




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 Jentzsch-Cuvillier, Nonnenstieg 8, 37075 Göttingen,
Germany

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

Inhaltsverzeichnis

Kurzfassung	III
Abstract	V
1 Einleitung	1
1.1 Motivation	1
1.2 Stand der Technik	3
1.2.1 Deep Learning-basierte Interferenzunterdrückung	4
1.2.2 Deep Learning-basierte Winkelschätzung	5
1.2.3 Öffentliche Datensätze für Automobilradar	7
1.3 Zielsetzung und Aufbau der Arbeit	9
2 Automobilradarsignalverarbeitung	11
2.1 Chirp Sequence-Radar	11
2.1.1 Basisband-Signalmodell	12
2.1.2 Antennenarray-Signalmodell	13
2.1.3 Radar-Signalverarbeitungskette	15
2.2 Gegenseitige Interferenzen	20
2.2.1 Signalmodell für linear frequenzmodulierte Interferenzen	22
2.2.2 Auswirkungen von Interferenzen	23
2.2.3 Geeignete Maßnahmen zur Interferenzunterdrückung	25
2.3 Single Snapshot-Winkelschätzung	26
2.3.1 Erweitertes Signalmodell	26
2.3.2 Traditionelle Verfahren zur Winkelschätzung	28
2.3.3 Schätzung der Zielanzahl	28
2.3.4 Limitierungen der Winkelschätzung	30
3 Deep Learning-basierte Interferenzunterdrückung	33
3.1 Generierung von geeigneten Datensätzen	34
3.1.1 Messung von Interferenzen	34
3.1.2 Simulation von Interferenzen	36
3.1.3 Hybrides Signalmodell	38
3.1.4 Datenvorverarbeitung	38
3.1.5 Trainings-, Test- und Validierungsdatensätze	40
3.2 Performance-Metriken	41
3.3 Interferenzunterdrückung im Frequenzbereich	42
3.3.1 Konzept und Architektur des CNN-Autoencoders	42
3.3.2 Training und Validierung	43
3.4 Testergebnisse	45
3.4.1 Performance bezüglich Vergleichsmetriken	46
3.4.2 Validierung mit realen Messungen	48
3.5 Zusammenfassung der Ergebnisse	49

4	Hochauflösende Winkelschätzung mittels Deep Learning	51
4.1	Generierung von Trainings- und Testdaten	52
4.1.1	Messaufbau und Radarsensorik	53
4.1.2	Sensorkalibrierung	54
4.1.3	Aufbereitung der Messergebnisse	56
4.1.4	Mehrziel-Signalmodelle	57
4.1.5	Datenvorverarbeitung	60
4.1.6	Szenarien zur Evaluierung und Bewertung der Performance	62
4.2	Schätzung der Ziellanzahl	63
4.2.1	Performance-Metriken der Klassifikation	64
4.2.2	Architektur der MLP-basierten Klassifikation	65
4.2.3	Evaluation und Vergleich mit dem Generalized Likelihood Ratio-Test	66
4.2.4	Erweiterung der MOE und Optimierung der Designparameter	68
4.2.5	Performance des erweiterten MOE-Netzwerks	71
4.3	Regressionsbasierte Winkelschätzung	74
4.3.1	Performance-Metriken für die Regression	75
4.3.2	Konzept und Architektur des Regressions-MLP	75
4.3.3	Evaluation und Vergleich mit der Maximum Likelihood-Schätzung	76
4.3.4	Optimierung der Netzwerkarchitektur und der Designparameter	79
4.3.5	Performance des optimierten Regressions-Netzwerks	79
4.4	Klassifikationsbasierte Schätzung des Winkelspektrums	85
4.4.1	Performance-Metriken der spektrumbasierten Winkelschätzung	86
4.4.2	Konzepte und Architekturen verschiedener DL-Ansätze	87
4.4.3	Nachverarbeitung und Zieldetektion	91
4.4.4	Einfluss der Zieldetektion auf die Performance	93
4.4.5	Evaluation und Vergleich mit der Maximum Likelihood-Schätzung	95
4.4.6	Validierung der hochauflösenden Winkelschätzung	102
4.5	Zusammenfassung der Ergebnisse	105
5	Diskussion der Ergebnisse	109
5.1	Vergleich mit dem Stand der Technik	109
5.2	Ausblick	111
6	Zusammenfassung	113
	Literaturverzeichnis	115
	Tabellen und Abbildungen	125
	Abkürzungsverzeichnis	131
	Symbolverzeichnis	133
	Danksagung	137
	Eigene Veröffentlichungen	139