Max-Planck-Institut für Verhaltensbiologie

Am Obstberg 1
78315 Radolfzell

Projekt: **ICARUS KI**

Titel Dokument: **Abschlussbericht**

Dokument:	ICAR_KI_Abschlussbericht
Förderkennzeichen:	50WB2235
Version:	final
Datum:	23.02.2024

Erstellt:	Uschi Müller		
Geprüft:	M.Krondorf, S.Hahn	Datum:	23.02.2024
Projekt Management:	Prof.Dr. Martin Wikelski	Datum:	24.02.2024

Verteiler: Michael Becker, Tetiana Hort (DLR)

S.Hahn, M.Plahl, M.Wikelski, T.Wild, N.Linek, U.Müller (MPIAB)

Unterzeichnet: Datum: 24.02.2024

Prof.Dr. Martin Wikelski, Direktor

Copying of this document, and giving it to others and the use or communication of the contents there-of, are forbidden without express authority. Offenders are liable to the payment of damages. All rights are reserved in the event of the grant of a patent or the registration of a utility model or design.

CONTENTS

1 EINLEITUNG 3
1.1 AUFGABENSTELLUNG 4
2 VORAUSSETZUNGEN, UNTER DENEN DAS VORHABEN DURCHGEFÜHRT WURDE 6
2.1 DIE AUFGABEN DER ARBEITSPAKETE IN DER ARBEITSPAKETSTRUKTUR 6
PROJEKTBETEILIGTE UND ARBEITSTEILUNG 9
2.2 PLANUNG UND ABLAUF DES VORHABENS 12
2.3 WISSENSCHAFTLICHER UND TECHNISCHER STAND AN DEM ANGEKNÜPFT WURDE 13
Beobachtungssysteme für Tiere *13*
Datenzentren und Datenarchive für wandernde Tiere *15*
2.4.1 VORHABENRELEVANTE ERFAHRUNG *19*
„ICARUS Space Segment“ und “ICARUS Space Project” *20*
ICARUS – Vorbereitende Satellitentechnologien *22*
Hosted Payload Studie *22*
ICARUS Bodensegment *22*
Entwicklung der Tiersender *25*
3 ERZIELTE ERGEBNISSE 29
3.1 AP 2000 UNIBW 29
3.2 AP 3000 29
3.3 AP 4000 HTWK LEIPZIG UND INRADIOS 29
3.4 AP 5000 MPI-AB 29
4 ZUSAMMENFASSUNG UND AUSBLICK 45
4.1 VORKOMMNISSE INNERHALB DER PROJEKTLAUFZEIT 45
4.2 NOTWENDIGKEIT UND ANGEMESSENHEIT DER GELEISTETEN ARBEIT 45
5 NUTZEN UND VERWERTBARKEIT DER ERGEBNISSE, ERFOLGSKONTROLLBERICHT 466
5.1 WIRTSCHAFTLICHE ERFOLGSAUSSICHTEN MIT ZEITHORIZONT 466
5.2 DIE WISSENSCHAFTLICH-TECHNISCHEN ERGEBNISSE DES VORHABENS 466
5.3 WISSENSCHAFTLICHE UND WIRTSCHAFTLICHE ANSCHLUSSFÄHIGKEIT 477
5.4 VERWERTBARKEIT DER ERGEBNISSE 477
5.5 ARBEITEN, DIE ZU KEINER LÖSUNG GEFÜHRT HABEN 477
5.6 PUBLIKATIONEN 488
5.7 EINHALTEN DER AUSGABEN- UND ZEITPLANUNG 488
5.8 FORTSCHRITT AUF DEM GEBIET DES VORHABENS BEI ANDEREN STELLEN 488

© Max-Planck-Institut
für Verhaltensbiologie

1 EINLEITUNG

Die Welt der Tiere gehört zu den wichtigsten Merkmalen, die unsere Erde auszeichnet. Die Menschen teilen mit ihnen den gemeinsamen Lebensraum. Unser Wohlergehen ist direkt mit der Existenz der Tiere verbunden, sei es als Nahrungsquelle, der Ursprung bzw. Überträger von Krankheiten, oder auch als Indikator für die Einflussnahme des Menschen auf die Natur bzw. natürlichen systemimmanenten Einflüssen und Veränderungen. Ständig wandern Milliarden von Tieren um den Erdball. Sie verbinden die entlegensten und unzugänglichsten Regionen auf der Erde und in den Ozeanen, und können dabei unsere Sensoren – Augen, Ohren und Nasen – für das Wohlergehen unseres Planeten Erde sein.

