, wird für die Analyse der Entfernung und Geschwindigkeit von Streuzentren der erfassten Objekte die Frequenzanalyse mittels der DFT, beschleunigt mit dem FFT-Algorithmus, verwendet. Vor Durchführung der Frequenzanalyse wird eine Fensterfunktion auf die Empfangssignale angewendet, deren Notwendigkeit im weiteren Verlauf detaillierter erläutert wird.

In Abbildung 3.17 ist die schematische Verarbeitung zur Generierung des Entfernungs- und Geschwindigkeitsspektrums exemplarisch an einem der  $M$  Kanäle dargestellt.

Neben der schnellen und effizienten Berechnung von Eingangssequenzen der Länge entsprechend einer Zweierpotenz bietet die DFT einen weiteren, für die Erkennung eines Objekts sehr wichtigen Mehrwert. Aufgrund ihrer Beschaffenheit generiert sie einen Prozessgewinn im Spektralbereich, der von der Anzahl der Messwerte abhängt. Dieser ist sehr anschaulich nachvollziehbar: Angenommen es liegt nur eine Stützstelle für die Berechnung der DFT vor, dann addieren sich die Rauschleistung und Signalleistung in der einzigen vorhandenen Frequenzzelle. Für eine DFT mit zwei Stützstellen verändert sich die Aufteilung der Rauschleistung, welche als weißes Rauschen angenommen wird, um den Faktor zwei für jede der resultierenden Frequenzzellen. Die Signalleistung jedoch bleibt aufgrund kohärenter Integration durch die DFT in einer Zelle. Damit verdoppelt

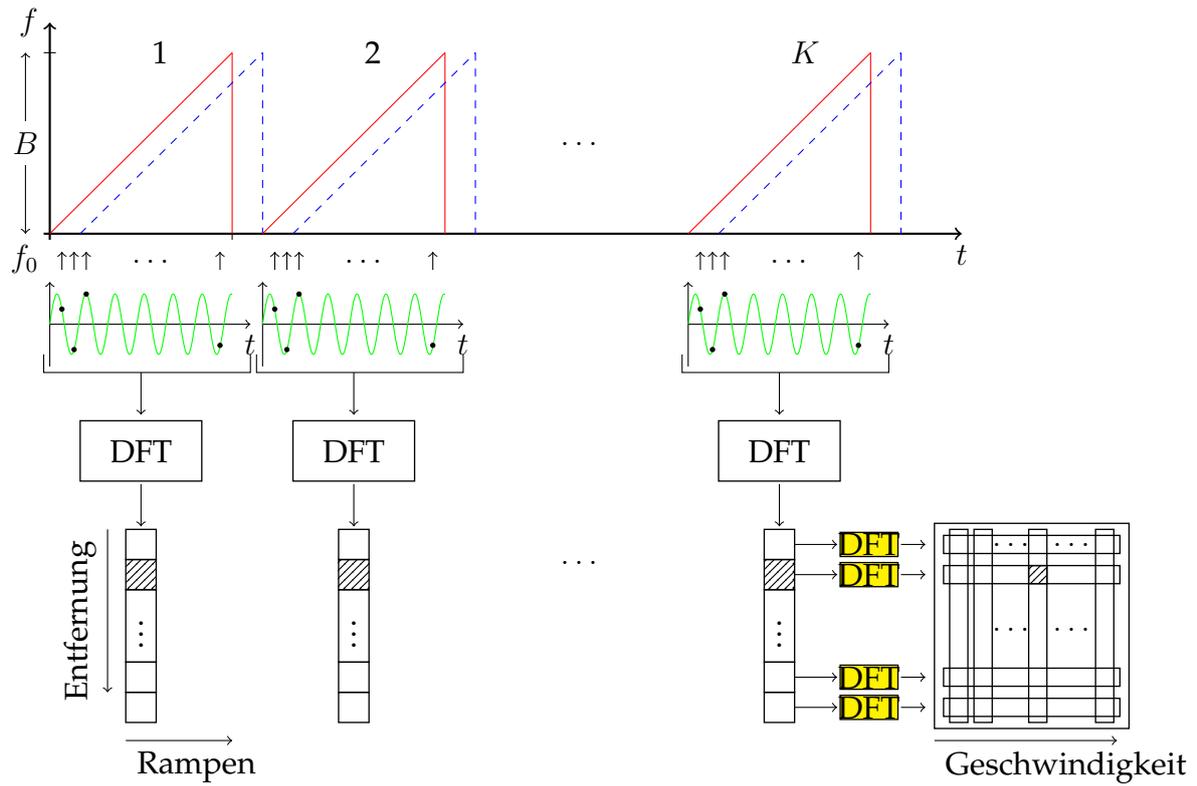


Abbildung 3.17: Methodik zur Generierung des Entfernung- und Geschwindigkeitsspektrum unter Verwendung der Chirp-Sequence Modulation

sich der Signal-Rausch Abstand von um den Faktor 2. Mit zunehmender Anzahl an Stützstellen verteilt sich die unkorrelierte Rauschleistung gleichmäßig auf alle entsprechenden Frequenzzellen. Der Gewinn ist somit abhängig von der Anzahl der Stützstellen. Meist wird dieser Gewinn in Dezibel angegeben.

$$G_{FFT} = 10 \log_{10} (\# \text{ Stützstellen}) \quad (3.60)$$

Für den Fall eines reellen Signals halbiert sich der Gewinn der DFT aufgrund der Symmetrie des Spektrums. Im Frequenzraum existiert nur die halbe Anzahl an unabhängigen komplexen Fourierkoeffizienten, wodurch auch nur die halbe Anzahl an Frequenzzellen vorhanden ist. Dies ist insbesondere beim Entfernungsspektrum zu beachten, da die Zeitsignale durch digitale Abtastwerte abgebildet sind.

Für die beiden in dieser Arbeit zu untersuchenden Modulationen ist der gesamte DFT-Gewinn  $G_{FFT} = 63,2$  dB.

Dieser große Gewinn an Dynamik im Spektrum ermöglicht die Detektion selbst von sehr kleinen Signalreflexionen an Streuzentren von relevanten Objekten. Um diese nicht von einem Nebenmaxima/Nebenkeule eines sehr starken Streuzentrums zu überdecken, wird eine Fensterfunktion mit ebenfalls hoher Dynamik benötigt. Damit wird aber auch gleichzeitig in Kauf genommen, dass sich die Frequenzseparationsfähigkeit der DFT im Vergleich zum Rechteckfenster verschlechtert. Gewählt wurde ein Dolph-Chebyshev Fenster mit  $-100$  dB Nebenmaxima Dämpfung. Für die Frequenzselektivität wurde empirisch eine Vergrößerung um eine Frequenzzelle im Vergleich zur Rechteckfensterung ermittelt.

Aufgrund der hohen Rohsignalraten des Radarsensor von über  $17,5$  GBit/s werden die Fouriertransformationen auf der FPGA Plattform implementiert und in Echtzeit ausgeführt.

Das ermittelte zweidimensionale Spektrum, äquivalent zur Entfernung- und Geschwindigkeitskombination (auch Range-Doppler Spektrum genannt), bildet die Basis der weiteren Schritte in der Signalverarbeitung.

#### 3.6.2 Signaldetektion im Rauschen

Ein elementarer Signalverarbeitungsschritt bei Radarsensoren ist die Unterscheidung von Signal- und Rauschanteilen. Weit verbreitet im Radarbereich sind dafür die Constant False Alarm Rate (CFAR)-Methoden. Eine detaillierte Beschreibung ist in [76] gegeben. An dieser Stelle soll ein Überblick über die Methodik und die verwendete Variante vorgestellt werden.

Die CFAR-Methodik beschreibt eine adaptive Schwellwertbestimmung basierend auf der Rauschschwelle des Signals in Kombination mit einer konstanten Falschalarmrate. Typischerweise wird für jede Entfernung- und Geschwindigkeitszelle im zweidimensionalen Amplitudenspektrum eine Schwelle berechnet. Anhand des Schwellwerts erfolgt die Einteilung entweder in ein Streuzentrum oder eine Rauschamplitude. Dies geschieht durch Vergleich der Schwelle mit dem

Amplitudensignal in der jeweiligen Zelle.

Mehrere Einflüsse in der Umgebung des Radars machen eine adaptive Anpassung dieser Schwelle notwendig. Durch Alterung und variierende Temperaturen schwankt die Verstärkung eines Radarempfängers geringfügig, was sich unmittelbar auf das Systemrauschen auswirkt [31]. Wechselnde Wetterbedingungen wie Regen, Schnee oder Nebel erzeugen zusätzliche reflektierende Streuzentren mit sehr schwachen Amplituden (mit geringem Signal-to-Noise Ratio (SNR)), welche irrelevant für die Umgebungsdetektion sind und im Fachterminus als Clutter bezeichnet werden. Da die Wettereinflüsse im Allgemeinen konstant über den gesamten Erfassungsbereich des Radars sind, heben diese den Rauschlevel im Spektrum zusätzlich an.

Zur Bestimmung des Rauschlevels werden je nach der Dimensionierung des CFARs um die zu testende Zelle eine gewisse Anzahl an umliegenden Zellen herangezogen. Je nach Variante werden diese Zellen entweder gemittelt (Cell Averaging (CA)) oder der Größe nach sortiert (Ordered Statistic (OS)). Das somit ermittelte Rauschniveau wird mit einem Skalierungsfaktor multipliziert um einen konfigurierbaren Schutzabstand zwischen Rauschen und Schwellwert einzuführen. Für die Anwendung im automobilen Umfeld hat sich der OS-CFAR als besonders geeignet erwiesen [77]. Ein Schutzabstand von 6 dB hat sich bei Radfahrermessungen als ausreichend gezeigt.

Zur Ausnutzung der Information aller Empfangskanäle werden diese im Entfernungs- und Geschwindigkeitsspektrum nichtkohärent integriert. Dabei werden die quadrierten Beträge der komplexen Amplitudenwerte gemittelt. Das so entstandene, über alle Kanäle gemittelte Spektrum wird zur Unterscheidung von Signalen und Rauschen mit der OS-CFAR Methode verwendet. Damit wird die Durchführung des CFAR-Algorithmus auf ein Spektrum anstelle von  $M$ -Spektrern reduziert, womit Rechenleistung eingespart werden kann. Gleichfalls wird mit der nichtkohärenten Integration eine Verringerung der Varianz des Rauschens erreicht [31, 78]. Mit der geringeren Rauschvarianz ist eine Detektion von weiteren Streuzentren mit niedrigerem SNR möglich [25].

Nach Unterscheidung der Signalanteile vom Rauschen entstehen Ausschnitte, die mehrere Entfernungs- und Geschwindigkeitszellen enthalten. Jedoch enthält nicht jede dieser Zellen die Information über ein Streuzentrum eines Objekts. Vielmehr ist die Information der Entfernung und Geschwindigkeit in den lokalen Maxima enthalten. Die benachbarten Zellen um ein solches lokales Maximum sind durch die Breite der Fensterfunktion im Spektrum maskiert und tragen keine relevante Objektinformation.

Mit dem Extrahieren der lokalen Maxima sind deren Positionen im Spektrum adressierbar. Die Auswahl der Entfernungs- und Geschwindigkeitszelle mit dem größten Amplitudenwert resultiert im ungünstigsten Fall in einer Abweichung von einer halben Frequenzzelle. Diese Quantisierungsauflösung beschränkt die Genauigkeit der Parameterschätzung. Wird eine genauere Bestimmung des Maximums benötigt [79], dann eignet sich dafür das Amplitudenbetragsspektrum, da durch den großen FFT-Gewinn auch Streuzentren mit sehr geringem SNR (bzw.

Rückstreuleistung oder RCS) auswertbar sind (vorausgesetzt, dass diese nicht wegen der Fensterfunktion durch größere Ziele maskiert werden).

In der Literatur [57, 80] wurden zahlreiche Methoden zur Interpolation untersucht. Für diese Arbeit wurde ein Kompromiss zwischen Effizienz und Genauigkeit gewählt. Die Interpolation zur Findung des Betragsmaximums wird für jedes lokale Maxima, bezogen auf die beiden Parameter Entfernung und Geschwindigkeit, in jedem der  $M$  Kanäle durchgeführt. Dafür wird eine zweidimensionale Parabel anhand der acht umliegenden Frequenzzellen, deren Beträge als Stützstellen dienen, um das lokale Maxima via Ausgleichsrechnung approximiert. Der Maximalwert der approximierten Parabel bestimmt die exakte Lokalisierung des lokalen Maximum bis auf den Bruchteil einer Frequenzzelle. Damit ist die Genauigkeit der Entfernung, Geschwindigkeit und Signalamplitude in einem Schritt erhöht. Zusätzlich zur Amplitude ist ebenfalls die exakte Phasenlage, vor allem für die Winkelschätzung, von großer Bedeutung. Diese wird mit einer Geraden approximiert unter Ausnutzung der bekannten exakten Position des Maximum der approximierten Parabel.

Um Übertragungsbandbreite einzusparen, ist der OS-CFAR-Algorithmus auf der FPGA-Plattform implementiert. Es werden lediglich die Frequenzzellen mit den komplexen Amplitudenwerten übertragen, deren Signalanteile über der CFAR-Schwelle liegen.

#### 3.6.3 Winkelschätzung

Nach Extraktion der lokalen Maxima im Range-Doppler Spektrum aus dem Rauschen, sind die relevanten Streuzentren von Objekten in der Radarumgebung bekannt. Um Rechenaufwand und Ressourcen einzusparen, wird die Schätzung der Richtung der Streuzentren anhand der Einfallswinkel auf das Antennenarray exklusiv für die extrahierten  $L$  lokalen Maxima durchgeführt.

Für die Bestimmung der Einfallswinkel gibt es eine Vielzahl an bekannten Methoden in der Literatur. Eine Übersicht der Bekanntesten bietet [81].

Die Strahlformung erfolgt auf digitale Weise [37], da diese im Vergleich zur mechanischen Strahlformung mit einem mechanischen Steller [32] oder elektrischer Strahlformung mit Phasenschiebern [32] es ermöglicht modellbasierte Verfahren zur Richtungsschätzung mit bestmöglicher Robustheit und Genauigkeit anzuwenden [62]. Bei der digitalen Strahlformung wird gleichzeitig Leistung aus mehreren Raumrichtungen empfangen und die Strahlformung als Signalverarbeitungsschritt in der digitalen Domäne durchgeführt.

Ausgewählt wurde ein digitaler Strahlformungsansatz, der den Empfangsstrahl in eine bestimmte Raumrichtung ausrichtet, um dann die Empfangsleistung zu messen. Beim Scannen über den gesamten Empfangswinkelbereich ergibt sich das Winkelspektrum. Diese Methode ist in der Literatur als konventioneller- oder Bartlett-Beamformer bekannt [81].

Die Gleichung zur Berechnung des räumlichen Spektrums des Bartlett-Beam-

former für eine Kombination der zwei Raumwinkel wurde in [73] veröffentlicht.

$$P_{BF}(\theta, \varphi) = \frac{\vec{a}(\theta, \varphi)^H \vec{y}(t) \vec{y}(t)^H \vec{a}(\theta, \varphi)}{\vec{a}(\theta, \varphi)^H \vec{a}(\theta, \varphi)} \quad (3.61)$$

Der Steuervektor  $\vec{a}(\theta, \varphi)$  ist aus Gleichung 3.48 und das Empfangssignal  $\vec{y}(t)$  aus Gleichung 3.50 bekannt. Der hermitesche Operator  $()^H$  kennzeichnet die hermitesche Matrixoperation. Zur Berechnung des räumlichen Spektrums für jedes lokale Maximum ist Gleichung 3.61 für jede mögliche Kombination der zwei Raumwinkel zu lösen. Dies erfordert eine hohe Rechenleistung. Mit geringen Anpassungen kann Gleichung 3.61 entsprechend umgeformt werden, um eine effizientere Berechnung zu ermöglichen.

Nach Normalisierung des Steuervektors  $\vec{a}(\theta, \varphi)$  auf Amplitude eins für alle Einträge wird der Nenner in Gleichung 3.61 ebenfalls eins und kann vernachlässigt werden. Die Normalisierung der Amplitude auf eins ist legitim, da die Information der Einfallswinkel nur in den Phasen der komplexen Empfangswerte enthalten ist. Wird zusätzlich nicht die Empfangsleistung als Kriterium zur Maximumsuche angewendet, sondern lediglich die Amplitude, folgt für das Amplitudenspektrum des Bartlett-Beamformers mit einer Kombination der beiden Raumwinkel

$$A_{BF}(\theta, \varphi) = \vec{y}(t)^H \vec{a}(\theta, \varphi). \quad (3.62)$$

Unter Verwendung der Array-Mannigfaltigkeitsmatrix  $\mathbf{A}_M(\theta, \varphi)$  ist mit einer Matrixmultiplikation die Berechnung des gesamten Amplitudenspektrums durchführbar.

$$\vec{A}_{BF}(\theta, \varphi) = \vec{y}(t)^H \mathbf{A}_M(\theta, \varphi) \quad (3.63)$$

Zur Erweiterung auf die Berechnung aller lokalen Maxima mit einer Matrixmultiplikation ist noch eine kleine Anpassung nötig. Dazu wird eine Empfangsmatrix  $\mathbf{Y}(t) = [\vec{y}_1(t), \dots, \vec{y}_L(t)]$  generiert, deren Einträge den Empfangsvektoren aller  $L$  lokalen Maxima entsprechen.

$$\mathbf{A}_{BF}(\theta, \varphi) = \mathbf{Y}(t)^H \mathbf{A}_M(\theta, \varphi) \quad (3.64)$$

Im Betragsamplitudenspektrum aller  $L$  lokalen Maxima wird für jede Zeile der Matrix  $\mathbf{A}_{BF}(\theta, \varphi)$  das Maximum bestimmt. Der Index des bestimmten Maximums entspricht den Einfallswinkeln in Azimut und Elevation. Das zweidimensionale Winkelspektrum für ein lokales Maximum ist exemplarisch in Abbildung 3.18 dargestellt. Zur Anwendung des beschriebenen Verfahrens wird unterstellt, dass sich nur ein Streuzentrum in jedem lokalen Maxima befindet. Diese Annahme kann als gültig deklariert werden, da die Entfernung- und Geschwindigkeitszellen eine sehr geringe Ausdehnung haben und die einzelnen Streuzentren in der Entfernung- und Geschwindigkeitsdomäne getrennt werden.

Wie aus Gleichung 3.64 zu entnehmen ist, hängt die Genauigkeit sehr stark von

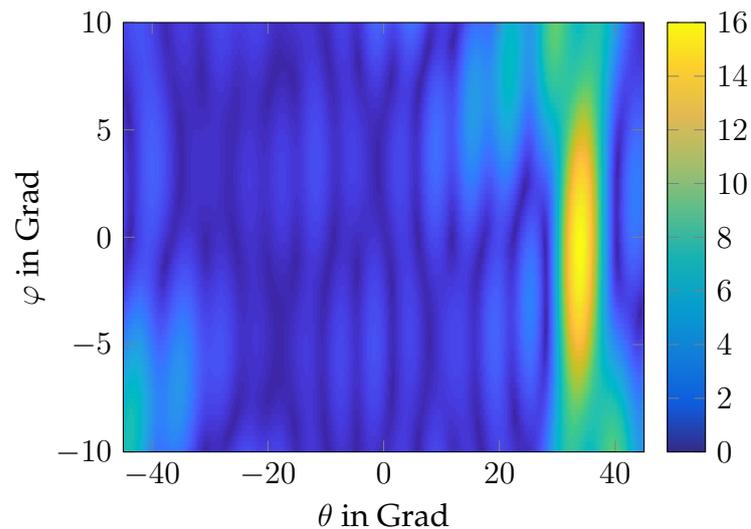
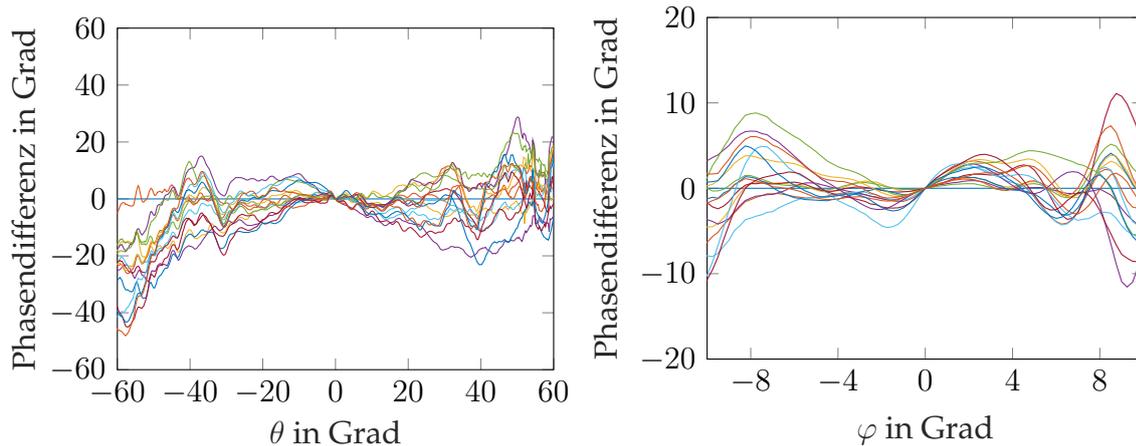


Abbildung 3.18: Exemplanische Darstellung des zweidimensionalen Winkelspektrums mit den Beträgen der Amplituden für ein lokales Maximum

der Array-Mannigfaltigkeitsmatrix ab. Dabei gilt es, die Anforderung zu erfüllen, dass Störeffekte, resultierend von der Hardware, keinen Einfluss auf die Winkelschätzung haben. Überprüft werden muss die Signallaufzeit der einzelnen Kanäle auf dem Radar Frontend und eine eventuelle Verzerrung der Eingangssignale in Abhängigkeit der Einfallsrichtung durch die Antennen.

Unter zu Hilfenahme der Messung in der Antennenmesskammer, auch Kalibrierung genannt, aufgenommen wie in Unterabschnitt 3.5.2 beschrieben, lassen sich die genannten Störeinflüsse bestimmen und korrigieren. Den Einfluss der Signallaufzeit auf die Phasen der Empfangskanäle ist aus der Messung in der Nullposition  $\theta = 0^\circ$  und  $\varphi = 0^\circ$  ermittelbar. In dieser Position wird jedes Element des Antennenarrays zum gleichen Zeitpunkt von der Wellenfront erreicht und müsste bei einem idealen, für jeden Kanal gleich langen Signalpfad die gleiche Phasenlage erzeugen. Die gemessenen Phasenabweichungen sind auf die unterschiedlich langen Signalpfade zurückzuführen und sind je nach Generierung der Array-Mannigfaltigkeitsmatrix zu berücksichtigen. Zwei Varianten dieser Signallaufzeitkalibrierung wurden getestet und sind im Einsatz.

Eine naheliegende Vorgehensweise ist das Messen jeder Winkelkombination in der Antennenmesskammer. Für jeweils eine Ebene in Azimut und Elevation ist dies noch praktikabel, jedoch für eine feingliedrige Erfassung aller Kombinationen steigt der Messaufwand unvermeidbar hoch an. Um diese Herausforderung zu lösen, wurde ein alternativer Ansatz verfolgt. Die Gesamtheit aller Kombinationen kann mit Gleichung 3.55 synthetisch generiert werden, wenn die genaue Position der Arrayelemente und die Wellenlänge des Sendesignals bekannt ist. Für die Position der Arrayelemente wurden die in Abbildung 3.13 gezeigten Ab-

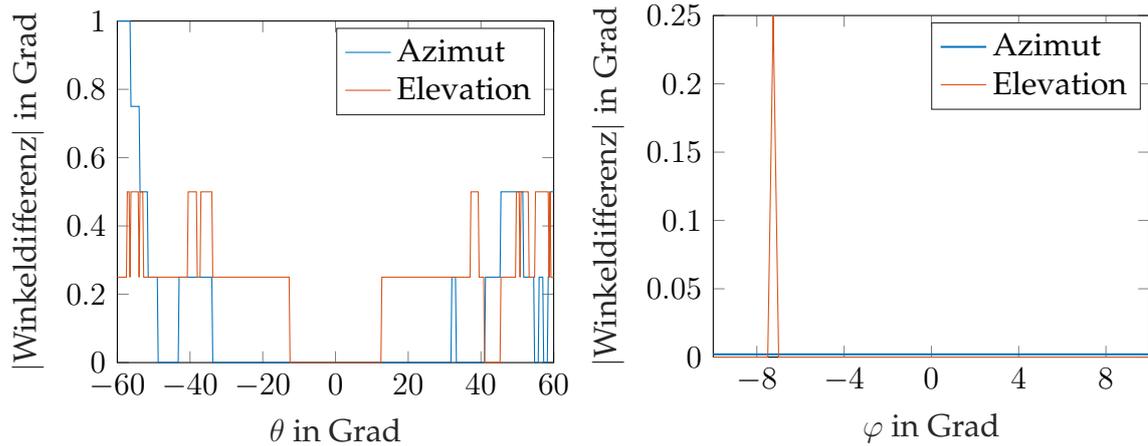


(a) Phasendifferenz im Azimutschnitt für jeden Empfangskanal (b) Phasendifferenz im Elevationsschnitt für jeden Empfangskanal

Abbildung 3.19: Phasendifferenzen zwischen den in der Antennenmesskammer bestimmten winkelabhängigen Signalen und der synthetisch generierten Mannigfaltigkeitsmatrix

stände verwendet. Die Signalwellenlänge wird mit  $\lambda_0 = \frac{c_0}{f_0}$  aus der Sendefrequenz bestimmt. Zur Korrektur der Signallaufzeiten werden die zueinander abweichenden Phasenlagen in der Nullposition zu den synthetisch erzeugten komplexen Amplituden addiert. Da für die Mannigfaltigkeitsmatrix diese Korrektur nur einmal vorgenommen werden muss, ist dies die bessere Lösung im Vergleich zur alternativen Korrektur der Empfangssignale.

Zur Validierung der synthetisch erzeugten Matrix, wurden die beiden Messungen in der Antennenmesskammer herangezogen. Für jede Winkelposition wurde ein Vergleich der Phasenlagen zwischen den synthetischen und gemessenen Werten mittels Differenzbildung durchgeführt. Der erste Kanal wurde dabei als Bezugspunkt verwendet und dessen Phase von allen anderen subtrahiert. Die Phasendifferenzen für den Azimut- und Elevationsschnitt sind in Abbildung 3.19 dargestellt. Es zeigt sich, dass im Öffnungsbereich der Antennen eine geringe Phasendifferenz auftritt. Innerhalb des Sichtbereichs der Antennenelemente konnte eine Phasenabweichung über alle Kanäle und alle Winkel von  $RMSE_{\theta,P} = 0,176^\circ$  und  $RMSE_{\varphi,P} = 0,045^\circ$  ermittelt werden. Die auftretende Diskrepanz zwischen den beiden mittleren Abweichungsquadratwerten hat mehrere Ursachen. Einen großen Einfluss auf die Genauigkeit der Phase hat das SNR des Empfangssignal. Mit Eingrenzung des Öffnungsbereich in Azimut auf den selben SNR-Bereich wie in der Elevation verringert sich die Abweichung auf  $RMSE_{\theta,P} = 0,099^\circ$ . Weiter wird die Phase durch den Positionswinkel bzw. den Sinus des Positionswinkel beeinflusst. Unter Einschränkung des Öffnungsbereichs in Azimut auf den gleichen wie in der Elevation, sinkt die Abweichung deutlich auf  $RMSE_{\theta,P} = 0,039^\circ$  und unterbietet die Abweichung in der Elevation. Damit ist dargelegt, dass die Kor-



(a) Differenz Soll zu Ist aus der Kalibrationsmessung für die Schätzung des Azimut  
 (b) Differenz Soll zu Ist aus der Kalibrationsmessung für die Schätzung der Elevation

Abbildung 3.20: Abweichung zwischen den erwarteten Einfallswinkeln aus den gemessenen Werten zu den mit dem Winkelschätzer bestimmten Einfallswinkeln

rektur und Generierung der synthetischen Mannigfaltigkeitsmatrix in den physikalisch gegebenen Grenzen eine ausreichende Genauigkeit bietet.

Zur Verifizierung der Genauigkeit des Winkelschätzalgorithmus wird dieser auf den bekannten Messdatensatz aus der Antennenmesskammer angewendet. Mit dieser Referenz kann eine Differenz zwischen Referenz und geschätztem Winkel bestimmt werden. Die Differenz für jede Winkelposition zeigt Abbildung 3.20. Sowohl die gemessenen als auch die synthetisch erzeugten Daten wurden mit einer Schrittweite von  $0,25^\circ$  im Winkel erzeugt. Für die Schätzung in Azimut tritt ein maximaler Fehler von  $1^\circ$  und in Elevation von maximal  $0,25^\circ$  auf. Im Test mit den Azimutdaten ist ein vom Winkel abhängiger Fehler zu beobachten, der mit betragsmäßig steigendem Winkel ebenfalls wächst. Dies bekräftigt den Einfluss des Sinus der Winkelposition wie zuvor bereits erwähnt. Dabei wirken sich bei betragsmäßig großen Winkeln kleine Abweichungen deutlich stärker aus, als bei kleineren. Der mittlere Abweichungsquadratwert in Azimut  $RMSE_{\theta,W} = 0,273^\circ$  und Elevation  $RMSE_{\varphi,W} = 0,028^\circ$  beschreibt Fehler in der Genauigkeit, die im Auflösungsbereich liegen. Die Auflösung der Winkelschätzung  $\Delta\theta = \Delta\varphi = 0,25^\circ$  ist durch die Schrittweite vorgegeben.

Die vorgestellte Methode erzielt eine hohe Genauigkeit in der Ermittlung der Einfallswinkel. In der Offlineauswertung spielt die Dauer und Ressourceneffizienz keine große Rolle. Für eine Implementierung in einem System zur Berechnung der Einfallswinkel in Echtzeit wurde eine ressourcenschonendere Methode angewandt. Das grundlegende Vorgehen ist dabei identisch zur vorigen Methode mit digitalem Beamforming und Erfassung der Empfangsamplitude. Im Gegensatz

zur ersten Variante werden die Einfallswinkel in Azimut und Elevation separat geschätzt.

Im ersten Schritt wird der Azimutwinkel mit den ersten 10 Antennenelementen im Array geschätzt. Hierfür wird das Koordinatensystem des Antennenarrays virtuell gedreht. Die Drehung erfolgt um  $90^\circ$  im mathematisch negativen Drehsinn um die  $x$ -Achse. Damit liegen die ersten 10 Elemente entlang der  $z$ -Achse in positiver Richtung und die restlichen 6 Elemente verteilt in der  $y$ - $z$ -Ebene. Als nicht gedrehte Referenz ist Abbildung 3.10 heranzuziehen. Nach der virtuellen Drehung ist der virtuelle Einfallswinkel in Elevation  $\varphi_V$  für das aus den ersten 10 Elementen bestehende ULA bestimmbar. Das Schema wird von der vorigen Winkelschätzung übernommen und die gemessene Kalibrationsmatrix in Azimut ist somit anwendbar. Da pro Schritt ein Winkel bestimmt wird, kann die gemessene Mannigfaltigkeitsmatrix verwendet werden, womit keine Korrekturen mehr benötigt sind. Nach Ausführung der Winkelschätzung ist der virtuelle Elevationswinkel bekannt. Für die Schätzung des virtuellen Azimutwinkels ist der Einfluss des virtuellen Elevationswinkels zu eliminieren. Dafür wird folgende Kompensation angewendet. Ausgangspunkt ist die Phasenbeschreibung für einen Kanal.

$$\phi_m = e^{-jk(y_m \sin(\theta_V) \cos(\varphi_V) + z_m \sin(\varphi_V))} \quad (3.65)$$

Als erstes wird der Einfluss der  $z$ -Komponente kompensiert.

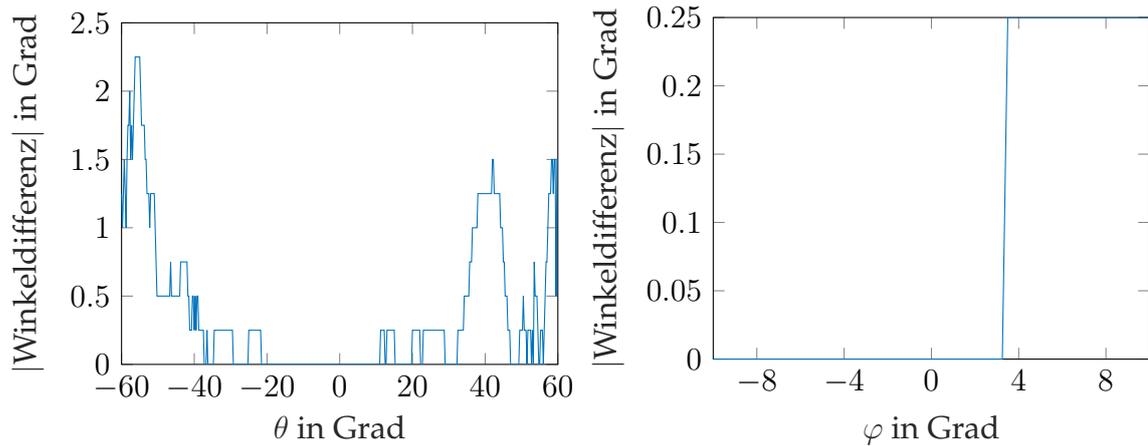
$$\phi_{m,komp1} = \phi_m e^{jk(z_m \sin(\varphi_V))} \quad (3.66)$$

Anschließend ist es notwendig den Einfluss des virtuellen Elevationswinkels auf die  $y$ -Komponente zu eliminieren.

$$\phi_{m,komp2} = (\phi_{m,komp1})^{\frac{1}{\cos(\varphi_V)}} \quad (3.67)$$

Diese Kompensation wird für jeden Kanal eines lokalen Maximums durchgeführt, dessen virtueller Elevationswinkel im ersten Schritt bereits bestimmt wurde. Nach der Kompensation ist es möglich, den virtuellen Azimutwinkel mit der gemessenen Kalibrationsmatrix in Elevation zu bestimmen.

Für die separate Schätzmethode wurde mit Hilfe der Kalibrationsmessung die Winkelabweichung in Azimut und Elevation bestimmt. Die Abweichungen über der Position ist in Abbildung 3.21 aufgetragen. Die mittleren quadratischen Abweichungen  $RMSE_{\theta_V, W} = 0,144^\circ$  und  $RMSE_{\varphi_V, W} = 0,647^\circ$  sind etwas größer als bei der kombinierten Schätzung, befinden sich jedoch noch in einem akzeptablen Bereich. Die größeren Abweichungen kommen von der kleineren effektiven Apertur sowie der Fehlerfortpflanzung durch die getrennte Schätzung und Verwendung des ersten Schätzergebnisses in der zweiten Schätzung.



(a) Differenz Soll zu Ist mit Kalibrationsmessung für die separate Schätzung des Azimut (b) Differenz Soll zu Ist mit Kalibrationsmessung für die separate Schätzung der Elevation

Abbildung 3.21: Abweichung zwischen den erwarteten Einfallswinkeln aus den gemessenen Werten zu den mit dem Winkelschätzer bestimmten Einfallswinkeln mit der separaten Schätzmethode

## Zusammenfassung

Im vorangegangenen Kapitel wurden die Grundlagen der Radarsensorik im Automobilbereich diskutiert und die zugrunde liegenden physikalischen Effekte analytisch beschrieben. Ein Objekt, das von einem Radar erfasst wird, kann aus mehreren Streuzentren bestehen, die charakteristische Eigenschaften tragen. Abhängig von der Geometrie, der Größe und des Materials eines Streuzentrums wird mehr oder weniger Signalleistung zurückgestrahlt und durch den RCS Wert gekennzeichnet. Die Information des Radarrückstreuquerschnitts ist aus der Signalamplitude am Empfänger zu extrahieren. Zur Bestimmung der Entfernung der Streuzentren wird die Signallaufzeit zwischen Aussenden und Empfangen ermittelt. Mit der Frequenzverschiebung des Empfangssignals gegenüber dem Sendesignal, induziert durch den Doppler-Effekt, ist die Geschwindigkeit auswertbar. Durch geeignete Modulation des Sendesignals in Form einer Frequenzmodulation ist die Entfernung implizit aus der Differenz des Mischsignals von Sender und Empfänger festzustellen. Unter Verwendung vieler kontinuierlicher sehr schneller frequenzmodulierter Rampen lässt sich die Geschwindigkeit erfassen. Die Chirp-Sequence Modulation wird im vorgestellten prototypischen 77 GHz Automobilradar eingesetzt. Zur räumlichen Lokalisierung der Streuzentren eines Objekts muss der Sensor in der Lage sein, die Einfallswinkel des Empfangssignals zu bestimmen. Dies wird mit Hilfe eines speziell entwickelten Antennenarrays ermöglicht. Zur Bestimmung beider Raumwinkel (Azimut und Elevation) wurde ein neues Antennenarray entworfen und im Front-End verwendet.

Die benötigten digitalen Signalverarbeitungsschritte zur Extraktion der Entfernungs-, Geschwindigkeits- und Richtungsinformation wurden im Detail dargestellt. Zur Minimierung des Rechenaufwands wurde die Signaldetektion bereits in der Entfernungs- und Geschwindigkeitsdomäne durchgeführt. Für die damit entdeckten lokalen Maxima wurde daraufhin die Richtung bestimmt. Dafür wurden zwei Methoden vorgestellt, die in etwa dieselben Toleranzen bezüglich der Winkelgenauigkeit aufweisen. Der massive Unterschied spiegelt sich im Rechenaufwand wieder, deshalb wurde nur die Methode mit separater Schätzung von Azimut und Elevation im Prototypsystem mit Echtzeitfähigkeit implementiert.

Im weiteren Verlauf bilden die charakteristischen Informationen der Streuzentren die Basis zur Lokalisierung und Klassifizierung von Radfahrern auf Basis von Radarsensordaten. Zur Erläuterung unterschiedlicher Zusammenhänge und zur Visualisierung wird das Entfernungs- und Geschwindigkeitsspektrum sowie die Darstellung der Streuzentren als Punkte im dreidimensionalen Raum verwendet.



