




Jonas Fuchs (Autor)

Hybride Deep Learning-Verfahren zur Interferenzunterdrückung und hochauflösenden Winkelschätzung für Automobilradaranwendungen



Jonas Fuchs

Hybride Deep Learning-Verfahren
zur Interferenzunterdrückung und
hochauflösenden Winkelschätzung
für Automobilradaranwendungen



Cuvillier Verlag Göttingen
Internationaler wissenschaftlicher Fachverlag

<https://cuvillier.de/de/shop/publications/8737>

Copyright:

Cuvillier Verlag, Inhaberin Annette Jentsch-Cuvillier, Nonnenstieg 8, 37075 Göttingen,
Germany

Telefon: +49 (0)551 54724-0, E-Mail: info@cuvillier.de, Website: <https://cuvillier.de>

KAPITEL 1

Einleitung

1.1 Motivation

Der Mensch ist bis heute der größte Risikofaktor im Straßenverkehr und mitverantwortlich für über 90 % der verursachten Unfälle [1]. Entsprechend sind Lösungen und Ansätze um die Sicherheit zu erhöhen Hauptbestandteile aktueller Forschung. So soll beispielsweise (teil-)autonomes Fahren einen erheblichen Anteil dazu beitragen die Sicherheit im Straßenverkehr in den kommenden Jahren zu erhöhen. Neben nahezu allen großen Automobilherstellern forschen auch viele andere Großkonzerne und Firmen aus dem Mobilitätssektor an selbstfahrenden Autos der Kategorie 3 oder höher [2]. Die Nationale Plattform Zukunft der Mobilität (NPM), ein Beratungsgremium der deutschen Bundesregierung, sieht die Implementierung von autonomer Mobilität bis 2025 beziehungsweise 2030 als eines der Ziele für die Zukunft unserer Mobilität. Des Weiteren wird im Bericht „Digitalisierung für den Mobilitätssektor“ der NPM der Bereich „Daten, Software und Künstliche Intelligenz“ als Schlüsseltechnologie zukünftiger Mobilitätskonzepte herausgestellt [3]. Eine Marktprognose für künstliche Intelligenz (KI) in der globalen Automobilindustrie schätzt die jährliche Wachstumsrate zwischen 2017 und 2025 auf 48 % [4].

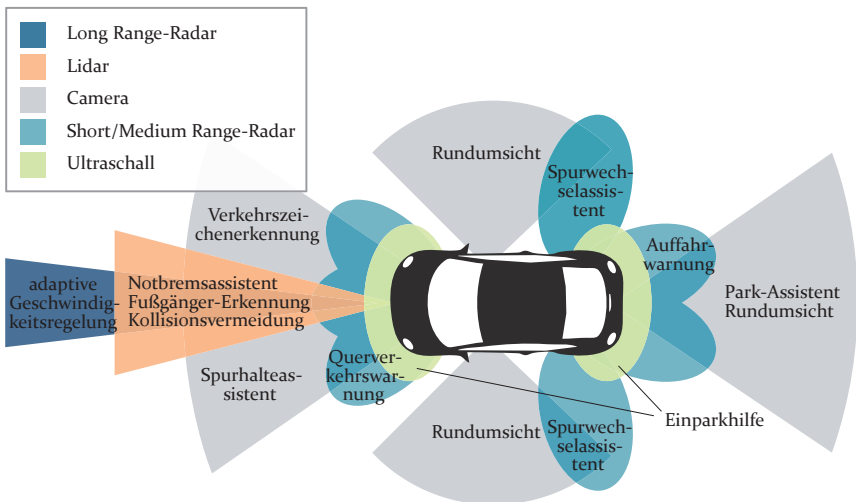


Abbildung 1.1: Umfeldwahrnehmung und Fahrerassistenzsysteme eines Kraftfahrzeugs unterteilt in verschiedene Sensormodalitäten sowie Anwendungs- und Entfernungsbereiche, nach [4].