Die Tiere haben mit ihrer Existenz, ihren Aktivitäten, ihrem Werden und Vergehen ganz wesentlichen Anteil daran, dass die Welt in der derzeitigen Form existiert. Und das wird auch in der Zukunft so sein. Wie immer wir, die Menschheit, der Natur gegenüber agieren, verspüren das zu allererst in ihren Auswirkungen verschiedene Tierarten. Der Grund hierfür ist, dass alle Tierarten spezielle Nischen besetzen, in denen sie sich jeweils ihre bislang gesicherte Existenz bewahrt haben. Verlieren die Tierarten ihre Nischen teilweise oder ganz, werden sie reduziert oder sterben aus, oder sie verändern ihr Verhalten und suchen sich z. B. einen neuen Lebensraum. Tiere sind also auch wichtig als Sensoren und Frühindikatoren und Betroffene von positiven und negativen Auswirkungen menschlichen Handelns. Sie sind auch für unsere Existenz essenziell, nicht nur als Nahrungsquelle, sondern auch im negativen Sinne als deren Vernichter. Weiterhin haben Tiere zunehmend wichtigere Rollen als Krankheitsüberträger und Verursacher von Epidemien. Etwa 70% der weltweiten Krankheitsepidemien, sei es SARS, West Nil Virus, oder Vogelgrippe, stellen Zoonosen dar, ausgelöst durch das Zusammenspiel zwischen Wildtieren, Nutztieren und Menschen. Man könnte diese Liste weiter fortführen. In dieser Kurzfassung muss darauf aber verzichtet werden.

Globale Daten über Tierbewegungen sind in der heutigen, international vernetzten Welt unabdingbar, um zu verstehen, wie man gleichzeitig die menschliche Gesundheit sowie die Tierwelt schützen kann. Tiere schützen unsere Lebensgrundlagen und geben uns Nahrung, aber sie zerstören auch unsere Nahrung, verbreiten katastrophale Krankheiten oder führen zum Absturz von Flugzeugen.

Um aktiv zur Lösung solcher Probleme beizutragen, aber auch um biologische Grundprinzipien zu verstehen, brauchen wissenschaftliche Disziplinen wie beispielsweise Zoologie oder Ökologie dringend Antworten auf die fundamentalen Fragen:

- Wo ist ein Tier zu jedem Zeitpunkt in seinem Leben?
- Was ist der interne Zustand eines Tieres, d.h., wie viel Energie verbraucht das Individuum gerade für welche Tätigkeit, und welche physiologischen Leistungen vollbringt es?
- Welche Verhaltensaktivität führt das Tier gerade durch?
- Was führt zum Tod eines Individuums?

Keine dieser fundamentalen Fragen kann bisher am freilebenden Tier über mittlere bis große Zeiträume beantwortet werden, speziell wenn es um kleine Tiere geht, die für uns Menschen von größter Relevanz sind, z.B. als Krankheitsverbreiter (allen voran Fledermäuse).

Generell ist es in einer Zeit großer globaler Veränderungen für die Menschheit von kritischem Interesse, sensitive biologische Indikatoren für Klima- und Umweltveränderungen zu etablieren und zu nützen.

© Max-Planck-Institut
für Verhaltensbiologie

Wildtiere, die auf der Welt die unterschiedlichsten Klimazonen bevölkern und zwischen Zonen wandern, sind ideal als Indikatoren geeignet.

Das Max-Planck-Institut für Verhaltensbiologie (MPIAB), vormals Max-Planck Institut für Ornithologie (MPIO), hat sich in den vergangenen Jahren massiv in nationalen und internationalen Organisationen für die globale und in nahezu Echtzeit mögliche Beobachtung insbesondere von kleinen Tieren eingesetzt. Für die globale Beobachtung kommen nur weltraumgestützte Systemlösungen in niedrigem Orbit in Frage. Es gibt aber weltweit kein geeignetes System, das die wachsenden Anforderungen aus der gesellschaftlich-wissenschaftlichen Aufgabenstellung erfüllt.

In diesem Zusammenhang ist auf den ersten Blick verwunderlich, dass alle Raumfahrtnationen in ihren Programmen zu Global Change, Changing Earth, Living Earth, GMES etc. zwar sehr erfolgreich Instrumente für die Beobachtung der physikalisch/chemischen Phänomene entwickelt haben und ihrer Bedeutung richtigerweise entsprechend weiterhin ausbauen und intensivieren, aber das raumfahrtgestützte globale Tiermonitoring noch nicht einbeziehen.

Es ist das Interesse und Ziel des Max-Planck-Instituts für Verhaltensbiologie, die initiale wissenschaftliche Führungsrolle für ein solches raumgestütztes System zu übernehmen und in Kooperationen mit weiteren Großforschungseinrichtungen die Durchführung zu ermöglichen.

Die Entwicklung der „Movebank“, einer globalen, frei verfügbaren Datenbank für Tierbewegungen unter MPIAB-Leitung sowie die Entwicklung eines technischen Demonstrators auf der Basis eines Raumstations-Experimentes ist Ausdruck dieser Führungsrolle.

Durch das Nutzen von KI könnten einerseits der Betrieb des Systems verbessert werden indem aus den bereits gesammelten Daten durch KI verbesserte Einstellungen für Tag und Raumsegment ermittelt werden, aber auch neue biologische Erkenntnisse durch eine Korrelation biologischer und technischer Daten ermöglichen. Zusätzlich kann die Größe der Tags extrem verringert werden, wenn die Position der Tags von KI aus der Dopplerverschiebung geschätzt werden kann.