# 4 Detektion von Radfahrern

## Inhalt

---

|            |  |           |
|------------|--|-----------|
| <b>4.1</b> | <b>Physikalische Attribute eines Radfahrers</b>            | <b>58</b> |
| 4.1.1      | Systembetrachtung  | 58        |
| 4.1.2      | Bewegungsanalyse   | 60        |
| 4.1.3      | Mikro-Doppler Effekt                                       | 66        |
| 4.1.4      | RCS  | 66        |
| <b>4.2</b> | <b>Modellierung eines Radfahrers</b>                       | <b>69</b> |
| 4.2.1      | Simulationsumgebung  | 69        |
| 4.2.2      | Radfahrermodell  | 69        |
| 4.2.3      | Sensormodell   | 71        |
| 4.2.4      | Validierung der Simulation                                 | 74        |
| 4.2.5      | Fußgängermodell  | 77        |
| <b>4.3</b> | <b>Extraktion von Merkmalen</b>                            | <b>79</b> |
| 4.3.1      | Objektausdehnung   | 80        |
| 4.3.2      | Streuzentrengeschwindigkeit                                | 81        |
| 4.3.3      | Räumliche Verteilung der Streuzentren                      | 82        |
| 4.3.4      | Eigengeschwindigkeit                                       | 89        |
| 4.3.5      | Erkennungsbereich  | 90        |
| <b>4.4</b> | <b>Anforderungen an einen artikulierten Radfahrerdummy</b> | <b>91</b> |

---

## Überblick

In den vergangenen Jahren wurde die Radarsensorik stetig leistungsfähiger, was den Einsatz in immer komplexeren Anwendungen ermöglichte. Einhergehend mit der Auflösungssteigerung sowohl in der Entfernung- als auch Geschwindigkeitsmessung und der dadurch entstandenen Möglichkeit, einzelne Streuzentren auf einem Objekt zu unterscheiden, ist das Radar geradezu prädestiniert für eine detaillierte Detektion der Fahrzeugumgebung [35].

Anhand der Auswertung des Mikro-Doppler Effekts [82] eröffnete sich ein großes Feld in der Detektion von bewegten Objekten durch deren charakteristische

Ausdehnung in der Geschwindigkeit und Entfernung [83–85]. Dabei lag der Fokus bisher stark auf der Detektion von Fußgängern, angetrieben durch Verbraucherschutzorganisationen wie EuroNCAP, die in 2014 erstmals Sicherheitstests für Fußgänger in ihrem Prüfprotokoll mit aufgenommen haben. Aufbauend auf weiteren Verbesserungen im Fußgängerschutz, werden die Testszenarien aktuell auch auf Radfahrer erweitert.

Die Analyse des menschlichen Ganges aus der Biomechanik, eine Teildisziplin der Kinesiologie, wurde zur Generierung von Bewegungsmodellen verwendet, die spezifische Radareigenschaften abbilden. Eingesetzt in Simulationen, konnten die ebenfalls messtechnisch erfasste Bewegungsprofile validiert werden [86–89].

Durch die Erfassung von mehreren Streuzentren, ausgehend von einem Objekt, besteht eine Notwendigkeit zur gemeinsamen Zuordnung dieser Detektionspunkte in ein physikalisch zusammenhängendes Objekt. Dafür haben sich Verfahren aus dem interdisziplinären Thema der Wissensentdeckung in Datenbanken (Knowledge Discovery in Databases) etabliert. Als Methodik werden Clustering Verfahren [90] eingesetzt, die Daten (semi)-automatisch gruppieren [91–94].

Im Folgenden wird beschrieben, wie Radfahrer mittels verbauter Radarsensoren am Fahrzeug detektiert werden können. Die Eigenschaften bezüglich des Mikrodoppler Effekt und des RCS-Wert für einen Radfahrer werden beleuchtet. Daraus gewonnene Erkenntnisse fließen in die Beschreibung eines Bewegungsmodells, spezifisch generiert für Radarsimulationen mit ein. Aus den Simulationen und messtechnisch erfassten Daten werden Merkmale extrahiert, welche charakteristisch für einen Radfahrer sind und diesen von anderen sich im Verkehr bewegten anderen Teilnehmern eindeutig abgrenzen.

## 4.1 Physikalische Attribute eines Radfahrers

Relevant für die Detektion eines Radfahrers ist die Ermittlung physikalischer Attribute, die speziell mit einem Radar erfassbar sind. Dafür wird das System Radfahrer im Detail analysiert hinsichtlich der Rückstreuungseigenschaften, der Geschwindigkeiten der einzelnen Komponenten, der räumlichen Ausdehnung und der Agilität in den Bewegungen. Anhand dieser Attribute wird ein Modell beschrieben, mit dem es möglich ist, synthetische Daten zu generieren und für die Validierung von gemessenen Daten heranzuziehen.

### 4.1.1 Systembetrachtung

Als Radfahrer wird das Gesamtsystem aus Fahrrad und menschlichem Fahrer bezeichnet. Untersuchungen und Forschungsschwerpunkte in der Beschreibung des Systems Radfahrer sind im Bereich der Biomechanik sowie in der Analyse der anliegenden Kräfte und Momente am Fortbewegungsmittel angesiedelt. Bei der Analyse der Biomechanik wird die ideale Sitzposition des Fahrers auf dem Fahrrad untersucht und auf eine maximale Kraftübertragung optimiert. Dabei wird die

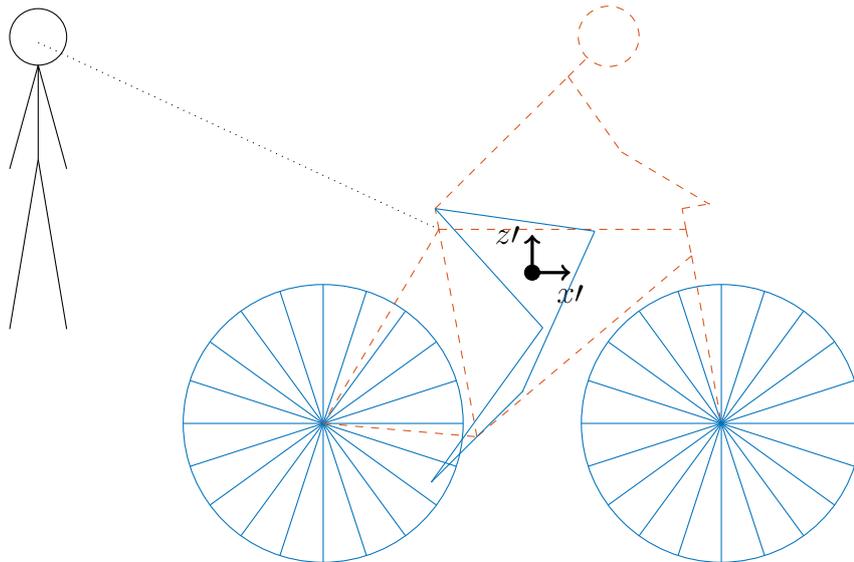


Abbildung 4.1: Bezugssystem Radarsensorik und Radfahrer mit Kennzeichnung der Komponenteneingliederung für starre (---) und rotierende Komponenten (—) mit Koordinatensystem des Massenschwerpunkts

benötigte Größe und Geometrie des Rahmens in Abhängigkeit der Körpergröße des Fahrers untersucht und angepasst [95, 96]. Anhand der Untersuchung der angreifenden Kräfte und Momente können Effekte wie die Selbststabilisierung und das Design der Lenkgeometrie beschrieben werden [96–98].

Diese Analysen können jedoch nur sehr bedingt zur Gewinnung von Erkenntnissen für die Detektion mit einem Radar beitragen. Unter Berücksichtigung der hochauflösenden Domäne in der Geschwindigkeit und Entfernung ist ein Hauptaugenmerk auf Bewegung, Bewegungsunterschiede sowie die räumliche Ausdehnung eines Fahrrads zu richten. Als Bezugssystem wird ein Beobachter außerhalb des Radfahrersystems gewählt, da ein Radarsensor ein Objekt wie einen Radfahrer ja als externer Beobachter erfasst. Unter dieser Voraussetzung lassen sich zwei Arten von Komponenten am Radfahrer abstrahieren.

Die erste Kategorie enthält Systemkomponenten des Radfahrers mit ausschließlich translatorischer Bewegung in Fahrtrichtung. Diese werden im weiteren Verlauf als starre Komponenten bezeichnet. Zuzuordnen sind dieser Gruppe der Oberkörper mit Kopf und die Arme des Fahrers, sowie der Rahmen, der Lenker und die Aufhängung des Fahrrads.

Der zweiten Art gehören Komponenten an, bei denen der translatorischen Bewegung eine rotatorische Bewegung überlagert ist. Diese werden im Folgenden als rotierende Komponenten gekennzeichnet. Dazu gehören die Beine, die Pedale mit Tretkurbel und das Vorder- und Hinterrad. Visualisiert ist die Zugehörigkeit der einzelnen Komponenten an der Abstraktion eines Radfahrers in Abbildung 4.1.

## 4 Detektion von Radfahrern

Für die Analyse wird ohne Einschränkung der Allgemeingültigkeit ein erwachsener Radfahrer angenommen mit einem gewöhnlichen Citybike und 28 Zoll Radgröße.

Die mathematische Beschreibung der räumlichen Ausdehnung eines Radfahrers bedarf keiner aufwendigen Analyse. Sie hängt in der Länge hauptsächlich vom Fahrrad ab und variiert zwischen 1,50 m und 2,00 m. In der Breite ist die Ausdehnung des Körpers vom Fahrer in Querrichtung oder der Lenker begrenzend, und das in einem typischen Bereich von 0,50 m bis 0,75 m. Für die Höhe befindet sich der Wertebereich zwischen 1,40 m und 1,90 m.

### 4.1.2 Bewegungsanalyse

Im vorangegangenen Unterkapitel konnten zwei Arten von Komponenten am Radfahrer abgeleitet werden. Es handelt sich dabei um starre und rotierende Komponenten. Für die Analyse der Bewegung werden diese Gruppen getrennt voneinander betrachtet.

Für die Beschreibung der Trajektorie der starren Komponenten wird das Radfahrersystem im Massenmittelpunkt zusammengefasst. Dies ist eine zulässige Vereinfachung, da bei Bewegungen in einer Ebene an allen Komponenten die Geschwindigkeitsvektoren in dieselbe Richtung zeigen und den gleichen Betrag aufweisen.

Die Bahn des Massenmittelpunktes und damit verbunden die Bahngeschwindigkeit der starren Komponenten wird analytisch nach [99] mit

$$\begin{aligned}\vec{r}(t) &= \vec{v}_{EGO}(t) \cdot t + \vec{r}_0 \\ \vec{v}_{EGO}(t) &= \frac{\vec{r}(t) - \vec{r}_0}{t}\end{aligned}\tag{4.1}$$

beschrieben, wobei  $\vec{r}_0$  den initialen Ortsvektor,  $\vec{r}(t)$  den zeitabhängigen Ortsvektor,  $\vec{v}_{EGO}(t)$  den zeitabhängigen Bahngeschwindigkeitsvektor, hier als Eigen Geschwindigkeitsvektor des Radfahrersystems, und  $t$  den variablen Zeitpunkt bezeichnet.

Die Bewegung der rotierenden Komponenten setzt sich im Allgemeinen aus einem translatorischen  $\vec{v}_{EGO}(t)$  und einem rotatorischen Anteil  $\vec{v}_T(t)$  zusammen. Die rotatorischen Bewegungsanteile der rotierenden Teile unterscheiden sich in eine reine und eine mit weiteren Geschwindigkeitsanteilen überlagerten kreisförmigen Bewegung. Zur Analyse werden gleichartig rotierende Komponenten zusammengefasst.

Zu den kreisförmig bewegten Komponenten ohne zusätzliche Geschwindigkeitsüberlagerungen, außer der Eigenbahngeschwindigkeit  $\vec{v}_{EGO}(t)$ , gehören die Pedale mit Tretkurbel, das Vorder- und Hinterrad sowie der Oberschenkel. Die Tangentialgeschwindigkeit  $\vec{v}_T(t)$  beschreibt zu jedem Zeitpunkt an einem beliebigen Punkt auf der Kreisoberfläche den Betrag und die Richtung der rotierenden Geschwindigkeitskomponente. Nach [99] ist die Tangentialgeschwindigkeit das

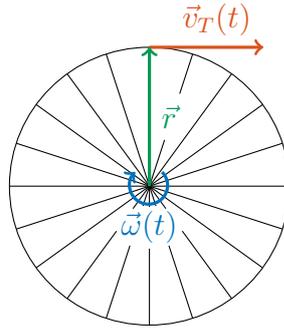


Abbildung 4.2: Exemplarische Darstellung der Tangentialgeschwindigkeit an einem Laufrad des Radfahrersystems

Kreuzprodukt aus Winkelgeschwindigkeitsvektor  $\vec{\omega}_w(t)$  und Kreisradius  $\vec{r}$ .

$$\vec{v}_T(t) = \vec{\omega}_w(t) \times \vec{r} \quad (4.2)$$

Exemplarisch wird in Abbildung 4.2 der physikalische Zusammenhang an den kreisförmig rotierenden Komponenten des Radfahrersystems verdeutlicht. Eine kleine Ausnahme stellt der Oberschenkel dar. Seine Bewegung ist ebenfalls kreisförmig mit Mittelpunkt an der Hüfte, jedoch nicht komplett sondern in einem eingeschränkten Winkelbereich; dieser variiert je nach Größe des Fahrers und der Sattelhöhe. Ebenso ist die Oberschenkelrotation nicht gleichförmig.

Die Beträge der Tangentialgeschwindigkeit  $\vec{v}_T(t)$  und der Eigengeschwindigkeit des Radfahrersystems  $\vec{v}_{EGO}(t)$  sind bei nicht rutschenden Laufrädern gleich groß. Initiiert wird diese Bewegung durch die Winkelgeschwindigkeit der Pedale  $\vec{\omega}_p(t)$ , welche über das Über- bzw. Untersetzungsverhältnis  $GTR$  an die Winkelgeschwindigkeit des hinteren Laufrades  $\vec{\omega}_w(t)$  über die Kette gekoppelt ist.

$$GTR = \frac{\vec{\omega}_p(t)}{\vec{\omega}_w(t)} \quad (4.3)$$

Die resultierenden Geschwindigkeitsbeträge in Bewegungsrichtung des Radfahrers an den Laufrädern erstrecken sich somit von null bis zum doppelten der Eigengeschwindigkeit  $\vec{v}_{EGO}(t)$ .

Der letzte noch zu beschreibende Teil ist die Bewegung des Unterschenkels. Diese ist gekennzeichnet durch eine Rotation um den Unterschenkelmittelpunkt sowie eine Überlagerung von Geschwindigkeitskomponenten in positiver und negativer  $x'$ - und  $z'$ -Richtung durch die Koordinatenachsen des Massenschwerpunktes, des Radfahrersystems, skizziert in Abbildung 4.1. Um diese Bewegung mathematisch zu beschreiben wurde eine Vektorkette über den einzelnen Gliedern des Beins aufgestellt. Dabei wurde die Position der Beinglieder in Abhängigkeit des Drehwinkels  $\alpha(t)$  der Pedale beschrieben und nach der Zeit differenziert. In Abbildung 4.3 ist die Vektorkette für ein Bein über die Beinglieder mit der im Folgenden verwendeten Nomenklatur skizziert. Die Beschreibung bezieht sich

#### 4 Detektion von Radfahrern

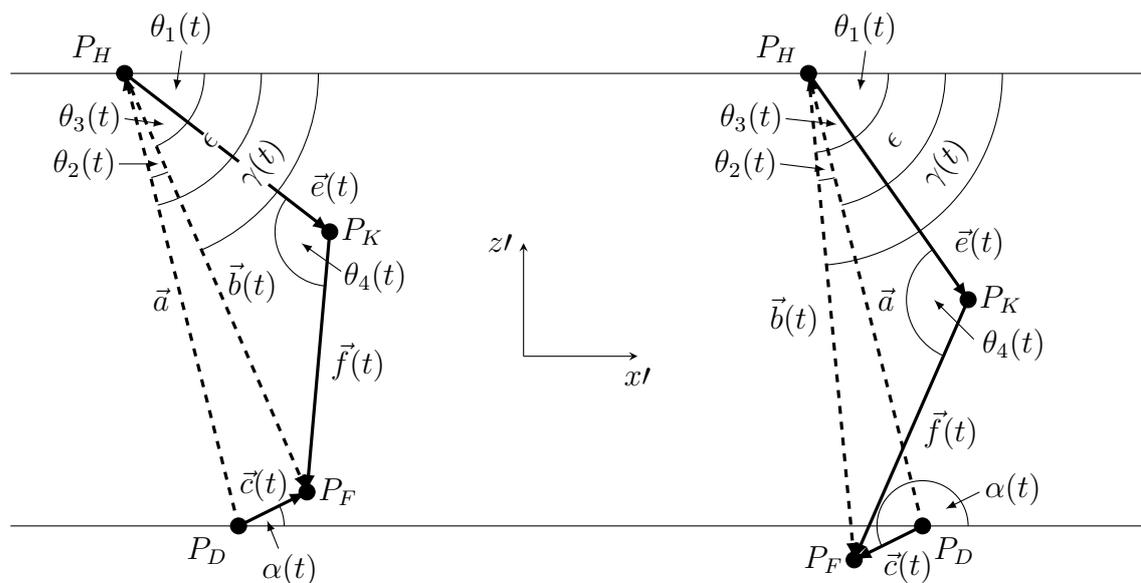


Abbildung 4.3: Skizze der Vektorkette der Beinglieder mit Bezeichnung der einzelnen Parts für zwei Zustände einer Pedalumdrehung, mit parallelen Bezugsachsen zum Koordinatensystem des Massenschwerpunkts

auf das Koordinatensystem, aufgespannt im Massenschwerpunkt des Radfahrersystems, und ist in Abbildung 4.1 dargestellt.

Bekannt, anhand der Geometrie des Fahrradrahmens, sind die Position der Hüfte  $P_H$  sowie die Drehachse der Pedale  $P_D$ . Des Weiteren wird als bekannt vorausgesetzt: die Länge der Tretkurbel  $|\vec{c}(t)|$ , die Länge von Ober- und Unterschenkel ( $|\vec{e}(t)|$ ,  $|\vec{f}(t)|$ ) und der Drehwinkel  $\alpha(t)$ . Zur Beschreibung der Geschwindigkeit des Knies und des Fuß zu jedem Zeitpunkt wird folgendes mathematische Modell zugrunde gelegt:

$$v_F(t) = \dot{P}_F(t) = \dot{P}_D + \dot{\vec{c}}(t) = \dot{P}_H(t) = \dot{\vec{e}}(t) + \dot{\vec{f}}(t) \quad (4.4)$$

$$v_K(t) = \dot{P}_K(t) = \dot{P}_H + \dot{\vec{e}}(t) \quad (4.5)$$

Zur vollständigen Beschreibung von Gleichung 4.4 wird  $\alpha(t)$ ,  $\vec{c}(t)$  und dessen zeitliche Ableitung  $\dot{\vec{c}}(t)$  benötigt.

$$\alpha(t) = \omega_P \cdot t \quad (4.6)$$

$$\vec{c}(t) = \begin{bmatrix} \cos(\alpha(t)) \cdot |\vec{c}(t)| \\ \sin(\alpha(t)) \cdot |\vec{c}(t)| \end{bmatrix} \quad (4.7)$$

#### 4.1 Physikalische Attribute eines Radfahrers

$$\dot{\vec{c}}(t) = \begin{bmatrix} -\sin(\alpha(t)) \cdot |\vec{c}(t)| \cdot \omega_P \\ \cos(\alpha(t)) \cdot |\vec{c}(t)| \cdot \omega_P \end{bmatrix} = v_F(t) \quad (4.8)$$

Die Geschwindigkeit des Fußes  $v_F(t)$  entspricht der zeitlichen Ableitung  $\dot{\vec{c}}(t)$ , da die Position  $P_D$  nicht zeitabhängig ist. Um die Geschwindigkeit des Knies  $v_K(t)$  zu bestimmen, ist es nötig Gleichung 4.5 vollständig zu beschreiben. Die Position der Hüfte  $P_H$  ist wiederum nicht zeitabhängig, wodurch  $v_K$  einzig durch  $\dot{\vec{e}}(t)$  beschrieben wird.

$$\vec{e}(t) = \begin{bmatrix} \cos(\theta_1(t)) \cdot |\vec{e}(t)| \\ \sin(\theta_1(t)) \cdot |\vec{e}(t)| \end{bmatrix} \quad (4.9)$$

$$\dot{\vec{e}}(t) = \begin{bmatrix} -\sin(\theta_1(t)) \cdot |\vec{e}(t)| \cdot \dot{\theta}_1(t) \\ \cos(\theta_1(t)) \cdot |\vec{e}(t)| \cdot \dot{\theta}_1(t) \end{bmatrix} \quad (4.10)$$

Die eindeutige Beschreibung des Winkels  $\theta_1(t)$  bedarf einer Fallunterscheidung aufgrund der unterschiedlichen Anordnungen für eine Pedalumdrehung.

$$\theta_1(t) = \begin{cases} \epsilon + \theta_2(t) - \theta_3(t) & \text{für } \epsilon < \gamma(t) \\ \epsilon - \theta_3(t) & \text{für } \epsilon = \gamma(t) \\ \epsilon - \theta_2(t) - \theta_3(t) & \text{für } \epsilon > \gamma(t) \end{cases} \quad (4.11)$$

Unter Anwendung des Kosinussatzes werden die Winkel  $\theta_2(t)$  und  $\theta_3(t)$  formuliert zu

$$\theta_2(t) = \arccos\left(\frac{|\vec{a}|^2 + |\vec{b}(t)|^2 - |\vec{c}(t)|^2}{2 \cdot |\vec{a}| \cdot |\vec{b}(t)|}\right) \quad (4.12)$$

$$\theta_3(t) = \arccos\left(\frac{|\vec{b}(t)|^2 + |\vec{e}(t)|^2 - |\vec{f}(t)|^2}{2 \cdot |\vec{b}(t)| \cdot |\vec{e}(t)|}\right) \quad (4.13)$$

Der zeitunabhängige Vektor  $\vec{a}$  wird durch Bildung der Differenz von  $P_H$  und  $P_D$  gebildet

$$\vec{a} = P_H - P_D \quad (4.14)$$

Durch Lösen der Vektorsubtraktion in Gleichung 4.15 wird  $\vec{b}(t)$  bestimmt

$$\vec{b}(t) = \vec{c}(t) - \vec{a} \quad (4.15)$$

#### 4 Detektion von Radfahrern

Die Winkel  $\epsilon$  und  $\gamma(t)$  werden durch das Vektorskalarprodukt beschrieben

$$\epsilon = \arccos \left( \frac{-\vec{a} \cdot \vec{e}_{x'}}{|\vec{a}| \cdot |\vec{e}_{x'}|} \right) \quad (4.16)$$

$$\gamma(t) = \arccos \left( \frac{\vec{b}(t) \cdot \vec{e}_{x'}}{|\vec{b}(t)| \cdot |\vec{e}_{x'}|} \right) \quad (4.17)$$

$$\vec{e}_{x'} = \begin{bmatrix} 1 \\ 0 \end{bmatrix} \quad (4.18)$$

Die zeitliche Ableitung von  $\vec{e}(t)$  wurde maschinenunterstützt numerisch unter Anwendung der Software Maplesoft™ Maple bestimmt.

Aus Redundanzgründen und zur späteren Verwendung bei der Modellierung des Radfahrersystems wird  $v_F(t)$  auf eine alternative Weise formuliert.

$$v_F(t) = \dot{P}_H + \dot{\vec{e}}(t) + \dot{\vec{f}}(t) \quad (4.19)$$

Um den Vektor  $\vec{f}(t)$  aufzustellen, wird ein weiterer Winkel  $\beta(t)$  definiert

$$\beta(t) = \theta_1(t) + 180^\circ - \theta_4(t) \quad (4.20)$$

Unter Anwendung des Kosinussatzes wird der Winkel  $\theta_4(t)$  analytisch bestimmt.

$$\theta_4(t) = \arccos \left( \frac{|\vec{e}(t)|^2 + |\vec{f}(t)|^2 - |\vec{b}(t)|^2}{2 \cdot |\vec{e}(t)| \cdot |\vec{f}(t)|} \right) \quad (4.21)$$

Damit wird  $\vec{f}(t)$  formuliert zu

$$\vec{f}(t) = \begin{bmatrix} \cos(\beta(t)) \cdot |\vec{f}(t)| \\ -\sin(\beta(t)) \cdot |\vec{f}(t)| \end{bmatrix} \quad (4.22)$$

und die zeitliche Ableitung  $\dot{\vec{f}}(t)$  von  $\vec{f}(t)$  als

$$\dot{\vec{f}}(t) = \begin{bmatrix} -\sin(\beta(t)) \cdot |\vec{f}(t)| \cdot \dot{\beta}(t) \\ -\cos(\beta(t)) \cdot |\vec{f}(t)| \cdot \dot{\beta}(t) \end{bmatrix} \quad (4.23)$$

Die resultierenden Geschwindigkeitsprofile für eine exemplarische Auswahl an Punkten auf den rotierenden Komponenten ist in Abbildung 4.4 und Abbildung 4.5 dargestellt. Das Geschwindigkeitsprofil an den Beinen, Abbildung 4.4, zeigt bis auf das Pedal bzw. den Fuß eine nicht symmetrische oszillierende Be-

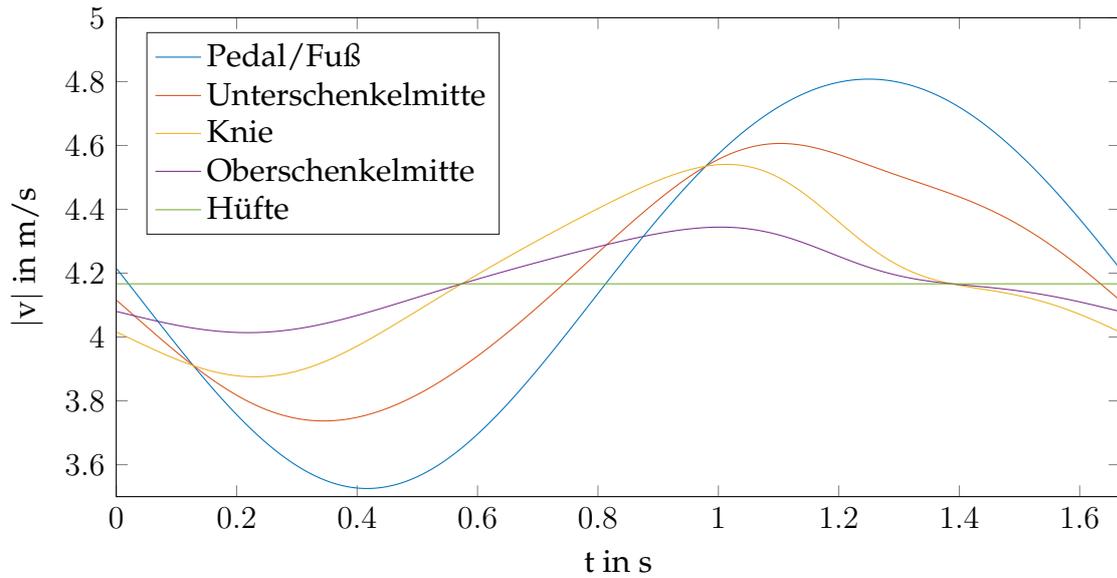


Abbildung 4.4: Exemplarische Darstellung des Geschwindigkeitsprofils eines Beines für eine Pedalumdrehung mit Übersetzungsverhältnis  $GTR = 3$ . Die Komponente Hüfte wurde so gewählt, dass die Eigengeschwindigkeit des Radfahrersystems genau getroffen wird

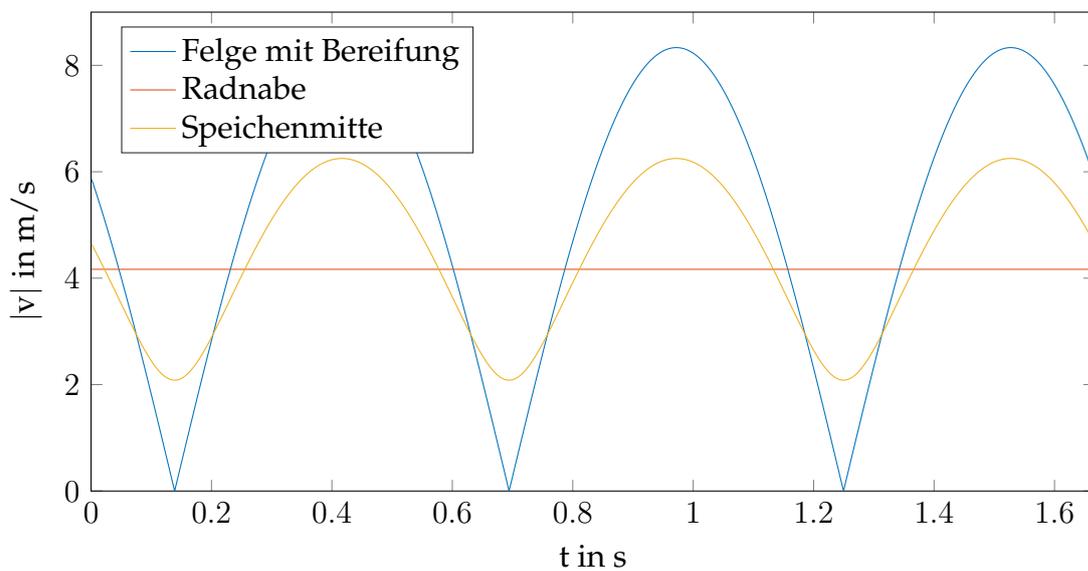


Abbildung 4.5: Exemplarische Darstellung des Geschwindigkeitsprofils eines Rades für eine Pedalumdrehung mit Übersetzungsverhältnis  $GTR = 3$ . Die Komponente Radnabe wurde so gewählt, dass die Eigengeschwindigkeit des Radfahrersystems genau erreicht wird

## 4 Detektion von Radfahrern

wegung um die Eigengeschwindigkeit  $v_{EGO} = 4,1667 \text{ m/s}$  des Radfahrersystems. Ursächlich dafür ist der Hebel zwischen Ober- und Unterschenkel, wodurch es zu zusätzlichen positiv und negativ beschleunigten Bewegungen für eine Pedalumdrehung kommt.

An den Rädern oszilliert die Geschwindigkeit ebenfalls um die Eigengeschwindigkeit  $v_{EGO} = 4,1667 \text{ m/s}$ , wie in Abbildung 4.5 illustriert. Der charakteristische Verlauf wird beschrieben durch eine Zykloide [100]. Per Definition ist die Zykloide eine Kurve, die von einem festen Punkt auf einem Kreis gezeichnet wird und virtuell auf einer Geraden abrollt. Je nach Abstand des festen Punktes zum Kreismittelpunkt und der Abweichung vom Kreisradius, wird eine gewöhnliche, verkürzte oder verlängerte Zykloide beschrieben. Im Geschwindigkeitsprofil der Räder beschreibt die Felge mit Bereifung eine gewöhnliche Zykloide und die Speichenmitte eine verkürzte Zykloide.

### 4.1.3 Mikro-Doppler Effekt

Treten an einem Objekt Geschwindigkeiten auf, die keine gleichförmige, translatorische Bewegungsrichtung aufweisen, wie z.B. Rotation oder Vibration, bezeichnet man diese als Mikro-Geschwindigkeiten. Diese Mikro-Bewegungen erzeugen eine zusätzliche Dopplerverschiebung, die mit einem entsprechend hochauflösenden Radar in der Geschwindigkeitsdomäne erfasst werden kann. In der Literatur wird dieses Phänomen als Mikro-Doppler Effekt bezeichnet [82].

Anwendung findet der Mikro-Doppler Effekt in vielen Gebieten, bei denen Bewegungen ausgewertet werden. In der Erfassung und Erkennung von Fußgängern und Radfahrern mit Radar ist der Mikro-Doppler Effekt ein zentrales Element [101–103]. Dabei wird die unterschiedliche Charakteristik der Mikro-Bewegungen [85] zum Klassifizieren genutzt [25]. Bezeichnet werden die ausgewerteten Mikro-Bewegungen auch als Mikro-Doppler Signaturen. Mit zunehmend hochauflösenden Messungen wird der Mikro-Doppler Effekt verwendet, um Unregelmäßigkeiten im Gang beim Einsatz in der Rehabilitation zu entdecken [104, 105].

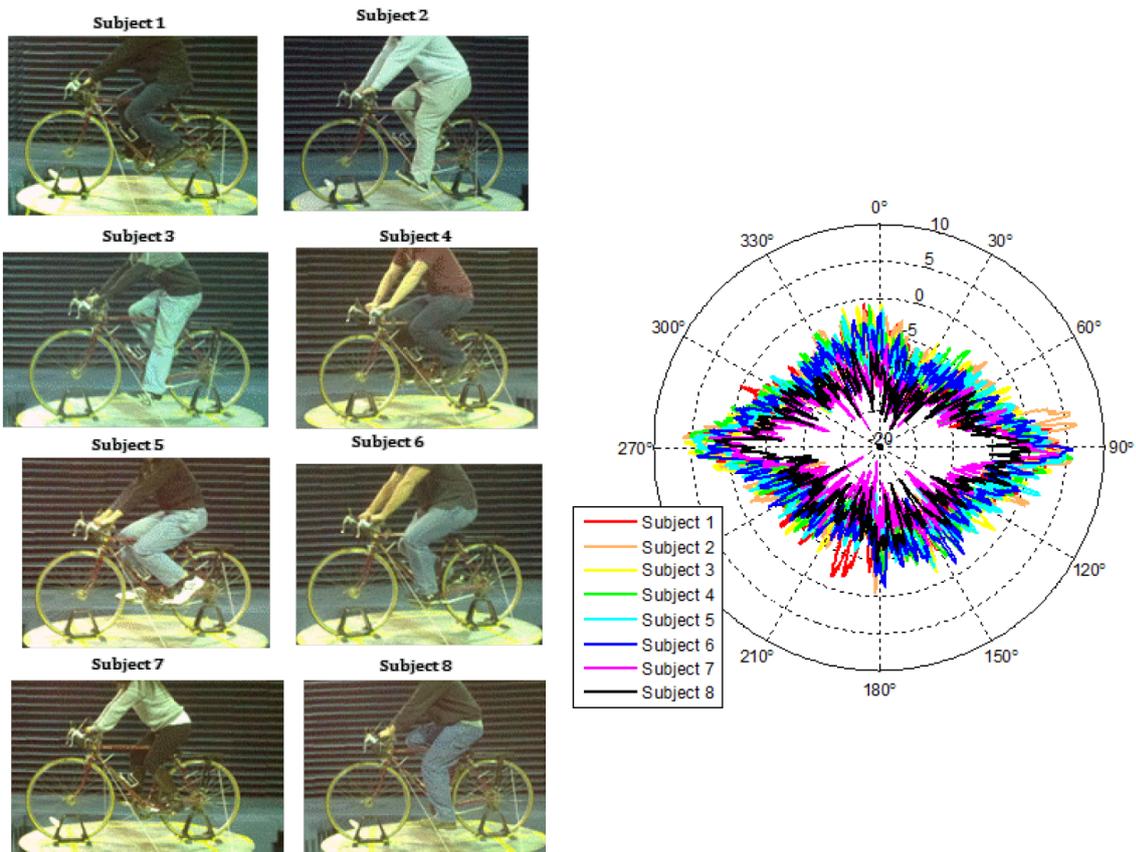
In den vorangegangenen Beschreibungen des Radfahrersystems konnte ebenfalls gezeigt werden, dass sich dieses aus vielen unterschiedlichen Bewegungen zusammensetzt mit den daraus resultierenden Geschwindigkeiten. Für die Klassifizierung von Radfahrern wird der Mikro-Doppler Effekt eine entscheidende Rolle spielen.

### 4.1.4 RCS

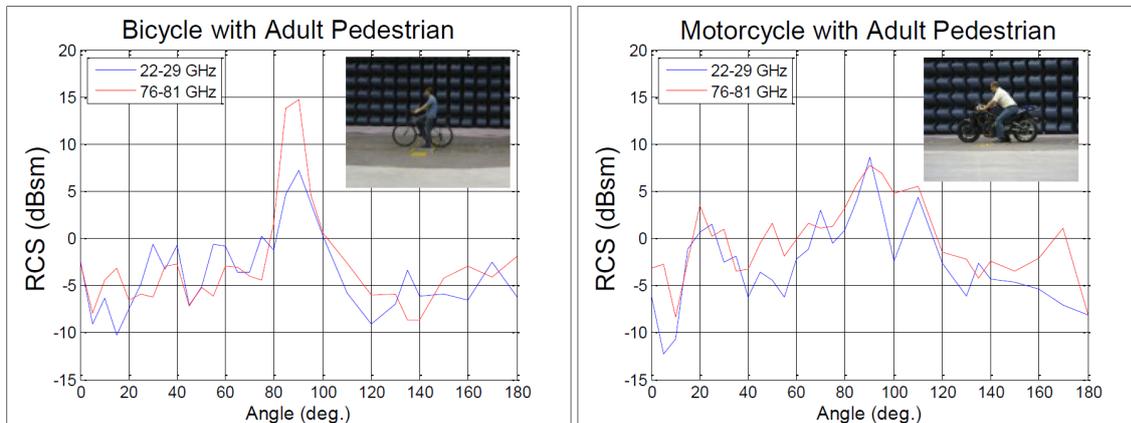
Die Bestimmung des RCS-Wertes für einen Radfahrer wurde in der Literatur bereits sehr detailliert durchgeführt. An dieser Stelle wird eine kurze Zusammenfassung der fundamentalen Ergebnisse gegeben.

In [43] wurde eine Messreihe von RCS-Messungen an Fahrrädern vorgestellt.

## 4.1 Physikalische Attribute eines Radfahrers



(a) Messaufbau der 8 Radfahrer zur Bestimmung des RCS-Wert aus [106] © 2016 IEEE  
 (b) RCS-Verlauf für die 8 Radfahrer aus [106] © 2016 IEEE



(c) Messaufbau und RCS-Verlauf für Fahrrad und Motorrad aus [44] © 2013 IEEE

Abbildung 4.6: Ergebnisse für die RCS-Verläufe und die Messaufbauten aus [44, 106])

#### 4 Detektion von Radfahrern

Dabei wurden 8 Fahrräder untersucht, deren Rahmen aus Karbon oder Metall gefertigt sind. Die Laufräder bestehen für alle untersuchten Räder aus Metall. Für die Messung wurden die Fahrräder auf einer drehenden Plattform in einer Antennenmesskammer montiert. Während der Messaufnahmen wurden die Fahrräder um  $360^\circ$  in  $0,1^\circ$  Schritten gedreht. Das Hintergrundrauschen der Messkammer, sowie Kopplungen zwischen Sender und Empfänger wurden eliminiert. Als Referenz Objekt zur RCS-Bestimmung diente eine Kugel mit 12" Durchmesser. Die Verläufe der 77 GHz RCS-Werte über dem Winkel weisen einen Wertebereich von  $-9$  dBsm bis  $0$  dBsm auf. Die Unterschiede zwischen den Testrädern liegen im Bereich von  $\pm 2,5$  dB.