Bereits heute existieren in modernen Kraftfahrzeugen (Kfz) eine Vielzahl an Fahrerassistenzsystemen (engl.: *advanced driver assistance systems*, ADAS), die dazu beitragen den

Komfort und die Sicherheit zu erhöhen, sowie Emissionen und Stress im Straßenverkehr zu reduzieren [1]. Ab Juli 2022 sind verschiedene ADAS-Funktionen, wie ein Notbremsassistentensystem und ein Notfall-Spurhalteassistent, Pflicht für neue Kraftfahrzeuge. Neue Lastkraftwagen und Busse benötigen zusätzlich noch eine hochentwickelte Fußgänger- und Radfahrererkennung [5]. Die Übersicht in Abb. 1.1 zeigt die verschiedenen ADAS-Funktionen und dafür verwendete Sensortechnologien. Insbesondere das Automobilradar stellt hierbei eine Schlüsseltechnologie für die zuverlässige Erkennung von Hindernissen und anderen Verkehrsteilnehmern dar. Als eine der wichtigsten Sensortechnologien für hochautomatisiertes Fahren (engl.: *highly automated driving*, HAD) ist es beispielsweise für die adaptive Geschwindigkeitsregelung (engl.: *adaptive cruise control*, ACC) oder den Spurwechselassistenten (engl.: *lane change assist*, LCA) zur Erkennung vorausfahrender Fahrzeuge und ihrer Geschwindigkeit unentbehrlich [6, 7]. Durch Vorteile wie einem geringen Formfaktor, niedrigen Kosten im Vergleich zu Lidar, sowie der hohen Robustheit bei schlechten Wetterbedingungen, ist Radar der bevorzugte Sensor für viele ADAS-Funktionen und autonom agierende Fahrzeuge [8–10].

Mit entsprechender Signalverarbeitung der Radarsignale kann mittels Frequenzschätzung die Entfernung, radiale Geschwindigkeit, sowie der Azimut- und Elevationswinkel von Hindernissen bestimmt werden. Die Auflösung in allen Dimensionen spielt eine entscheidende Rolle für die Zuverlässigkeit und Sicherheit von Radarsensorik und wird dementsprechend durch Weiterentwicklungen der Technologie, neuen Wellenformen oder leistungsfähigerer Signalverarbeitung stetig verbessert [9–13]. Durch die geforderte Entfernungsauflösung wird jedoch auch die Frequenzbänder immer mehr ausgereizt, da die Entfernungsauflösung indirekt proportional zur Bandbreite ist. Entsprechend sind Interferenzen zwischen einzelnen Radarsensoren unvermeidbar und werden in Zukunft noch deutlich zunehmen [14]. Zudem führt die fehlende Regulierung innerhalb der Frequenzbänder für Automobilradar ebenfalls dazu, dass die steigende Anzahl der Radarsensoren pro Fahrzeug (vgl. Abb. 1.1) mit Mehrfachbelegungen des Spektrums einhergeht [15, 16]. Diese gegenseitigen Interferenzen resultieren in Verzerrungen des Basisbandsignals, wodurch das Grundrauschen angehoben wird, sich die Wahrscheinlichkeit für Fehldetektionen erhöht und potenzielle Geisterziele entstehen [7]. Damit ist eine verlässliche Interferenzerkennung und Interferenzunterdrückung für Automobilradare essenziell, um autonomes Fahren mit Level 4 bis 5 gemäß der Definition in [17] zu realisieren und jederzeit einen zuverlässigen Betrieb gewährleisten zu können.

Des Weiteren wird für eine hochgenaue Lokalisierung von Zielen neben der Entfernungsauflösung auch eine hohe Winkelauflösung benötigt. Die Anforderungen für das autonome Fahren in Level 4 und 5 an die Winkelauflösung des Radars betragen weniger als 1° , was selbst unter Nutzung von Multiple-Input Multiple-Output (MIMO) Technologien sehr aufwändig zu realisieren ist [12]. Um diesen Anforderungen zu genügen, werden sogenannte hochauflösende Winkelschätzverfahren benötigt, um die von der Apertur des Sensors vorgegebene physikalische Auflösungsgrenze zu unterbieten. Viele hochauflösende Signalverarbeitungsalgorithmen setzen jedoch entweder die Verfügbarkeit mehrerer Messungen voraus, oder erfordern eine zusätzliche Vorverarbeitung, welche die Gesamtapertur effektiv verringert. Modellbasierte Methoden, wie die Maximum Likelihood-Schätzung (engl.: *maximum likelihood estimation*, MLE), funktionieren wiederum nur unter der Annahme des korrekten Signalmodells und sind im Allgemeinen sehr rechenaufwändig [18]. Zudem

steigt der Rechenaufwand der MLE exponentiell mit der Anzahl der zu schätzenden Winkel, wodurch ein Einsatz in der Praxis nicht praktikabel ist.