1.1 Aufgabenstellung

Das ICARUS Experimentalsystem liefert als weltraumgestütztes IoT Kommunikationssystem auf der ISS seit März 2021 wissenschaftlich hochinteressante Daten über weltweite Tierbewegungen. Das ICARUS System soll durch den Einsatz von KI in zweierlei Hinsicht massiv verbessert werden:

a) Die Kommunikationswahrscheinlichkeit der miniaturisierten Tags hängt offenbar sehr stark von den jeweils vorherrschenden Umweltbedingungen ab, z.B. ob ein Tier sich vorwiegend im Unterholz, Schilf, Wald, Feld oder der Luft aufhält. Weiterhin beeinflusst das Wetter sowie das Tierverhalten den Energiehaushalt der Tags, die primär auf Solarenergie angewiesen sind. Wetter, Tierverhalten und Umweltbedingungen beeinflussen sich aber auch gegenseitig stark. Durch Einsatz von KI kann das optimale Einsatzprotokoll für die Tier-Tags aus der hochdimensionalen Kombination der oben genannten dynamischen Faktoren ermittelt werden. Hierzu sollen die in

© Max-Planck-Institut
für Verhaltensbiologie

der Movebank gesammelten Daten der Tiere mit den Daten aus dem ICARUS User Data Center kontinuierlich verrechnet werden. KI-Algorithmen können dann die besten Kombinationen aus Energieverbrauch der Tags (v.a. durch GPS-Messungen) und Energieeintrag berechnen und Datenaufnahmemuster vorschlagen. Diese Muster werden unmittelbar auf den im Feldeinsatz befindlichen Tags eingestellt (durch Programmierung über die ISS an die Tags) und können so experimentell verifiziert werden. Die neu gewonnenen Daten fließen dann unmittelbar wieder in die KI-Berechnungen ein und optimieren die vorgeschlagenen Muster weiter.

b) Der größte Energietreiber im ICARUS System ist die Eigenbestimmung des GPS-Ortes durch die Tier-Tags. Bisher ist GPS-Ortung im ICARUS System notwendig, da die Tags zur Voraussage der Orbit-Zeiten der ISS ihren eigenen Standort am Boden genau kennen müssen. Zudem ist diese Standortbestimmung biologisch-wissenschaftlich von hoher Wichtigkeit, auch um das Habitat der Tiere zu kennen (siehe Punkt a). Durch Einsatz von KI kann die energieaufwendige GPS-Ortung durch energieeffiziente Doppler-Ortung ersetzt werden. Dies hat den fundamentalen Vorteil, dass dann die ICARUS Tags der nächsten Generation massiv verkleinert werden können, sowohl im derzeitigen ICARUS-Experimentalsystem als auch hinsichtlich zukünftiger, zusätzlicher Payloads.

© Max-Planck-Institut
für Verhaltensbiologie

2 VORAUSSETZUNGEN, UNTER DENEN DAS VORHABEN DURCHGEFÜHRT WURDE

2.1 Die Aufgaben der Arbeitspakete in der Arbeitspaketstruktur

Die Arbeiten erfolgten entsprechend nachfolgender Arbeitspaketstruktur. Die Arbeitspaketbeschreibung von MPIAB und die der Unterauftragnehmer sind nachfolgend aufgeführt.