Ein Fahrrad als einzelnes bewegtes Objekt wird in der Realität nur sehr selten vorkommen. Weitere Untersuchungen mit Vermessung von Radfahrern sind in [106] veröffentlicht worden. Der Messaufbau war identisch zur vorangegangenen Beschreibung, jedoch mit acht verschiedenen menschlichen Fahrern auf einem gleich bleibenden Fahrrad, wie zu sehen in Abbildung 4.6a. Um die Messzeit zu reduzieren und die Dauer des Stillhalten für den Fahrer erträglich zu machen, wurde eine Schrittweite von  $0,2^\circ$  verwendet. Mit zusätzlichem Fahrer erhöht sich der RCS-Wert für die Messung über alle Winkel. Der Wertebereich erstreckt sich von  $-5$  dBsm bis  $3$  dBsm mit  $\pm 3$  dB Variation zwischen den acht menschlichen Fahrern. Maximal wird der RCS-Wert in der Seitenansicht des Radfahrers zum Radar und minimal in der Frontalansicht wie dargestellt in Abbildung 4.6b. Die höhere Reflexion in der Seitenansicht ist auf die Räder zurückzuführen. Zur genaueren Untersuchung der Räder wurden in [107] die RCS-Werte der einzelnen Komponenten des Fahrrads separat vermessen und simuliert. Damit konnte die These bestätigt werden, dass die Räder eine hohe Dynamik im RCS haben.

Weitere Messungen von Radfahrern wurden in [44] gezeigt. Hier ist eine Messung über  $180^\circ$  in  $5^\circ$  Schritten durchgeführt worden. Das Minimum liegt ebenfalls in der Frontalansicht und das Maximum in der Seitenansicht. Die ermittelten RCS-Werte liegen im Bereich von  $-7$  dBsm bis  $15$  dBsm, was einen großen Unterschied zu [106] darstellt. Ebenfalls wurde ein Motorrad vermessen, dessen RCS-Verlauf der Messung in [106] sehr stark ähnelt. Beide Verläufe sind in Abbildung 4.6c abgebildet. Die Unterschiede bei den Radfahrern sind ohne weitere Informationen nur mutmaßlich zu erklären. Die Messungen aus [44] decken sich mit denen der Räder in [107]. Da die Montagehöhe der Antennen zur Messung nur in [44] mit  $57$  cm angegeben ist, liegt die Vermutung nahe, dass die Einbauhöhe für die differierenden Ergebnisse verantwortlich ist.

Im weiteren Verlauf der Arbeit wird mit den vorgestellten Ergebnissen gearbeitet und keine zusätzliche messtechnische Bestimmung des RCS-Wertes durchgeführt.

## 4.2 Modellierung eines Radfahrers

Aus den vorhergehenden Ergebnissen lässt sich ein Modell eines Radfahrers speziell für Radarsimulationen generieren. Als Softwareplattform zur Erstellung des Modells und zur Durchführung der Simulationen wurde Mathworks® Matlab/Simulink gewählt. Basierend auf diesem Modell werden verschiedene Erkenntnisse gewonnen. Zum einen wird es bei der Extraktion von Merkmalen des Radfahrersystems, welche mit einem Radar detektiert werden können, verwendet. Zum anderen können damit die unterschiedlichsten, oftmals sicherheitskritischen Szenarien untersucht werden ohne eine Gefahr für Mensch und Material darzustellen.

Zur Modellierung gehört die Erstellung eines Modells des Radfahrers, das in die verwendete Simulationsumgebung passt. Weiterhin wird die Signalverarbeitung aus Abschnitt 3.6 auf den generierten Daten angewandt, wodurch fehlerhafte Einflüsse von dieser vorab als Fehlerquelle ausgeschlossen werden können.

Ergebnisse der Simulation mit Vergleich von gemessenen Radfahrern, sowie deren Modellierung, wurden in [108] vorgestellt und veröffentlicht. Die folgenden Ausführungen greifen diese auf und erläutern zusätzliche Details.

### 4.2.1 Simulationsumgebung

Um die gewünschten Erkenntnisse aus der Simulation zu generieren, ist die Wahl einer geeigneten Simulationsumgebung essenziell. Im vorliegenden Fall wird dafür eine Abbildung der realen Welt benötigt. Diese wird durch abschnittsweise Betrachtung von einzelnen Bereichen realisiert, welche mit einem dreidimensionalen kartesischen Koordinatensystem beschrieben werden. Vereinfacht für die Simulation wird angenommen, dass sich das Radfahrersystem ausschließlich entlang der x-z-Ebene bewegt. Die Möglichkeit der Beobachtung des Radfahrers über  $360^\circ$  hinaus bleibt trotz der Bewegungseinschränkung bestehen, da das Radar in der Simulation frei in seiner Positionierung und Ausrichtung gewählt werden kann. Dies führt zu einem weiteren dreidimensionalen kartesischen Koordinatensystem, dessen Ursprung sich direkt im simulierten Radarsensor befindet. Zur Verdeutlichung ist die verwendete Simulationsumgebung in Abbildung 4.7 schematisch dargestellt.

### 4.2.2 Radfahrermodell

Wie in der Bewegungsanalyse des Radfahrersystems ermittelt, befinden sich an diesem eine Vielzahl unterschiedlicher Geschwindigkeiten. Um diese im Modell abbilden zu können, wird der Radfahrer aus Punkten zusammengesetzt, die reflektierende Streuzentren repräsentieren. Es wird für das Modell eine Punktmenge von ca. 450 Stück gewählt. Die Anzahl der Punkte wird im Folgenden anhand von Simulationen mit dem fertigen Gesamtmodell und vergleichbaren realen Messun-

#### 4 Detektion von Radfahrern

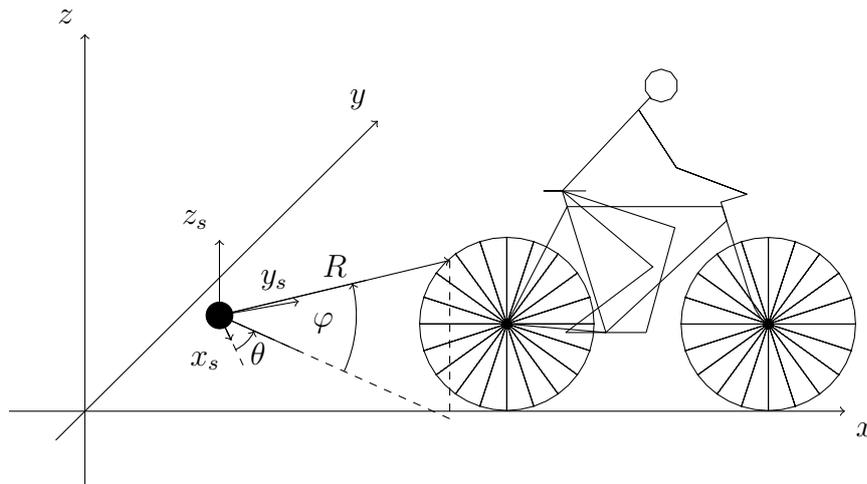


Abbildung 4.7: Schematische Visualisierung der genutzten Simulationsumgebung mit Radfahrerkoordinatensystem  $(x, y, z)$  und Sensorkoordinatensystem  $(x_s, y_s, z_s)$

gen validiert und nach Möglichkeit auf ein Minimum reduziert, zur Beschleunigung der Simulation. Jeder Modellpunkt besitzt die drei Eigenschaften, Position im dreidimensionalen Raum, Geschwindigkeit im dreidimensionalen Raum und charakteristischer RCS-Wert. Bei den verwendeten RCS-Werten wurde dabei auf die in [106] veröffentlichten Messdaten zurückgegriffen.

Die Anordnung, und dadurch die Position der Zielpunkte ist dabei durch die Geometrie des Radfahrersystems vorgegeben. Für die Modellierung wurde die Aufteilung in Modellgruppen nach [109] ausgewertet mit dem Ergebnis, dass ca. 75 % auf Trekking- und Cityräder sowie auf Mountainbikes entfällt. Da sich die Geometrie für diese Modelltypen bei der Detektion mit einem Radarsensor nicht signifikant unterscheidet, wird das Simulationsmodell daran angelehnt. Die Parameter Rahmenhöhe  $R_H$ , Rahmenlänge  $R_L$ , Sitzhöhe  $S_H$ , Lenkerhöhe  $L_H$  und Tretkurbellänge  $T_L$  wurden dabei an einen Fahrer mit 175 cm Körpergröße angepasst [96]. Ein wenig vereinfacht wurde dabei der gleiche Wert für Rahmenhöhe und Rahmenlänge angenommen, welcher aus der Innenbeinlänge von 83 cm zu 55 cm bestimmt wird.

$$\text{Rahmenlänge} = \text{Rahmenhöhe} \approx \text{Innenbeinlänge} \cdot 0,665 \quad (4.24)$$

Für die Tretkurbellänge wurde der Standard von 17 cm verwendet. Die Sitzhöhe wird mit der bekannten Faustformel [96] zu 70 cm approximiert.

$$\text{Sitzhöhe} \approx \text{Innenbeinlänge} \cdot 0,85 \quad (4.25)$$

Ebenso wurde eine nicht sportliche Fahrweise angenommen, wodurch es zu einer aufrechten Sitzposition kommt, was dazu führt, dass die Lenkerhöhe nur ca. 1 cm

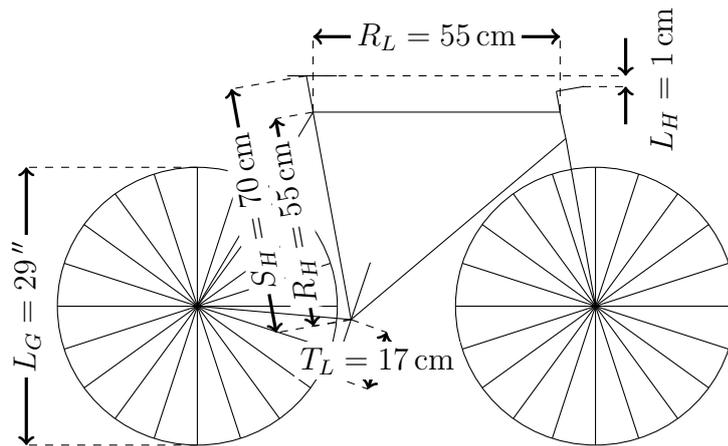


Abbildung 4.8: Skizze der Rahmengenometrie mit Maßen, welche für das Simulationsmodell verwendet wurden

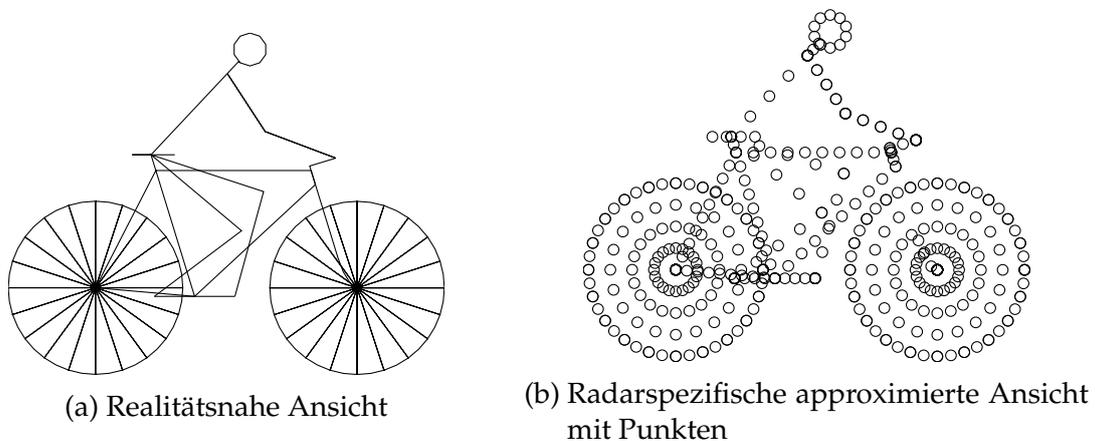


Abbildung 4.9: Radfahrermodell in zwei verschiedenen Ansichten

unter der Sitzhöhe liegt. Die Laufradgröße  $L_G$  ist variabel wählbar im Bereich von 22 bis 29 Zoll. Die verwendeten Maße sind in Abbildung 4.8 skizziert. Ebenfalls variiert werden kann die Körpergröße des Fahrers in 5 cm Schritten zwischen 155 cm und 195 cm. Mit den festgelegten Parametern für die Rahmengenometrie wird das Modell generiert. Visualisiert ist das Radfahrermodell in Abbildung 4.9. Dieses wird in die Simulationsumgebung integriert und mit den Bewegungsgleichungen aus Unterabschnitt 4.1.2 fortbewegt. Vorgegeben wird dabei eine Winkelgeschwindigkeit für die Pedale, anhand derer sich die restlichen Bewegungen der Beine und über das *GTR* die der Räder berechnet.

### 4.2.3 Sensormodell

Für die Simulation von Radardaten ist die Wahl der Abstraktionsebene stark von der zur Berechnung verfügbaren Rechenleistung abhängig, die durch Mehrkern-

#### 4 Detektion von Radfahrern

prozessorplattformen bereitgestellt wird. Um in vertretbaren Zeiten zu Resultaten zu kommen, muss ein Kompromiss zwischen möglichst detailgetreuer Abbildung der Realität im Modell und benötigter Rechenzeit gefunden werden.

In der hier vorliegenden Arbeit wurde die Abstraktionsebene auf dem Level der Beschreibung des Basisbandsignals (Beatsignal) eines Chirp-Sequence modulierten Radarsensors gewählt, wie in Abbildung 3.2b nach dem ADC Wandler dargestellt. Dies bietet mehrere Vorteile, welche im Folgenden kurz erläutert werden.

Die Wahl des Radarsensortyps für die Simulation wurde auf Basis der für Messungen zur Verfügung stehenden prototypischen Radarsensorhardware getroffen. Damit sind die simulierten Daten mit real gemessenen Daten vergleichbar, und die Ergebnisse können validiert werden. Gleichzeitig wird dadurch auch die Modellierung des Radfahrers verifiziert.

Die Anforderung an die verwendete Mehrkernmikroprozessorarchitektur ist durch die hohe Abstraktionsebene gering und das Potential der Mehrkernarchitektur kann durch Parallelisierung der Berechnungsschritte nahe am Optimum ausgenutzt werden. Dies führt schneller zu verwertbaren Resultaten und einer guten Ausnutzung der Recheneffizienz.

Die geringen Rechenanforderungen an die Simulationshardware führen dazu, dass ein Simulationsmodell mit hoher Detailtreue eines Radfahrers entwickelt und verwendet werden konnte. Im Hinblick auf die Extraktion von Merkmalen eines Radfahrers mittels Detektion von Streuzentren, welches ein essenzieller Bestandteil dieser Arbeit ist, erscheint dieser Ansatz am zielführendsten zu sein.

Die Abstraktion auf dem Level des Beatsignals ist ebenso ein bekannter Ansatz in der Literatur zur Beschreibung von Radarsignalen auf Basis der Entfernung, der radialen Geschwindigkeit sowie des Einfallswinkels der zu detektierenden physikalischen Objekte bzw. verschiedener verteilter Streuzentren auf einem Objekt [89, 110–112].

Bekannt aus Unterabschnitt 3.2.2 ist die Beschreibung des Beatsignals der Chirp-Sequence Modulation. Für das Sensormodell wird diese in den zeit-diskreten Bereich überführt und zusätzlich die Information der  $M$  Kanäle beachtet. Angelehnt

an die Ausführungen in [48] ist die Modellgleichung für den Sensor.

$$s(n, k, m) = A \cdot \cos(2\pi(\phi_0 + f_R n T_{\text{sample}} - f_D k T_{\text{RRI}} + f_A)) + n(t) \quad (4.26)$$

$$f_R = 2 \frac{R_0}{c_0} \frac{B}{T_{\text{RRI}}} \quad (4.27)$$

$$f_D = \frac{-2v_r f_0}{c_0} \quad (4.28)$$

$$f_A = \frac{1}{\lambda_0} p_m^T d_a \quad (4.29)$$

$$p_m = \begin{bmatrix} x_m \\ y_m \\ z_m \end{bmatrix} \quad (4.30)$$

$$d_a = \begin{bmatrix} \cos(\theta) \cos(\varphi) \\ \sin(\theta) \cos(\varphi) \\ \sin(\varphi) \end{bmatrix} \quad (4.31)$$

Durch die Beschreibung im Zeitbereich ist es möglich die kompletten, bereits bestehenden Signalverarbeitungsalgorithmen, beginnend mit dem gemessenen Zeitsignal des für Messungen verwendeten Radarsystems zu übernehmen. Eventuelle Fehlerquellen in der Auswertung, werden dadurch bereits im Vorfeld vermieden.

Aus Gleichung (4.26) lassen sich Parameter extrahieren, welche zur Berechnung des Zeitsignals benötigt werden und vom Radfahrersimulationsmodell, von der Simulationsumgebung und der Radarsensorkonfiguration bereitgestellt werden. Sie werden für jedes zu detektierende Objekt benötigt. Einteilen lassen sich diese Parameter in drei Gruppen: Modulationsparameter, Antennenarrayparameter und Fahrradmodellparameter.

Die Modulationsparameter sind, wie im Namen schon anklingend, abhängig von der verwendeten Modulation bzw. des Radarsensortyps. Diese Parameter sind über einen Simulationslauf konstant und beeinflussen auf unterschiedliche Weise das Zeitsignal mit Auswirkungen auf das Messergebnis. Bei der verwendeten Chirp-Sequence Modulation beschränkt sich die Anzahl der Parameter auf drei: die Bandbreite  $B$ , die Rampenintervalldauer  $T_{\text{RRI}}$  und die Trägerfrequenz  $f_0$ . Für den Einfluss der Bandbreite  $B$  auf die Auflösung der Objektentfernung wird auf Gleichung 3.22 verwiesen. Der Zusammenhang von  $T_{\text{RRI}}$  und der Sendefrequenz  $f_0$  mit der Geschwindigkeitseindeutigkeit ist aus Gleichung 3.26 zu entnehmen.

Ebenfalls konstant während einer Simulation bleiben die Antennenarrayparameter. Diese beschreiben die räumliche Position  $p_m$  der auf die Hauptstrahlrichtung idealisierten Antennenelemente. Mit den verteilten Antennenelementen wird eine Bestimmung der Raumwinkel in Azimut  $\theta$  und Elevation  $\varphi$  eines Objektes möglich. Die Grundlagen hierfür sind in Unterabschnitt 3.6.3 bereits ausführlich erläutert worden.

Ein Set an variablen Parametern für die Dauer eines Messzyklus ist durch die

Fahrradmodellparameter repräsentiert. Zu ihnen gehören die initiale Objektentfernung  $R_0$  für jeden Zyklus, die relative radiale Objektgeschwindigkeitskomponente  $v_r$  für jede der  $K$  Rampen sowie ebenfalls die Raumwinkel  $\theta$  und  $\varphi$  für jede Rampe. Um die Entfernung und radiale Geschwindigkeitskomponente richtig zu bestimmen, wird dem Radarmodell eine Position und Ausrichtung gegeben. Zur Vereinfachung ist der Sensor während einer Simulation ortsfest.

Um eine möglichst realitätsgetreue Abbildung zu simulieren wurde ein Filter in die Verarbeitungskette integriert, das verdeckte Punkte des Modells während des Simulationslaufes ausblendet. Dabei werden die Einfallswinkel auf den Sensor von den einzelnen Punkten verglichen und bei Modellpunkten mit Winkeln in einem vorgegebenen gleichen Bereich ( $\pm 0,125^\circ$ ) nur der mit der kürzesten Distanz zum Sensor verwendet. Demnach variiert die Anzahl der Simulationspunkte je nach Blickwinkel.

Die Signalamplitude  $A$  wird mittels der Radargleichung approximiert, bekannt aus Unterabschnitt 3.1.1. Der Signalamplitude wird ein Rauschterm  $n(t)$  überlagert, modelliert mit additivem weißen Gauß'schen Rauschen. Es wird bewusst nur eine Rauschquelle abgebildet und weitere Störquellen wie Mehrwegausbreitung der Welle oder Interferenz nicht verwendet. Diese sind für die verfolgten Ziele dieser Arbeit auch nur von sehr geringer Relevanz.

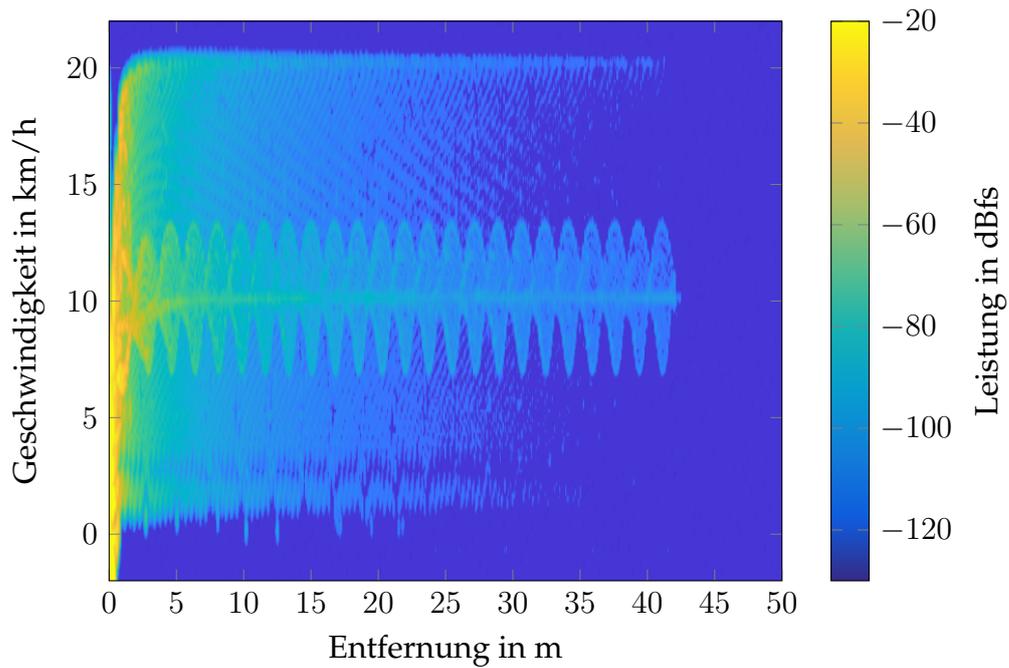
Mit den vorgestellten Parametern und Gleichungen ist es möglich, Simulationen von Radardaten im Zeitbereich zu generieren. Diese haben den Vorteil der vollständigen Reproduzierbarkeit und werden daher zur Validierung und Verifizierung von digitalen Signalverarbeitungsalgorithmen angewandt.

### 4.2.4 Validierung der Simulation

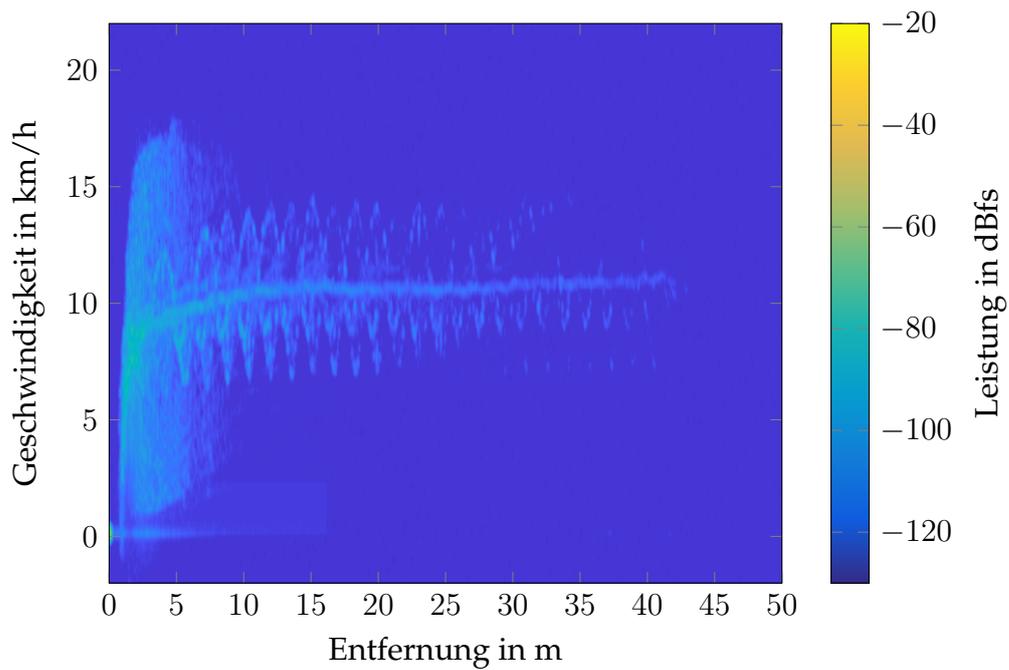
Zur Prüfung des Simulationsmodells eines Radfahrers wurden mehrere Simulationsläufe durchgeführt und mit messtechnisch erfassten Radfahrerdaten verglichen. Die Szenarien bilden einen longitudinal vom Sensor sich entfernenden und einen transversal von rechts nach links fahrenden Radfahrer ab. Sowohl die Simulation als auch die Messung wurden mit beiden Modulationen und variierenden Geschwindigkeiten von 10 km/h, 15 km/h und 20 km/h ausgeführt. Exemplarisch wurden zwei Szenarien ausgewählt und in Abbildung 4.10 bzw. Abbildung 4.11 dargestellt. In den Entfernungs- und Geschwindigkeitsspektren sind mehrere Zyklen kumuliert, wodurch die erfasste Bewegung über die Zeit nachvollzogen werden kann. Der direkte Vergleich zwischen den gemessenen und simulierten Spektren zeigt eine sehr gute Übereinstimmung.

Sowohl die Simulation als auch die Messung werden vorverarbeitet, so dass nur Streuzentren über der CFAR-Schwelle gespeichert werden. Für einen besseren Kontrast wurde den Spektren ein künstlich generierter Rauschteppich unterlegt. Dieser orientiert sich am realen Rauschverhalten.

Die teilweise auftretende Signalfuktuation in den Messungen ist auf destruktive Überlagerung durch Mehrwegausbreitung zurückzuführen, welche in der Si-



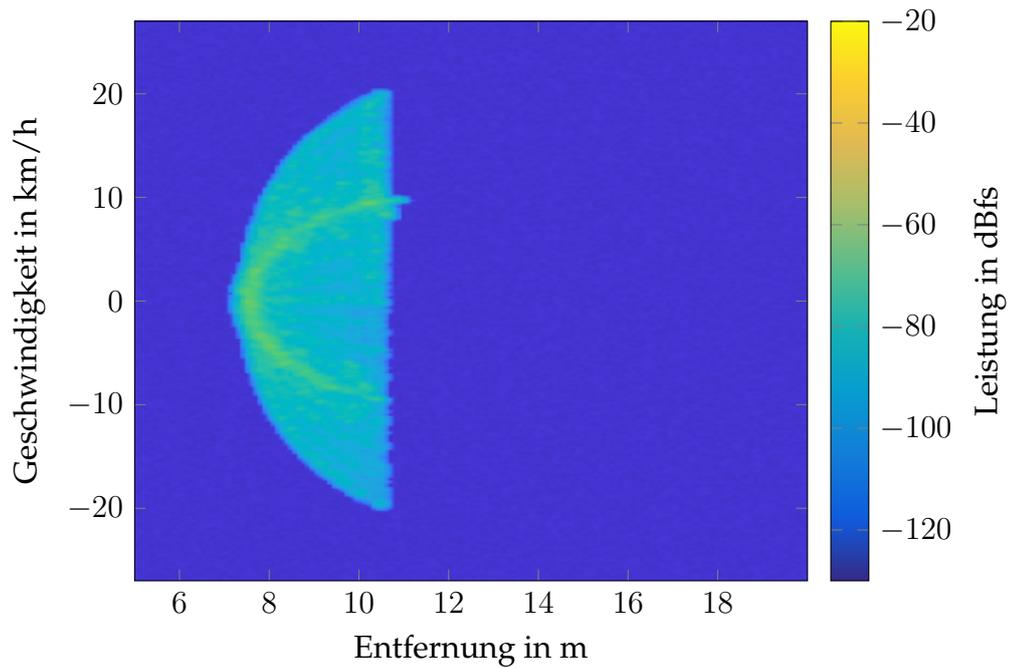
(a) Simulation



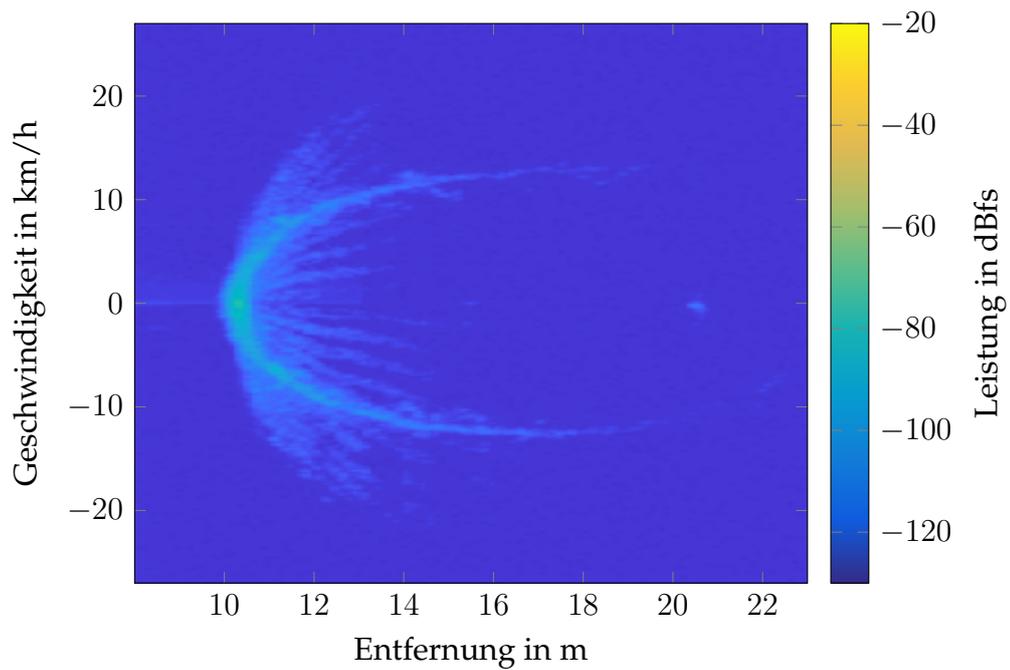
(b) Messung

Abbildung 4.10: Radardaten eines Radfahrers longitudinal zur Sensorblickrichtung mit 10 km/h bewegt kumuliert über mehrere Zyklen mit Modulation 1

#### 4 Detektion von Radfahrern



(a) Simulation



(b) Messung

Abbildung 4.11: Radardaten eines Radfahrers transversal in Sensorblickrichtung von links nach rechts bewegt mit 15 km/h kumuliert über mehrere Zyklen mit Modulation 2

mulation nicht berücksichtigt wurde. Für die Signalamplitude in den Simulationen ist die Dämpfung über der Entfernung geringer als für den realen Radarsensor. Dabei beeinflussen unerwünschte Hardwareeigenschaften der verwendeten Bauteile den Radarsensor zusätzlich, können aber in der Simulation wegen des zu hohen Aufwands nicht berücksichtigt werden. Abgesehen von diesen Einschränkungen sind die Bewegungen und Mikrobewegungen sowie die Entfernungen im wesentlichen realitätsnah abgebildet.

Zur Validierung des simulierten Radar Antennenarrays wird für jedes detektierte Streuzentrum der Einfallswinkel geschätzt. In Kombination mit der Entfernung wird ein Punkt im dreidimensionalen kartesischen Raum für jedes Streuzentrum generiert und dargestellt. Die Empfangsleistung für jedes Streuzentrum wird durch Variation der Punktgröße angedeutet. Die Punkte sind farblich codiert mit den entsprechenden Geschwindigkeiten. Dargestellt ist diese Ansicht in Abbildung 4.12 für beide gewählte Szenarien.

Die Position im dreidimensionalen Raum der Streuzentren stimmt mit den erwarteten überein. Die Form des Rades ist in Abbildung 4.12a erkennbar. Die Verteilung der Geschwindigkeiten stimmt mit den theoretisch erwarteten Werten für die radiale Geschwindigkeitskomponente überein. Ebenso passen die Geschwindigkeiten und Punktpositionen zu den Punkten, die vom Körper des Fahrers zurückgestreut wurden. Mit der Geschwindigkeit und der Position kann nachgewiesen werden, dass die Simulation mit dem Modell des Antennenarrays korrekte Ergebnisse liefert. Zusätzlich herangezogen für einen Abgleich wurden die Arbeiten von [85, 103]. Die dort gezeigten Entfernungs- und Geschwindigkeitsspektren zeigen einen simultanen Verlauf zu den hier vorgestellten.

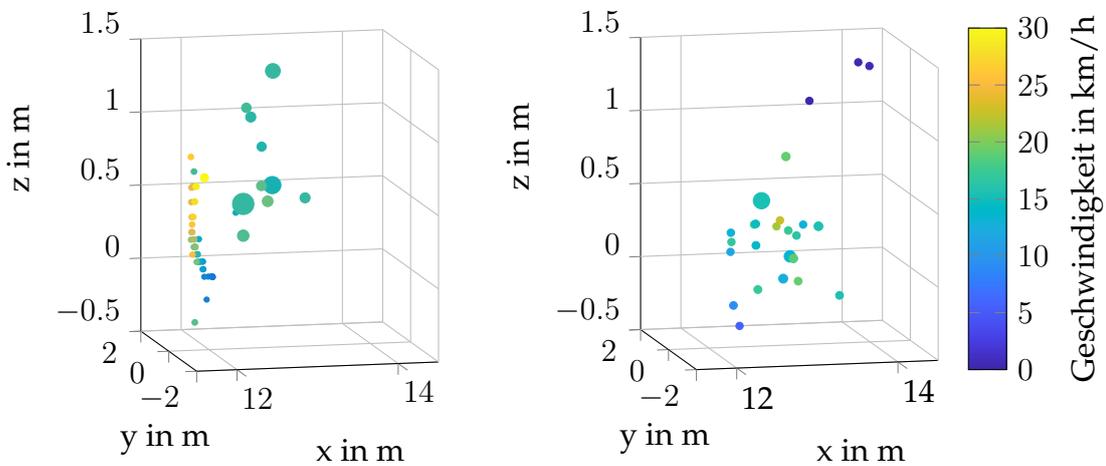
Daraus abzuleiten ist eine generelle Verwendbarkeit der Modelle für das Radar und den Radfahrer zur Abbildung der realen Welt in der Simulation. Die Anzahl der für die Simulation verwendeten Streuzentren variiert sehr stark in Abhängigkeit der Ausrichtung vom Radfahrer zum Radar. Eine generelle Ausdünnung der Streuzentren ist nicht zielführend, da beispielsweise an den Rädern immer ein alternierendes Streuzentrum eine bestimmte Geschwindigkeitskomponente trägt, welche im Spektrum in Kombination mit den anderen Streuzentren zu einer Ausdehnung in der Geschwindigkeitsverteilung führt.

### 4.2.5 Fußgängermodell

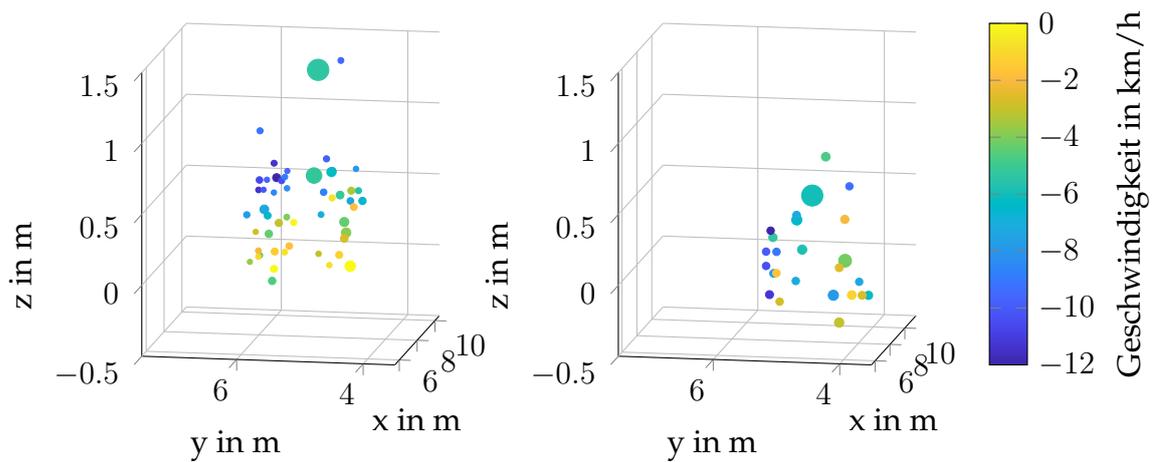
Als zweite Klasse für die spätere Objektklassifizierung wurde ein weiteres Modell eines im Straßenverkehr oft vorkommenden, bewegten Objektes, dem Fußgänger, verwendet. Dabei konnte auf das Fußgängermodell aus [25] zurückgegriffen werden. An dieser Stelle gibt es einen kurzen Überblick über das Modell und die zugrunde liegenden Bewegungsmuster. Detaillierte Informationen können aus [25] entnommen werden.