In den genannten Bereichen der Radarsignalverarbeitung können Methoden des maschinellen Lernens (ML) angewendet werden, um Algorithmen für traditionelle Problemstellungen der Hochfrequenz (HF)-Signalverarbeitung zu trainieren und die Leistungsfähigkeit und Robustheit von konventionellen Verfahren zu übertreffen. Durch die zunehmende Verfügbarkeit von Rechenleistung, Datensätzen und Software für maschinelles Lernen (ML) ist die Deep Learning (DL)-basierte Radarsignalverarbeitung mittlerweile ein hochaktuelles und aktives Forschungsgebiet [19]. Deep Learning beschreibt hierbei ein Teilgebiet von ML, das sogenannte tiefe künstliche neuronale Netze nutzt [20]. Ein essenzieller Bestandteil für die Anwendung von DL-basierten Verfahren in der Signalverarbeitung ist die Existenz von entsprechenden Datensätzen für das Training der Modelle. Gerade im Automobilbereich ist die Erstellung von Datensätzen, insbesondere die Annotation der Daten, jedoch sehr aufwändig [10]. Aktuell ist entsprechend kein weit verbreiteter und großer Datensatz für Automobilradar verfügbar, welcher dem Stand der Technik entspricht [9]. Deshalb sind für den Erfolg von DL im Automobilbereich alternative und vor allem automatisierte Lösungen notwendig. Hier wird mit den entwickelten hybriden modell- und datenbasierten Verfahren angesetzt, wodurch eine aufwändige manuelle Annotation von Daten eingespart werden soll. Insbesondere für die Interferenzunterdrückung soll durch DL-Methoden eine erhöhte Robustheit erzielt werden, indem beispielsweise die Algorithmen auf verschiedenste Modulationsarten von interferierenden Radarsensoren trainiert werden. Auch im Bereich der Winkelschätzung besteht viel Potenzial für neue DL-basierte Schätzverfahren, welche durch entsprechendes Training eine hochauflösende Winkelschätzung mit konstantem Rechenaufwand in Echtzeit ermöglichen und dabei zugleich robuster gegenüber Modellfehlern und Rauscheinflüssen sind.

1.2 Stand der Technik

Im Rahmen des EU HORIZON 2020 Projektes PRYSTINE („Programmable Systems for Intelligence in Automobiles“) ¹, aus dem auch die vorliegende Arbeit entstand, wurden am Lehrstuhl für Technische Elektronik die genannten Vorteile von DL-Methoden näher untersucht. Dabei wurden verschiedenste Stufen der Signalverarbeitungskette für Automobilradar durch DL-Modelle ersetzt, trainiert und deren Leistungsfähigkeit gegenüber der traditionellen Radarsignalverarbeitung evaluiert. Die traditionelle Signalverarbeitungskette, bestehend aus Interferenzdetektion, Interferenzreduktion, Range-Doppler Verarbeitung, Zieldetektion, Winkelschätzung, Zielklassifikation, und Tracking wird in Abschnitt 2.1.3 detailliert thematisiert. Im Folgenden wird ein Überblick über den aktuellen Stand der Technik der DL-basierten Radarsignalverarbeitung gegeben, wobei der Fokus auf den drei Kerngebieten dieser Arbeit liegt: der Interferenzreduktion, der Winkelschätzung, sowie aktuell verfügbaren Datensätzen hierfür. Ein allgemeiner Überblick über Anwendungen von DL in den darauf aufbauenden Stufen der Radarsignalverarbeitung, wie Zieldetektion, Klassifikation, Tracking oder semantischer Segmentierung wird beispielsweise in [9] gegeben.

¹PRYSTINE Projekt Homepage: <https://prystine.eu> (aufgerufen am 15.04.2022)

1.2.1 Deep Learning-basierte Interferenzunterdrückung

Interferenzunterdrückung, also der konventionelle Ansatz der Detektion der Störung und anschließender Rekonstruktion der gestörten Signale, ist bereits der Standard bei aktuellen kommerziellen Radarsensoren [10]. Hierbei gibt es algorithmisch unterschiedliche Ansätze, um gestörte Abtastwerte zu rekonstruieren oder zu filtern. Diese werden meist im Zeitbereich angewendet [21–23]. Eine Herausforderung im Entwurf von algorithmischen sowie modellbasierten Ansätzen besteht darin, Robustheit gegenüber unterschiedlichsten Arten und Leistungen von Interferenzsignalen zu erreichen, da diese im Allgemeinen unbekannt sind und keinem definierbaren Muster folgen. Datenbasierte Ansätze, wie beispielsweise DL, können hingegen durch Training mit entsprechenden Datensätzen von hoher Quantität und Qualität sehr komplexe Modelle erlernen.