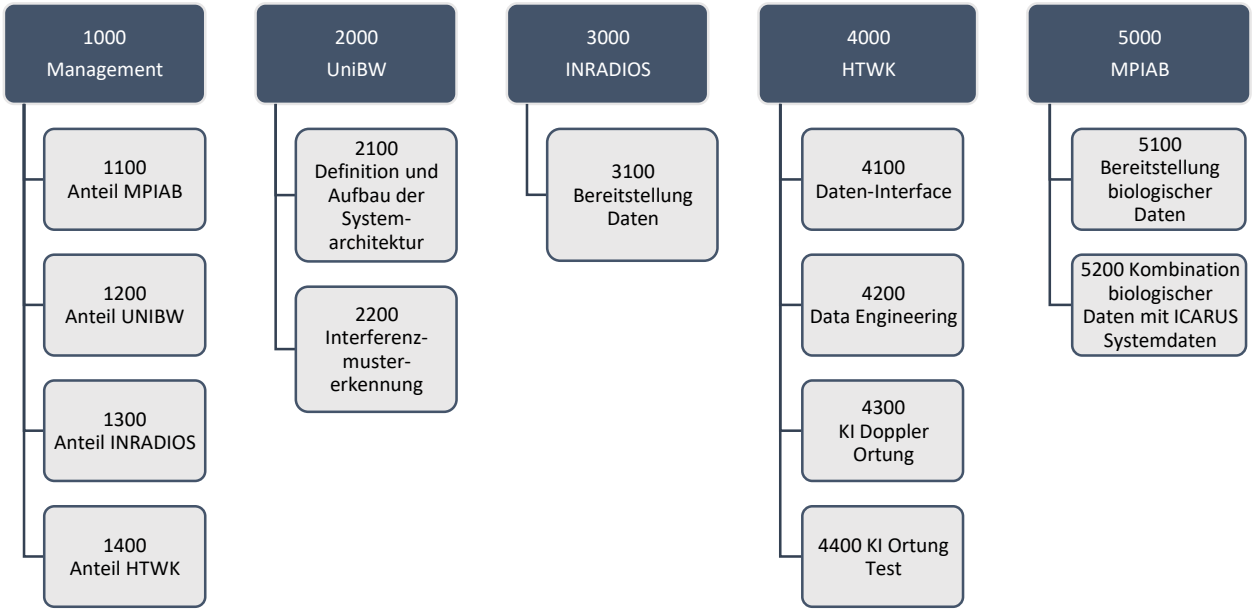

Abbildung 1: Übergeordnete Arbeitspaketstruktur des Vorhabens

Die Aufgaben der Arbeitspakete der Arbeitspaketstruktur sind in Tabelle 1 gezeigt.

Tabelle 1: Arbeitspaketbeschreibungen

AP Nr.	*AP Titel*	*Aufgaben*
1000	**Management**	---
1100	Projektmanagement Anteil MPIAB	• Erarbeiten und Ausführen aller administrativer und vertraglicher Aufgaben • Management der Schnittstelle zum Zuwendungsgeber • Kostenkontrolle des Vorhabens • Teilnahme an Kick-off, Arbeits- und Projektbesprechungen, Endpräsentation

© Max-Planck-Institut für Verhaltensbiologie

AP Nr.	*AP Titel*	*Aufgaben*
		• Teilnahme an Telefonkonferenzen • Zuarbeit zu den gemeinsamen Zwischenberichten • Zuarbeit zum gemeinsamen Endbericht
1200	Projektmanagement Anteil UniBW	• Erarbeiten und Ausführen aller administrativer und vertraglicher Aufgaben • Management der Schnittstelle zum Zuwendungsgeber • Kostenkontrolle des Vorhabens • Teilnahme an Kick-off, Arbeits- und Projektbesprechungen, Endpräsentation • Teilnahme an Telefonkonferenzen • Zuarbeit zu den gemeinsamen Zwischenberichten • Bericht „Eine skalierbare Multi-AI-Modell-Systemarchitektur", der die unterstützten KI-Modelle und -Frameworks sowie technische Daten zu den Berechnungsfähigkeiten des Systems enthalten muss • Bericht „Icarus-Interferenzerkennung und Eigenschaftsanalyse". • Vortrag „Takeaways zur Icarus-Interferenzanalyse", die die Kennzahlen zur Empfangsdatenverbesserung sowie einen Überblick über die Interferenzeigenschaften aufzeigen soll
1300	Projektmanagement Anteil INRADIOS	• Erarbeiten und Ausführen aller administrativer und vertraglicher Aufgaben • Management der Schnittstelle zum Zuwendungsgeber • Kostenkontrolle des Vorhabens • Teilnahme an Kick-off, Arbeits- und Projektbesprechungen, Endpräsentation • Teilnahme an Telefonkonferenzen • Zuarbeit zu den gemeinsamen Zwischenberichten • Zuarbeit zum gemeinsamen Endbericht
1400	Projektmanagement Anteil HTWK	• Erarbeiten und Ausführen aller administrativer und vertraglicher Aufgaben • Management der Schnittstelle zum Zuwendungsgeber • Kostenkontrolle des Vorhabens • Teilnahme an Kick-off, Arbeits- und Projektbesprechungen, Endpräsentation • Teilnahme an Telefonkonferenzen • Zuarbeit zu den gemeinsamen Zwischenberichten • Zuarbeit zum gemeinsamen Endbericht
2000	**UniBW**	**---**

© Max-Planck-Institut
für Verhaltensbiologie

AP Nr.	*AP Titel*	*Aufgaben*
2100	Definition und Aufbau der Systemarchitektur	• Definition des Umfangs der angestrebten KI-Modelle. • Definition aller Systemanforderungen auf der Grundlage der geplanten KI-Modelle, einschließlich einer detaillierten Definition des Rechenbedarfs. • Identifizierung des KI-Software-Frameworks und der Bibliothek. • Auswahl der Hardware-Ressourcen.
2200	Interferenzmustererkennung	• Definition aller Systemanforderungen auf der Grundlage der geplanten KI-Modelle, einschließlich einer detaillierten Definition des Rechenbedarfs. • Identifizierung des KI-Software-Frameworks und der Bibliothek. • Auswahl der Hardware-Ressourcen.
3000	**INRADIOS**	---
3100	Bereitstellung Daten	• Bereitstellung aller verfügbaren von dem ICARUS space segment empfangenen TAG Daten • Bereitstellung der vom ICARUS space segment ermittelten Empfangsparameter der TAG Daten • Bereitstellung aller Informationen rund um die vom Tag und des ICARUS space segment erzeugten Daten und deren Bedeutung • Bereitstellung der Telemetriedaten zur Errechnung der ISS Position • Erzeugung der benötigten Datenformate
4000	**HTWK**	---
4100	Daten-Interface	• Übernahme des Datenformats aus AP 3100 in die KI-Softwareumgebung • Implementierung von automatisierten Software-Routinen, die die Daten des ICARUS Telemetriekanals parsen und jeweils Daten-Tupel von Tag Koordinaten, Doppler-Versatz und ICARUS Orbitpositions bilden • Abgleich der übernommenen ICARUS-Orbitpositionsdaten mit INRADIOS zu Verifikationszwecken der Interface Software
4200	Data-Engineering	• Aufbereitung der ICARUS Telemetrie Daten-Tupel in einen KI-kompatiblen Datensatz • Übernahme der von UniBw vorgeschlagenen Entwicklungsumgebung sowie die vorgeschlagene KI-Trainingsmethoden, um verschiedenen Deep-Neural Networks zu trainieren