Die Modellierung eines Fußgängers erfolgte auf ähnliche Weise wie die eines Radfahrers, wie in Unterabschnitt 4.2.2 beschrieben. Markante Körperteile an ei-

#### 4 Detektion von Radfahrern



(a) Simulation eines longitudinal bewegten Radfahrers (b) Messung eines longitudinal bewegten Radfahrers



(c) Simulation eines transversal bewegten Radfahrers (d) Messung eines transversal bewegten Radfahrers

Abbildung 4.12: 3D Punkte, die ein Streuzentrum repräsentieren mit der Geschwindigkeit farblich markiert sowie der Empfangsleistung als Punktgröße kodiert



Abbildung 4.13: Punktmodell eines Fußgängers zur Verwendung in Radarsimulationen

nem Fußgänger wurden mittels Streuzentren modelliert. Dazu gehören der rechte und linke Fuß, das rechte und linke Knie, die rechte und linke Hand, der rechte und linke Ellbogen sowie der Kopf. Abgebildet ist das Punktmodell in Abbildung 4.13.

Zur Bestimmung des Bewegungsablaufs wurde eine Filmaufnahme durchgeführt, bei der ein Proband mit ca. 1,75 m Körpergröße Markierungen an den zuvor aufgezählten Stellen trug. Für jedes Bild des Films wurde pixelgenau die Position der Markierungen anhand einer Referenzmessung bestimmt. Die Bewegung eines jeden markanten Körperteils konnte in einem Weg-Zeit Diagramm aufgetragen werden. Mittels numerischer Differenzierung wurden diese in Geschwindigkeits-Zeit Diagramme überführt.

Das Extrahieren von Parametern aus diesen Verläufen ist dem Verfahren zur 3D Rekonstruktion [113] menschlicher Bewegungen mit Hilfe der Fourier-Zerlegung nachempfunden. Somit wird eine Synthese der Geschwindigkeitsverläufe für beliebig lange Sequenzen möglich. Um auch die Weg-Zeit-Funktionen verschiedenster Zeitpunkte zu synthetisieren, werden die Geschwindigkeitsverläufe integriert.

Die Information der Geschwindigkeit, der Punktpositionen im Raum während der Bewegung sowie der RCS-Wert der Körperteile sind ausreichend, um im Simulator aus Unterabschnitt 4.2.3 angewandt zu werden. Übernommen wurden die RCS-Werte der Glieder aus [25], in der eine detaillierte Analyse beschrieben ist. Exemplarisch ist ein über der Zeit kumuliertes Entfernung- und Geschwindigkeitsspektrum zur Verfolgung der Bewegung in Abbildung 4.14 gezeigt.

## 4.3 Extraktion von Merkmalen

Charakteristische Merkmale bilden die Grundlage der Objektklassifizierung. Umso eindeutiger die Unterscheidung von Objekten zueinander ist, umso einfacher lassen sich diese in separate Gruppen trennen. Nachfolgend werden Charakte-

## 4 Detektion von Radfahrern

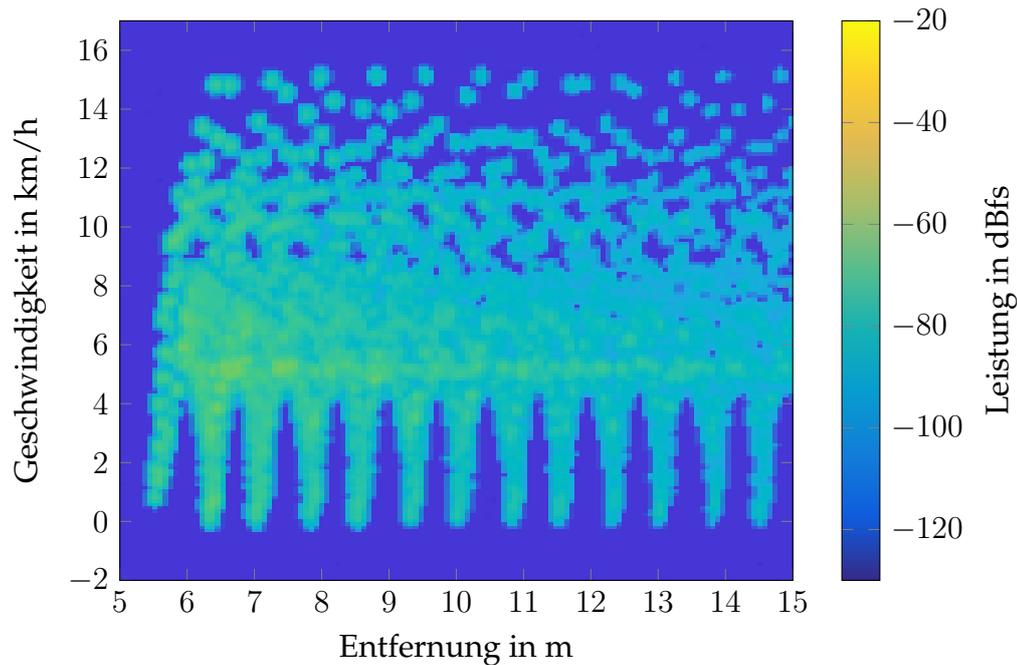


Abbildung 4.14: Bewegungsverlauf eines Fußgänger kumuliert über der Zeit im Entfernungs- und Geschwindigkeitsspektrum

ristika von Radfahrern untersucht, die mit einem Radarsensor detektiert werden können. Die Messfähigkeit der Entfernung, der Geschwindigkeit und der Richtung eines Radars eröffnet dafür eine Bandbreite an Möglichkeiten zur Unterscheidung. In den Betrachtungen wird vorausgesetzt, dass die einzelnen Streuzentren des Radfahrers entsprechend gruppiert wurden.

### 4.3.1 Objektausdehnung

Die Ausdehnung eines Objektes ist mit einem Radarsensor indirekt bestimmbar. Die Objektausdehnung wird durch eine Gruppe von detektierten Streuzentren eines physikalischen Objekts abgebildet. Die maximalen Abstände aller Raumrichtungen im dreidimensionalen Raum beschreiben die Ausdehnungsmaxima. Diese Ausdehnungen entsprechen direkt den Maßen eines Radfahrers in der Länge, Breite und Höhe. Ihre Ausmaße sind abhängig von der Ausrichtung des Radfahrers zum Radarsensor und dem damit illuminierten Bereich auf dem Radfahrer.

Exemplarisch in Abbildung 4.12 sind die zwei Ausrichtungen eines Radfahrers mit der größten Unterscheidung in der Ausdehnung bei der Detektion mit Radar aufgezeigt. Die Szenarien beschreiben einen longitudinal und einen transversal bewegten Radfahrer.

Die Darstellungen illustrieren sehr deutlich die Abhängigkeit der Radfahrerausrichtung zur Bestimmung der Ausdehnung. Durch Verdeckungen wird jeweils mindestens eine Raumrichtung in der Ausdehnungsdetektion eines Radfahrers

beeinflusst.

Die verkürzte Ausdehnung in Abhängigkeit der Ausrichtung eines Radfahrers ist so charakteristisch, dass sie wiederum verwendet werden kann, um auf die Ausrichtung zurückzuschließen. Diese ist gekoppelt an eine Bewegungsrichtung und wäre allein basierend auf der Auswertung der Ausdehnung mehrdeutig. Diese Mehrdeutigkeit kann durch Hinzunahme der Geschwindigkeitsinformation der Streuzentren eliminiert werden bzw. das Vorzeichen der Geschwindigkeit reicht als Indikator bereits aus.

Die Ausdehnung ist als Merkmal nur sinnvoll anwendbar für einzelne Messzyklen. Bei einer kumulierten Auswertung über der Zeit eignet sich die Objektausdehnung nur geringfügig zur Charakterisierung. Der Einfluss von Modulationsparametern auf die Objektausdehnung wird vernachlässigt, da sich die Entfernungszellengröße z.B. mit der Bandbreite ändert, diese aber im Vergleich zur Winkelgenauigkeit einen verschwindend geringen Einfluss hat.

#### 4.3.2 Streuzentrengeschwindigkeit

Auch für die Geschwindigkeit gilt, dass ein Streuzentrum alleine keine charakteristische Aussage über das Objekt liefern kann. Im Verbund mit weiteren Streuzentren, die sich auf dem physikalischen Objekt befinden, ist sie jedoch ein hilfreiches Maß. Über das gesamte Radfahrerobjekt erstreckt sich die radiale, relative Geschwindigkeitskomponente von der entgegengesetzten Eigenbewegungsgeschwindigkeit des Radarsensors bis hin zur doppelten, relativen Eigengeschwindigkeit des Radfahrers plus der entgegengesetzten Bewegungsgeschwindigkeit des Radarsensors. Theoretisch wäre es zwar möglich, mit sehr hoher Trittfrequenz an den Pedalen höhere Geschwindigkeiten zu generieren als die doppelte relative Eigengeschwindigkeit des Radfahrers. Dies wurde in der Praxis weder beobachtet noch entspricht es der Grundidee einer Gangschaltung.

Bezogen auf Abbildung 4.12 ist gut zu erkennen, dass die Geschwindigkeit der Streuzentren der Laufräder vom tiefsten bis zum höchsten Punkt entlang der z-Achse ansteigt. Dies deckt sich mit der theoretischen Betrachtung aus Unterabschnitt 4.1.2. Daraus ist es möglich, die vertikale Ausrichtung des Radfahrers abzuleiten. Unter Hinzunahme der dreidimensionalen Information der Streuzentren und der Geschwindigkeitsverteilung ist ein Rückschluss auf die Ausrichtung des erfassten Laufrades möglich. Vereinfacht kann man davon ausgehen, dass die Ausrichtung des Laufrades der gesamten Radfahrerausrichtung entspricht. Dies trifft in den meisten Fällen zu, außer in Kurvenfahrten am vorderen der beiden Laufräder wegen des Lenkeinschlages.

In Kombination mit der Entfernung ist das bereits bekannte Entfernungs- und Geschwindigkeitsspektrum zur Charakterisierung sehr gut geeignet. Hierin zeigt sich die Geschwindigkeitsausdehnung über der Entfernung, in Abbildung 4.15a beispielhaft gezeigt.

Typisch für einen Radfahrer ist dabei die weitgefächerte Geschwindigkeitsaus-

## 4 Detektion von Radfahrern

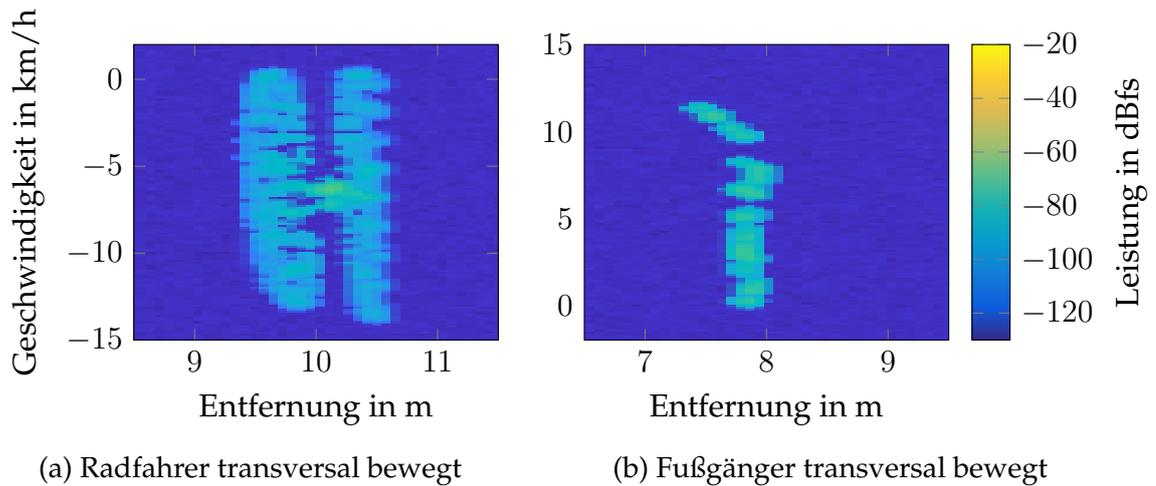


Abbildung 4.15: Entfernung- und Geschwindigkeitsspektrum eines einzelnen Messzyklus

dehnung an beiden Laufrädern. Diese begrenzen gleichzeitig auch die Ausdehnung in der Entfernung. Zwischen den Geschwindigkeitsprofilen der beiden Laufräder befindet sich noch auf der halben Höhe entsprechend der Eigengeschwindigkeit des Radfahrers eine relative gleichförmige Geschwindigkeitskomponente. In diesem Geschwindigkeitsbereich liegen ggf. noch kleinere Geschwindigkeitsausdehnungen, die dann von den Pedalbewegungen und Beinbewegungen des Fahrradfahrer herrühren. Im Einzelbild sind diese etwas schwierig zu erkennen, im Zeitverlauf aufgetragen, wie in Abbildung 4.10 zu sehen, sind diese oszillierenden Bewegungen eindeutig zu erkennen. Die typische H-Form des Radfahrers ist sehr charakteristisch und unterscheidet sich sehr deutlich von beispielsweise der eines Fußgängers, siehe dazu Abbildung 4.15b.

In größerer Entfernung reicht die rückgestreute Leistung der Laufräder nicht mehr aus um detektiert zu werden. Die Pedalbewegung im Kontrast dazu ist in einer deutlich größeren Entfernung noch detektierbar, was sie zu einem sehr sicheren Radfahrermerkmal macht. Ungünstigerweise ist die Pedalbewegung nicht direkt an die Fahrradbewegung gekoppelt, wie es beispielsweise bei den Laufrädern der Fall ist. Die Signifikanz dieses Merkmals sinkt dadurch nicht, jedoch dessen Auftrittswahrscheinlichkeit während der Bewegung.

Die Wahl der Frequenzmodulation hat in dieser Auswertung keinen Einfluss, da die Geschwindigkeitsauflösung für beide Varianten nahezu identisch ist und die Geschwindigkeitseindeutigkeit in diesen Szenarien nicht annähernd erreicht wird.

### 4.3.3 Räumliche Verteilung der Streuzentren

Die räumliche Verteilung der Streuzentren trägt eine eindeutige Signatur des Radfahrers. Beschränkt auf eine zweidimensionale Darstellung der Streuzentren in

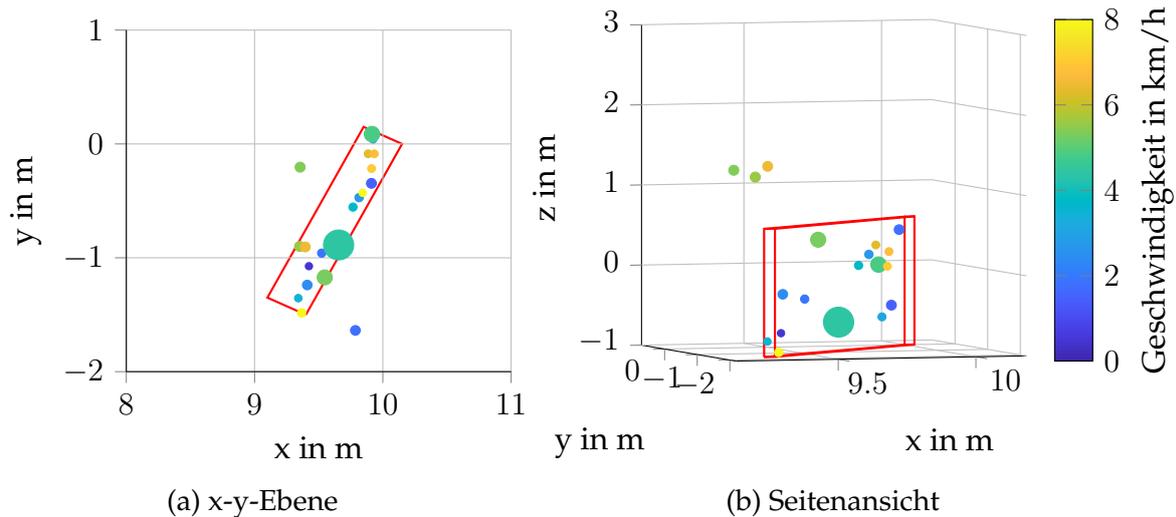


Abbildung 4.16: Exemplarische Darstellung eines Radfahrers aus Streuzentren mit farblich kodierter Geschwindigkeit und Kennzeichnung der Amplitude anhand der Punktgröße

der  $x$ - $y$ -Ebene (Vogelperspektive) zeigt ein Radfahrer Punktverteilungen in einem Rechteckbereich mit deutlich größerer Länge als Breite, wie in Abbildung 4.16a gezeigt. Erweitert man die Ansicht im dreidimensionalen Raum, so ist zu erkennen, dass ein Radfahrer im Gesamten einen Quader aufspannt, siehe hierfür Abbildung 4.16b.

Mit der charakteristischen räumlichen Verteilung der erfassten Streuzentren ist die Bewegungsrichtung und daraus ein approximierter Geschwindigkeitsvektor für jedes Streuzentrum abzuschätzen. Damit kann eine Prädiktion der Trajektorie eines Radfahrers generiert und darauf dann entsprechend reagiert werden. Die relative, radiale Geschwindigkeitskomponente ist dafür nicht geeignet. Ebenso ist es nicht erforderlich mehrere Messzyklen zu verfolgen, um auf die Bewegungsgeschwindigkeit zu schließen. Die Information ist direkt in einem einzigen Messzyklus gegeben. Das Verfahren zur Schätzung im zweidimensionalen Raum wurde in [114] als Bewegungsrichtungsschätzung (Direction of Movement (DOM)) vorgestellt und veröffentlicht.

Definiert ist die Bewegungsrichtung als Vektor. Mit dem Betrag der DOM ist die Bewegungsgeschwindigkeit beschrieben und die DOM Richtung beschreibt folglich die Bewegungsrichtung. Der DOM Ansatz basiert auf der Annahme, dass die Streuzentren eines Radfahrers als Gerade in der  $x$ - $y$ -Ebene approximiert werden können. Als gegeben wird die Bekanntheit der Zugehörigkeit der Streuzentren zu einem Radfahrer angenommen. Zur Approximation einer Geraden durch die Radfahrerstreuzentren wurden zwei bekannte Verfahren getestet und deren Performance auf die Bestimmung der Bewegungsrichtung gegenübergestellt. Ausgewählt wurden die Hough-Transformation [115] und der Random Sample Consensus (RANSAC) Algorithmus [116]. Diese beiden Methoden überzeugen durch ihre

## 4 Detektion von Radfahrern

Robustheit gegenüber Ausreißern in Datensätzen.

Die Hough-Transformation ist ein Brute-Force-Ansatz aus der digitalen Bildverarbeitung. Sie wird ihrem Entwicklungsgrund nach zur Erkennung von Kanten in Bildern verwendet. Um die Hough-Transformation einzusetzen, werden die detektierten Streuzentren in ein feinmaschiges, kontinuierliches und zweidimensionales Netz eingetragen. Die Verwendung der Hesse-Normalform zur Parametrisierung der Gerade führt nach [117] zur Vermeidung von Steigungswerten gleich null oder unendlich, die sonst bei Parallelen zur x- bzw. y-Achse auftauchen würden.

$$d = x \cos(\alpha) + y \sin(\alpha) \quad (4.32)$$

Mit den Parametern  $d$  und  $\alpha$  wird ein Dualraum aufgespannt. Dieser wird durch eine Matrix repräsentiert. Jede Kombination von  $d$  und  $\alpha$ , die ein Streuzentrum trifft, erhöht den korrespondierenden Eintrag in der Matrix um +1. Zur Findung der am besten passenden Geraden wird die Matrix nach dem Eintrag mit dem höchsten Wert durchsucht. Der höchste Matrixwert repräsentiert die am besten angenäherten Parameter  $d$  und  $\alpha$ .

Der RANSAC Algorithmus ist ein nicht deterministischer, iterativer Ansatz zur Schätzung von Modellparametern in einem Datensatz mit rauschbehafteten Daten. Um das Modell einer Geraden zu schätzen, wählt der Algorithmus zufällig zwei Datenpunkte aus, die eine Linie definieren. Die restlichen Daten werden dann in innen und außerhalb liegende Punkte eingeordnet. Dafür wird der Abstand von Punkt zur Linie als Kriterium herangezogen. Diese Prozedur wird so lange wiederholt, bis die Linie mit den meisten innenliegenden Datenpunkten gefunden ist. Durch die ermittelten Punkte wird mit der Methode der kleinsten Quadrate eine Gerade approximiert.

Diese Gerade nähert dann die Bewegungsrichtung des Radfahrers an. Sie ist dabei aber nicht eindeutig, da der Radfahrer sich in beide Richtungen entlang der Geraden bewegen kann. Um diese Mehrdeutigkeit aufzulösen, wird die Information des relativen, radialen Geschwindigkeitsvektors  $\vec{v}_r$  für jedes Streuzentrum verwendet.

$$\vec{v}_{r, \text{Streuzentrum}} = \frac{\begin{bmatrix} x_{\text{Streuzentrum}} \\ y_{\text{Streuzentrum}} \end{bmatrix}}{\sqrt{x_{\text{Streuzentrum}}^2 + y_{\text{Streuzentrum}}^2}} v_r \quad (4.33)$$

Die Bestimmung der DOM für jedes Streuzentrum läuft schematisch wie folgt ab. Im Ersten Schritt wird der Schnittwinkel  $\alpha$  der approximierten Geraden mit der x-Achse ermittelt.

$$\alpha = \arctan(m) \quad (4.34)$$

Für die Hough-Transformation ist der Winkel  $\alpha$  Teil der Parameter. Beim RANSAC wird er aus der Steigung  $m$  der Geraden gewonnen. Mit bekanntem  $\alpha$  wird

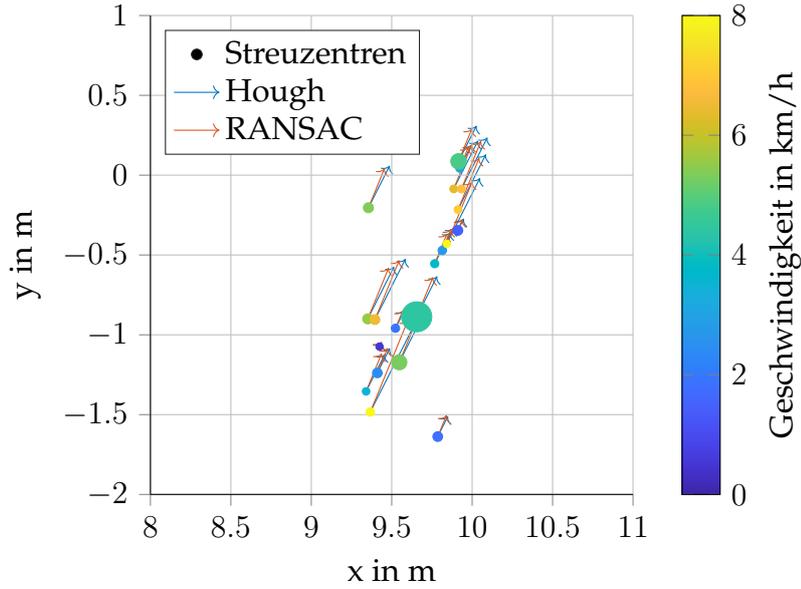


Abbildung 4.17: Beispiel für das Ergebnis der DOM Bestimmung eines Radfahrers mit Hough-Transformation und RANSAC

der  $x$ -Einheitsvektor  $\vec{e}_x$  um diesen Winkel rotiert und als Richtung für die DOM angenommen.

$$D\vec{O}M = \begin{bmatrix} \cos(\alpha) & -\sin(\alpha) \\ \sin(\alpha) & \cos(\alpha) \end{bmatrix} \vec{e}_x \quad (4.35)$$

Zur Prüfung der vermuteten Richtung wird dann das Skalarprodukt von  $D\vec{O}M$  und  $\vec{v}_r$  gebildet. Der Index des Streuzentrums wird für eine bessere Übersichtlichkeit vernachlässigt.

$$\beta = \arccos \left( \frac{D\vec{O}M \vec{v}_r}{|D\vec{O}M| |\vec{v}_r|} \right) \quad (4.36)$$

$$D\vec{O}M = \begin{cases} D\vec{O}M & \text{für } \beta \leq 90^\circ \\ -D\vec{O}M & \text{für } \beta > 90^\circ \end{cases} \quad (4.37)$$

Als letztes wird der Bewegungsrichtungsvektor normiert, so dass sein Betrag der Bewegungsgeschwindigkeit entspricht.

$$D\vec{O}M = D\vec{O}M \frac{|\vec{v}_r|^2 |D\vec{O}M|}{D\vec{O}M \vec{v}_r} \quad (4.38)$$

Das Ergebnis der DOM Auswertung ist für die beiden Parameterschätzer in

#### 4 Detektion von Radfahrern

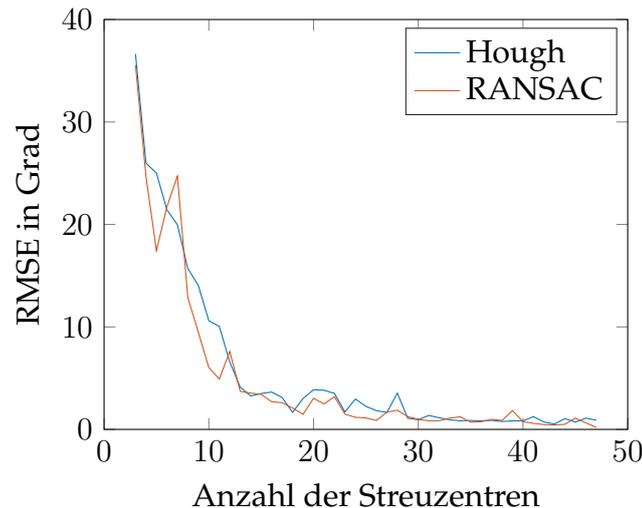


Abbildung 4.18: Mittlere quadratische Abweichung der Richtungsschätzung über die Anzahl der Streuzentren aus [114] © 2018 IEEE

Abbildung 4.17 an einen zufällig ausgewählten Messzyklus aus einer Messreihe gezeigt. Im dargestellten Beispiel unterscheidet sich das Ergebnis mit den verschiedenen Schätzern nur sehr geringfügig. Für eine Untersuchung der Schätzgenauigkeit wurde ein Datensatz an Messungen angelegt, der sowohl synthetisch erzeugte als auch real gemessene Daten mit der genauen Ausrichtung des Radfahrers zum Radar enthält. Der erzeugte Datensatz umfasst zirka 2500 Messzyklen. Davon sind zirka 70 % synthetische Daten, da diese eine sehr exakte Information über die Ausrichtung des Objekts liefern. Bei den gemessenen Daten ist aufgrund der Messmethodik eine geringe Abweichung zu erwarten. Zur Generierung der Messdaten wurde auf einer Freifläche ein Kreis gezeichnet und in 12 identische Abschnitte unterteilt. Entlang der Abschnittskanten bewegte sich der Radfahrer. Eine zusätzliche Erfassung der Bewegung durch ein GPS System wurde nicht verwendet.

Die Abschätzung des Fehlers erfolgt mit dem mittleren quadratischen Fehler.

$$RMSE = \sqrt{\frac{\sum_{n=1}^N (\hat{\alpha}_n - \alpha_n)^2}{N}} \quad (4.39)$$

Als Parameter wird der Schnittwinkel  $\alpha$  mit der  $x$ -Achse verwendet. Die Ausrichtung des Radfahrers wurde dementsprechend beschrieben. Über den gesamten Testdatensatz erreicht die Methode mit der Hough-Transformation eine Abweichung von  $RMSE_{Hough} = 16^\circ$  und mit RANSAC von  $RMSE_{RANSAC} = 15^\circ$ . In diesem Abweichungsbereich ist mit diesen Methoden keine verwendbare Schätzung möglich. Unter Einbeziehung der Streuzentrenanzahl pro Messzyklus verändert sich die Abweichung in Abhängigkeit dieser Anzahl. Dargestellt ist der Verlauf in Abbildung 4.18. Sehr deutlich zu erkennen ist, dass die Abweichung

stark von der Anzahl der Streuzentren, detektiert in einem Messzyklus, abhängt. Der RMSE sinkt von  $35^\circ$  bei 5 Streuzentren auf unter  $2^\circ$  bei 48 Streuzentren. Ein für die Praxis gutes Limit ist bei einer Abweichung von  $5^\circ$  gegeben. Dafür ist eine Mindestanzahl von 13 Streuzentren pro Messzyklus notwendig.

Um die Ausrichtung des Radfahrers zu schätzen, ist eine hohe Anzahl an Streuzentren vorteilhaft. Durch den  $\mu$ -Doppler Effekt variiert innerhalb des Radfahrerobjekts für nahezu jedes Streuzentrum die Geschwindigkeit stark. Zur Prädiktion der Position in einem der zukünftigen Messzyklen ist die Eigengeschwindigkeit des Radfahrers interessant. Die Extraktion der Eigengeschwindigkeit eines Radfahrers wird in Unterabschnitt 4.3.4 separat beschrieben.

In der räumlichen Verteilung der Streuzentren steckt noch weitere Information zur Fahrtrichtungsbestimmung. Bisher fand nur die Auswertung in zwei Raumdimensionen statt. In der dritten Raumdimension steckt ein Indikator für eine Kurvenfahrt und die Krümmungsrichtung der Kurve.

Beim Durchfahren einer Kurve neigt sich der Radfahrer abhängig vom Kurvenradius, in Kurvenrichtung. Dies wird unter Zweiradfahrern als in die Kurve legen bezeichnet. Aus der physikalischen Betrachtung der Kräfte an einem Radfahrer bei einer Kurvenfahrt ist der Neigungswinkel  $\psi$  abzuleiten [96].

$$\tan(\psi) = \frac{|\vec{v}_{EGO}(t)|^2}{|\vec{r}|g} \quad (4.40)$$

Der Neigungswinkel  $\psi$  setzt sich aus der Division der quadrierten Eigengeschwindigkeit  $\vec{v}_{EGO}$  des Radfahrers mit dem Kurvenradius  $\vec{r}$  und der Gravitation  $g$  der Erde zusammen.

Um auf den Kurvenradius zu schließen, müssen die weiteren Parameter aus Gleichung 4.40 aus den Messdaten extrahiert werden. Hier wird wiederum verlangt, innerhalb eines Messzyklus die Parameter bereit zu stellen und diese nicht über der Zeit mit mehreren Messzyklen zu erfassen. Die Gravitation, eine der vier Grundkräfte der Physik, ist bekannt und wird mit  $g = 9,81 \text{ m/s}^2$  angenommen. Die Eigengeschwindigkeit wird aus den vorangegangenen Betrachtungen gewonnen und detailliert in Unterabschnitt 4.3.4 beschrieben. Zur Ermittlung des Neigungswinkels wird die Verteilung der Streuzentren im dreidimensionalen Raum verwendet.

Die Verteilung der Streuzentren eines Radfahrers lässt sich im dreidimensionalen Raum durch eine Ebene abbilden. Dabei wurde der RANSAC Ansatz weiterhin zur Approximation einer Ebene aus den Positionen der Streuzentren verwendet. Zur Bestimmung des Neigungswinkels des Radfahrers werden die Normalenvektoren der approximierten Ebene und der x-y-Ebene verwendet. Durch Lösen des Skalarproduktes der beiden Normalenvektoren ist  $\psi$  eindeutig bestimmt. Einsetzen der ermittelten Parameter und Umstellen von Gleichung 4.40 liefert dann den Kurvenradius. Per Definition ist eine Linkskurve durch einen negativen Winkel gekennzeichnet und eine Rechtskurve mit einem positiven.

Ein exemplarisches Szenario zur Bestimmung der Kurvenradien ist in einer

#### 4 Detektion von Radfahrern

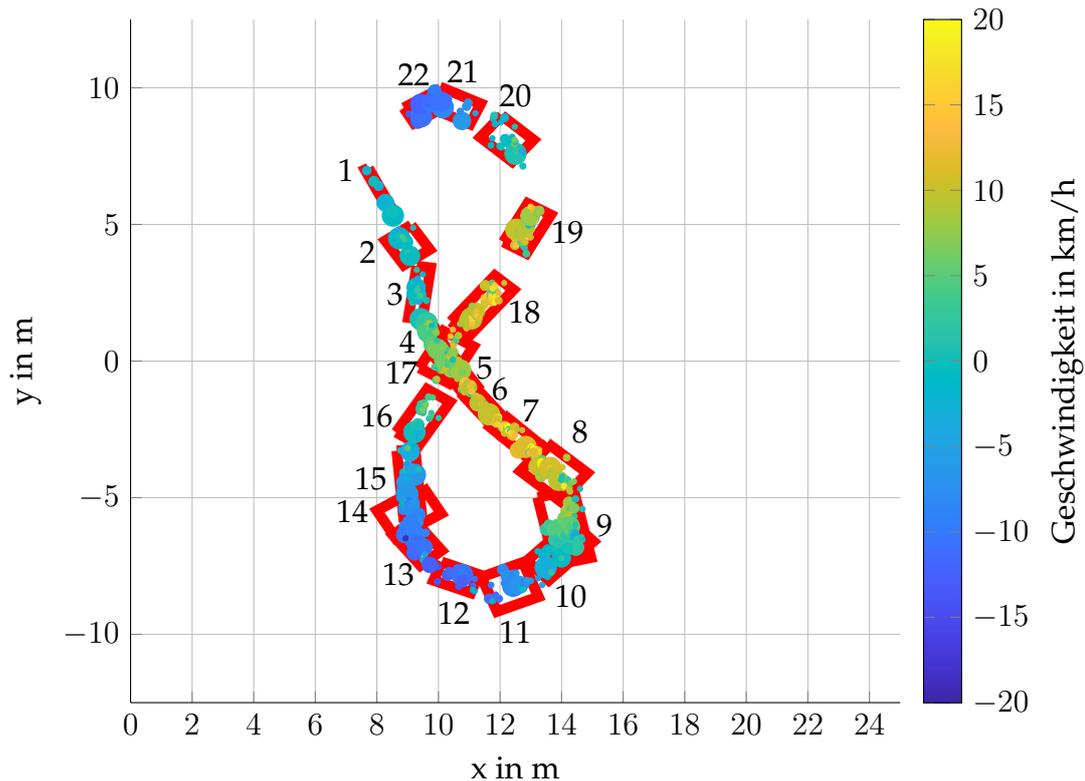


Abbildung 4.19: Aufgezeichnete Messdaten eines Szenario mit Bewegungsverlauf einer Acht zum Nachweis der Kurvenradien. Die Position des Radars ist im Koordinatenursprung gegeben.

Achterfahrt nachvollzogen, siehe hierfür Abbildung 4.19. Die exakte Bewegung des Radfahrers wurde nicht mit einem Messsystem zur Positions- und Lagenlokalisierung aufgezeichnet. Daher kann für die Kurvenradienschätzung keine Abweichung angegeben werden. An dieser Stelle wird somit lediglich das Verfahren auf Plausibilität geprüft. In Tabelle 4.1 sind zu den jeweiligen Zeitpunkten die Positionen der Streuzentren mit roten Umrahmungen markiert.

Das Vorzeichen des Kurvenradius ist als Indikator für eine Linkskurve (negativ) und Rechtskurve (positiv) definiert. Die ermittelten Kurvenradien der jeweiligen Positionen sind plausibel nachzuvollziehen. Nachfolgende Streuzentrenpositionen liegen entsprechend an den zu erwartenden durch den Kurvenradius vorhergesagten räumlichen Positionen. Annähernd Geradeausfahrt ist im Beispiel durch sehr große Kurvenradien gekennzeichnet. Theoretisch ist ein Kurvenradius von unendlich zu erwarten, dieser wird in der Praxis jedoch so gut wie nie ermittelt, da ein Radfahrer während der Bewegung sehr kleine Pendelbewegungen entlang seiner Querachse ausführt.

Um die Verteilung der Streuzentren als Informationsquelle verwenden zu können, müssen davon genügend vorhanden sein. Die Anzahl der erfassten Streuzentren pro Messzyklus wurde in Abhängigkeit der Modulation untersucht. Da-

Tabelle 4.1: Geschätzte Kurvenradien aus dem Neigungswinkel des Radfahrers passend zu den Positionen in Abbildung 4.19

|              |      |      |       |      |       |        |      |      |
|--------------|------|------|-------|------|-------|--------|------|------|
| Position     | 1    | 2    | 3     | 4    | 5     | 6      | 7    | 8    |
| Kurvenradius | 20 m | 4 m  | -14 m | 19 m | -14 m | -120 m | 36 m | 19 m |
| Position     | 9    | 10   | 11    | 12   | 13    | 14     | 15   | 16   |
| Kurvenradius | 16 m | 3 m  | 10 m  | 4 m  | 3 m   | 5 m    | 22 m | 40 m |
| Position     | 17   | 18   | 19    | 20   | 21    | 22     |      |      |
| Kurvenradius | 16 m | -8 m | -6 m  | -2 m | -3 m  | -5 m   |      |      |

für wurde ein Datensatz bestehend aus 3600 Messzyklen zur Hälfte aus Daten mit Modulation 1 und zur anderen Hälfte aus Daten mit Modulation 2 verwendet. Die Szenarien sind dabei identisch. Bezogen auf einen Messzyklus ist mit Modulation 1 eine Anzahl von 38,6 Streuzentren erfasst worden. Mit Modulation 2 waren es 37,4 Streuzentren pro Messzyklus. Diese geringe Abweichung manifestiert keinen Vorteil für eine der beiden Modulationen.

#### 4.3.4 Eigengeschwindigkeit

Für Funktionen auf einem höheren Abstraktionslevel als einzelne Punkte von Streuzentren sind allgemeinere Bewegungsmuster komprimiert auf einen Punkt oder eine Hülle gefordert. Aus Unterabschnitt 4.3.3 ist die Bewegungsrichtung (DOM) und eine eventuelle Kurvenfahrt bekannt. Diese Schätzungen lassen einen Rückschluss auf die Fortbewegungsrichtung des Radfahrers in einem zukünftigen Messzyklus zu. Um die Vorhersage auf einen höheren Detailgrad zu heben, ist es notwendig, die Eigengeschwindigkeit des Radfahrers aus dem aktuellen Messzyklus zu ermitteln. Beginnend mit gewöhnlichen Bewegungsmustern, die im Straßenverkehr vorkommen, wird eine geeignete Methode anhand synthetischer Messzyklen entwickelt.