Tabelle 1.1: Stand der Technik zur Deep Learning-basierten Interferenzerkennung und -reduktion.

Publ.	Detekti- on	Redukti- on	Netzwerk Typ	Domäne	Datensatz
[24]		✓	RNN	Zeitsignal (TD)	Simulationsdaten (76–78 GHz)
[25]		✓	MLP, AE	Doppler-Winkel (FD)	Messdaten (3,3–10,3 GHz [*])
[26]	✓		U-Net	Spektrogramm (TFD)	Radioastronomie Messdaten (L-Band)
[27]	✓	✓	CNN, ResNet	Spektrogramm (TFD)	Simulationsdaten (X-Band #)
[28]		✓	CNN	Range-Profil (FD), Range-Doppler (FD)	Simulationsdaten (75,8–76,2 GHz)

TD: Zeitbereich, FD: Frequenzbereich, TFD: Zeit-Frequenz-Bereich (engl.: *time-frequency domain*, TFD)

Synthetic Aperture-Radar (SAR)

* Ultrabreitband (engl.: *ultra-wideband*, UWB) Radarbildgebung durch die Wand

Eine Übersicht über den Stand der Technik von DL-basierten Methoden zur Interferenzunterdrückung, untergliedert in die beiden Teilbereiche Detektion und Reduktion von Interferenzen, ist in Tab. 1.1 aufgeführt. Generell ist eine Detektion der Interferenz sowohl im Zeitbereich (engl.: *time domain*, TD) als auch im Frequenzbereich (engl.: *frequency domain*, FD) möglich. Hierbei eignen sich beispielsweise sogenannte rückgekoppelte neuronale Netzwerke (RNN) zur Entfernung der Störung und anschließender Rekonstruktion der gestörten Abtastwerte im Zeitsignal [24]. Die in [24] gezeigten Ergebnisse wurden jedoch nur für eine einzelne Wellenform des Störers und mittels Simulationsdaten validiert. Eine Studie von Autoencodern (AE) zur Reduktion von Interferenzen im Frequenzbereich wurde in [25] durchgeführt. Dabei werden sowohl Simulations- als auch Messdaten eines Ultrabreitband (engl.: *ultra-wideband*, UWB) Radarsystems verwendet. Allerdings werden hier keine aktiven HF Interferenzen betrachtet, sondern der Einfluss der Wellenausbreitung durch die Wand als Interferenzeffekt bezeichnet. Zudem erfolgt die Verarbeitung im neuronalen Netz nicht als Matrix, sondern in vektorisierter Form. Dadurch eignet sich

die Methode nicht für größere Matrizen, da ein Zusammenhang von benachbarten Pixeln nicht berücksichtigt wird.

Eine weitere Architektur neuronaler Netze, die ursprünglich für die Bildverarbeitung entstand, ist das Faltungsnetzwerk (engl.: *convolutional neural network*, CNN) [20]. In einem CNN wird die Eingabematrix eines Bildes mit erlernten Kernel-Werten gefaltet, um Merkmale aus den Eingabedaten zu extrahieren. In [26] werden CNNs in der sogenannten U-Net Architektur nach [29] verwendet, um Interferenzen im Spektrogramm zu erkennen. Durch das eingebettete Downsampling und anschließendes Upsampling der Eingangsdaten in der U-Net Architektur nach [29] mittels entsprechender Faltungsschichten, wird eine Maske mit der Interferenzwahrscheinlichkeit für jedes Pixel im Spektrogramm erzeugt. Hierbei ergibt sich jedoch das Problem des Thresholding-Effekts, welcher auch in [28] beobachtet wurde. Dabei lernt das Netzwerk statt der eigentlichen Interferenzerkennung nur einen einfachen Schwellenwert, ab dem die Unterdrückung durchgeführt wird, beziehungsweise die Interferenzwahrscheinlichkeit zu 1 gesetzt wird. Eine Ursache für den Effekt ist in der Methodik begründet, da ein Thresholding-Algorithmus als Referenz für das Training des DL-Modells verwendet wird [26]. Dieses Beispiel zeigt ein fundamentales Problem der automatisierten Generation von annotierten Datensätzen mittels Referenzalgorithmen, welches mit hybriden Verfahren gelöst werden soll.