© Max-Planck-Institut
für Verhaltensbiologie

AP Nr.	*AP Titel*	*Aufgaben*
		• Erstellen einer Matlab-Umgebung, um künstliche Doppler-Ortungsdaten für das Training zu erzeugen. Damit werden künftige ICARUS Satellitenmissionen simuliert und die Performance des KI-Doppler-Ortungsansatzes verifiziert
4300	KI-Doppler Ortung	• Training verschiedener Typen von Deep-Neural Networks mit den Trainingsdaten • Performancevergleich verschiedener Netztypen mittels eines für alle gleichen Verifikationsdatensatzes • Auswahl eines geeigneten Neuronalen Netztyps
4400	KI-Ortung Test	• Das trainierte Neuronale Netz wird mit ICARUS Telemetriedaten und künstliche erzeugten Verifikationsdatensätzen getestet • Statistische Auswertung der Verifikationsergebnisse • Dokumentation
5000	**MPIAB**	**---**
5100	Bereitstellung biologischer Daten	• Alle verfügbaren ICARUS Tier-tracking Daten werden zwischen UDC und Movebank zusammengeführt • Meta-Daten aller Tiere und genaue technische Informationen der ICARUS Tags werden in einer Datenbank bereitgestellt
5200	Kombination biologischer Daten mit ICARUS Systemdaten	• Für jede GPS Koordinate eines Tags werden die entsprechenden Sensorparameter der ICARUS Tags sowie die Umweltdaten bereitgestellt • In Movebank werden über das Env-Data Modul die GPS Koordinaten der Tags mit allen verfügbaren Remote Sensing Daten in Übereinstimmung gebracht • Durch entsprechende KI Verfahren werden die großen verfügbaren Datenmengen auf Muster untersucht • Die erkannten optimalen Tag-Settings werden in Zusammenarbeit mit INRADIOS in Algorithmen der neuen ICARUS Tags überführt und angewandt

Projektbeteiligte und Arbeitsteilung

Die sich ergebende Struktur von Zuwendungsgeber bis hin zu den Auftragnehmern (UAN) der Zuwendung ist in nachfolgender Abbildung 2 gezeigt.