Die Eigengeschwindigkeit wird aus allen Geschwindigkeitszellen im Entfernungs- und Geschwindigkeitsspektrum, über der Detektionsschwelle liegend, eines Radfahrers ermittelt. Ausgenutzt wird dabei die Symmetrie eines Radfahrers bezüglich den auftretenden Geschwindigkeitskomponenten über und unter der tatsächlichen Eigengeschwindigkeit. Um alle Zellen miteinander zu kombinieren wird der Median verwendet. Durch die höhere Robustheit gegenüber Ausreißern, im Vergleich zum arithmetischen Mittelwert ist er die bessere Wahl. Der ermittelte Median der radialen Geschwindigkeit wird anschließend mit der DOM-Methode aus Unterabschnitt 4.3.3 auf die Bewegungsrichtung transformiert. Dafür wird der Mittelpunkt des Radfahrers als Bezugspunkt für die radiale Geschwindigkeitskomponente verwendet.

Validiert wurde diese Methode mit 3600 Messzyklen mit bekannter Lage, Position und Geschwindigkeit von 10 km/h bis 20 km/h, aufgeteilt zu gleichen Teilen

für die beiden bereits verwendeten Modulationen. Für die Zyklen mit Modulation 1 ist die Abweichung mit  $RMS E_{vEgo,Mod1} = 2,20$  km/h nahezu identisch zur Modulation 2 mit  $RMS E_{vEgo,Mod2} = 2,34$  km/h. Demnach hat die Modulation nur einen sehr geringen Einfluss auf die Ermittlung der Eigengeschwindigkeit.

Methoden wie in [118, 119] vorgestellt, können auf Radfahrer nicht angewandt werden. Die Mikrobewegungen der Pedale und Räder am Radfahrersystem sind im Verhältnis zur Eigengeschwindigkeit in der Anzahl zu dominant.

Um eine höhere Genauigkeit zu erreichen, ist die Verwendung mehrerer Messzyklen unter Umständen hilfreich. Dies ist jedoch nicht Teil dieser Arbeit und wird daher nicht weiter verfolgt.

### 4.3.5 Erkennungsbereich

Die vorherigen Beschreibungen untersuchen die einzelnen Merkmale eines Radfahrers. An dieser Stelle wird beleuchtet, bis zu welcher Entfernung diese Charakteristika mit der verwendeten Radarsensorik zu erkennen sind. Dafür wurde ein Messaufbau mit statischem Radarsensor und einem longitudinal bewegten Radfahrer verwendet. Das Radfahrersystem bewegt sich dabei beschleunigend und sich entfernend vor dem Sensor.

Aufgetragen im Entfernungs- und Geschwindigkeitsspektrum kumuliert über der Zeit ist die Messreihe in Abbildung 4.20 dargestellt.

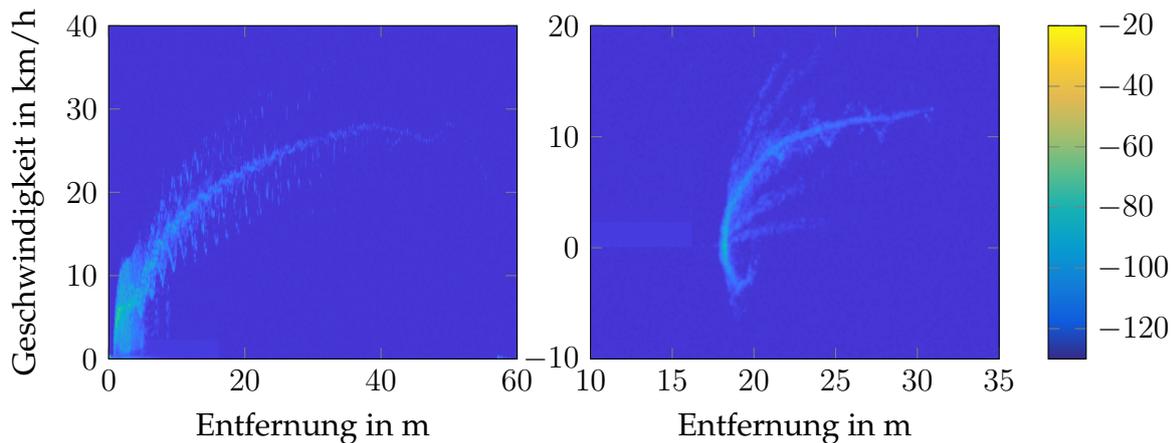
Das bewegte Objekt ist bis maximal 58 m Entfernung zum Radar zu erkennen. Aus der theoretischen Herleitung mit Gleichung 3.6 kann diese Erkenntnis bestätigt werden.

$$\begin{aligned}
 R_{max} &= \sqrt{\frac{P_T G_T G_R \lambda_0^2}{64\pi^2 P_{R,min}} \sin\left(\frac{\theta_{3dB}}{2}\right) \sin\left(\frac{\varphi_{3dB}}{2}\right) \Delta r \varpi \sum_i \sigma_i} \\
 &= \sqrt{\frac{10 \text{ mW } 15 \text{ dB } 10 \text{ dB } \lambda_0^2}{64\pi^2 - 120 \text{ dBm}} \sin\left(\frac{41^\circ}{2}\right) \sin\left(\frac{9^\circ}{2}\right) 1,8 \text{ m } 1 \text{ m}^{-1}} = 61,3 \text{ m}
 \end{aligned} \tag{4.41}$$

Zur Abschätzung von  $R_{max}$  wurde für den Radfahrer eine Länge des illuminierten Raums von 1,8 m und ein summierter RCS von 1 m<sup>2</sup> angenommen. Nach Unterabschnitt 4.1.4 liegt der RCS Wert für einen Radfahrer in longitudinaler Bewegung typischerweise in diesem Bereich.

Ebenfalls aus Abbildung 4.20a ist die Bewegungsgeschwindigkeit der Beine und Pedale bis ca. 42 m detektierbar. Die geringere Erkennung in der Entfernung folgt aus den geringeren Rückstreuungseigenschaften dieser Komponenten. Für die beiden Laufräder ergibt sich ein noch geringerer Erfassungsbereich mit dem Radarsensor. Der gezeigte Verlauf stellt den schwierigsten Fall für die Räderdetektion dar, da aufgrund der Beobachtungsrichtung direkt orthogonal auf die Radnarbe hauptsächlich der Gummimantel reflektiert. Für transversal verlaufende Bewegungen konnte eine Detektion der Räder bis zu einer Distanz von 22 m festgestellt werden, wie in Abbildung 4.20b illustriert.

#### 4.4 Anforderungen an einen artikulierten Radfahrerdummy



(a) Longitudinal bewegter Radfahrer

(b) Transversal bewegter Radfahrer

Abbildung 4.20: Erkennungsbereich eines Radfahrers im Entfernung- und Geschwindigkeitsspektrum kumuliert über der Zeit

## 4.4 Anforderungen an einen artikulierten Radfahrerdummy

Bei der Entwicklung und Validierung von Fahrfunktionen ist es üblich Dummies einzusetzen. Dieses Vorgehen ermöglicht es hochdynamische Fahrmanöver zu testen, ohne dabei einen Menschen in Gefahr zu bringen oder gar zu verletzen. Solche Dummies finden hauptsächlich Anwendung bei Crashtests mit Fahrzeugen. Ausgestattet mit einer Vielzahl an Sensoren liefern sie wichtige Erkenntnisse über wirkende Kräfte bei einer Kollision. Mit der Entwicklung von Fahrerassistenzsystemen für Fußgänger und Radfahrer entstand neuer Bedarf an Fußgänger- und Radfahrerdummies. Im Förderprojekt PROSPECT [8] wurde der Radfahrerdummy der Firma 4activeSystems in vielen der hier bereits adressierten Belange und Möglichkeiten weiterentwickelt [120].

Grundlegend wird an eine solche technische Einrichtung die Anforderung gestellt, die Realität im höchsten Exaktheitsgrad abzubilden. Die Genauigkeit in der Nachbildung beginnt bei den physikalischen Ausmaßen, erstreckt sich über die Nutzbarkeit für alle im Fahrzeug verwendeten Sensortypen, und endet bei der Thematik der einfachen Handhabbarkeit. Die folgenden Beschreibungen beziehen sich spezifisch auf die Erfassung mit einem Radarsensor.

Große Bemühungen werden im Allgemeinen in die realitätsgetreue Erscheinung eines Dummies gesteckt. Die physikalischen Ausdehnungen leiten sich dabei von den im Straßenverkehr benutzten Fahrrädern ab. Der menschliche Fahrer ist als Erwachsener modelliert. Für die verwendeten Materialien muss dieselbe Rückstrahlcharakteristik gegeben sein wie für den „echten“ Radfahrer. Hierzu wurden für die Spezifikation eines Fußgängerdummy Messungen in [88] und für einen Radfahrerdummy in [107] ausgewertet. Bei der Wahl der Materialien gilt es



Abbildung 4.21: Radfahrerdummy und Radfahrer in paralleler Fahrt zum Vergleich der optischen Erscheinung, aus [121]

zusätzlich die Handhabbarkeit und Robustheit zu beachten. Diese müssen genügend Stabilität aufweisen, um während der Bewegung in Form zu bleiben und auch einem unvorhergesehenen Aufprall standhalten. Gleichzeitig soll das Dummysystem einfach zu transportieren sein.

So wie auch bei den Crashtestdummys wird eine Wiederverwendbarkeit für mehrere Kollisionen gefordert. Der Dummy ist so konstruiert, dass ein Aufprall mit einem Fahrzeug keine bleibenden Schäden bei den involvierten Teilnehmern hinterlässt. Dafür ist der Dummy aus weichen Materialien hergestellt und mit vielen Sollbruchstellen mit Magneten oder Steckelementen konstruiert. Dies ermöglicht eine Wiederverwendung des Dummys auch nach einer Kollision.

Ein völlig stationärer Radfahrerdummy ist nur für eine kleine Anzahl an Tests geeignet. Ein artikulierter Dummy mit bewegten Laufrädern ist für nahezu alle Testszenarien einsetzbar. Artikuliert beschreibt in diesem Zusammenhang die Verwendung von Gelenken an einem Dummy, um Bewegungen des menschlichen Vorbilds so realistisch wie möglich nachzuahmen. Wie in den vorangegangenen Unterkapiteln beschrieben, sind für die Bewegungscharakteristika hauptsächlich die drehenden Räder und die Beinbewegung des Radfahrers verantwortlich. Die Pedalierbewegung findet aufgrund der neuen Ergebnisse in dieser Arbeit in zukünftigen Dummys ihren Einsatz. Ebenso wird die Kurvenneigung eines sich in Bewegung befindenden Radfahrers zukünftig berücksichtigt. Weitere Anpassungen für verschiedene Sensorarten sowie der Vergleich zwischen einem menschlichen Radfahrer und des Radfahrerdummy sind in [121] gezeigt. Ein Auszug daraus zeigt den Dummy in paralleler Fahrt zu einem realen Radfahrer in Abbildung 4.21.

## Zusammenfassung

Für die Detektion eines Radfahrers mit einem Radarsensor sind mehrere unterschiedliche Facetten zu betrachten. Um zu verstehen, wie ein Radarsensor einen Radfahrer wahrnimmt, wird vorab ein genaues Verständnis des Gesamtsystems „Radfahrers“ benötigt. Die offensichtlichsten Komponenten im System, ein menschlicher Fahrer sowie ein mechanisches Fahrrad, sind vollkommen unabhängig

#### 4.4 Anforderungen an einen artikulierten Radfahrerdummy

vom gewählten Sensortyp. Da diese im Gesamtsystem miteinander interagieren, ist eine getrennte Beschreibung nicht zielführend. Als geeignetere Untergliederung des Systems haben sich die verschiedenen Bewegungsmuster herausgestellt. Hierbei wird zwischen quasi-statischer Bewegung und rotierenden Elementen unterschieden. Bei genauerer Analyse der Bewegungen stellt man fest, dass sich außer den Beinen, den Pedalen und den Rädern alle anderen Komponenten gleichförmig mit der Eigengeschwindigkeit des Radfahrers fortbewegen. Interessant bezüglich der Radarsensorik ist der Mikro-Doppler Effekt, mit dem die variierenden Mikrobewegungen bzw. Rotationen direkt in einem Messzyklus gemessen werden können und eine charakteristische Ausdehnung im Entfernungs- und Geschwindigkeitsspektrum zeigen.

Anhand dieses Wissens konnte ein repräsentatives Modell des Radfahrers entwickelt werden. Dieses fand Verwendung in einer flexiblen Simulationsumgebung für Radardaten. Mit Nachweis der Übereinstimmung von Simulation und Messung durch geeignete Validierungsverfahren ist jetzt die Möglichkeit gegeben, eine Vielzahl an Daten auch synthetisch zu generieren. Auf deren Basis können neue radfahrerspezifische Merkmale extrahiert und darauf aufbauend komplexe Fahrerassistenzsysteme entwickelt werden, dies alles natürlich auch mit paralleler Verifizierung anhand von gemessenen Radardaten.

Aus den Simulationen konnte eine Vielzahl an typischen Merkmalen eines Radfahrersystems gewonnen werden. Naheliegend ist zu aller erst einmal die Auswertung der Objektausdehnung, da diese physikalisch sehr einfach zu beschreiben ist. Je nach Ausrichtung eines Radfahrers ist dessen räumliche Ausdehnung und Positionierung verschieden und damit einzigartig. Sehr markant sind die stark variierenden Geschwindigkeiten der einzelnen erfassten Streuzentren und deren Lage im Radfahrersystem. Besonders außergewöhnlich ist die Pedalierbewegung, die sonst kein anderer Verkehrsteilnehmer aufweist. In der Verteilung der Streuzentren im Raum steckt zusätzlich zur Ausdehnung noch weitere Information über den Radfahrer. Kennzeichnend ist die Anordnung als Linie bei Projektion aller Punkte auf der x-y-Ebene. In dieser Linie steckt die Richtung, in die sich der Radfahrer bewegt. Die Kombination aus Richtungsinformation und radialer, relativer Geschwindigkeit führt schließlich zur Bestimmung der Bewegungsrichtung. Unter Hinzunahme der dritten Dimension in z-Richtung ist die Neigung des Radfahrers bestimmbar. Diese stellt einen zuverlässigen Indikator für eine Kurvenfahrt dar. Aus der Neigung ist es auch möglich den Kurvenradius zu bestimmen, was für eine Bewegungsprädiktion von großem Nutzen ist. Für eine Signalverarbeitung auf einer höheren Abstraktionsebene ist es vereinfachend, den Radfahrer in einem Punkt mit seiner Eigengeschwindigkeit, die der Fortbewegungsgeschwindigkeit entspricht, zusammen zu fassen. Mit Ermittlung des Median aus allen Streuzentrengeschwindigkeiten ist dies bis zu einem gewissen Genauigkeitsgrad selbst in einem einzigen Messzyklus möglich. In allen Betrachtungen konnten keine signifikanten Unterschiede für die beiden verwendeten Modulationen festgestellt werden.

Bei der Erprobung neuer Funktionen und Fahrerassistenzsysteme ist es not-

#### *4 Detektion von Radfahrern*

wendig, diese in der Realität zu testen. Um Schaden von Mensch und Material so gering wie möglich zu halten, ist der Einsatz von Radfahrerdummy's unerlässlich. Hierfür werden realitätsgetreue technische Einrichtungen benötigt, die einen Radfahrer möglichst realitätsgetreu abbilden. In die Modifizierung und Optimierung eines Radfahrerdummy's bezüglich Radarsensoren flossen die gewonnenen Erkenntnisse aus dieser Arbeit mit ein.

# 5 Klassifizierung von Radfahrern

## Inhalt

---

|  |            |
|--|------------|
| <b>5.1 Neuronale Netze</b>                       | <b>96</b>  |
| 5.1.1 Aktivierungsfunktion                       | 98         |
| 5.1.2 Backpropagation                            | 101        |
| 5.1.3 Faltende Neuronale Netze                   | 103        |
| <b>5.2 Bereichsdetektion</b>                     | <b>105</b> |
| 5.2.1 Clustering im Bildbereich                  | 106        |
| 5.2.2 Bereichsdetektionsnetzwerk                 | 110        |
| <b>5.3 Datenpräparation</b>                      | <b>111</b> |
| 5.3.1 Generierung von Trainings- und Testdaten   | 112        |
| <b>5.4 Klassifizierung</b>                       | <b>114</b> |
| 5.4.1 Faltendes Neuronales Netz                  | 115        |
| 5.4.2 Klassifizierungsnetz mit Bereichsdetektion | 118        |

---

## Überblick

Die Entwicklung von Fahrerassistenzsystemen erfordert eine spezifische Funktionalität in Abhängigkeit der Verkehrsbedingungen und deren Teilnehmer. Die Bewegungsdynamik von Fußgängern, Radfahrern und motorisierten Kraftfahrzeugen unterscheidet sich dabei in hohem Maße. Essenzielle Bedeutung kommt der Einordnung von gewonnenen Sensordaten in Klassen zu, deren Inhalt auf physikalischen Objekten basiert. Ist die Klasse eines sich im Straßenverkehr befindenden Objekts bekannt, ermöglicht dies eine der Verkehrssituation entsprechenden adäquaten Systemreaktion.

Erste Bestrebungen, Merkmale aus Radardaten für eine Klassifikation von Fahrzeugarten zu extrahieren, wurden in [122–124] erarbeitet. Hauptsächlich zur Bestimmung des Verkehrsaufkommens und zur automatischen Erfassung in Mautsystemen ist die Kenntnis des Fahrzeugtyps notwendig. Anhand der länglichen Ausdehnung und Höhe, erfasst über der Zeit, konnte eine Einteilung in verschiedene Klassen vorgenommen werden. Evolutionär erhöhte sich die Anzahl der detektierten Streuzentren bei den Radargenerationen stetig bis hin zu einigen zehn

für Radfahrer und Fußgänger. Eine optimale Ausnutzung der Informationsfülle in jedem Messzyklus führte zur Verwendung von Support Vector Machines (SVMs), die aus einem Datensatz an Trainingsvektoren die Klassen im Vektorraum größtmöglich voneinander abgrenzen. Ein Einsatz zur Klassifizierung von verschiedenen Verkehrsteilnehmern im städtischen Umfeld [25, 125–127] oder zur Erkennung unterschiedlicher Arten von Interferenz im Radarsignal [128] ist mit SVMs möglich.

Hochauflösende, bildgebende Radarsensoren schufen die Möglichkeit, bekannte Mustererkennungsmethoden aus der Bildverarbeitung zu nutzen. Neuronale Netze können auf massiv parallelisierten Systemen (Graphics Processing Unit (GPU)) trainiert und zur Klassifizierung eingesetzt werden. Beginnend mit einer Radaranwendung zur Gangarterkennung von Menschen [129, 130] über die Unterscheidung von Schwimmbewegungen [131] bis hin zur Klassifizierung von Verkehrsteilnehmern [132–134] erstreckt sich deren Einsatzbereich.

Eine weitere Möglichkeit der Klassifizierung auf Punktebene ist mit der Point-Net Methode gegeben [135, 136]. Zuerst eingesetzt in hochauflösenden Lidarpunktwolken, wurden erste erfolgreiche Verwendungen mit Radardaten in [137] vorgestellt.

### 5.1 Neuronale Netze

Schon im antiken Griechenland träumten Erfinder von denkenden Maschinen. Als Computer erfunden wurden, war es unvorstellbar wie diese Maschinen jemals intelligent werden können. In der heutigen Zeit erfreut sich künstliche Intelligenz einer großen Akzeptanz und Anwendung in der Automatisierung von Arbeitsroutinen, in der Sprach- und Bilderkennung, in der medizinischen Diagnose und der Unterstützung wissenschaftlicher Grundlagenforschung [138].

Herausfordernd für die künstliche Intelligenz ist die Lösung von Aufgaben, die ein Mensch einfach durch Intuition lösen kann, welche jedoch nicht durch eine Liste formaler mathematischer Regeln beschreibbar ist, wie beispielsweise die Erkennung von gesprochenen Worten oder Gesichter in einem Bild. Zur Erlangung dieser Fähigkeit durchläuft jeder Mensch einen persönlichen Lernprozess, der durch das Sammeln von eigenen Erfahrungen geprägt ist.

Um zu verstehen wie Menschen lernen, ist zuerst ein Verständnis für die Struktur des Gehirns von Nöten. Das menschliche Gehirn besteht aus etwa 100 Milliarden Nervenzellen, die auch als Neuronen bezeichnet werden. Diese sind durch sogenannte Synapsen miteinander verbunden. Die Stärke der Verknüpfung der ca. 100 Billionen Synapsen ist abhängig von der jeweiligen Aktivität zwischen den Neuronen. Wirft man nur einen flüchtigen Blick auf ein Objekt, so ist diese Verbindung sehr schwach und kurzlebig. Durch wiederholtes Ansehen des Objekts stärkt sich die Verbindung zwischen den aktivierten Neuronen. Es entsteht ein Netz aus Neuronen mit verschieden starken Verbindungen. Diese Struktur ermöglicht ein Erlernen komplexer Muster ohne eine Abstraktion der zugrunde lie-

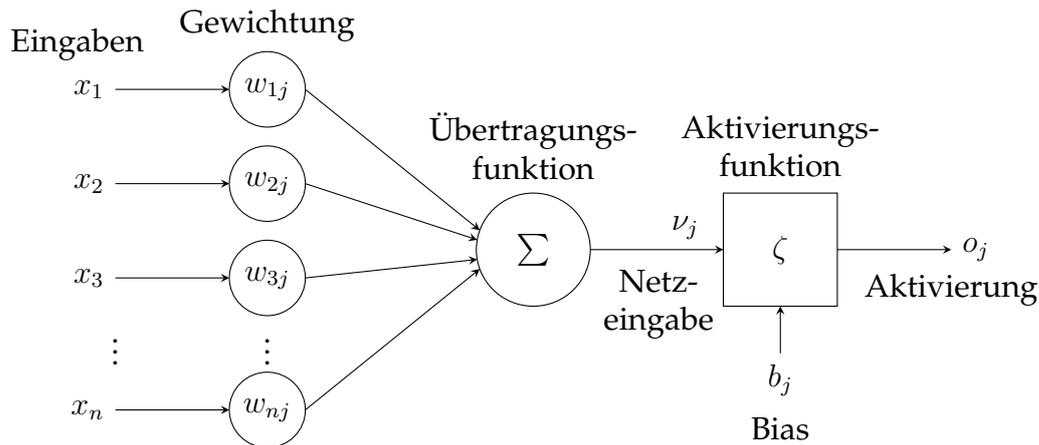


Abbildung 5.1: Modell eines künstlichen Neuron

genden Regeln. Nicht möglich ist eine nachträgliche Ermittlung einer eventuellen hinterlegten Logik in dem neuronalen Netz.

Für künstliche neuronale Netze dient die Struktur des menschlichen Gehirns als Vorbild. Im Kontext der künstlichen Intelligenz ist ein neuronales Netz eine Methode des maschinellen Lernens [139]. Maschinelles Lernen beschreibt Methoden, die einen Computer befähigen, anhand eines Grundprogramms eigenständige, intelligente Aktivitäten über die Grundprogrammierung hinaus zu erlernen. Um ein neuronales Netz auf einer Recheneinheit abzubilden, werden die Neuronen und Synapsen eines menschlichen Gehirns entsprechend adaptiert.

Die mathematische Beschreibung eines künstlichen Neurons, auch als Perzeptron bezeichnet, ist durch das Modell in Abbildung 5.1 visualisiert.

$$o_j = \zeta(\nu_j) \quad (5.1)$$

$$\nu_j = b_j + \sum_{i=1}^n x_i w_{ij} \quad (5.2)$$

Die Eingänge  $x_i$  eines Neurons können in ihrer Anzahl variieren. Sie symbolisieren die Synapsen. Mit der Gewichtung  $w_{ij}$  ist die Stärke der Verbindung zwischen den Neuronen notiert. Die Summe der Produkte aus Eingängen und Gewichten wird als Eingangsgröße der Aktivierungsfunktion  $\zeta$  bezeichnet. Der Bias  $b_j$  bewirkt eine Verschiebung der Netzeingabe  $\nu_j$ . Die Aktivierungsfunktion unterscheidet sich für unterschiedliche Netzarten und ist für gewöhnlich eine nicht-lineare Funktion. Bekannte Beispiele sind die Sigmoidfunktion und die Rectifier (ReLU) Funktion [140]. Die Aktivierung  $o_j$  repräsentiert die Ausgabe eines künstlichen Neurons. Das künstliche Neuron ist die kleinste Einheit eines künstlichen neuronalen Netzes. Ein Netz entsteht erst mit der Verknüpfung vieler Neuronen. Das einfachste zu realisierende Netz besitzt eine Ausgabeschicht in Vorwärtsrichtung und wird als einschichtiges Netz bezeichnet. Um die Abstraktion zu ver-

## 5 Klassifizierung von Radfahrern

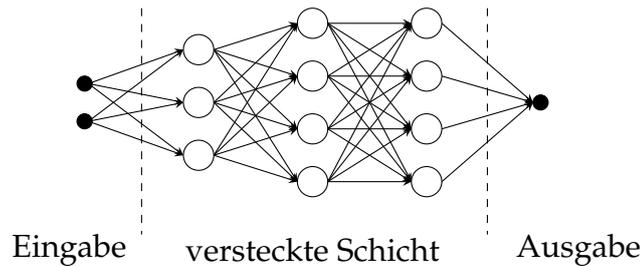


Abbildung 5.2: Exemplarische Darstellung eines tiefen neuronalen Netzes

bessern werden Netze mit mehreren Schichten gebildet. Die sogenannten mehrschichtigen, vorwärts gerichteten Netze besitzen mehrere Schichten von denen einige versteckt sind und deren Ausgabe außerhalb des Netzes nicht sichtbar ist. Umso mehr Schichten ein Netz besitzt, umso größer ist die Tiefe und man bezeichnet es dann als tiefes neuronales Netz. Um einem Netz ein Gedächtnis zu implementieren, werden zeitlich versetzte Rückkopplungen der Neuronen eingebaut. Ein solches Netz wird als rekurrentes Netz bezeichnet. Als Beispiel ist ein tiefes neuronales Netz mit mehreren versteckten Schichten in Abbildung 5.2 dargestellt.

Im Ausgangszustand ist ein solches Netz ohne Funktion. Vergleichbar mit einem menschlichen Gehirn muss es lernen. Bekannt sind drei Verfahren für das Lernen eines neuronalen Netzes. Bei allen dreien werden die Gewichte der Neuronen zufällig initialisiert. Das am weitesten verbreitete Verfahren ist das überwachte Lernen. Hierbei werden dem Netz Eingangsmuster gezeigt, deren Soll-Ausgabe bekannt ist. Die dem Lernzustand entsprechende Ist-Ausgabe des Netzes wird mit der bekannten, zu erwartenden Soll-Ausgabe verglichen. Das Netz wird so lange verändert, bis der Unterschied zwischen Ist- und Soll-Ausgabe möglichst gering wird. In der Regel wird dafür in mehrlagigen Netzen die sogenannte Backpropagation-Methode [141] angewendet.

Im Gegensatz dazu steht das unüberwachte Lernen. Dabei lernt das Netz ausschließlich von den Eingangsmustern. Das Netz ändert sich entsprechend der Eingaben dann selbständig.

Bestärkendes Lernen schließt die Aufzählung der Lernmethoden ab. Es wird dann eingesetzt, wenn nicht für jedes Eingabemuster ein passendes Ausgabemuster vorgegeben werden kann. Dem System wird eine Aufgabe gestellt, die es lösen soll. Nach einem Testlauf von mehreren Zeitschritten ist eine Bewertung möglich, anhand derer das System lernt.

### 5.1.1 Aktivierungsfunktion

Im menschlichen Gehirn werden die Neuronen durch elektrische Impulse, ankommend durch mehrere Synapsen, aktiviert und dazu angeregt, ebenfalls einen elektrischen Impuls abzugeben. Um diesen Mechanismus in einem künstlichen,

neuronalen Netz nachzubilden, wird mit Hilfe einer Aktivierungsfunktion die Entscheidung anhand der Netzeingabe  $\nu_j$  getroffen. Ohne eine solche Funktion ist der Ausgabebereich eines Neuron linear von  $-\infty$  bis  $\infty$ . Die Aufgabe der Funktion besteht darin, den gesamten Ausgabebereich auf einen vordefinierten Bereich zu limitieren.

Eine sehr naheliegende Aktivierungsfunktion ist durch die Sprungfunktion gegeben, visualisiert in Abbildung 5.3a. Anhand eines Schwellwertes wird entschieden, ob die Ausgabe 0 oder 1 ist. Mit dieser Variante einer Aktivierungsfunktion werden sehr gute Ergebnisse bei einfachen Ja / Nein Entscheidungen erzielt. Wird jedoch der binäre Ausgaberaum des Netzwerkes überschritten, beispielsweise durch mehrere Klassen, in die unterteilt werden soll, stößt ein kleines Netz sehr schnell an seine Grenzen bzw. muss für eine relativ simple Aufgabe eine Netzstruktur mit sehr vielen Neuronen gewählt werden. Um dies zu Umgehen, ist eine anteilige Aktivierung eines Neurons erstrebenswert, was zu einem größeren Ausgabebereich führt.

Mit einer Funktion erster Ordnung ist das Problem der binären Aktivierung auf äußerst triviale Weise gelöst. Durch die Linearität dieser Funktion entsteht eine neue Herausforderung in der Methode der Backpropagation, eine detaillierte Beschreibung wird in Unterabschnitt 5.1.2 erörtert, die das Gradientenverfahren anwendet. Für die Ableitung nach  $x$  ist der Gradient für  $o_j = c\nu_j$  konstant  $c$ , was wiederum zu einer Unabhängigkeit von  $x$  führt. Kommt es während des Lernvorgangs zu einem Prädiktsfehler, dann sind die Änderungen durch die Backpropagation ebenfalls konstant und führen zu keiner eingangsabhängigen Änderung. Werden alle Schichten eines Netzwerkes mit einer linearen Funktion aktiviert, so ist der Ausgang eine Linearkombination aller Schichten und kann somit vereinfachend auf eine Schicht reduziert werden. Dadurch verliert das Netz seine Tiefe und die Komplexität der mit dem Netz lösbaren Aufgabe sinkt ebenfalls. Um diesem Nachteil entgegenzuwirken, werden je nach Anwendungsfall verschiedene nichtlineare Funktionen zur Aktivierung eingesetzt.

Die Sigmoidfunktion ist eine für Klassifizierungsaufgaben weit verbreitete Variante der Aktivierung [138]. Eine Darstellung des Verlaufs des  $o_j = \frac{1}{1+e^{-\nu_j}}$  Sigmoid ist in Abbildung 5.3c gegeben. Eine Kombination aus mehreren Schichten liefert eine Aktivierung, die nicht linear ist, wodurch eine Degenerierung der Schichten verhindert wird. Durch die Charakteristika der Funktion wird der Wertebereich der Ausgabe auf 0 bis 1 reduziert, wodurch es zu keiner dominanten Aktivierung im Netz kommen kann. Im Abszissenbereich von -2 bis 2 zeichnet sich der Sigmoid durch eine sehr steile Steigung aus, was dazu führt, den Wert der Funktion schnell in eine bestimmte Tendenz zu leiten. Dies führt zu klaren Unterscheidungen in der Vorhersage. Einen kleinen Nachteil hat diese Funktion jedoch inne. Sie ändert sich in den flachen Seitenbereichen, in denen sie sich ihrem Maxima und Minima annähert, für jedes  $\nu_j$  nur sehr geringfügig. Dadurch kommt es im Gradientenverfahren zu sehr kleinen Änderungen, was oftmals dazu führt, dass die Trainingszeit sich deutlich verlängert oder keine Verbesserung mehr durch zu-

## 5 Klassifizierung von Radfahrern

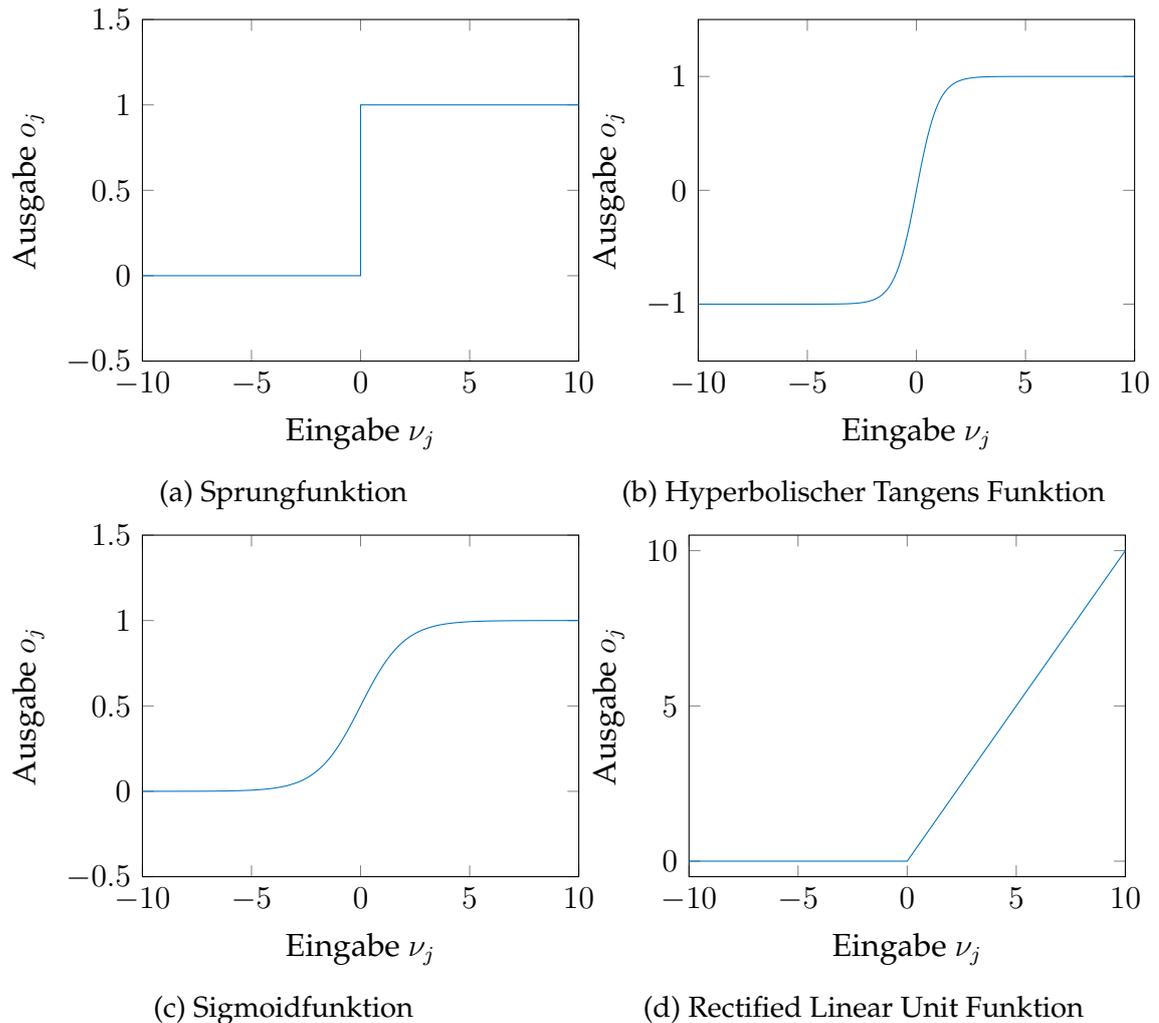


Abbildung 5.3: Verschiedene Aktivierungsfunktionen des Neuronenausgang

sätzliches Training erzielt werden kann.

Ähnlich der Sigmoidfunktion verläuft der hyperbolische Tangens. Es ist möglich ihn als Sigmoid zu beschreiben.

$$\tanh(x) = 2\text{sigmoid}(2x) - 1 \quad (5.3)$$

Der hyperbolische Tangens zeigt sehr ähnliche Eigenschaften wie der Sigmoid. Feine Unterschiede liegen im Wertebereich von -1 bis 1 und in der etwas höheren Steigung. Abhängig von der Anforderung an den Gradienten im Lernprozess ist die Auswahl zwischen diesen beiden Aktivierungsfunktionen zu treffen.

Als letzte und in den aktuellen Varianten von neuronalen Netzen am häufigsten anzutreffende Aktivierungsfunktion ist die Rectified Linear Unit (ReLU) Funktion zu nennen [142]. Dargestellt in Abbildung 5.3d ist zu erkennen, dass es sich hierbei ebenfalls um eine nicht lineare Funktion handelt. Damit ist eine Degenerierung

des Netzes ausgeschlossen. Der Wertebereich ist für diese Funktion unbegrenzt von 0 bis  $\infty$ . Im Kontrast zum Sigmoid und des hyperbolischen Tangens sind bei einer ReLU Funktion nicht immer alle Neuronen aktiv. Dadurch wird das Netzwerk etwas ausgedünnt, was zur Einsparung von Prozessierungsleistung führt. Mit der Gradienten Backpropagation ist der negative Zahlenbereich ebenfalls im Gradient 0. Dies führt zu einem „Sterben“ der Neuronen, da diese ihren Wert nicht mehr verändern. Um dies zu vermeiden wird oftmals anstelle von 0 im negativen Zahlenspektrum 0,1 verwendet, um den Neuronen eine Chance zu geben, sich über mehrere Iterationen wieder als Netzbestandteil zu etablieren.