Eine weitere Möglichkeit ist die Umsetzung der Interferenzdetektion mit CNNs als klassisches Klassifikationsproblem mit einem VGG-16 Netzwerk [27]. Die anschließende Interferenzreduktion der Synthetic Aperture-Radar (SAR) Bilder wird mit einer ResNet-basierten Architektur nach [30] implementiert, wobei für das Training beider Schritte Simulationsdaten die Grundlage bildeten. Die Autoren in [28] verwenden ebenfalls CNNs, um eine Interferenzreduktion für Automobilradar im Frequenzbereich zu realisieren. Hierbei werden verschiedene Repräsentationen der Daten im Frequenzbereich evaluiert und auch komplexwertige Signale betrachtet. Der verwendete Datensatz ist allerdings sehr klein und basiert allein auf Simulationen. Zusätzlich wurde auch hier der bereits erwähnte Thresholding-Effekt beobachtet.

Insgesamt sind im Bereich der Deep Learning-basierten Interferenzunterdrückung keinerlei öffentliche Datensätze für Automobilradar im Frequenzbereich 76–81 GHz verfügbar. In den aufgeführten Beispielen des Stands der Technik erfolgt die Annotation von Datensätze entweder mittels Referenzalgorithmen, welche in der Folge einen erheblichen Einfluss auf die Performance der DL-Methoden haben, oder durch aufwändige manuelle Arbeit. Die Mehrheit der publizierten Verfahren ist zudem nur anhand von Simulationsdaten oder für gänzlich verschiedene Radarsysteme und Anwendungsbereiche validiert.

1.2.2 Deep Learning-basierte Winkelschätzung

Maschinelles Lernen und insbesondere neuronale Netze werden bereits seit dem letzten Jahrhundert für die Winkelschätzung eingesetzt. Frühere Ansätze nutzen sogenannte Netzwerke der radialen Basisfunktionen (engl.: *radial basis function network*, RBFN), wobei jedes Neuron eine Gauß'sche Aktivierungsfunktion verwendet [31]. Seit dem 21. Jahrhundert werden vermehrt künstliche neuronale Netze auf Basis des mehrlagigen Perzeptrons (engl.: *multilayer perceptron*, MLP) sowie neueren Konzepten wie AE und CNNs verwendet. Eine detaillierte Gegenüberstellung des Stands der Technik zur DL-basierten Winkelschätzung bezüglich der verwendeten Netzwerktopologie, Vergleichsmetriken und

Referenzalgorithmen, sowie ausgewählter Modellparameter, ist in Tab. 1.2 (Auszug aus dem Zeitschriftenbeitrag [32] des Autors) zu finden.

Generell lässt sich die DL-basierte Winkelschätzung in die drei Unterbereiche aufteilen: Schätzung der Modellordnung (engl.: *model order estimation*, MOE), Regression und Klassifikation. Regressionsbasierte Ansätze [33–36] geben die Winkelschätzwerte direkt aus und benötigen aufgrund der unbekanntes Zielanzahl eine vorhergehende MOE, von der die Anzahl der Ausgangsneuronen abhängt. Hierbei können sowohl unterschiedliche Netzwerke für beide Aufgaben trainiert, als auch Regression und MOE in einem Netzwerk vereint werden [35]. Weitere Veröffentlichungen studieren die Schätzung der Modellordnung mittels DL und vergleichen die Leistungsfähigkeit mit herkömmlichen Methoden zur Schätzung der Modellordnung [36–39].

Tabelle 1.2: Zusammenfassung des Stands der Technik zu Deep Learning-basierter Winkelschätzung.