© Max-Planck-Institut
für Verhaltensbiologie

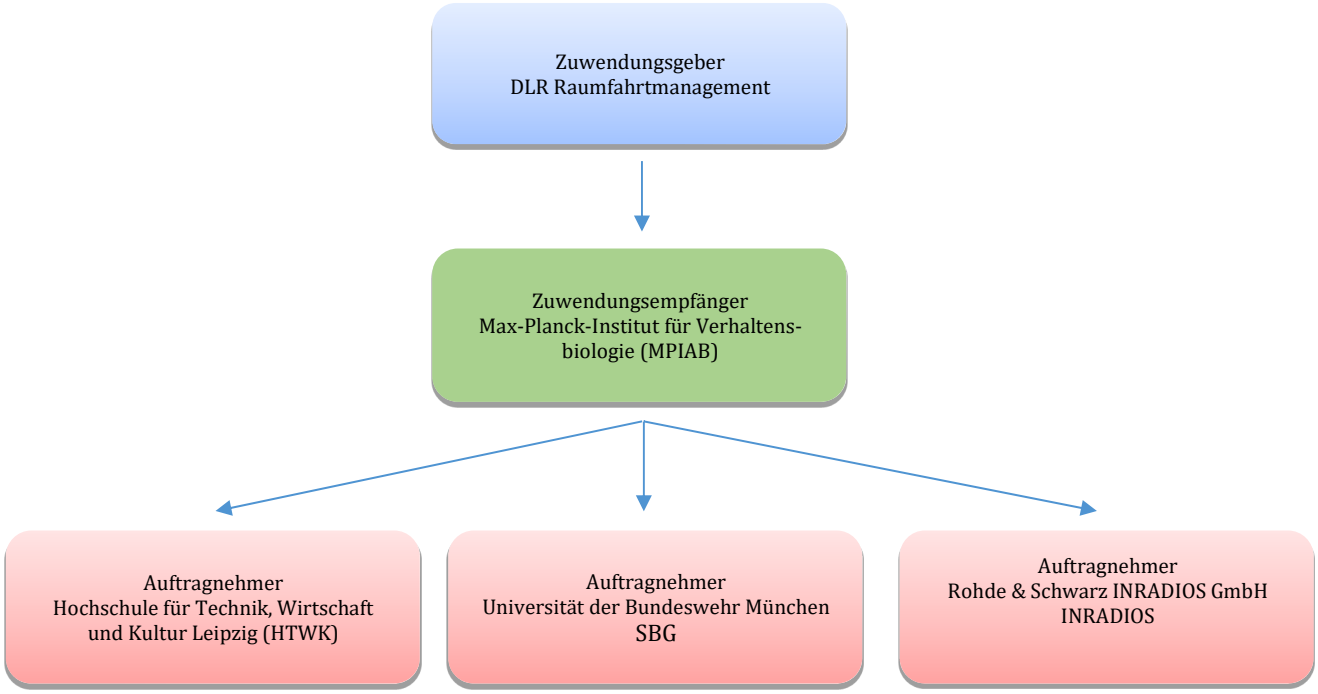

Abbildung 2: Organisationsstruktur des Vorhabens

Die Erfahrung des im Vorhaben zusammengeführten Instituts und der beteiligten Industrie ergänzen sich hervorragend für eine erfolgreiche Umsetzung der Ziele des Vorhabens. Mit dem Max-Planck-Institut für Verhaltensbiologie führt eine Organisation mit weltweitem Ansehen und hervorragendem wissenschaftlichen Hintergrund das Vorhaben. Mit den bereits geleisteten Vorarbeiten und den dabei gewonnenen Erfahrungen kann das MPIAB auch als Nutzer der im Vorhaben erarbeiteten Technologien wertvolle Beiträge einbringen und grundlegenden Anforderungen an das Gesamtsystem ICARUS vorgeben.

Die Expertise der Projektleiter, deren Unterauftragnehmer sowie deren Aufgaben am ICARUS KI Vorhaben sind in nachfolgender Tabelle 2 gelistet.

Tabelle 2: Projektbeteiligte des Vorhabens

Projektbeteiligte	Expertise	Rolle / Aufgaben im Vorhaben
Max-Planck-Institut für Verhaltensbiologie (MPIAB)	Forschungsschwerpunkt Globale Tierwanderungen, Auswertung von Bewegungsmustern von Organismen, Einbeziehung von Umweltparametern in Bewegungsanalysen	Projektleitung: Koordination der UAN, Datenauswertung: KI-Anwendung auf Kombination biologischer, umweltabhängiger und technischer Parameter
Universität der Bundeswehr München	Forschungsschwerpunkt Satellitenkommunikation, fachlich ausgewiesen im Bereich der Signalübertragung, Betreiber der	Unterauftragnehmer: Erstellen der KI-Softwareumgebung und Support bei der

© Max-Planck-Institut für Verhaltensbiologie

Projektbeteiligte	Expertise	Rolle / Aufgaben im Vorhaben
Institut für Informationstechnik	„Munich Spacecom Labs“ als zentrale Experimentalbodenstation	Replikation der Umgebung bei allen Projektbeteiligten
Rohde & Schwarz INRADIOS GmbH	Physical Layer Entwurf des ICARUS Systems. HDL Programmierung des ISS-Raumsegmentes. In Kooperation mit TUD maßgeblich verantwortlich für die ICARUS Tag-Hardware- und FirmwareEntwicklung	Unterauftragnehmer: Bereitstellung aller Informationen rund um die vom Tag und des ICARUS space segment erzeugten Daten.
Hochschule für Technik, Wirtschaft und Kultur Leipzig (HTWK) Institut für Elektronik und Biomedizinische Informationstechnik	Doppler-Ortung und ISS Überflugsimulation mittels Matlab, Simulation der Doppler-Ortung und KI-basierte Ortung	Unterauftragnehmer: Training der KI mit Datensätzen, Abgleich der Ortungsergebnisse verschiedener Neuronaler Netztypen

Die Ansprechpartner und Kontaktdaten der jeweiligen Projektbeteiligten des Vorhabens sind in Tabelle 3 gelistet.

Tabelle 3: Ansprechpartner der jeweiligen Projektbeteiligten des Vorhabens

Projektbeteiligte	Ansprechpartner	Kontaktdaten
Max Planck Institut für Verhaltensbiologie	Prof. Dr. Martin Wikelski	Am Obstberg 1 78315 Radolfzell wikelski@ab.mpg.de 07732 1501 25 (Frau Sabine Knopf)
Universität der Bundeswehr München, Institut für Informationstechnik	Prof. Dr.-Ing. Andreas Knopp	Werner-Heisenberg-Weg 39 85577 Neubiberg andreas.knopp@unibw.de 089 6004 7500 (Frau Heidrich, Herr Weber)
Rohde & Schwarz INRADIOS GmbH	Dr.-Ing. Steffen Bittner	Nossener Brücke 12 01187 Dresden steffen.bittner@rohde-schwarz.com 0351 340 907 0
Hochschule für Technik, Wirtschaft und Kultur Leipzig (HTWK), Institut für Elektronik und Biomedizinische Informationstechnik	Prof. Dr.-Ing. Marco Krondorf	HTWK Leipzig Wächterstraße 13 04107 Leipzig Marco.krondorf@htwk-leipzig.de

© Max-Planck-Institut für Verhaltensbiologie

0341 3076 1126

2.2 Planung und Ablauf des Vorhabens

Die Laufzeit des Vorhabens war ursprünglich auf 15 Monate angesetzt. Es war geplant, die Untersuchungen ab dem 01.01.2022 bis 31.03.2023 durchzuführen.