### 5.1.2 Backpropagation

Für die am weitesten verbreitete Lernmethode des überwachten Lernens, hat sich die Backpropagation oder auch Fehlerrückführung etabliert. Sie ermöglicht eine automatische Fehlerminimierung des neuronalen Netzes. Dabei ist es notwendig zu jeder Eingabe  $\vec{\eta}$  den erwarteten Ausgabewert  $\vec{\varrho}$  zu kennen. Der Ablauf des Backpropagation-Algorithmus gliedert sich in drei Phasen. Beginnend mit dem Anlegen des Eingabemuster an der Netzeingabeschicht, über den Vergleich der Netzausgabe mit der Referenz und Bestimmung der Differenz, welche den Netzfehler beschreibt, bis hin zur letzten Phase mit der Minimierung des Netzfehlers, durch Anpassen der Neuronengewichtung in Abhängigkeit ihres Einfluss auf den Fehler für jede Schicht von der Ausgabe- bis zur Eingabeschicht. Die nachfolgenden Ausführungen orientieren sich an [141, 143]

Der Netzfehler wird beschrieben anhand der Kostenfunktion  $C(X, \xi)$ .

$$C(X, \xi) = \frac{1}{2G} \sum_{i=1}^G \|\vec{\varrho}_i - \vec{o}^J\|_2^2 = \frac{1}{2G} \sum_{i=1}^G \sum_{l=1}^{n_D} (\varrho_l - o_l^D)^2 \quad (5.4)$$

Zur Bestimmung wird ein Trainingsdatensatz  $X = [(\vec{\eta}_1, \vec{\varrho}_1), \dots, (\vec{\eta}_G, \vec{\varrho}_G)]$  mit  $G$  bekannten Ein- und Ausgabepaaren angewendet. Ebenso fließt die Gesamtheit der Parameter eines neuronalen Netzes mit  $J$  Schichten zusammengefasst als  $\xi = [\vec{w}^1, \vec{b}^1, \dots, \vec{w}^J, \vec{b}^J]$  mit ein. Die Anzahl der eingehenden Verbindungen eines Neuron der letzten Schicht wird mit  $n_D$  bezeichnet. Die Aktivierung  $o$  eines Neurons ist bekannt aus Gleichung 5.1, und mit  $\vec{o}^J$  wird die Aktivierung der letzten Schicht für jedes Trainingsdatenpaar bezeichnet. Ziel ist es, die Kostenfunktion auf ein Minimum zu optimieren. Ein typisches Optimierungsverfahren für den gegebenen Anwendungsfall ist das Gradientenverfahren [144]. Für den Gradient der Kostenfunktion  $C$  unter Berücksichtigung aller Parameter  $\xi$  und des Trainingsdatensatz  $X$  gilt:

$$\nabla C(X, \xi) = \frac{\partial C(X, \xi)}{\partial \xi} = \left[ \frac{\partial C(X, \xi)}{\partial \vec{w}^1}, \frac{\partial C(X, \xi)}{\partial \vec{b}^1}, \dots, \frac{\partial C(X, \xi)}{\partial \vec{w}^J}, \frac{\partial C(X, \xi)}{\partial \vec{b}^J} \right] \quad (5.5)$$

## 5 Klassifizierung von Radfahrern

Folgt man der Richtung des Gradienten  $\nabla C (X, \xi^\beta)$  zu einer Epoche  $\beta$ , dann wird eine minimierte Kostenfunktion  $C (X, \xi^{\beta+1})$  gefunden. Als Epoche wird der Zeitraum bezeichnet, der benötigt wird, um alle Beispiele im Training gesehen zu haben.

$$\xi^{\beta+1} = \xi^\beta - \gamma \nabla C (X, \xi^\beta) \quad (5.6)$$

Als Lernrate wird der Skalierungsfaktor  $\gamma$  bezeichnet. Die Parametrisierung der Lernrate beeinflusst die Lerndauer eines neuronalen Netzes. Es wird ein Kompromiss zwischen Lernerfolg und Lerndauer benötigt [145]. Das Gradientenverfahren kann lokale Minima nicht vom globalen Minimum unterscheiden. Methoden, um dies zu verhindern, sind in [146] beschrieben.

Zur Bestimmung des Gradienten ermöglicht die Backpropagation eine rekursive Berechnung der einzelnen Ableitungen [147]. Die Kostenfunktion  $C_i(X_i, \xi)$  für ein einzelnes Trainingsbeispielpaar  $(\vec{\eta}_i, \vec{\varrho}_i)$  mit eingesetzter Aktivierungsfunktion  $o_l^D = \zeta(\nu_l)$  und der gewichteten Eingabe  $\nu_l^D = b_l^D + \sum_{k=1}^{n_D} o_k^{D-1} w_{kl}^D$  ist der Ausgangspunkt zur Bestimmung des Gradienten.

$$C_i(X_i, \xi) = \frac{1}{2} \sum_{l=1}^{n_D} (\varrho_l^D - \zeta(\nu_l^D))^2 \quad (5.7)$$

Unter Anwendung der Kettenregel

$$\begin{aligned} \frac{\partial C_i}{\partial w_{lk}^D} &= \frac{\partial \nu_l^D}{\partial w_{lk}^D} \frac{\partial o_l^D}{\partial \nu_l^D} \frac{\partial C_i}{\partial o_l^D} \\ \frac{\partial C_i}{\partial b_l^D} &= \frac{\partial \nu_l^D}{\partial b_l^D} \frac{\partial o_l^D}{\partial \nu_l^D} \frac{\partial C_i}{\partial o_l^D} \end{aligned} \quad (5.8)$$

und mit  $d = D$  erhält man für die letzten Elemente des Gradienten.

$$\begin{aligned} \frac{\partial C_i}{\partial w_{lk}^D} &= \sum_{k=1}^{n_D} o_k^{D-1} \zeta'(\nu_l^D) (\varrho_l^D - o_l^D) \\ \frac{\partial C_i}{\partial w_{lk}^D} &= \zeta'(\nu_l^D) (\varrho_l^D - o_l^D) \end{aligned} \quad (5.9)$$

Die Aktivierung der vorherigen Schicht  $o_k^{D-1}$  beeinflusst die Kostenfunktion folgendermaßen.

$$\frac{\partial C_i}{\partial o_k^{L-1}} = \frac{\partial \nu_l^D}{\partial o_k^{L-1}} \frac{\partial o_l^D}{\partial \nu_l^D} \frac{\partial C_i}{\partial o_l^D} \quad (5.10)$$

Für  $d < D$  erhält man die allgemeine Form.

$$\frac{\partial C_i}{\partial o_k^d} = \frac{\partial \nu_l^{d+1}}{\partial o_k^d} \frac{\partial o_l^{d+1}}{\partial \nu_l^{d+1}} \frac{\partial C_i}{\partial o_l^{d+1}} \quad (5.11)$$

Zur rekursiven Bestimmung des Gradienten gilt Folgendes.

$$\begin{aligned} \frac{\partial C_i}{\partial w_{lk}^d} &= \frac{\partial \nu_l^d}{\partial w_{lk}^d} \frac{\partial o_l^d}{\partial \nu_l^d} \frac{\partial C_i}{\partial o_l^d} \\ \frac{\partial C_i}{\partial b_l^d} &= \frac{\partial \nu_l^d}{\partial b_l^d} \frac{\partial o_l^d}{\partial \nu_l^d} \frac{\partial C_i}{\partial o_l^d} \end{aligned} \quad (5.12)$$

Für den Algorithmus zur Bestimmung des Gradienten gilt folgender Formalismus.

$$\begin{aligned} \delta_l^d &= \frac{\partial C_i}{\partial w_{lk}^d} = \sum_{k=1}^{n_d} w_{lk}^{d+1} \delta_k^{d+1} \zeta'(\nu_l^d) \\ \delta_l^d o_k^{d-1} &= \frac{\partial C_i}{\partial b_l^d} \end{aligned} \quad (5.13)$$

Um den Gradient für alle Trainingsbeispiele zu berechnen, wird dieser aufsummiert und gemittelt.

$$\nabla C(X, \xi) = \frac{1}{N} \sum_{i=1}^N \nabla C_i(X_i, \xi) \quad (5.14)$$

Ausgenutzt werden kann dieser Sachverhalt zur Beschleunigung des Trainings. Es wird nur über eine bestimmte Untermenge der Trainingsdaten, der MiniBatch, gemittelt. In der Literatur ist dies unter dem Namen stochastisches Gradientenverfahren zu finden und liefert dieselben Ergebnisse wie das Gradientenverfahren.

### 5.1.3 Faltende Neuronale Netze

Eine weit verbreitete Form tiefer neuronaler Netze sind die faltenden, neuronalen Netze (Convolutional Neural Network (CNN)). Den Durchbruch erlangten sie mit der Idee, lediglich Gewichte von kleinen Faltungskernen zu lernen, die über die mehrdimensionale Eingabe bewegt werden, und ein gefiltertes Bild (Channel) generieren [148, 149]. Mittlerweile werden sie bei einer Vielzahl von Anwendungen eingesetzt, wobei die Objekterkennung in Bildern [150], die Spracherkennung [151] und die Steuerung von Robotern [152] die bekanntesten sind. In dieser Arbeit steht die Verwendung in der Bildverarbeitung und darin die Klassifizierung von Objekten im Fokus.

Diese Netze sind aus mehreren faltenden Schichten zusammengesetzt, siehe ex-

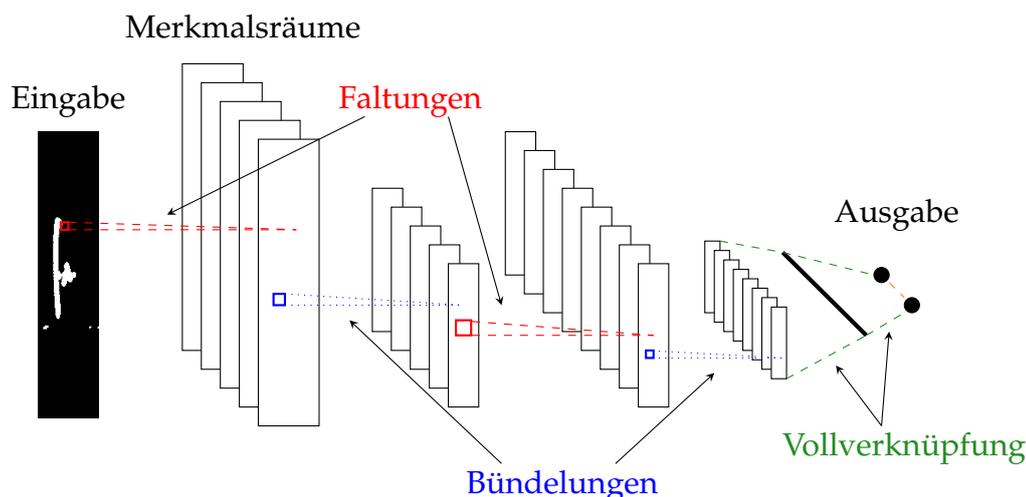


Abbildung 5.4: Beispiel eines faltenden Netzwerk

empirisch Abbildung 5.4. Jede faltende Schicht erhöht die Abstraktionsebene der Eingabedaten und liefert Merkmalsräume (feature maps), aus denen komplexe Informationen gewonnen werden. Zur Reduzierung der Parameter werden Bündelungsschichten (Pooling) zwischen die faltenden Schichten eingefügt. Durch Zusammenfassen von Bildpunkten eines Channel zu einer Ausgabe wird die Größe der Merkmalsräume komprimiert. Als Klassifikatoren dienen anschließend an die letzte Faltungsschicht mehrere voll verknüpfte Schichten.

Als Eingabe einer faltenden Schicht wird ein zwei- oder dreidimensionaler Tensor verwendet. Mit einer diskreten Faltung wird die Aktivität eines jeden Neurons berechnet. Hierfür wird eine kleine Faltungsmatrix (Filterkernel  $F$ ) über die Eingabedaten bewegt. Die Ausgabe  $o^l$  eines Neurons in der faltenden Schicht berechnet sich als Produkt des Filterkernel der Größe  $\Gamma$  und dem aktuellen unterliegenden Bildausschnitt [138], abgebildet in Abbildung 5.5.

$$o^l(x, y) = (F * o^{l-1})(x, y) = \sum_{i=1}^{\Gamma} \sum_{j=1}^{\Gamma} o(x-i, y-j) F(i, j) \quad (5.15)$$

Die Neuronen der faltenden Schicht reagieren auf Reize einer lokalen Umgebung in Bildern der vorigen Schicht. Biologisches Vorbild für dieses Verhalten ist das rezeptive Feld des Auges. Dabei werden Bereiche, bestehend aus vielen Rezeptoren, auf wenige Ganglienzellen (Nervenknotten) abgebildet. Die Gewichte, welche denen des Filterkerns entsprechen, sind für eine faltende Schicht identisch.

Um das Netz robust gegenüber kleinen Variationen in der Eingabe zu präparieren und die Anzahl der Gewichte zu reduzieren, wird eine Bündelungsschicht (Pooling) eingesetzt. Dabei werden je nach Größe des Pooling nebeneinander liegende Werte zusammengefasst. Dabei gibt es zwei Methoden der Zusammenfassung, als Maximum oder als Mittelwert aus allen Werten. Üblicherweise wird in

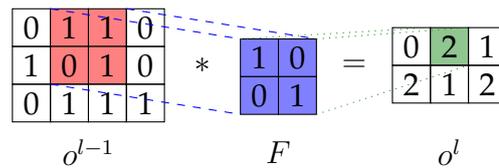


Abbildung 5.5: Zweidimensionale diskrete Faltung

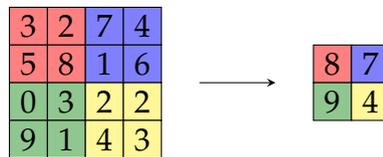


Abbildung 5.6: Max Pooling mit einem 2x2-Filter und Schrittweite 2

faltenden Netzen das Max Pooling gewählt, da es in der Erfassung von Invarianzen überlegen ist [153]. Beispielhaft ist das Max Pooling in Abbildung 5.6 visualisiert.

Zur Optimierung der benötigten Trainingsschritte konnte in [154] gezeigt werden, dass eine Normierung der Aktivierungen aller Neuronen im Mittel zu 0 mit Standardabweichung 1 dazu führt, dass eine Änderung der Gewichte in einer höheren Schicht keine Anpassung der darunterliegenden Schichten bedarf. In der Literatur ist dies als Batch Normalisation bekannt.

Das Trennen der Eingabe in die gewünschte Ausgabeklasse übernimmt ein klassisches, voll verknüpftes neuronales Netz. Die letzte Schicht des faltenden Netzes ist die Eingabe für das neuronale Netz. Mit der Anzahl der Eingabeneuronen steigt die benötigte Anzahl an Parametern überproportional an.

Durch zufälliges Eliminieren von Verbindungen zwischen Neuronen wird das Netz dazu gezwungen, verschiedene Repräsentationen des Klassifizierungsproblems zu erlernen. Dieser Dropout wird sehr häufig zwischen den voll verknüpften Schichten durchgeführt.

Am Ausgang eines neuronalen Netzes wird eine Softmax Schicht verwendet. Sie skaliert den Ausgabevektor der letzten Schicht auf Werte zwischen 0 und 1 unter der Bedingung, dass sie in Summe 1 ergeben. Dadurch wird dieses Maß häufig als Pseudowahrscheinlichkeit der Klassenzugehörigkeit interpretiert.

## 5.2 Bereichsdetektion

Vor der Klassifizierung von Objekten steht die Detektion von Bereichen oder Regionen in den Eingabedaten an. Mit ihr wird ein Teilausschnitt extrahiert und anschließend an den Klassifikator übergeben. Häufig verwendet werden dafür Clustering Algorithmen [90], die einzeln erfasste Datenpunkte zu einem Objekt zusammenfassen. Weit verbreitet ist der Density-Based Algorithm for Discovering Clusters in Large Spatial Databases with Noise (DBSCAN) [155]. Die so zu-

sammengefassten Parameter detektieren einen Bereich in den Eingabedaten, der als passenden Ausschnitt für den Klassifikator freigestellt wird. Alternativ, direkt im Bildbereich, wurde eine neue Methode zum Clustern in dieser Arbeit entwickelt. Eine detaillierte Beschreibung folgt in Unterabschnitt 5.2.1. Im Bereich der neuronalen Netze wurde diese Aufgabe ebenfalls bearbeitet. Dabei wurden sogenannte Bereichsdetektionsnetzwerke (Region Proposal Network (RPN)) entwickelt. In Kombination mit einem faltenden Netz ermöglichen diese eine direkte Klassifizierung eines Objekts und die Ermittlung des Bereichs in dem das Objekt sich befindet. Näheres dazu ist in Unterabschnitt 5.2.2 zu finden.

### 5.2.1 Clustering im Bildbereich

Ein physikalisches Objekt dehnt sich bei hochauflösenden Radarsensoren über mehrere Messinkremente in der Abbildungsebene aus. Nach der sensorspezifischen Signalverarbeitung liegt primär eine Belegungskarte des Messbereichs vor. Bei einem Radarsensor beispielsweise das Entfernung- und Geschwindigkeitsspektrum mit den extrahierten Streuzentren. Um Messpunkte, erfasst an einem physikalischen Objekt, zu einem Objekt zusammenzufassen, werden spezielle Algorithmen benötigt. Für den Einsatz in der Abbildungsebene eines Radarsensors wurde im Laufe dieser Arbeit ein Algorithmus adaptiert und in [156] vorgestellt. Die nachfolgenden Ausführungen stellen das Verfahren und die Adaption auf Radardaten vor und geben einen Überblick der Anwendbarkeit.

Das zu Grunde liegende Verfahren kommt aus der digitalen Bildverarbeitung und ist bekannt als Border Following [157]. Es findet Anwendung in der Analyse von Strukturen, wie beispielsweise Kanten in einem Bild. Die klassische Methodik erzielt eine hohe Funktionalität bei Strukturen, deren Abbildung sich durchgehend über benachbarte Pixel erstreckt. Bei Unterbrechungen von einem bis zu mehreren Pixeln, werden zwei Strukturen erkannt. Um auftretende Lücken in einer Struktur bis zu einem definierten Abstand zuzulassen, ist eine Weiterentwicklung der Border Following Algorithmen [158], die zur Anwendung in der automatischen Texterkennung entwickelt wurden, zu verwenden. Beide Varianten des Algorithmus verwenden binäre Bilder als Eingangsdaten. Per Definition ist der Pixelwert 0 gleich schwarz und der Pixelwert 1 gleich weiß.

Der essenzielle Teil des Algorithmus in [158] ist die Verwendung einer Suchmaske mit variabler Größe. Damit lässt sich anwendungsbezogen die Nummer der zugelassenen Pixellücken regulieren. Die formale Bezeichnung der Suchmaske ist  $(m, n)$ -Maske. Mit den Parametern  $m$  und  $n$  lässt sich die Suchmaskengröße steuern.

$$(m, n)\text{-Maske} = (2m + 1) \times (2n + 1) \quad (5.16)$$

Zwei Beispiele einer solchen Suchmaske sind in Abbildung 5.7 visualisiert. Die  $(1, 1)$ -Maske entspricht einer Suchmaske, wie angewendet im klassischen Algorithmus ohne eine Möglichkeit, Lücken zu überbrücken. Die Markierung  $\times$  in der



## 5 Klassifizierung von Radfahrern

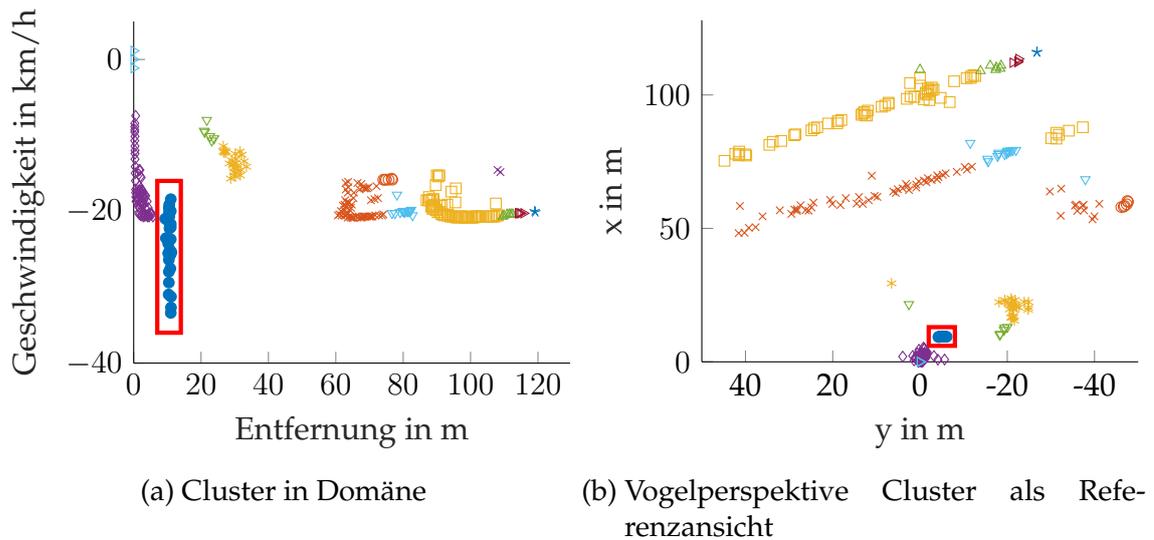


Abbildung 5.8: Ergebnis des Clusterings in der Entfernungs- und Geschwindigkeitsdomäne mit einer (25,15)-Suchmaske auf Basis aufgezeichneter Messdaten

Der Algorithmus findet Strukturen in Bildern anhand ihrer äußeren Kanten. Für Radardaten ist dies noch nicht ausreichend. Es werden sowohl die Randdaten eines Objekts als auch die im Objekt liegenden Punkte benötigt. Hierfür besteht die Notwendigkeit den Suchmaskendurchlauf zu modifizieren. Dieser darf nicht beim ersten neu gefundenen Pixel stoppen, sondern muss komplett durchlaufen werden und alle Pixel mit dem Wert 1, mit der aktuellen Strukturnummer überschreiben. Die Suchmaske wird anschließend auf das zuerst gefundene Pixel verschoben.

Um Datenverlust durch das Verwenden des Rahmens, gefüllt mit Nullwerten, zu vermeiden, wird das Bild um einen äußeren Rahmen mit vordefiniertem Wert 0 erweitert. Der äußere Rand hat die Größe  $m+1$  von der Bild Ober- und Unterkante nach außen bzw.  $n+1$  vom rechten und linken Bildrand nach außen.

Durch Ignorieren einer Messdimension kommt es zu mehrfacher Belegung ein und desselben Pixels in einem Bild. Um Verlust von Datenpunkten zu vermeiden werden diese mit allen drei Messgrößen beibehalten und alle mehrfachen Pixel in das Cluster aufgenommen.

Naheliegender anzuwenden ist diese Methode in den sich aus den Messbereichen ergebenden Bildkombinationen. Dazu zählt die Entfernungs- und Geschwindigkeitskombination, die Geschwindigkeits- und Richtungskombination sowie die Richtungs- und Entfernungskombination. Fokussiert auf das Clustering eines Radfahrers wurden die Kombinationen empirisch auf ihre Eignung hin untersucht.

In der Entfernungs- und Geschwindigkeitsdomäne konnte ein gutes Ergebnis für bewegte Radfahrer beobachtet werden. Eine Auswertung ist in Abbildung 5.8 dargestellt. Der Radfahrer ist mit dem roten Rechteck gekennzeichnet. Alle Streu-

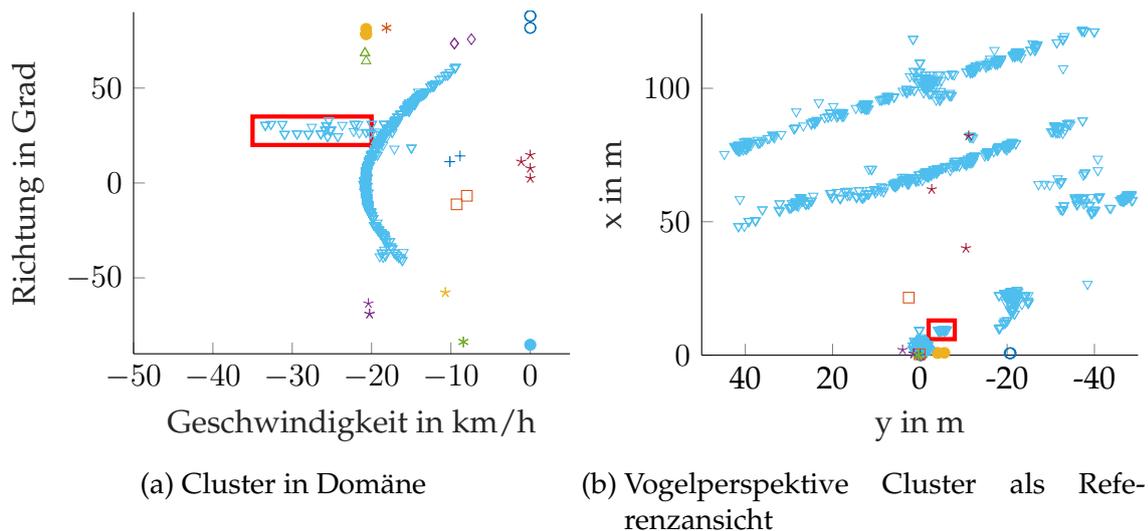


Abbildung 5.9: Ergebnis des Clustering in der Geschwindigkeits- und Richtungsdomäne mit einer (25,15)-Suchmaske auf Basis aufgezeichneter Messdaten

zentren, die dem Objekt zugehörig sind, wurden zu einem Cluster gruppiert. Die jeweils erkannten Cluster sind farblich und symbolisch markiert. Deutlich zu erkennen ist, dass sich diese Domäne nicht für Standziele eignet. Im gezeigten Beispiel bewegt sich nur der Radfahrer. Dies führt dazu, dass Streuzentren mit gleicher Entfernung zum Radar, jedoch aus unterschiedlicher Richtung kommend, zusammengefasst werden obwohl sie in der Realität voneinander entfernt liegen und nicht zum selben physikalischen Objekt gehören.

Die Geschwindigkeits- und Richtungsdomäne zeigt sich als ungeeignet zum Einsatz der Clustermethode. Sowohl bei stehenden als auch bei bewegten Objekten ist die Trennung nicht ausreichend und es wird ein umfangreiches Cluster gebildet, in dem sich fast alle Streuzentren befinden. Abbildung 5.9 zeigt wieder das Beispiel eines bewegten Radfahrers. Wiederum sind die Cluster farblich und symbolisch gekennzeichnet. Die rote Umrahmung markiert den Radfahrer. Aufgrund der gleichen Geschwindigkeit der stehenden Objekte und die Überdeckung entlang eines großen Winkelbereichs, lässt sich der Radfahrer nicht von den stehenden Objekten trennen.

Die Richtungs- und Entfernungsdomäne stellt sich als am besten geeignet zum Einsatz des Verfahrens dar. Für stehende und bewegte Objekte ist eine Trennung und damit ein Clustern der Objekte möglich. Nach Transformation dieser Domäne von der Polardarstellung zu kartesischen Koordinaten erhält man die Referenzansicht, wobei die gute Eignung nicht überrascht. Aus Abbildung 5.10 ist das Ergebnis gut zu erkennen. Lediglich durch Betrachtung der räumlichen Position ist es die zu bevorzugende Domäne.

## 5 Klassifizierung von Radfahrern

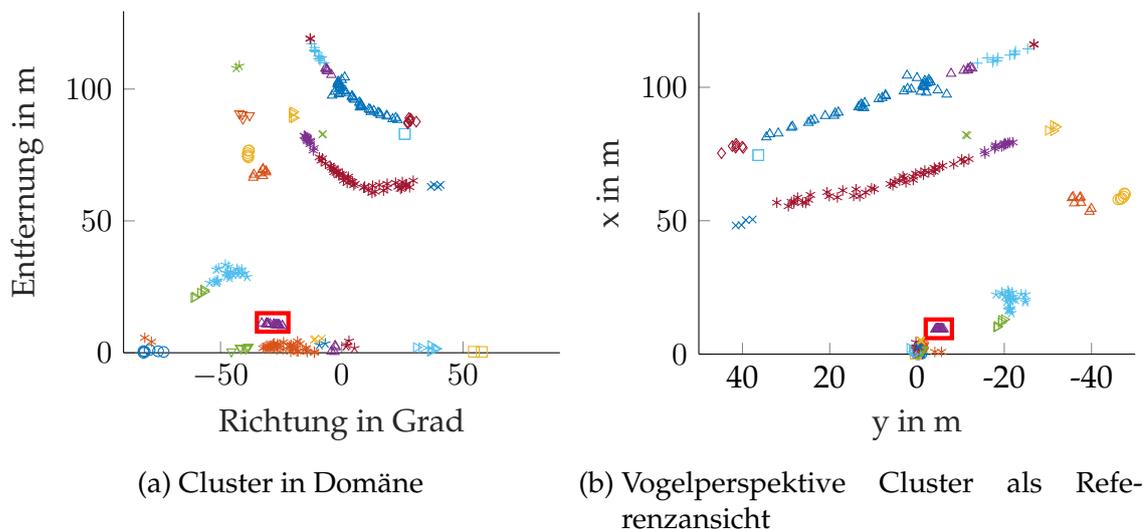


Abbildung 5.10: Ergebnis des Clusterings in der Richtungs- und Entfernungsdomäne mit einer (25,15)-Suchmaske auf Basis aufgezeichneter Messdaten

### 5.2.2 Bereichsdetektionsnetzwerk

In einem Bild, ob von einer Videokamera oder mit einem Radar generiert, können mehrere Objekte abgebildet sein. Um diese zu klassifizieren, ist es notwendig, vorab den interessierenden Bereich zu lokalisieren. Hierfür werden unter anderem sogenannte Region Proposal Netzwerke (RPNs) eingesetzt. Sie sind für gewöhnlich einem faltenden neuronalen Netz vorgelagert, um den Inhalt der detektierten Region direkt zu klassifizieren. Eine erste Kombination von Bereichserkennung und Klassifizierung mit einem Netzwerk wurde in [159] vorgestellt, auch bekannt unter der Bezeichnung R-CNN (Region-based CNN). Das Eingabebild wird mit einem selektiven Suchalgorithmus (selective search algorithm [160]) auf mögliche Bereiche mit Objekten durchsucht und generiert über 2000 Vorschläge. Jeder Vorschlag wird einem CNN zugeführt. Dessen Ausgabe speist eine SVM zur Klassifizierung der Bereichsinhalte. Dieser triviale Ansatz ist sehr rechenaufwendig und durch den nicht adaptiven Suchalgorithmus dazu neigend, schlechte Regionsvorschläge zu generieren.

Eine Weiterentwicklung des R-CNN vom selben Autor wurde als Fast R-CNN bekannt [161]. Der Unterschied besteht darin, das Eingabebild direkt einem CNN zuzuführen und die generierten Merkmalsräume anschließend der Regionsuche mit dem selektiven Suchalgorithmus zu übergeben. In den Merkmalsräumen werden die Bereiche gesucht und auf eine fixe Größe justiert, um in eine voll verknüpfte Schicht mit anschließender Softmax Schicht eingespeist zu werden. Durch das Einsparen einer großen Anzahl an SVMs und CNNs wird die Geschwindigkeit der Auswertung signifikant erhöht. Das Nadelöhr des selektiven Suchalgorithmus bleibt jedoch weiterhin bestehen.

Um den letzten limitierenden Faktor zu eliminieren, wurde ein weiterer Entwicklungsschritt in [162] unter dem Namen Faster R-CNN vorgestellt. Es nutzt ein RPN, dessen Eingang mit der letzten Schicht eines initialen CNN gespeist wird. Seine Ausgabe ist ein Set an rechteckigen Bereichsvorschlägen, wovon jedem Vorschlag ein Bewertungswert mitgeliefert wird. Zur Generierung der Bereichsvorschläge mit Objekten als Inhalt, wird ein kleines Netzwerk (RPN) über die letzte faltende Schicht des initialen CNN geschoben. Dieses besteht aus einem Klassifizierer und einem Regressor. Im folgenden Kontext wird ein Satz von Parametern zur Rotation und Skalierung eines Bildes, abhängig von den Eingabedaten, als Regressor bezeichnet. Eingeführt wurden sogenannte Anker, welche den Mittelpunkt des Verschiebefenster beschreiben. Mit dem Klassifizierer wird die Wahrscheinlichkeit für ein Objekt im untersuchten Bereich ermittelt und der Regressor liefert die zugehörigen Koordinaten. Für jedes Pixel werden mehrere Ankerboxen mit unterschiedlicher Skalierung und Seitenverhältnissen vorgeschlagen. Da einige dieser Ankerboxen eine große Überlappung untereinander haben, wird zur Vermeidung von redundanter Information der Non-Maximum Suppression (NMS) [163] Algorithmus eingesetzt, basierend auf der Klassifizierungswahrscheinlichkeit der Ankerbereiche. Nach Anwendung des NMS werden die wahrscheinlichsten Vorschläge bis zur Anzahl  $s$  verwendet.

Der Trick, wodurch Faster R-CNN schneller wird, liegt in der simultanen Verwendung der letzten Schicht des initialen CNN für die Bereichsdetektion und die Klassifizierung des im Bereich lokalisierten Objekts. Um dies zu gewährleisten, müssen die Eingabedaten für das Klassifizierungsnetz dieselbe Größe aufweisen. Dies ist nach dem RPN allgemein nicht der Fall. Hierfür wird eine spezielle Bündelungsschicht für die Bereiche benötigt, bezeichnet als interessierende Bereichsbündelung (Region of Interest (ROI) pooling) [161]. Der Ausschnitt, gekennzeichnet durch die Bereiche aus dem Merkmalsraum der letzten Schicht des initialen CNN, wird unterteilt in die Anzahl an benötigten Eingabedaten mit möglichst gleich großen Teilen. Die Region muss nicht zwingend ganzzahlig teilbar durch die Eingabegröße sein. Mit Max Pooling wird die Unterteilung des Bereichs in die richtige Größendimension überführt.

Für das Training des RPN ist ebenfalls Backpropagation mit dem stochastischen Gradientenverfahren anwendbar. Für detaillierte Informationen gilt der Verweis auf [162].

## 5.3 Datenpräparation

Zur Anwendung von neuronalen Netzen in der Klassifizierung werden Trainings- und Testdaten benötigt. Daten, die während des Training einem Netz gezeigt werden, sind dem Validierungsprozess fernzuhalten und umgekehrt. Konventionell ist die Erzeugung solcher Datensätze mit erhöhtem Aufwand verbunden. Die Generierung erfolgt durch Aufnahmen von Messreihen in großer Anzahl. Einfach gesagt, je mehr Daten, desto besser. Diese Aussage ist nicht allgemeingültig, deckt

## 5 Klassifizierung von Radfahrern

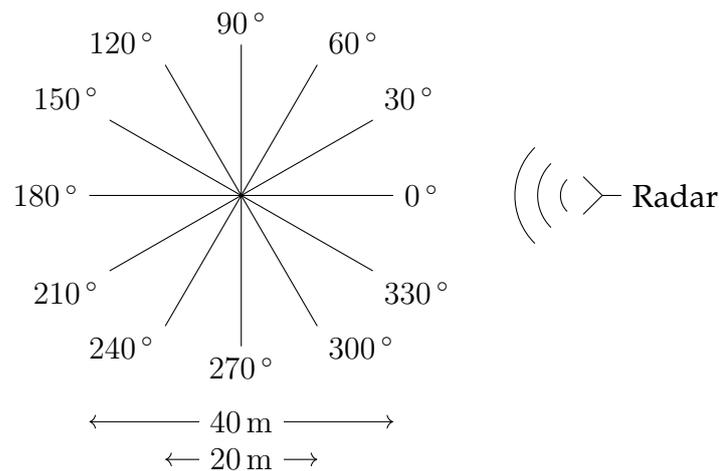


Abbildung 5.11: Schematischer Messaufbau zur Erzeugung/Messung von Trainings- und Testdaten

aber einen großen Teil der Anwendungen ab, in denen neuronale Netze und insbesondere faltende Netze eingesetzt werden. Nicht nur die Erstellung der Menge an Daten stellt eine Herausforderung dar, sondern vor allem auch die Markierung (sogenanntes Labeling) der Dateninhalte und deren Lokalisierung ist mit einem hohen, zum Teil nicht automatisierbaren Aufwand gekoppelt. Eine weitere Bedingung an die Datensätze besteht in der Abbildung möglichst aller Variationen der zu klassifizierenden Inhalte. Nur mit ausreichender Abdeckung des Variantenreichtums können die Netze eine Generalisierungsfähigkeit erreichen.

### 5.3.1 Generierung von Trainings- und Testdaten

Für die Generierung der Trainings- und Testdatensätze besteht die Notwendigkeit eine geeignete zweidimensionale Abbildung der aus dem Radarsensor gewonnenen Informationen zu definieren. Den Ausführungen in Kapitel 4 folgend, trägt die Objektausdehnung und Geschwindigkeit zu einem massiven Anteil an der Charakterisierung eines Radfahrers in den Radardaten bei. Eine sich dafür gut eignende Darstellung der Signalinformation stellt das Entfernungs- und Geschwindigkeitsspektrum dar. Es bietet neben den charakteristischen Informationsanteilen auch noch eine kontinuierliche Auflösung über den gesamten Messbereich, was zu einer einfachen Generierung in Bildform führt. Ohne Kompensation der entfernungsabhängigen Signaldämpfung ist eine Auswertung der Amplitude im Entfernungs- und Geschwindigkeitsspektrum unverfälscht nicht möglich. Deshalb wurde die Amplitudeninformation eliminiert, indem Binärbilder in folgender Weise generiert wurden. Alle Bereiche des Spektrums, die über der CFAR-Schwelle liegen, erhalten den Pixelwert 1 und somit die Farbinformation weiß. Als Rauschen detektierte Bereiche bekommen den Pixelwert 0 und damit die Farbe schwarz zugeteilt. Damit ergibt sich ein weiterer Vorteil. Im Gegensatz zu einem

Tabelle 5.1: Anzahl der Trainings- und Validierungsdaten

| Objekttyp               | Modulation 1 | Modulation 2 |
|-------------------------|--------------|--------------|
| Synthetischer Fußgänger | 19 400       | 18 660       |
| Synthetischer Radfahrer | 47 400       | 45 500       |
| Gemessener Fußgänger    | 16 000       | 12 300       |
| Gemessener Radfahrer    | 18 000       | 19 900       |

farbigen Bild mit den Schichten Rot Grün Blau komprimiert sich dieses auf eine Schicht, wodurch in einem faltenden Netz nur ein Drittel der Operationen pro Schichten benötigt wird. Bei der Erzeugung von Trainingsdaten wurde von der aktuell gängigen Methode mit Aufzeichnen von großen Messreihen abgewichen. Die grundlegend verfolgte Idee ist in [164, 165] abgewandelt wiederzufinden. Als Trainingsdaten werden synthetisch erzeugte Daten verwendet. Für jeden Messzyklus wird ein entsprechendes Bild generiert. Anwendung dabei finden der Simulator sowie die Modelle des Radfahrers und des Fußgängers aus Abschnitt 4.2. Dies bietet mehrere Vorteile. Es werden keine aufwendigen Messfahrten mit einem Testfahrzeug benötigt und die Gefahr für Leben und Material ist auf ein Minimum reduziert. Des Weiteren ist eine einfache, zeitsparende Objektmarkierung (Labeling) durch eine effiziente Automatisierung zu erzielen. In der Simulation ist zu jedem Zeitpunkt die genaue Position des Modells bekannt. Zusätzlich wurde durch Verwendung von lediglich einem Modell pro Simulationszyklus die Verarbeitung weiter vereinfacht. Die Bildgröße wurde für ein faltendes Netz ohne Bereichsdetektion auf  $80 \times 380$  Pixel festgelegt. Dieser Bildausschnitt entspricht einer Ausdehnung von 5,1 m und einem Geschwindigkeitsbereich von 52,3 km/h für die erste Modulation und 7,8 m bzw. 54,2 km/h für die zweite Modulation. Dies ist ausreichend für die verwendeten Szenarien mit einer maximalen Radfahrgeschwindigkeit von 25 km/h. Beim Ansatz des Faster R-CNN wird das gesamte Entfernungs- und Geschwindigkeitsspektrum als Bild verwendet. Für Modulation 1 ergibt sich dafür die Bildgröße von  $2048 \times 1024$  Pixel und für Modulation 2 von  $1024 \times 2048$  Pixel. Die Trainingsdaten und auch die Testdaten wurden nach dem Schema in Abbildung 5.11 generiert bzw. aufgezeichnet.