Publ.	Regress- sion	Klassifi- kation	MOE	Netz- werk Typ	Array Größe	Snapshots	Kohär. Signale	Trai- niert mit	Vali- diert mit
[33]	✓			RBFN	6	N/A	✓	S	S
[34]	✓			RBFN, PNN, MLP	10, 16	1024 ^S , 2 ^M	✗	S	S, M
[37]			✓	MLP	6*	20	✓	S	S
[38]			✓	MLP	6*	10	✓	S	S
[36]	✓		✓	MLP	3 [#]	10	✓	S	S
[35]	✓		✓	MLP	16	1	N/A	S	S
[39]	✓		✓	MLP, AE, DAG	10	50-400	✓	S	S
[40]		✓		MLP	20	1, 10	✓	S, M	S, M
[41]		✓		MLP, AE	10	400	✗	S	S
[42]		✓		MLP, AE	20	800	✓	S	S
[43] [§]				MLP, AE	20	1000 ^T , 1000-16000 ^V	✗	S	S
[44]		✓		CNN	16	∞ ^T , 100-10000 ^V	✗	S	S
[45]		✓		CNN, MLP	20	1-10	✓	S, M	S, M
[46]		✓	✓	CRNN	11	100	✓	S	S

S: Simulationsdaten, M: Messdaten, T: Training, V: Validierung, N/A: keine Angabe

* nach Spatial Smoothing, # UCA mit 9 Antennen, unterteilt in 4 überlappende Teilarrays à 3 Elemente

§ Die Autoren nutzen DL nur zur Rekonstruktion der Kovarianzmatrix und wenden anschließend herkömmliche Verfahren an.

Der dritte Ansatz vereint die Regression und die vorangehende MOE durch eine Schätzung des Winkelspektrums [40]. Ähnlich zu herkömmlichen spektrumbasierten Winkelschätzverfahren, wie Beamforming oder dem MUSIC-Algorithmus (engl.: *multiple signal*

classification, MUSIC), rekonstruiert das neuronale Netz ein Winkelspektrum, aus dem die entsprechende Anzahl der Ziele sowie deren Winkel abgeleitet werden. Ein populärer Ansatz basiert auf einer AE-Topologie, welche zunächst eine räumliche Filterung des Signals vornimmt [41]. Anschließend können eines oder mehrere MLP-Netzwerke das Winkelspektrum rekonstruieren. Darauf aufbauend analysieren weitere Publikationen diesen Ansatz für kohärente Signale, niedriges Signal-zu-Rausch-Verhältnis (SNR) sowie Sparse Arrays [42, 43, 47]. Auch das Konzept der CNNs wurde bereits erfolgreich für die Winkelschätzung adaptiert und angewendet [44–46], jedoch nur für sehr große Antennenarrays oder viele Snapshots (Momentaufnahmen).

Insgesamt wird aus dem Überblick in Tab. 1.2 deutlich, dass im Stand der Technik die Winkelschätzung für Automobilradar bisher kaum vertreten ist. Zu den speziellen Anforderungen für dieses Anwendungsgebiet gehört eine begrenzte Anzahl an Antennen, und somit limitierte Apertur und ein einzelner Snapshot. Des Weiteren verwendet die überwiegende Mehrheit der Veröffentlichungen sowohl für das Training als auch die Evaluierung der DL-Methoden reine Simulationsdaten. Um jedoch auch für reale Anwendungen aussagekräftige Ergebnisse zu erzielen, muss insbesondere für sicherheitskritische Anwendungen wie autonomes Fahren, zumindest eine Validierung basierend auf realen Messdaten stattfinden.

1.2.3 Öffentliche Datensätze für Automobilradar

Die zugrundeliegenden Datensätze sind für den Erfolg von DL-basierten Verfahren essenziell [10, 49]. In den letzten Jahren wurde diese Problematik erkannt und es wurden jedes Jahr mehrere Radardatensätze speziell für das autonome Fahren veröffentlicht [50–57]. Tab. 1.3 gibt einen Überblick über die enthaltenen Sensordaten, die verwendeten Radartypen, sowie das Datenformat und die Annotationen (Ground Truth). Im Folgenden soll die Verwendbarkeit für Signalverarbeitungsmethoden wie die hochauflösende Winkelschätzung oder die Interferenzunterdrückung evaluiert werden.

Die Datensätze nuScenes [51], Astyx HiRes2019 [50], RADIATE [54] und RadarScenes [55] enthalten verschiedene Szenarien aus dem Straßenverkehr, mit einer relativ großen Anzahl verschiedener Objektklassen (Fußgänger, Fahrradfahrer, PKW, LKW, etc.). Die wahre Position und Ausdehnung von Objekten (Annotation) ist durch sogenannte zweidimensionale oder dreidimensionale Bounding-Boxen gegeben, wobei RadarScenes mit einer Punkt-basierten Annotation eine Ausnahme darstellt. Allerdings sind die Radardaten nur in Form von bereits vorverarbeiteten Punktwolken verfügbar, weshalb sich diese Datensätze lediglich für High-Level Signalverarbeitung wie Klassifikation, Tracking, semantische Segmentierung oder Kartierung eignen.