		Monate des Projekts														
AP	Aufgabe	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15
AP 1000	**Projektmanagement**															
AP 1100	Projektmanagement MPI															
AP 1200	Projektmanagement UniBW															
AP 1300	Projektmanagement INRADIOS															
AP 1400	Projektmanagement HTWK															
2000	**UniBW**															
AP 2100	Definition und Aufbau der Systemarchitektur															
AP 2200	Interferenzmustererkennung															
AP 3000	**INRADIOS**															
AP 3100	Bereitstellung Daten															
AP 4000	HTWK															
AP 4100	Dateninterface															
AP4200	Data-Engineering															
AP4300	KI-Doppler Ortung															
AP4400	KI-Ortung Test															
AP 5000	**MPI**															
AP 5100	Bereitstellung biologischer Daten															
AP 5200	Kombination biologischer Daten mit ICARUS Systemdaten															

Legende:

	Uni BW München

© Max-Planck-Institut
für Verhaltensbiologie

	HTWK
	INRADIOS
	MPI

Tabelle 4: Planung und Ablauf des Vorhabens

Aufgrund einer kostenneutralen Laufzeitverlängerung, wurden die Arbeiten zum 31.12.2023 abgeschlossen. Grund für die beantragte kostenneutrale Laufzeitverlängerung war Personalmangel auf Seiten des Unterauftragnehmers HTWK Leipzig.

2.3 Wissenschaftlicher und technischer Stand an dem angeknüpft wurde

Beobachtungssysteme für Tiere

Seit den frühen 60er-Jahren haben die Ökologen und die Zoologen Radioübermittler an Tieren angebracht, um deren Aufenthaltsorte, Bewegungen und biologische Parameter wie z.B. die Körpertemperatur aufzuzeichnen. Frühe „Geolocation"-Aufzeichnungsgeräte mussten vom Tier zurückgeholt werden, so dass nur solche Individuen untersucht werden konnten, die zur genauen Position, an der sie markiert wurden, zurückkehren – ein erheblicher Schwachpunkt für methodische Untersuchungen.

Die verwendeten Systeme können in „lokale" und „globale" Systeme kategorisiert werden.

Lokale Systeme

Dabei werden bodenbasierte Empfangssysteme unter Verwendung von VHF/UHF bzw. mobile Telefonnetze eingesetzt. Diese Systeme liefern heute gute Ortungsgenauigkeiten über die Verwendung von GPS Empfänger. VHF und UHF basierte Systeme sind räumlich nur sehr begrenzt anwendbar, da eine Kommunikation abhängig von der Größe der Tiersender nur im Bereich von einigen Metern bis zu einigen Kilometern möglich ist. Auf mobilen Telefonnetzen basierte Systeme haben überall dort eine gute Verfügbarkeit, wo eine gute Infrastruktur und damit auch Menschen sind. In weiten Teilen Afrikas oder Sibiriens, bzw. auf den Weltmeeren existieren aber überhaupt keine Mobilfunknetze, ebenso nur eingeschränkt in Krisenregionen wie derzeit im Nahen Osten. Damit können auch solche Systeme räumlich nur begrenzt eingesetzt werden. Des Weiteren ist bei den mobilen Telefonnetzen eine sehr hohe Sendeleistung erforderlich, die für die überwiegende Anzahl der oben beschriebenen wissenschaftlichen Anwendungen nicht den notwendigen Grad der Miniaturisierung der Tiersender ermöglicht.

Globale Systeme

Seit den siebziger Jahren wurde die satellitengestützte Verfolgung großer Tiere möglich (über NIMBUS, später Argos und Orbcom). Satellitenfernmessung erlaubt Forschern, einzelnen Individuen über große Abstände und im unwegsamen Gelände zu folgen. Die Sender, die anfangs benutzt wurden, waren einige Kilogramm schwer. Wegen des Gewichts der Sender war der Bereich auf große Tiere wie Bären, Wale und

© Max-Planck-Institut
für Verhaltensbiologie

später Albatrosse begrenzt. Die fortschreitende Technologieentwicklung hinsichtlich der Miniaturisierung von Bauteilen, ermöglicht inzwischen eine Verringerung des Gewichts und der Größe der Sender.

Systeme wie das französische Argos System, welches als Nutzlast auf den meteorologischen Satelliten wie z.B. „MetOp“ (Argos-3) installiert ist, wurden zunächst als wissenschaftliches Mittel zur Erfassung und Übertragung von meteorologischen und ozeanographischen Daten konzipiert (z.B. Bojen, Container, Schiffsverfolgung) und ist insbesondere nur für weitverteilte Nutzer geeignet und in der Anzahl von Nutzern flächenbezogen deutlich limitiert. Argos verwendet für die Datenübertragung ein Verfahren, das innerhalb des verwendeten Frequenzbands nur den Empfang eines einzigen Tiersenders erlaubt. Senden mehrere Tiersender gleichzeitig, stören sie sich gegenseitig. Das Verfahren ist auch nicht robust bei anderen Störern im Frequenzband.