Für die Simulations- und Messreihen ist der Radarsensor statisch positioniert, und die Objekte bewegen sich entlang der Trajektorien aus Abbildung 5.11. Die Trajektorien sind in zwei Längenvarianten aufgenommen worden. Jeweils wurde das Radar an den Beginn der mit  $0^\circ$  gekennzeichneten Trajektorie positioniert. Als Objekt wurde ein Radfahrer sowie ein Fußgänger simuliert bzw. vermessen. Die Geschwindigkeit für den Radfahrer wurde von 10 km/h bis 25 km/h in 5 km/h Inkrementen variiert. Der Fußgänger bewegte sich mit normaler Ganggeschwindigkeit von ungefähr 5 km/h bis 8 km/h durch den Parcours. Gemessen wurde auf einer Freifläche ohne Störeinflüsse durch weitere Objekte.

Mit diesem Aufbau wird die Ausrichtung des Radfahrers bzw. Fußgängers über

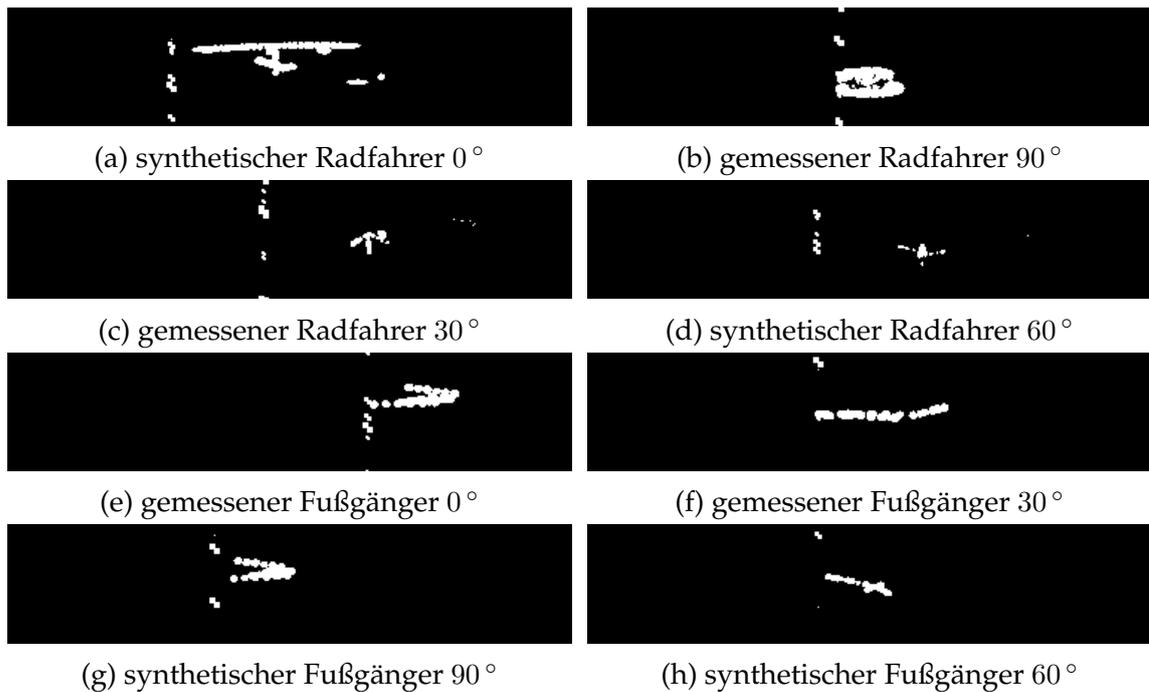


Abbildung 5.12: Beispiele für Trainings- und Testdaten, sowohl synthetisch als auch messtechnisch generiert. In der Horizontalen ist die Geschwindigkeit repräsentiert und in der Vertikalen die Entfernung.

die klassische longitudinale und transversale Bewegung hinaus erweitert. Es musste jedoch ein Kompromiss gefunden werden in der Anzahl der Ausrichtungen. Diese Art von Messaufbau wurde in [25] postuliert und an dieser Stelle adaptiert.

Nach der Transformation der Daten in binäre Bilddateien steht die in Tabelle 5.1 aufgeführte Anzahl für Training und Validierung zur Verfügung.

Speziell für die synthetischen Daten ist eine Verschiebung der Bilddateien angewendet worden, um eine mittige Zentrierung als Lernkriterium auszuschließen.

Die Markierung der Bildinhalte konnte stark vereinfacht werden. Für die synthetischen Daten ist aus dem Modell die Position und der Objekttyp bekannt. Bei den Messungen ist durch Aufnahme nur eines Objekts pro Messung die Zuordnung ebenfalls problemlos lösbar. Die Detektion der Position ist mit der Clustermethode in Binärbildern einfach zu realisieren. Eine nicht automatisierte Markierung (Labeln von Hand) wurde nicht benötigt.

Einige Beispiele für die erhaltenen Bilder im Datensatz zeigt Abbildung 5.12. Diese Auswahl soll lediglich zu einem kleinen Einblick verhelfen.

## 5.4 Klassifizierung

Zur Klassifizierung wurden zwei Klassen ausgewählt, Radfahrer und Fußgänger. Über die Auswahl und Generierung des Netzdesigns entstand eine betreute

Abschlussarbeit eines Masterstudenten [166]. Eruiert werden konnte ein faltendes Netz mit vorgelagerter Lokalisierung der Objekte mittels Binärbildclustering und ein Faster R-CNN mit kombinierter Lokalisierung und Klassifizierung. Deren Aufbau und Performanz wird im Folgenden vorgestellt.

### 5.4.1 Faltendes Neuronales Netz

In Anlehnung an das LeNet-5 [167] entstand ein Netzwerkdesign wie in Abbildung 5.13 visualisiert. Die Wahl, diese Netzstruktur als Grundlage zu verwenden, wurde aufgrund der gleichen Art von Eingabebildern getroffen. Die Autoren speisten ebenfalls Binärbilddateien in das Netz, wodurch nur eine Eingabeschicht benötigt wird. Bis zur Entstehung der verwendeten Netzstruktur wurden mehrere Netzarchitekturen erstellt mit variierender Anzahl an Schichten und deren Größe. Aus diesen kristallisierte sich eine Netzstruktur heraus, die wenige Schichten beinhaltet, jedoch in jeder dieser Schichten eine große Anzahl an Faltungskernen verwendet. Dieses verhältnismäßig kleine Netz bietet die Möglichkeit schnell und effizient trainiert zu werden und eine zukünftige Integrierbarkeit direkt in der verwendeten Radarplattform. Die für den gegebenen Anwendungsfall, der Klassifizierung von Objekten, entwickelte Netzstruktur wird nachfolgend detailliert vorgestellt.

Als Eingabeschicht erwartet die Architektur ein  $380 \times 80$  Pixel großes Binärbild. Darauf folgend ist eine faltende Schicht mit 16 diversen Kernen der Größe  $17 \times 17$ . Die Merkmalsräume werden nach Batch Normalisierung und ReLU-Aktivierung mit einer  $2 \times 2$  Max Pooling Schicht reduziert. Anschließend folgt eine zweite faltende Schicht mit Kernelgröße  $13 \times 13$  und 32 Kanälen als Ausgabe. Ihr folgt wiederum eine Batch Normalisierung, eine ReLU Aktivierung und ein Max Pooling mit  $2 \times 2$  ohne Überlappung. Die dritte und letzte faltende Schicht hat eine Kernelgröße von  $3 \times 3$  bei 64 Kanälen. Nach Batch-Normalisierung, ReLU-Aktivierung und Max Pooling  $2 \times 2$  folgt eine Dropout Schicht, die zufällig die Hälfte aller Neuronen auf 0 setzt. Diese extrahierten Merkmalsräume fließen in eine voll verknüpfte Schicht mit Eingangsdimension 256. Nach einer weiteren Dropout Schicht mit zufälliger Eliminierung der Hälfte aller Verbindungen folgt eine weitere, voll verknüpfte und 128 Neuronen umfassende Schicht. Nach der letzten voll verknüpften Schicht mit 2 Ausgaben werden mit der Softmax Funktion die Ausgabewerte normalisiert.

Trainiert wurde das Netz jeweils für die beiden Modulationsvarianten mit den zwei vorgestellten Klassen Radfahrer und Fußgänger. Zum Training wurden die synthetischen Daten angewendet. Als Softwareumgebung zum Training der Netze wurde Mathworks<sup>®</sup> Matlab/Simulink eingesetzt. Die Validierung erfolgte anhand der Messdaten. Als Bewertungskriterien finden die Genauigkeit (Precision) und Auffindung (Recall) Einsatz. Die Berechnung erfolgt anhand der Indikatoren true positive  $t_p$ , false positive  $f_p$  und false negative  $f_n$ . Als true positive ist ein erkanntes Objekt bezeichnet, das richtig klassifiziert wurde. Mit false positive wird

## 5 Klassifizierung von Radfahrern

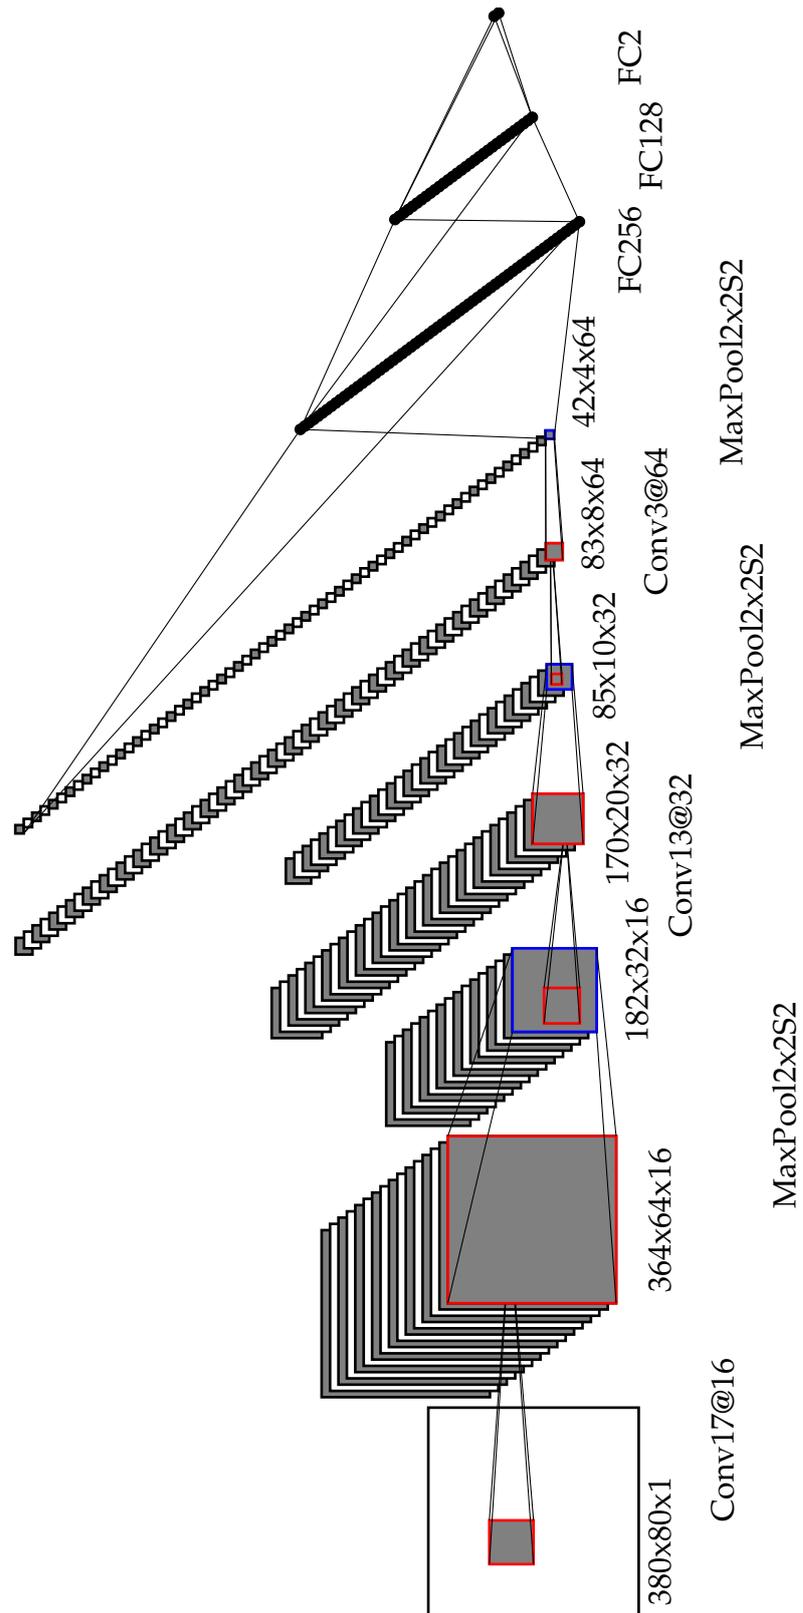


Abbildung 5.13: Struktur des verwendeten faltenden Netzwerk zur Klassifizierung

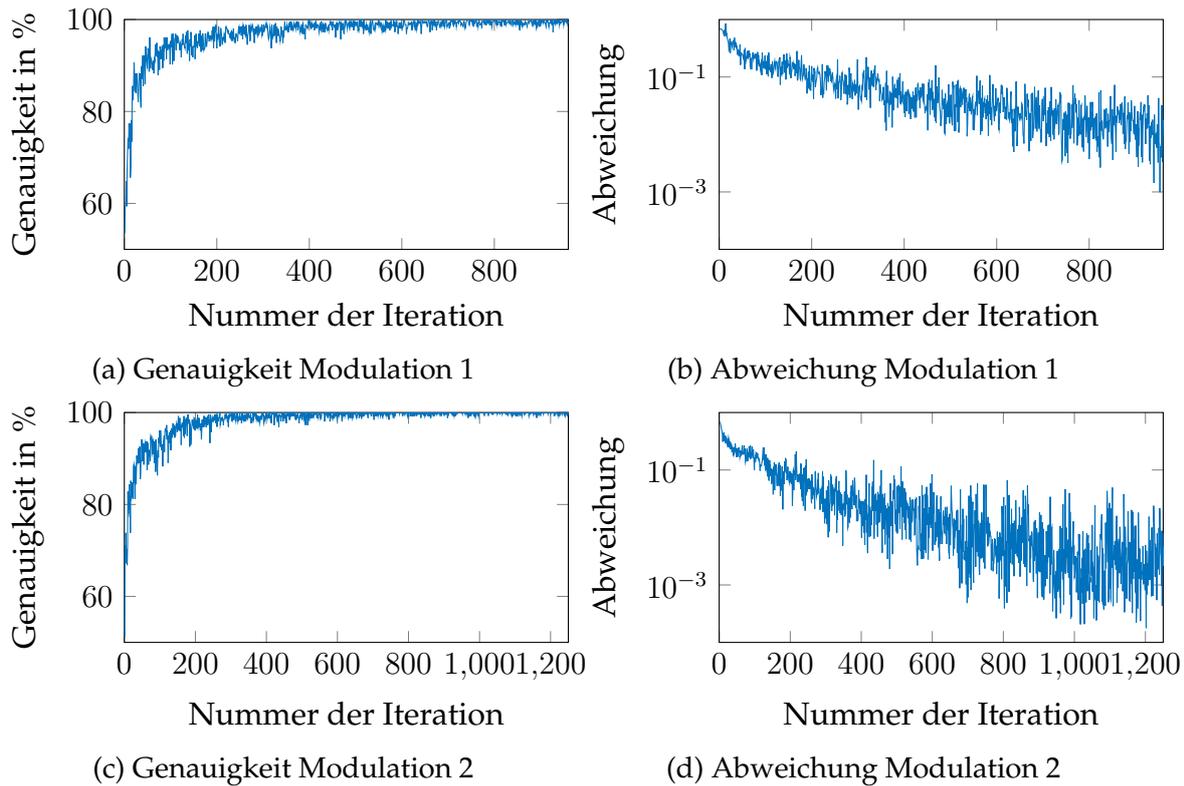


Abbildung 5.14: Genauigkeit und Abweichung im Trainingsprozess

die falsche Klassifizierung eines erkannten Objekts gezählt. Ein false negative ist ein nicht erkanntes Objekt. Die Bewertung des Detektors ist vorrangig anhand  $f_n$  gegeben. Für die Qualität des Klassifikators sind  $t_p$  und  $f_p$  relevant.

$$\begin{aligned} \text{Precision} &= \frac{t_p}{t_p + f_p} \\ \text{Recall} &= \frac{t_p}{t_p + f_n} \end{aligned} \quad (5.17)$$

Der Verlauf des Trainingsprozesses für die beiden Modulationsvarianten ist in Abbildung 5.14 dargestellt. Gut zu erkennen ist das schnelle Konvergieren der Genauigkeit an nahezu bis 100%. Dies führt zu einem Trainingslauf, in dem nicht alle Trainingsdaten benötigt werden, da das Abbruchkriterium - keine Verbesserung der Genauigkeit - früh erreicht wird. Die Abweichung zeigt den Fehler der Ausgabe des Netzes zur bekannten Eingabe.

Die Bewertung von Detektor und Klassifizierer ist in Tabelle 5.2 aufgetragen. Für die Szenarien mit einem Objekt pro Messung konnte der Detektor, ausgeführt mit der Bildclusteringmethode aus Unterabschnitt 5.2.1, alle Objekte erkennen. Klassifizierung der Objekte liefert eine Precision im Bereich von 85%. Ein Wert der angesichts der Verwendung nur synthetischer Trainingsdaten sehr gut ist.

Tabelle 5.2: Bewertungsmaße für das faltende Netz mit Feinabstimmung mittels Transfer Learning

| Modulation   | Netzwerk | Precision | Recall | $t_p$  | $f_p$ | $f_n$ |
|--------------|----------|-----------|--------|--------|-------|-------|
| Modulation 1 | CNN      | 0,894     | 1      | 9422   | 1118  | 0     |
| Modulation 2 | CNN      | 0,857     | 1      | 8594   | 306   | 0     |
| Modulation 1 | transCNN | 0,987     | 1      | 10 398 | 142   | 0     |
| Modulation 2 | transCNN | 0,963     | 1      | 9432   | 368   | 0     |

Zur Feinabstimmung der trainierten Netze wurde die Methode des Transfer Learning angewendet, mit einer kleinen Anzahl an messtechnisch erfassten Trainingsdaten von ca. 5% der verwendeten synthetischen Trainingsdaten. Die daraus resultierenden Genauigkeitswerte der Klassifizierung zeigen eine signifikante Steigerung, siehe hierzu Tabelle 5.2. Die Genauigkeit und Abweichung für das Transfer Learning sind in Abbildung 5.15 abgebildet. Die Steigerung der Precision zeigt, dass die synthetischen Daten sich sehr gut dazu eignen, ein Netz und dessen Gewichte vorzutrainieren. Um die Fähigkeiten des Netzes komplett auszunutzen, werden noch messtechnisch erfasste Daten benötigt. Die Diskrepanz zwischen den synthetischen und messtechnischen Daten konnte nicht komplett eliminiert werden. Festgestellt werden konnte in detaillierteren Untersuchungen, dass die CFAR-Schwelle und damit der Rauschpegel bzw. die Varianz des Rauschens das Aussehen der Eingabebilder leicht beeinflussen. Ebenso beeinflusst die Freiraumdämpfung das Binärbild. Diese Parameter wurden in der Simulation mit einfachen Modellen abgebildet, wodurch es zu Diskrepanzen mit der realen Umgebung kommt.

Unter Beachtung der separaten Auswertung in nur einem Messzyklus, sind die erzielten Ergebnisse umso bemerkenswerter. Für vergleichbare Aufgabenstellungen in der Literatur wurden mehrere Messzyklen zur Klassifizierung von verschiedenen Bewegungen eines Menschen verwendet, mit in etwa vergleichbaren Ergebnissen [168–171].

#### 5.4.2 Klassifizierungsnetz mit Bereichsdetektion

Eine Abstraktionsebene höher in der Signalverarbeitung ist die Klassifizierung mit Bereichsdetektion anzusiedeln. Es entfällt die Notwendigkeit einer Vorverarbeitung der Bilddateien zur Extraktion der Bereiche, deren Inhalt bedeutsam ist. Angewandt wurde der Faster R-CNN Ansatz, beschrieben in Unterabschnitt 5.2.2. Der Charme dieser Variante liegt in der direkten Verwendung des Binärbilds über den gesamten Sichtbereich des Radarsensors.

Für die erste Modulation erhält das Netzwerk ein  $2048 \times 1024$  Pixel großes Eingabebild und für die zweite Modulation ist die Eingabe  $1024 \times 2048$  Pixel groß.

Zum Training wurde die Mathworks® Matlab/Simulink Funktion trainFaster-

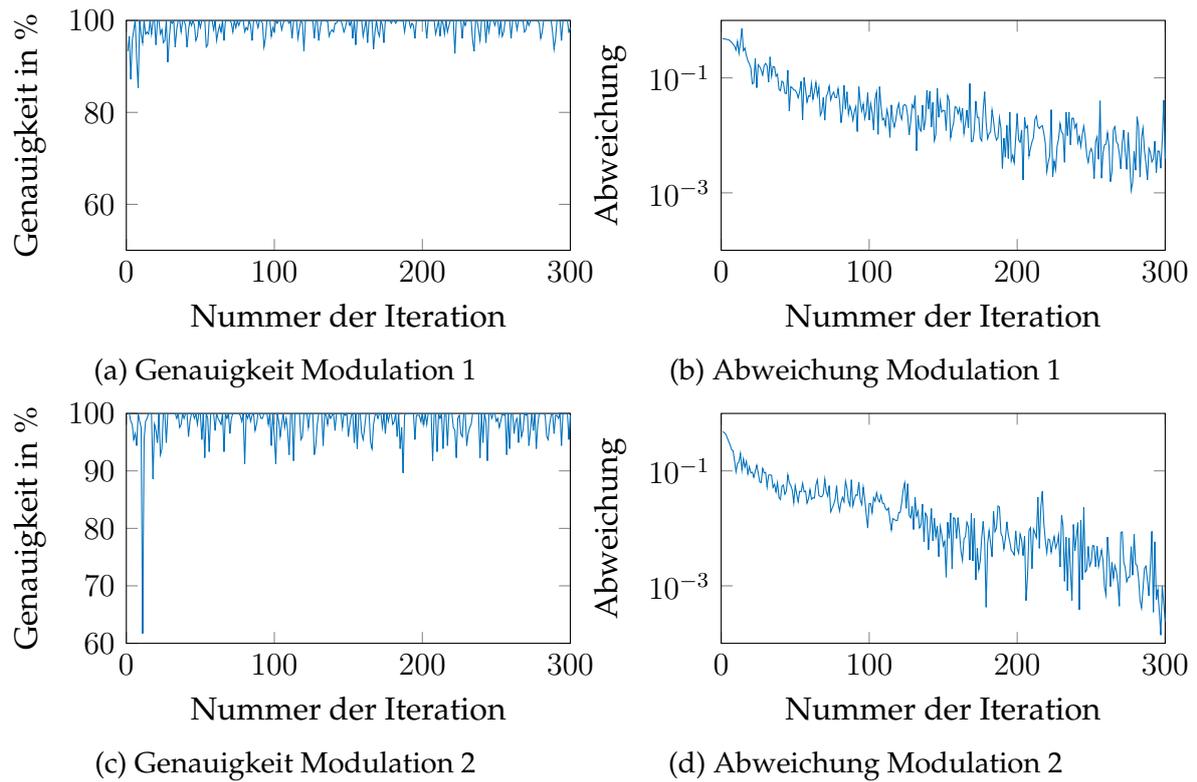


Abbildung 5.15: Genauigkeit und Abweichung im Trainingsprozess mit Transfer Learning

Tabelle 5.3: Bewertungsmaße für das Faster RCNN Netzwerk

| Modulation   | Netzwerk    | Precision | Recall | $t_p$ | $f_p$ | $f_n$ |
|--------------|-------------|-----------|--------|-------|-------|-------|
| Modulation 1 | Faster-RCNN | 0,973     | 0,764  | 8280  | 233   | 2558  |
| Modulation 2 | Faster-RCNN | 0,958     | 0,743  | 4680  | 206   | 1619  |

RCNNObjectDetector verwendet. Diese Implementierung teilt den Trainingsprozess in 4 Stufen. Zu Beginn wird das RPN zur Detektion der relevanten Bereiche in den Eingabebildern trainiert. Anschließend erfolgt das Training des Objektklassifikators. Hierfür wurden via Transfer Learning die vortrainierten Netze aus Unterabschnitt 5.4.1 eingesetzt. Als dritte Stufe wird das RPN erneut trainiert. Im letzten Schritt wird das gesamte Netzwerk ein weiteres Mal mit allen Trainingsdaten fein abgestimmt.

Zur Bewertung finden die aus Unterabschnitt 5.4.1 bekannten Indikatoren und Kriterien Anwendung, aufgeführt in Tabelle 5.3.

Im Vergleich zu den faltenden Netzen mit vorgelagerter Objektdetektion sind die Ergebnisse der Klassifizierung nur marginal verändert. Durch Anwendung der vortrainierten faltenden Netze ist dies ein zu erwartendes Ergebnis. Diese erreichte Qualität von 76 % Erkennung von Objekten in den Testdaten deckt sich mit den in [162] vorgestellten Werten. Ein gravierender Unterschied zwischen den beiden verwendeten Modulationsarten konnte nicht festgestellt werden.

## Zusammenfassung

Um Inhalte einer Radarmessung einer Gruppe zuordnen zu können, gibt es verschiedene Ansätze und Methoden. Diese unterscheiden sich im Aufwand der Datenvorverarbeitung. Bei Anwendung einer SVM ist es notwendig, charakteristische Merkmale in Vorverarbeitungsschritten zu extrahieren. Im Kontrast dazu steht die Möglichkeit einer automatisierten Extraktion von Merkmalen mittels eines neuronalen Netz. Mit einem Bild als Eingabe extrahieren faltende neuronale Netze charakteristische Formen und Muster. Anschließend werden diese Merkmale direkt einem Klassifikator übergeben, gebildet aus einem neuronalen Netz, der die Klassenzugehörigkeit bestimmt. Für gewöhnlich wird ein solches Netzwerk auf Ausschnitte aus dem gesamten Erfassungsbereich angewendet, die Objekte enthalten könnten. Zur Auswahl dieser Bildteile wurden zwei Methoden identifiziert.

Ein klassischer Ansatz mit Zusammenfassen einzelner erfasster Streuzentren zu einem Objekt anhand der räumlichen Verteilung, wurde vorgestellt. Dabei ist eine modifizierte Methode aus der Bildverarbeitung im Einsatz, die es erlaubt in drei verschiedenen Erfassungsräumen die Streuzentren zu clustern. Anhand der zusammengefassten Positionen der Objektstreuzentren ist ein Rückschluss auf den

relevanten Bildbereich möglich.

Ebenso besteht die Möglichkeit ein Bereichsdetektionsnetzwerk in Kombination mit einem faltenden Klassifikationsnetz zu verwenden. Die verwendete Methode ist bekannt als Faster R-CNN. Das Netzwerk liefert als Ergebnis den Objekttyp und zusätzlich den Bereich, in dem sich das Objekt befindet. Es ist somit ein Detektor und Klassifikator in einem.

Abweichend von dem weit verbreiteten Schema wurden zum Training der Netze massiv synthetische Daten verwendet. Die so trainierten Netze zeigen gute Ergebnisse bei der Validierung mit gemessenen Daten, wobei noch Steigerungspotential bei der Genauigkeit möglich ist. Dieses wurde mit Hilfe von Transfer Learning und einem kleinen Datensatz an Messdaten auch gehoben. Für die Genauigkeit des Klassifikators konnten Steigerungen um bis zu 9% erzielt werden. Die Anwendung von synthetisch erzeugten Daten für ein Vortraining des Netzwerkes konnte als probate Methode identifiziert werden. Bemerkenswert ist die hohe Erkennungs- und Klassifizierungsrate unter der Voraussetzung der Nutzung nur eines einzigen Messzyklus von ca. 50 ms Dauer.

Mit Nutzung der vortrainierten Netze konnte das Training der Kombination aus Bereichsdetektion und Klassifikation beschleunigt werden. Die Qualität des Klassifikators weicht nur unwesentlich von den reinen Klassifikationsnetzen ab. Für die Bereichsdetektion wurden ebenfalls gute Ergebnisse erzielt. Im Testdatensatz konnte die Faster R-CNN Methode 76% der relevanten Bereiche detektieren.

Für die zwei Varianten der Sendesignalmodulation konnten keine signifikanten Unterschiede in der Detektion und Klassifikation ermittelt werden.



## 6 Zusammenfassung

In dieser Dissertation wurde die Fragestellung untersucht, ob die Fähigkeit zur Lokalisierung und Identifizierung eines bildgebenden Radarsensors ausreichend ist um Radfahrer zu erkennen. Hervorzuheben dabei sind die Untersuchung von Charakteristiken des Radfahrers im zwei- und dreidimensionalen kartesischen Raum, sowie in der kombinierten Aufbereitung von Entfernung und Geschwindigkeit als ein zentraler Punkt der durchgeführten Forschungsarbeiten.

Zuerst wurden dafür die Anforderungen bezüglich des abzudeckenden Detektionsbereich eines Radars ermittelt. Dafür wurden groß angelegte Bewegungsstudien mit Analyse der Fortbewegung von Radfahrern in europäischen Metropolen von Schweden und Deutschland genutzt. Diese führten zu Merkmalsdaten wie die mittlere und maximale Fortbewegungsgeschwindigkeit eines Radfahrers. Zusätzlich sind aus dem Feld der Unfallanalyse die häufigsten Kollisionen zwischen motorisierten Fahrzeugen und Radfahrern bekannt. Diese bestätigen die erfassten Bewegungsgeschwindigkeiten von Radfahrern und erweitern den notwendigen dynamischen Erfassungsbereich des Radars noch um die Fahrzeugeigenesgeschwindigkeit. Einen signifikanten Anteil an Unfällen mit einem involvierten Radfahrer beschreiben kreuzende Szenarien, sowohl von rechts als auch von links kommend. Die Geschwindigkeitsinformation und bekannte Unfallkonstellationen dienen als Indikator zur Auslegung der Betriebsparameter für den eingesetzten Radarprototyp.

Diese sehr flexible Radarsensorplattform hat frei wählbare Modulationsparameter und ist nur durch die verwendeten Hardwarekomponenten limitiert. Eine Weiterentwicklung dieser Plattform in Richtung Detektierbarkeit von Streuzentren im dreidimensionalen Raum mit einem Antennenarray, ausgedehnt in zwei Raumdimensionen, wurde im Zuge dieser Arbeit erfolgreich durchgeführt. Als Sendesignalmodulation kam die im Automobilbereich mittlerweile standardmäßige Chirp-Sequence Modulation zum Einsatz, wobei zwei unterschiedliche Parametrisierungen verwendet wurden. Es konnte jedoch kein nennenswerter Unterschied in der Erkennung eines Radfahrers beim Betrieb mit den zwei Parametersätzen festgestellt werden. Die Signalverarbeitungskette beginnt mit den Amplitudenwerten des Analog-Digital Wandlers. Die Signalverarbeitung wird bis zur Ausgabe der Entfernung- und Geschwindigkeitszellen nach der Signaldetektion im Rauschen auf einem FPGA ausgeführt. Die weiterführenden Schritte der Winkelschätzung wurden für die Erkennung beider Raumwinkel in Azimut und Elevation nach der Datenaufzeichnung offline mittels Mathworks® Matlab/Simulink entwickelt und validiert.

In ersten Messungen eines bewegten Radfahrer zeigten sich charakteristische

Ausdehnungen in der Geschwindigkeit und Entfernung. Mit diesen Beobachtungen und zusätzlicher Auswertung der physikalischen Attribute eines Radfahrers, wurde ein detailliertes Modell eines Radfahrers entwickelt. Dabei lag der Fokus auf der Beschreibung der Geschwindigkeit, wofür eine detaillierte Bewegungsanalyse eines Radfahrers durchgeführt wurde, und der Position der Streuzentren. Das entwickelte Modell wurde mit einem Radarsimulator kombiniert, um auch synthetische Daten generieren zu können. Nach Validierung der simulierten Daten mit gemessenen Aufzeichnungen konnte das neue, realitätsgetreue Modell eines Radfahrers zur Entwicklung von Algorithmen, Verfahren und zur Merkmalsextraktion verwendet werden.

Die offensichtlichen Merkmale der Objektausdehnung und die radiale relative Geschwindigkeit der einzelnen Streuzentren können einfach ermittelt werden und sind erste Indikatoren für den Objekttyp Radfahrer. Eine neue Methode konnte entwickelt werden, anhand derer es möglich ist, mit Hilfe der räumlichen Verteilung der Streuzentren direkt auf die Objektgeschwindigkeit zu schließen. In der Auswertung der Streuzentrenverteilung konnte noch ein weiterer Indikator für eine bzw. keine Kurvenfahrt entdeckt werden.

Teile der Ergebnisse flossen direkt in die Weiterentwicklung eines Radfahrer-dummys für EuroNCAP Testszenarien im Rahmen eines Forschungskonsortiums mit ein.

Zur Klassifizierung eines Radfahrers wurden im letzten Schritt auch Methoden des maschinellen Lernens aus der Bildverarbeitung auf ihre Einsatzmöglichkeiten hin untersucht. Als Radar-Eingangsbild für das neuronale Netzwerk fiel die Wahl auf das Entfernungs- und Geschwindigkeitsspektrum aufgrund der gut selektierbaren Merkmale. Als Lerndatensatz für ein faltendes neuronales Netz wurden synthetisch generierte Daten eingesetzt. Zum Testen kamen dann reale Messdaten zum Einsatz. Für die Lokalisierung des relevanten Bildausschnitts wurde eine Methode entwickelt, um Streuzentren eines Objekts zu einer Gruppe zusammenzufassen. Des Weiteren wurde ein spezielles neuronales Netz verwendet um die relevanten Bildregionen eigenständig zu ermitteln und darauf dann eine Klassifizierung auszuführen. Die Genauigkeit der Klassifikation erreicht beim Training mit rein synthetischen Daten ca 85%. Mit Verwendung eines kleinen Anteil an gemessenen Daten im Training konnte die Genauigkeit noch auf 96% gesteigert werden. Das Netzwerk mit kombinierter Lokalisierung erreichte ähnliche Genauigkeiten und fand zu etwa 75% Objekte im Bild.

### 6.1 Ausblick

Die zentralen Fragestellungen zur Erkennung eines Radfahrers mittels Radar konnten geklärt werden. Als offener Punkt bleibt noch die Frage des Mehrwerts der dreidimensionalen Detektion von Streuzentren. Ein Einsatz zur Identifizierung von Kurvenfahrten scheint damit möglich zu sein. Ob eine Klassifizierung bzw. Lokalisierung damit noch besser oder optimiert werden kann, könnte ein Aufga-

benschwerpunkt von zukünftigen Arbeiten sein.

Eine Möglichkeit zur Klassifizierung von Punktwolken wurde in [135, 136, 172] vorgestellt. Diese Methoden wurden entwickelt und zur Klassifizierung von Objekten in hochauflösenden Laserscanneraufnahmen angewandt. Ein erster Einsatz dieser Methode auf Radardaten wurde in [137] gezeigt, mit vielversprechenden Ergebnissen.

Untersuchungen in hochkomplexen urbanen Gebieten stellen ebenfalls noch einen großen Forschungsbedarf dar. Hierbei kommt es zu einer Vielzahl von Objekten in einem Messzyklus. Diese große Menge an Objekten und Streuzentren exakt zu lokalisieren, zu klassifizieren und zu präzisieren sind die nächsten Herausforderungen für zukünftige Radarsysteme. Speziell bei schwachen Verkehrsteilnehmern wie Fußgängern und Radfahrern ist die Trennung mehrere auf engem Raum bewegter Probanden äußerst herausfordernd. Eventuell ist es dabei zielführender, Muster mit einer unterschiedlichen Personenanzahl zu lernen, als diese so trennen zu wollen, um sie dann als Einzelobjekte klassifizieren zu können.

Im Bereich des hoch automatisierten Fahrens werden hochauflösende Radarsensoren eine zentrale Rolle einnehmen. Gemeinsam in einem Sensorverbund tragen sie zu einer hoch genauen Lokalisierung und Umfelderkennung bei. Mit der hohen Robustheit gegenüber Umwelteinflüssen können Ausfallzeiten der anderen Sensortechnologien überbrückt werden. Damit sind Robustheitsanforderungen und Ausfallsicherheiten erzielbar, wie sie für den sicheren und unfallfreien Betrieb von autonomen Fahrzeugen gefordert sind.