Für die Datensätze Oxford Radar RobotCar [48, 52] und MulRan [53] werden mechanisch rotierende Radarsysteme verwendet, die systembedingt eine sehr hohe Winkelauflösung erreichen. Solche Systeme sind eher aus dem Bereich der Schifffahrt bekannt, benötigen viel Platz und müssen deshalb auf dem Fahrzeugdach montiert werden. Außerdem fehlen in diesen Datensätzen die Geschwindigkeitsinformationen, weshalb die konventionelle Radarsignalverarbeitung für Automobilradar hier nicht angewendet werden kann.

Des Weiteren wurden in 2021 noch weitere Datensätze veröffentlicht, die zum ersten Mal auch Radar-Rohdaten zur Verfügung stellen. In den Studien CARRADA [57], CRUW [56] und RADDet [58] werden Kfz-Radarsensoren, wie beispielsweise der AWR1843 von Texas Instruments (CRUW, RADDet), eingesetzt. Durch die Verfügbarkeit von Rohdaten, eignen

sich die Datensätze prinzipiell für die Auswertung mit verschiedensten Signalverarbeitungsmethoden. Zusätzlich erfolgte hier eine Annotation der Datensätze im Frequenzbereich, statt in kartesischen Koordinaten auf Basis der Punktwolken. Allerdings sind die Daten von CARRADA bereits in den Winkelbereich transformiert, und für die hochauflösende Winkelschätzung nicht mehr zu verwenden. Die Autoren von RADDet verwenden ein eigenes trainiertes Netzwerk zur Detektion, Klassifikation und Annotation. Dieses ist jedoch fehleranfällig und weist einige Fehldetektionen und Fehlklassifikationen auf [58], weshalb sich die erstellte Ground Truth ohne manuelle Korrekturen nicht für das weitere Training von DL-Modellen eignet.

Tabelle 1.3: Öffentlich verfügbare Datensätze für Automobilradar.

Datensatz	Radar	Kamera	Lidar	Radartyp	Datenformat	Objekt-Annotationklassen
Astyx HiRes (2019) [50] [§]	✓	✓	✓	Automotive	Punktwolke	7 3D Bounding-Box
nuScenes (2020) [51]	✓	✓	✓	Automotive [#]	Punktwolke	23 3D Bounding-Box
Oxford Radar RobotCar (2020) [52]	✓	✓	✓	Mechanisch Rotierend	Range-Winkel	0 ✗
MulRan (2020) [53]	✓		✓	Mechanisch Rotierend	Range-Winkel	0 ✗
RADIATE (2020) [54]	✓	✓	✓	Mechanisch Rotierend	Punktwolke	8 2D Bounding-Box
RadarScenes (2021) [55]	✓	✓		Automotive	Punktwolke	11 Punkt-basiert
CRUW (2021) [56]	✓	✓		Automotive	Rohdaten	3 Bounding-Box ^{FB}
CARRADA (2021) [57]	✓	✓		Automotive	Range-Doppler-Winkel	3 Punkt-basiert ^{FB} Masken ^{FB} Bounding-Box ^{FB}
RADDet (2021) [58]	✓	✓		Automotive	Rohdaten	6 Punkt-basiert ^{FB} Bounding-Box ^{FB}

[#] niedrig auflösend, [§] Datensatz aktuell nicht mehr verfügbar (Stand: August 2021), ^{FB} im Frequenzbereich

Wie aus der kurzen Übersicht in Tab. 1.3 ersichtlich wird, enthalten die meisten verfügbaren Datensätze nur Punktwolken in Verbindung mit 2D/3D-Objekt Annotationen, Entfernungswinkel Bilder ohne Geschwindigkeitsinformationen oder anderweitig vorverarbeitete Daten. Der beabsichtigte Verwendungszweck der veröffentlichten Datensätze ist großteils die Radar-basierte Detektion, Klassifikation und das Tracking von Objekten. Die Winkelschätzung beziehungsweise Lokalisierung erfolgt in den Publikationen dagegen nur mittels Standardmethoden und wird nicht weiter evaluiert. Datensätze mit Rohdaten und geeigneter Annotation, um beispielsweise eine hochauflösende Winkelschätzung zu evaluieren, sind im Stand der Technik nicht mit ausreichender Quantität und Qualität verfügbar. Zudem werden zwar in einigen Datensätzen explizit extrinsische Störungen wie beispielsweise durch Wettereffekte (Oxford, nuScenes, RADIATE, RadarScenes) betrachtet, Interferenzen werden dagegen in keiner der Veröffentlichungen erwähnt. Aus der vorliegenden Analyse lässt sich entsprechend schlussfolgern, dass aktuell kein geeigneter