# Literatur

- [1] G.-A. Ahrens, U. Becker, T. Böhmer, F. Richter und R. Wittwer. *Potenzielle des Radverkehrs für den Klimaschutz*. Techn. Ber. Technische Universität Dresden, 2013.
- [2] Umwelt Bundesamt. *Radverkehr*. <https://www.umweltbundesamt.de/themen/verkehr-laerm/nachhaltige-mobilitaet/radverkehr>. Abruf am 22.08.2018. 2016.
- [3] Bosch eBike Systems. *Mobilität von morgen - eBikes auf dem Vormarsch*. <https://www.bosch-ebike.com/de/ebike-erleben/stories/marktcheck/>. Abruf am 22.08.2018.
- [4] Statistisches Bundesamt. *UNFALLENTWICKLUNG AUF DEUTSCHEN STRASSEN 2017*. Techn. Ber. Statistisches Bundesamt (Destatis), Wiesbaden, 2018.
- [5] Europäische Kommission. *Verkehr 2050: Kommission legt ehrgeizigen Plan zur Mobilitätssteigerung und Emissionsminderung vor*. [http://europa.eu/rapid/press-release\\_IP-11-372\\_de.htm](http://europa.eu/rapid/press-release_IP-11-372_de.htm). Abruf am 22.08.2018.
- [6] Euro NCAP. *Fußgänger-AEB (Notbremsautomatik)*. <https://www.euroncap.com/de/fahrzeugsicherheit/die-bedeutung-der-bewertungen/schutz-von-ungeschuetzten-verkehrsteilnehmern-vru/fussgaenger-aeb-notbrem-sautomatik/>. Abruf am 22.08.2018. 2016.
- [7] Euro NCAP. *AEB-Notbremssystem für Radfahrer*. <https://www.euroncap.com/de/fahrzeugsicherheit/die-bedeutung-der-bewertungen/schutz-von-ungeschuetzten-verkehrsteilnehmern-vru/aeb-notbremssystem-fuer-radfahrer/>. Abruf am 22.08.2018. 2018.
- [8] IDIADA AUTOMOTIVE TECHNOLOGY SA. *PROSPECT Project*. <http://www.prospect-project.eu>. Abruf am 23.08.2018.
- [9] European Commission. *Eight Framework Programme Horizon 2020*. <https://ec.europa.eu/programmes/horizon2020>. Abruf am 23.08.2018. 2018.
- [10] M. Wisch, M. Lerner, A. Schneider, Janos Juhász, Glász Attila, J. Kovaceva, András Bálint und M. Lindman. *Accident Analysis, Naturalistic Observations and Project Implications - Part A*. Techn. Ber. PROSPECT Consortium, 2016.
- [11] J. Stoll, A. Schneider, M. Wisch, P. Seiniger und T. Schaller. *The addressed VRU scenarios within PROSPECT and associated test catalogue*. Techn. Ber. PROSPECT Consortium, 2016.

- [12] Unfallforschung der Versicherer. *Unfallforschung kompakt - Innerörtliche Unfälle mit Fußgängern und Radfahrern*. Techn. Ber. Gesamtverband der Deutschen Versicherungswirtschaft e.V., 2013.
- [13] M. Pereira, M.-P. Bruyas, C. Kaufmann, V. Britschgi, J. L. D. Gil und A. Zaoral. »Reported use of speed control systems: cruise control and speed limiter«. In: *IET Intelligent Transport Systems* 7.4 (Dez. 2013), S. 425–431.
- [14] Dr. Ing. h.c. F. Porsche AG. *Technische Daten Porsche 918 Spyder*.
- [15] Kraftfahrt-Bundesamt. *Neuzulassungen von Pkw in den Jahren 2008 bis 2017 nach technischen Merkmalen*. [https://www.kba.de/DE/Statistik/Fahrzeuge/Neuzulassungen/Motorisierung/n\\_motorisierung\\_pkw\\_zeitreihe\\_techn\\_merkmale.html](https://www.kba.de/DE/Statistik/Fahrzeuge/Neuzulassungen/Motorisierung/n_motorisierung_pkw_zeitreihe_techn_merkmale.html). Abruf am 29.08.2018.
- [16] Bosch Gruppe. *Antiblockiersystem*. <https://www.bosch-mobility-solutions.de/de/produkte-und-services/pkw-und-leichte-nutzfahrzeuge/fahrsicherheitssysteme/antiblockiersystem/>. Abruf am 29.08.2018.
- [17] Bosch Gruppe. *Elektronisches Stabilitätsprogramm - Verhindert Schleudern*. <https://www.bosch-mobility-solutions.de/de/produkte-und-services/pkw-und-leichte-nutzfahrzeuge/fahrsicherheitssysteme/elektronisches-stabilitaetsprogramm/>. Abruf am 29.08.2018.
- [18] ADAC Autotest. *Kurze Bremswege sind kein Hexenwerk*. [https://www.adac.de/infotestrat/tests/auto-test/bremswege\\_2016/](https://www.adac.de/infotestrat/tests/auto-test/bremswege_2016/). Abruf am 29.08.2018.
- [19] M. Johnson, D. Chong, J. Carroll, R. Katz, J. Oxley und J. Charlton. *Naturalistic Cycling Study: Identifying Risk Factors for Cyclists in the Australian Capital Territory*. Techn. Ber. Monash University - Accident Research Centre, 2014, S. 78.
- [20] M. Dozza und J. Werneke. »Introducing naturalistic cycling data: What factors influence bicyclists' safety in the real world?« In: *Transportation Research* 24 (Mai 2014), S. 83–91.
- [21] K. Schleinitz, T. Petzoldt, L. Franke-Bartholdt, J. Kreams und T. Gehlert. »The German Naturalistic Cycling Study - Comparing cycling speed of riders of different e-bikes and conventional bicycles«. In: *Safety Science Special Issue Article* (2015), S. 8.
- [22] M. Bulla. »Geschwindigkeiten, Verzögerungen und Beschleunigungen nicht motorisierter, ungeschützter Verkehrsteilnehmer am Beispiel Fahrrad und Inlineskates«. Diplomarbeit. Fachhochschule München, 2004.
- [23] N. Tiemann. »Ein Beitrag zur Situationsanalyse im vorausschauenden Fußgängerschutz«. Diss. Universität Duisburg-Essen, 2011.
- [24] B. Bartels und C. T. Ebersmehl. *Bewegungsverhalten von Fußgängern im Straßenverkehr*. Techn. Ber. Verkehrsunfallforschung an der TU Dresden GmbH (VUFO), 2014.

- [25] E. Schubert. »Klassifikation leicht verwundbarer Verkehrsteilnehmer mit hochauflösendem Automobilradar«. Diss. Universität Ulm, 2018.
- [26] *Euro NCAP AEB VRU Test Protocol v2.0.2*. 2018.
- [27] H. Zöllner und W. Hugemann. »Zur Problematik der Bremsreaktionszeit im Straßenverkehr«. In: *37. BDP-Kongress für Verkehrspsychologie*. 1998.
- [28] B. Schoettle. *SENSOR FUSION: A COMPARISON OF SENSING CAPABILITIES OF HUMAN DRIVERS AND HIGHLY AUTOMATED VEHICLES*. Techn. Ber. The University of Michigan - Sustainable Worldwide Transportation, 2017.
- [29] H. Winner, S. Hakuli, F. Lotz und C. Singer. *Handbuch Fahrerassistenzsysteme - Grundlagen, Komponenten und Systeme für aktive Sicherheit und Komfort*. 3. Aufl. Berlin Heidelberg New York: Springer-Verlag, 2015.
- [30] H. Winner. »Die lange Entwicklung von ACC«. In: *Fahrerassistenz-Workshop*. 2003.
- [31] A. K. Ludloff. *Praxiswissen Radar und Radarsignalverarbeitung*. 4. überarb. und erw. Aufl. 2008. Berlin Heidelberg New York: Springer-Verlag, 2008.
- [32] M. I. Skolnik. *Introduction to Radar Systems*. 3. Aufl. New York: McGraw-Hill Education, 2001.
- [33] L. Laursen. *Autonomous Emergency Braking*. <https://spectrum.ieee.org/transportation/self-driving/autonomous-emergency-braking>. Abruf am 06.09.2018. 2014.
- [34] J. Hasch. »Driving Towards 2020: Automotive Radar Technology Trends«. In: *Microwaves for Intelligent Mobility (ICMIM), 2015 IEEE MTT-S International Conference on*. Apr. 2015, S. 1–4.
- [35] J. Dickmann, J. Klappstein, M. Hahn, N. Appenrodt, H.-L. Bloecher, K. Werber und A. Sailer. »„Automotive Radar the Key Technology For Autonomous Driving: From Detection and Ranging to Environmental Understanding“«. In: *2016 IEEE Radar Conference (RadarConf)*. Mai 2016, S. 1–6.
- [36] J. Hasch, E. Topak, R. Schnabel, T. Zwick, R. Weigel und C. Waldschmidt. »Millimeter-Wave Technology for Automotive Radar Sensors in the 77 GHz Frequency Band«. In: *IEEE Transactions on Microwave Theory and Techniques* 60.3 (März 2012), S. 845–860.
- [37] M. I. Skolnik. *Radar Handbook*. Hrsg. von M. I. Skolnik. 3. Auflage. McGraw Hill, 2008.
- [38] B. Huder. *Einführung in die Radartechnik*. 1999. Aufl. Wiesbaden: Teubner, 1999.
- [39] S. Lutz. »MIMO-Radar Systemarchitektur und Parameterschätzung für komplexe Mehrzielszenarien«. Diss. Friedrich-Alexander-Universität Nürnberg-Erlangen, 2015.

- [40] S. E. Yuter. *Precipitation Radar*. Techn. Ber. Department of Atmospheric Science, University of Washington, Seattle, 2003.
- [41] D. Cimini, G. Visconti und F. S. Marzano. *Integrated Ground-Based Observing Systems*. Springer, Berlin, Heidelberg, 2011.
- [42] M. Kalcher. *Klassifizierung von Hydrometeoren basierend auf polarimetrischen Wetterradardaten*. Masterarbeit an der Universität Wien. 2015.
- [43] D. Belgiovane und C.-C. Chen. »Radar Scattering Properties of Bicycles at 77 GHz«. In: *2015 IEEE International Symposium on Antennas and Propagation UNSC/URSI National Radio Science Meeting*. Juli 2015, S. 502–503.
- [44] K. Geary, J. S. Colburn, A. Bekaryan, S. Zeng, B. Litkouhi und M. Murad. »Automotive radar target characterization from 22 to 29 GHz and 76 to 81 GHz«. In: *Radar Conference (RADAR), 2013 IEEE*. Apr. 2013, S. 1–6.
- [45] H. Rohling und M.-M. Meinecke. »Waveform design principles for automotive radar systems«. In: *Radar, 2001 CIE International Conference on, Proceedings*. 2001, S. 1–4.
- [46] M. Kronauge. »Waveform Design for Continuous Wave Radars«. Diss. Technische Universität Hamburg-Harburg, 2014.
- [47] A. G. Stove. »Linear FMCW radar techniques«. In: *IEEE Proceedings on Radar and Signal Processing* 139.5 (Okt. 1992), S. 343–350.
- [48] C. Schroeder und H. Rohling. »X-Band FMCW Radar System with Variable Chirp Duration«. In: *2010 IEEE Radar Conference*. Mai 2010, S. 1255–1259.
- [49] V. Winkler. »Range Doppler Detection for automotive FMCW Radars«. In: *European Radar Conference (EuRAD) 2007*. Okt. 2007, S. 166–169.
- [50] V. Winkler. »Novel Waveform Generation Principle for short-range FMCW-Radars«. In: *2009 German Microwave Conference*. März 2009, S. 1–4.
- [51] M. Kronauge und H. Rohling. »New chirp sequence radar waveform«. In: *IEEE Transactions on Aerospace and Electronic Systems* 50.4 (Okt. 2014), S. 2870–2877.
- [52] C. Sturm, T. Zwick und W. Wiesbeck. »An OFDM System Concept for Joint Radar and Communications Operations«. In: *VTC Spring 2009 - IEEE 69th Vehicular Technology Conference*. Apr. 2009, S. 1–5.
- [53] J. Fink und F. K. Jondral. »Comparison of OFDM Radar and Chirp Sequence Radar«. In: *2015 16th International Radar Symposium (IRS)*. Juni 2015, S. 315–320.
- [54] C. Knill, J. Bechter und C. Waldschmidt. »Interference of Chirp Sequence Radars by OFDM Radars at 77 GHz«. In: *2017 IEEE MTT-S International Conference on Microwaves for Intelligent Mobility (ICMIM)*. März 2017, S. 147–150.

- [55] D. E. Barrick. *FM/CW Radar Signals and Digital Processing*. Techn. Ber. National Oceanic und Atmospheric Administration, 1973.
- [56] H. D. Griffiths. »New ideas in FM radar«. In: *Electronics Communication Engineering Journal* 2.5 (Okt. 1990), S. 185–194.
- [57] U. Lübbert. »Target Position Estimation with a Continuous Wave Radar Network«. Diss. Technische Universität Hamburg-Harburg, 2005.
- [58] M. Reiher und B. Yang. »Extending the Frequency Matching in Linear FM-CW Radar Exploiting Extreme Frequencies«. In: *2009 IEEE Radar Conference*. Mai 2009, S. 1–6.
- [59] J. R. Klauder, A. C. Price, S. Darlington und W. J. Albersheim. »The theory and design of chirp radars«. In: *The Bell System Technical Journal* 39.4 (Juli 1960), S. 745–808.
- [60] F. Roos, D. Ellenrieder, N. Appenrodt, J. Dickmann und C. Waldschmidt. »Range Migration Compensation for Chirp-Sequence based Radar«. In: *2016 German Microwave Conference (GeMiC)*. März 2016, S. 317–320.
- [61] C. E. Shannon. »Communication in the Presence Of Noise«. In: *Proceedings of the IEEE* 86.2 (Feb. 1998), S. 447–457.
- [62] O. Lange. »Optimierung von Antennenarrays zur verbesserten Richtungs-schätzung für automobile Radarsysteme«. Diss. Universität Stuttgart, 2012.
- [63] A. Kortke. »Analyse und Kalibration von linearen Microstrip-Patch-Antennenarrays«. Diss. Technische Universität Berlin, 2006.
- [64] G. Lehner. *Elektromagnetische Feldtheorie*. Springer Berlin Heidelberg New York, 2005.
- [65] C. A. Balanis. *Antenna Theory - Analysis and Design*. John Wiley & Sons, 2005.
- [66] H. L. V. Trees. *Optimum Array Processing - Detection, Estimation, and Modulation Theory*. New York: John Wiley & Sons, 2002.
- [67] M. Zatman. »How narrow is narrowband?«. In: *IEE Proceedings - Radar, Sonar and Navigation* 145.2 (Apr. 1998), S. 85–91.
- [68] IEEE. »IEEE Standard for Definitions of Terms for Antennas - Redline«. In: *IEEE Std 145-2013 (Revision of IEEE Std 145-1993) - Redline* (März 2014), S. 1–92.
- [69] F. Meinl, M. Stolz, M. Kunert und H. Blume. »An Experimental High Performance Radar System for Highly Automated Driving«. In: *IEEE MTT-S 2017 International Conference on Microwaves for Intelligent Mobility*. 2017.

- [70] F. Meinl, M. Kunert und H. Blume. »Massively Parallel Signal Processing Challenges within a Driver Assistant Prototype Framework First Case Study Results with a Novel MIMO-Radar«. In: *2014 International Conference on Embedded Computer Systems: Architectures, Modeling, and Simulation (SAMOS XIV)*. Juli 2014, S. 351–357.
- [71] F. Meinl, E. Schubert, M. Kunert und H. Blume. »Realtime FPGA-based Processing Unit for a High-Resolution Automotive MIMO Radar Platform«. In: *2015 European Radar Conference (EuRAD)*. Sep. 2015, S. 213–216.
- [72] M. Wolf. *Entwicklung und Design eines Antennenarrays für ein hochauflösendes Automobilradar zum Schutz von schwachen Verkehrsteilnehmern*. Masterarbeit an der Friedrich-Alexander Universität Erlangen-Nürnberg. 2017.
- [73] M. Stolz, M. Wolf, F. Meinl, M. Kunert und W. Menzel. »A New Antenna Array and Signal Processing Concept for an Automotive 4D Radar«. In: *2018 15th European Radar Conference (EuRAD)*. Sep. 2018, S. 63–66.
- [74] B. B. Jones, F. Y. M. Chow und A. W. Seeto. »The Synthesis of Shaped Patterns with Series-Fed Microstrip Patch Arrays«. In: *IEEE Transactions on Antennas and Propagation* 30.6 (Nov. 1982), S. 1206–1212.
- [75] M. Sullivan. *Practical Array Processing*. McGraw Hill, 2008.
- [76] H. Rohling. »Radar CFAR Thresholding in Clutter and Multiple Target Situations«. In: *Aerospace and Electronic Systems, IEEE Transactions on AES-19.4* (Juli 1983), S. 608–621.
- [77] H. Rohling und R. Mende. »OS CFAR PERFORMANCE IN A 77 GHz RADAR SENSOR FOR CAR APPLICATION«. In: *Proceedings of 1996 CIE International Conference on Radar*. Okt. 1996, S. 109–114.
- [78] M. A. Richards. *Fundamentals of Radar Signal Processing*. 1. Aufl. Madison: McGraw Hill Professional, 2005.
- [79] M. Reiher. »Optimierung von Sendesignalen zur Vermeidung von Scheinzielen für frequenzmodulierte Dauerstrich-Radarsysteme im Automobil«. Diss. Universität Stuttgart, 2011.
- [80] M. Gasior. »Improving Frequency Resolution of Discrete Spectra«. Diss. AGH University of Science und Technology Krakow, 2006.
- [81] H. Krim und M. Viberg. »Two decades of array signal processing research: the parametric approach«. In: *Signal Processing Magazine, IEEE* 13.4 (Juli 1996), S. 67–94.
- [82] V. C. Chen, F. Li, S. S. Ho und H. Wechsler. »Micro-Doppler Effect in Radar: Phenomenon, Model, and Simulation Study«. In: *IEEE Transactions on Aerospace and Electronic Systems* 42.1 (Jan. 2006), S. 2–21.
- [83] S. Heuel und H. Rohling. »Pedestrian recognition based on 24 GHz radar sensors«. In: *Radar Symposium (IRS), 2010 11th International*. Juni 2010, S. 1–6.

- [84] S. Heuel und H. Rohling. »Pedestrian recognition in automotive radar sensors«. In: *Radar Symposium (IRS), 2013 14th International*. Bd. 2. Juni 2013, S. 732–739.
- [85] E. Schubert, F. Meinl, M. Kunert und W. Menzel. »High Resolution Automotive Radar Measurements of Vulnerable Road Users - Pedestrians & Cyclists«. In: *2015 IEEE MTT-S International Conference on Microwaves for Intelligent Mobility (ICMIM)*. Apr. 2015, S. 1–4.
- [86] P. van Dorp und F. Groen. »Human walking estimation with radar«. In: *Radar, Sonar and Navigation, IEE Proceedings - 150.5* (Okt. 2003), S. 356–365.
- [87] H. Ritter und H. Rohling. »Pedestrian detection based on automotive radar«. In: *Radar Systems, 2007 IET International Conference on*. Okt. 2007, S. 1–4.
- [88] E. Schubert, M. Kunert, W. Menzel, J. Fortuny-Guasch und J.-M. Chareau. »Human RCS measurements and dummy requirements for the assessment of radar based active pedestrian safety systems«. In: *Radar Symposium (IRS), 2013 14th International*. Bd. 2. Juni 2013, S. 752–757.
- [89] E. Schubert, M. Kunert, A. Frischen und W. Menzel. »A Multi-Reflection-Point Target Model for Classification of Pedestrians by Automotive Radar«. In: *2014 11th European Radar Conference (EuRAD)*. Okt. 2014, S. 181–184.
- [90] M. Ester und J. Sander. *Knowledge Discovery in Databases*. Springer-Verlag Berlin Heidelberg GmbH, 2000.
- [91] E. Schubert, F. Meinl, M. Kunert und W. Menzel. »Clustering of High Resolution Automotive Radar Detections and Subsequent Feature Extraction for Classification of Road Users«. In: *2015 16th International Radar Symposium (IRS)*. Juni 2015, S. 174–179.
- [92] T. Wagner, R. Feger und A. Stelzer. »Modification of DBSCAN and application to range/Doppler/DoA measurements for pedestrian recognition with an automotive radar system«. In: *2015 European Radar Conference (EuRAD)*. Sep. 2015, S. 269–272.
- [93] J. Schlichenmaier, F. Roos, M. Kunert und C. Waldschmidt. »Adaptive clustering for contour estimation of vehicles for high-resolution radar«. In: *2016 IEEE MTT-S International Conference on Microwaves for Intelligent Mobility (ICMIM)*. Mai 2016, S. 1–4.
- [94] T. Wagner, R. Feger und A. Stelzer. »A fast grid-based clustering algorithm for range/Doppler/DoA measurements«. In: *2016 European Radar Conference (EuRAD)*. Okt. 2016, S. 105–108.
- [95] F. R. Whitt und D. G. Wilson. *Bicycling Science Ergonomics and Mechanics*. MIT Press, 1974.
- [96] M. Gressmann. *Fahrradphysik und Biomechanik - Technik Formeln Gesetze*. DeLius Klasing, 2010.

- [97] W. Suhr und H.-J. Schlichting. »Gleichgewicht auf zwei Rädern - Physik des Radfahrens«. In: *Physik in unserer Zeit* 38.5 (Sep. 2007), S. 238–241.
- [98] K. J. Astrom, R. E. Klein und A. Lennartsson. »Bicycle dynamics and control: adapted bicycles for education and research«. In: *IEEE Control Systems* 25.4 (Aug. 2005), S. 26–47.
- [99] H. Kuchling. *Taschenbuch der Physik*. 21. Aufl. Muenchen: Hanser Fachbuchverlag, 2014.
- [100] I. N. Bronshtein, K. A. Semendyayev, G. Musiol und H. Muehlig. *Handbook of Mathematics*. Hrsg. von 5th. Springer Berlin Heidelberg New York, 2005.
- [101] L. Vignaud, A. Ghaleb, J. L. Kerneec und J. Nicolas. »Radar high resolution range amp; micro-Doppler analysis of human motions«. In: *2009 International Radar Conference SSurveillance for a Safer World”(RADAR 2009)*. Okt. 2009, S. 1–6.
- [102] I. Prokopenko, K. Prokopenko und I. Martynchuk. »Moving objects recognition by micro-Doppler spectrum«. In: *2015 16th International Radar Symposium (IRS)*. Juni 2015, S. 186–190.
- [103] D. Belgiovane und C. C. Chen. »Micro-Doppler characteristics of pedestrians and bicycles for automotive radar sensors at 77 GHz«. In: *2017 11th European Conference on Antennas and Propagation (EUCAP)*. März 2017, S. 2912–2916.
- [104] A. Seifert, M. G. Amin und A. M. Zoubir. »New analysis of radar micro-Doppler gait signatures for rehabilitation and assisted living«. In: *2017 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*. März 2017, S. 4004–4008.
- [105] A. Seifert, A. M. Zoubir und M. G. Amin. »Radar-based human gait recognition in cane-assisted walks«. In: *2017 IEEE Radar Conference (RadarConf)*. Mai 2017, S. 1428–1433.
- [106] D. Belgiovane und C. C. Chen. »Bicycles and human riders backscattering at 77 GHz for automotive radar«. In: *2016 10th European Conference on Antennas and Propagation (EuCAP)*. Apr. 2016, S. 1–5.
- [107] D. J. Belgiovane, C. C. Chen, S. Y. P. Chien und R. Sherony. »Surrogate Bicycle Design for Millimeter-Wave Automotive Radar Pre-Collision Testing«. In: *IEEE Transactions on Intelligent Transportation Systems* PP.99 (2017), S. 1–10.
- [108] M. Stolz, E. Schubert, F. Meinl, M. Kunert und W. Menzel. »Multi-Target Reflection Point Model of Cyclists for Automotive Radar«. In: *2017 European Radar Conference (EURAD)*. Okt. 2017, S. 94–97.

- [109] Zweirad-Industrie-Verband. *Zahlen - Daten - Fakten zum Fahrradmarkt in Deutschland 2016*. Zweirad-Industrie-Verband. März 2017. URL: [http://www.ziv-zweirad.de/fileadmin/redakteure/Downloads/Marktdaten/PK\\_2017-ZIV\\_Praesentation\\_7.03.2017\\_oT.pdf](http://www.ziv-zweirad.de/fileadmin/redakteure/Downloads/Marktdaten/PK_2017-ZIV_Praesentation_7.03.2017_oT.pdf).
- [110] M. Buhren und B. Yang. »Simulation of Automotive Radar Target Lists using a Novel Approach of Object Representation«. In: *2006 IEEE Intelligent Vehicles Symposium*. 2006, S. 314–319.
- [111] M. Buhren und B. Yang. »Automotive radar target list simulation based on reflection center representation of objects«. In: *Intern. Workshop on Intelligent Transportation (WIT)*. März 2006, S. 161–166.
- [112] M. Buhren und B. Yang. »Extension of Automotive Radar Target List Simulation to consider further Physical Aspects«. In: *2007 7th International Conference on ITS Telecommunications*. Juni 2007, S. 1–6.
- [113] Z. Zhang und N. F. Troje. »3D Periodic Human Motion Reconstruction from 2D Motion Sequences«. In: *2004 Conference on Computer Vision and Pattern Recognition Workshop*. Juni 2004, S. 186–186.
- [114] M. Stolz, M. Li, Z. Feng, M. Kunert und W. Menzel. »Direction of Movement Estimation of Cyclists with a High-Resolution Automotive Radar«. In: *2018 IEEE MTT-S International Conference on Microwaves for Intelligent Mobility (ICMIM)*. Apr. 2018, S. 1–4.
- [115] P. C. Hough V. »Method and means for recognizing complex patterns«. 3069654. Dez. 1962.
- [116] M. A. Fischler und R. C. Bolles. »Random Sample Consensus: A Paradigm for Model Fitting with Applications to Image Analysis and Automated Cartography«. In: *Communications of the ACM* 24.6 (Juni 1981), S. 381–395.
- [117] R. O. Duda und P. E. Hart. »Use of the Hough Transformation to detect lines and curves in pictures«. In: *Communications of the ACM* 15.1 (Jan. 1972), S. 11–15.
- [118] D. Kellner, M. Barjenbruch, K. Dietmayer, J. Klappstein und J. Dickmann. »Instantaneous lateral velocity estimation of a vehicle using Doppler radar«. In: *Information Fusion (FUSION), 2013 16th International Conference on*. Juli 2013, S. 877–884.
- [119] J. Schlichenmaier, L. Yan, M. Stolz und C. Waldschmidt. »Instantaneous Actual Motion Estimation with a Single High-Resolution Radar Sensor«. In: *2018 IEEE MTT-S International Conference on Microwaves for Intelligent Mobility (ICMIM)*. Apr. 2018, S. 1–4.
- [120] 4active Systems. *4activeBS static bicyclist*. <http://www.4activesystems.at/en/products/dummies/4activebs.html>. Abruf am 06.12.2018. 2018.
- [121] T. Wimmer, M. Fritz und H.-J. Lernpass. *Dummy Development*. Techn. Ber. PROSPECT Consortium, 2018.

- [122] G. S. Hobson, H. Roe und J. P. Hawley. »Microwave Classification of Road Vehicles«. In: *1990 20th European Microwave Conference*. Bd. 2. Sep. 1990, S. 996–1001.
- [123] H. Roe und G. S. Hobson. »Improved discrimination of microwave vehicle profiles«. In: *1992 IEEE MTT-S Microwave Symposium Digest*. Juni 1992, 717–720 vol.2.
- [124] I. R. Urazghildiiev, R. Ragnarsson, K. Wallin, A. Rydberg, P. Ridderstrom und E. Ojefors. »A vehicle classification system based on microwave radar measurement of height profiles«. In: *RADAR 2002*. Okt. 2002, S. 409–413.
- [125] S. Heuel und H. Rohling. »Two-stage pedestrian classification in automotive radar systems«. In: *Radar Symposium (IRS), 2011 Proceedings International*. Sep. 2011, S. 477–484.
- [126] S. Heuel und H. Rohling. »Pedestrian classification in automotive radar systems«. In: *Radar Symposium (IRS), 2012 13th International*. Mai 2012, S. 39–44.
- [127] S. Villeval, I. Bilik und S. Z. Gürbüz. »Application of a 24 GHz FMCW automotive radar for urban target classification«. In: *2014 IEEE Radar Conference*. Mai 2014, S. 1237–1240.
- [128] R. Zhang und S. Cao. »Support vector machines for classification of automotive radar interference«. In: *2018 IEEE Radar Conference (RadarConf18)*. Apr. 2018, S. 0366–0371.
- [129] R. P. Trommel, R. I. A. Harmanny, L. Cifola und J. N. Driessen. »Multi-target Human Gait Classification Using Deep Convolutional Neural Networks on Micro-Doppler Spectrograms«. In: *2016 European Radar Conference (EuRAD)*. Okt. 2016, S. 81–84.
- [130] Y. Shao, S. Guo, L. Sun und W. Chen. »Human Motion Classification Based on Range Information with Deep Convolutional Neural Network«. In: *2017 4th International Conference on Information Science and Control Engineering (ICISCE)*. Juli 2017, S. 1519–1523.
- [131] J. Park, R. J. Javier, T. Moon und Y. Kim. »Micro-Doppler Based Classification of Human Aquatic Activities via Transfer Learning of Convolutional Neural Networks«. In: *Sensors* 16 (2016).
- [132] S. Capobianco, L. Facheris, F. Cuccoli und S. Marinai. »Vehicle classification based on convolutional networks applied to FM-CW radar signals«. In: *CoRR* 1710.05718 (2017). arXiv: 1710.05718. URL: <http://arxiv.org/abs/1710.05718>.
- [133] A. Angelov, A. Robertson, R. Murray-Smith und F. Fioranelli. »Practical classification of different moving targets using automotive radar and deep neural networks«. In: *IET Radar, Sonar and Navigation* (Apr. 2018).

- [134] R. Prophet, M. Hoffmann, A. Ossowska, W. Malik, C. Sturm und M. Vossiek. »Pedestrian Classification for 79 GHz Automotive Radar Systems«. In: *2018 IEEE Intelligent Vehicles Symposium (IV)*. Juni 2018, S. 1265–1270.
- [135] C. R. Qi, H. Su, K. Mo und L. J. Guibas. »PointNet: Deep Learning on Point Sets for 3D Classification and Segmentation«. In: *arXiv preprint arXiv:1612.00593* (2016).
- [136] C. R. Qi, L. Yi, H. Su und L. J. Guibas. »PointNet++: Deep Hierarchical Feature Learning on Point Sets in a Metric Space«. In: *arXiv preprint arXiv:1706.02413* (2017).
- [137] O. Schumann, M. Hahn, J. Dickmann und C. Wöhler. »Semantic Segmentation on Radar Point Clouds«. In: *2018 21st International Conference on Information Fusion (FUSION)*. Juli 2018, S. 2179–2186.
- [138] I. Goodfellow, Y. Bengio und A. Courville. *Deep Learning*. MIT Press, 2017.
- [139] V. Sze, Y. H. Chen, T. J. Yang und J. S. Emer. »Efficient Processing of Deep Neural Networks: A Tutorial and Survey«. In: *Proceedings of the IEEE* 105.12 (Dez. 2017), S. 2295–2329.
- [140] B. Ding, H. Qian und J. Zhou. »Activation functions and their characteristics in deep neural networks«. In: *2018 Chinese Control And Decision Conference (CCDC)*. Juni 2018, S. 1836–1841.
- [141] R. Hecht-Nielsen. »Theory of the backpropagation neural network«. In: *International 1989 Joint Conference on Neural Networks*. 1989, 593–605 vol.1.
- [142] Y. LeCun, L. Bottou, G. B. Orr und K.-R. Müller. *Neural Networks: Tricks of the Trade - Efficient BackProp*. Hrsg. von G. B. Orr und K.-R. Müller. Springer, Berlin, Heidelberg, 1998.
- [143] M. Nielsen. *How the backpropagation algorithm works*. <http://neuralnetworksanddeeplearning.com/chap2.html>. Abruf am 09.01.2019.
- [144] W. Dahmen und A. Reusken. *Numerik für Ingenieure und Naturwissenschaftler*. Springer-Verlag Berlin Heidelberg, 2008.
- [145] L. N. Smith. »No More Pesky Learning Rate Guessing Games«. In: *CoRR* (2015). arXiv: 1506.01186. URL: <http://arxiv.org/abs/1506.01186>.
- [146] R. O. Duda, P. E. Hart und D. G. Stork. *Pattern Classification*. Wiley, 2000.
- [147] D. E. Rumelhart, G. E. Hinton und R. J. Williams. »Learning representations by back-propagating errors«. In: *Nature* 323 (Okt. 1986), S. 533–536.
- [148] Y. L. Cun. *Generalization and Network Design Strategies*. Techn. Ber. University of Toronto, 1989.

- [149] Y. L. Cun, B. Boser, J. S. Denker, R. E. Howard, W. Hubbard, L. D. Jackel und D. Henderson. »Advances in Neural Information Processing Systems 2«. In: Hrsg. von D. S. Touretzky. San Francisco, CA, USA: Morgan Kaufmann Publishers Inc., 1990. Kap. Handwritten Digit Recognition with a Back-propagation Network, S. 396–404.
- [150] A. Krizhevsky, I. Sutskever und G. E. Hinton. »ImageNet Classification with Deep Convolutional Neural Networks«. In: *Proceedings of the 25th International Conference on Neural Information Processing Systems - Volume 1*. Lake Tahoe, Nevada, 2012.
- [151] T. N. Sainath, B. Kingsbury, G. Saon, H. Soltau, A.-r. Mohamed, G. Dahl und B. Ramabhadran. »Deep Convolutional Neural Networks for Large-scale Speech Tasks«. In: *Neural Netw.* 64 (2015), S. 39–48.
- [152] S. Levine, C. Finn, T. Darrell und P. Abbeel. »End-to-End Training of Deep Visuomotor Policies«. In: *CoRR* abs/1504.00702 (2015). arXiv: 1504.00702. URL: <http://arxiv.org/abs/1504.00702>.
- [153] D. Scherer, A. Müller und S. Behnke. »Evaluation of Pooling Operations in Convolutional Architectures for Object Recognition«. In: *Proceedings of the 20th International Conference on Artificial Neural Networks: Part III. ICANN'10*. Thessaloniki, Greece: Springer-Verlag, 2010, S. 92–101.
- [154] S. Ioffe und C. Szegedy. »Batch Normalization: Accelerating Deep Network Training by Reducing Internal Covariate Shift«. In: *CoRR* abs/1502.03167 (2015). arXiv: 1502.03167. URL: <http://arxiv.org/abs/1502.03167>.
- [155] M. Ester, H.-P. Kriegel, J. Sander und X. Xu. »A Density-Based Algorithm for Discovering Clusters in Large Spatial Databases with Noise«. In: *Proceedings of 2nd International Conference on Knowledge Discovery and Data Mining*. 1996.
- [156] M. Stolz, M. Li, Z. Feng, M. Kunert und W. Menzel. »High Resolution Automotive Radar Data Clustering with Novel Cluster Method«. In: *2018 IEEE Radar Conference (RadarConf18)*. Apr. 2018, S. 0164–0168.
- [157] S. Suzuki und K. Abe. »Topological Structural Analysis of Digitized Binary Images by Border Following«. In: *Computer Vision, Graphics, and Image Processing* 30 (Apr. 1985), S. 32–46.
- [158] M. Yamada und K. Hasuike. »Document image processing based on enhanced border following algorithm«. In: *[1990] Proceedings. 10th International Conference on Pattern Recognition*. Bd. ii. Juni 1990, 231–236 vol.2.
- [159] R. Girshick, J. Donahue, T. Darrell und J. Malik. »Rich feature hierarchies for accurate object detection and semantic segmentation«. In: *2014 IEEE Conference on Computer Vision and Pattern Recognition*. Juni 2014, S. 580–587.

- [160] J. R. R. Uijlings, K. E. A. van de Sande, T. Gevers und A. W. M. Smeulders. »Selective Search for Object Recognition«. In: *International Journal of Computer Vision* 104 (2013), S. 154–171.
- [161] R. Girshick. »Fast R-CNN«. In: *2015 IEEE International Conference on Computer Vision (ICCV)*. Dez. 2015, S. 1440–1448.
- [162] S. Ren, K. He, R. Girshick und J. Sun. »Faster R-CNN: Towards Real-Time Object Detection with Region Proposal Networks«. In: *IEEE Transactions on Pattern Analysis and Machine Intelligence* 39.6 (Juni 2017), S. 1137–1149.
- [163] J. Hosang, R. Benenson und B. Schiele. »Learning Non-maximum Suppression«. In: *2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*. Juli 2017, S. 6469–6477.
- [164] S. R. Richter, V. Vineet, S. Roth und V. Koltun. »Playing for Data: Ground Truth from Computer Games«. In: *CoRR abs/1608.02192* (2016). arXiv: 1608.02192.
- [165] S. Shah, D. Dey, C. Lovett und A. Kapoor. »AirSim: High-Fidelity Visual and Physical Simulation for Autonomous Vehicles«. In: *CoRR abs/1705.05065* (2017). arXiv: 1705.05065.
- [166] P. J. Schneider. *Klassifikation von Verkehrsteilnehmern in FMCW-Radar Mikro-Doppler Signaturen mittels CNN, basierend auf simulierten und realen Trainingsdaten*. Masterarbeit an der Universität Stuttgart. 2018.
- [167] Y. Lecun, L. Bottou, Y. Bengio und P. Haffner. »Gradient-based learning applied to document recognition«. In: *Proceedings of the IEEE* 86.11 (Nov. 1998), S. 2278–2324.
- [168] Y. He, Y. Yang, Y. Lang, D. Huang, X. Jing und C. Hou. »Deep Learning based Human Activity Classification in Radar Micro-Doppler Image«. In: *2018 15th European Radar Conference (EuRAD)*. Sep. 2018, S. 230–233.
- [169] M. G. Amin und B. Erol. »Understanding deep neural networks performance for radar-based human motion recognition«. In: *2018 IEEE Radar Conference (RadarConf18)*. Apr. 2018, S. 1461–1465.
- [170] H. Du, Y. He und T. Jin. »Transfer Learning for Human Activities Classification Using Micro-Doppler Spectrograms«. In: *2018 IEEE International Conference on Computational Electromagnetics (ICCEM)*. März 2018, S. 1–3.
- [171] H. T. Le, S. L. Phung und A. Bouzerdoum. »Human Gait Recognition with Micro-Doppler Radar and Deep Autoencoder«. In: *2018 24th International Conference on Pattern Recognition (ICPR)*. Aug. 2018, S. 3347–3352.
- [172] J. Huang und S. You. »Point cloud labeling using 3D Convolutional Neural Network«. In: *2016 23rd International Conference on Pattern Recognition (ICPR)*. Dez. 2016, S. 2670–2675.



# Lebenslauf

Der Lebenslauf wurde aus Gründen des Datenschutzes entfernt.