Datensatz für Automobilradar verfügbar ist, der dem Stand der Technik entspricht. Eine ähnliche Schlussfolgerung ziehen auch die Autoren in [9] und [19].

1.3 Zielsetzung und Aufbau der Arbeit

Im Rahmen der vorliegenden Arbeit sollen neuartige Methoden demonstriert werden, um Radardatensätze für Deep Learning – inklusive Annotationen – in ausreichender Qualität und Quantität zu erzeugen. In hybriden Verfahren sollen Simulationen und Messungen kombiniert werden, um Trainings-, Test- und Validierungsdatensätze zu generieren und damit DL-basierte Algorithmen zu entwickeln. Ziel der Anwendung von Deep Learning ist es, die Robustheit und Leistungsfähigkeit im Vergleich zu herkömmlichen Methoden zu verbessern. Um die entwickelten DL-Verfahren mit Messdaten zu validieren, sollen die hybriden Verfahren auf detaillierten Signalmodellen basieren. Sowohl die Generierung und Annotation von Daten, als auch die Auswertung und Validierung soll anschließend automatisiert erfolgen. Damit ist die Effektivität der DL-Verfahren nicht von traditionellen Signalverarbeitungsalgorithmen oder dem erheblichen manuellen Aufwand zur Erstellung einer Ground Truth abhängig.

Bezogen auf die Interferenzreduktion wird einerseits eine erhöhte Robustheit gegenüber verschiedenen Interferenzarten angestrebt. Andererseits soll auch die Leistungsfähigkeit bezüglich verschiedenen Metriken wie beispielsweise dem Signal-zu-Interferenz-plus-Rausch-Verhältnis im Vergleich zum Stand der Technik verbessert werden. Für die Winkelschätzung ist insbesondere die hohe Trennfähigkeit von Zielen von Bedeutung, die optimalerweise das physikalische Limit des verwendeten Antennenarrays übertrifft (auch als hochauflösend (engl. *super-resolution*) bezeichnet). Als Zielsetzung für die DL-basierte Winkelschätzung wird eine Verbesserung der Auflösungswahrscheinlichkeit sowie des mittleren Fehlers der Schätzung im Vergleich zum Stand der Technik angestrebt.

Zunächst werden in Kapitel 2 die notwendigen Grundlagen und das Signalmodell für das Automobilradar betrachtet. Dabei wird die gesamte Kette der Radarsignalverarbeitung kurz zusammengefasst, sowie detaillierte Modelle für gegenseitige Interferenzen und die Winkelschätzung aufgestellt. In Kapitel 3 wird ein neuartiger Ansatz zur DL-basierten Interferenzreduktion vorgestellt. Durch die Kombination von Simulationen und Messungen realer Interferenzen werden hybride Datensätze erzeugt, DL-Modelle zur Interferenzreduktion trainiert und anschließend mit Messdaten validiert. Der zweite Teil der Arbeit beschäftigt sich mit der hochauflösenden Winkelschätzung mittels DL. In Kapitel 4 werden modell- und datenbasierte Ansätze zur Datengeneration kombiniert und evaluiert. Anschließend werden verschiedene Methoden und Ansätze zur hochauflösenden Winkelschätzung mit kleinen Antennenarrays und nur einem Snapshot vorgestellt und analysiert. Die entwickelten Ansätze zur DL-basierten Winkelschätzung werden mit den Datensätzen trainiert, optimiert und evaluiert, sowie deren Leistungsfähigkeit mit dem Stand der Technik anhand verschiedener Metriken verglichen und schließlich mittels Messdaten validiert. Die Ergebnisse beider Kapitel werden in Kapitel 5 nochmals in den Kontext des aktuellen Stands der Technik gesetzt und diskutiert. Abschließend werden die Erkenntnisse dieser Arbeit in Kapitel 6 zusammengefasst.