Die über die Argos-Nutzlast auf den MetOp und NOAA Satelliten verfügbaren und global einsetzbaren Geräte für kleinere Tiere basieren auf der Messung der Dopplerverschiebung. Deren Genauigkeit liegt zwischen 100 Meter und einigen 100 km. Häufig müssen große Datenlücken festgestellt werden, welche technisch und nicht objekt-bedingt sind. Ein zu ICARUS vergleichbarer Tiersender (z.B. hinsichtlich der Anzahl der GPS-Positionen), aber ohne die Möglichkeit der Sensorik, ist ca. 5-mal schwerer und 7-mal teurer bzw. mehr als 10-mal teurer im Betrieb.

ICARUS hat gegenüber vorhandenen Systemen den Vorteil der Kombination von globaler Verfügbarkeit, höherem Grad der Miniaturisierung und der Fähigkeit des gleichzeitigen Empfangs von vielen Tiersendern. Dies wird erreicht durch die Kombination eines weltraumbasierten Kommunikationssystems mit neuesten Verfahren und Technologien der Nachrichtentechnik, der Entwicklung eines darauf abgestimmten Kommunikationskonzepts und einer miniaturisierten terrestrischen Lösung beim Tiersender, die die neueste Generation von Elektronikbausteinen intelligent verknüpft.

Derzeit eingesetzte Technologien zum Aufspüren und globalen Verfolgen von Tieren über Satelliten schließen immer noch ungefähr 75 % der Vögel und Säugetierarten aus. Dies beruht darauf, dass die meisten Tiere klein sind. Viele ökologisch und ökonomisch wichtige Arten sind sogar sehr klein, z.B. Fledermäuse, Singvögel oder Wanderheuschrecken. In Abbildung 2 ist das Körpergewicht über die Anzahl der Arten aufgezeigt, sowie die Grenzen der verfügbaren Tracking-Technologien für diese Tiere.

© Max-Planck-Institut
für Verhaltensbiologie

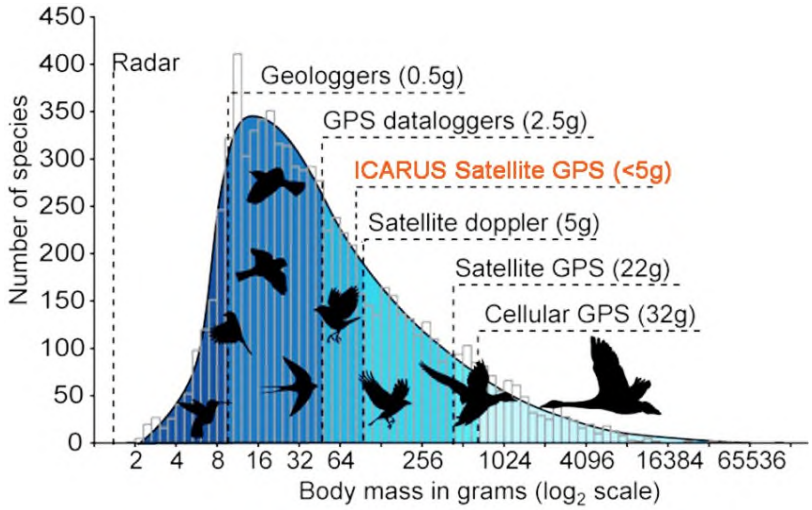

Abbildung 3: **Verteilung der Anzahl der Vogelarten auf der Welt bezogen auf ihr Körpergewicht und Verfügbarkeit von Tracking-Technologien für deren Beobachtung (basierend auf [12])**

Eine allgemeine Regel besagt, dass an Tieren angebrachte Geräte („Tags“) nicht mehr als ca. 3 % des Körpergewichts des Tieres wiegen sollen, um das natürliche Verhalten der Tiere durch das zusätzliche Gewicht nicht zu beeinflussen. Die Genauigkeit und Zuverlässigkeit von übertragenen Daten ist ebenfalls von größter Bedeutung, sowie die Datenmenge.

Mit den 5 g leichten Tiersendern von ICARUS, können bisher ca. 40 % der Vogel- und Säugetierarten beobachtet werden. Mit fortschreitender Technologieentwicklung und weiterer Miniaturisierung hin zum 1 g Tiersender könnten sogar mehr als 80 % der Arten erfasst werden. Darüber hinaus ist zu berücksichtigen, dass mit zunehmender Anzahl der Arten auch eine völlig neue Qualität der Messungen und Ergebnisse erreicht wird, da weitere Tiergruppen erfasst werden wie beispielsweise die Singvögel.

Entscheidende Nutzeranforderungen sind die erreichbare Ortungsgenauigkeit, flexible Anbindung von Sensoren zur Erfassung biologischer Parameter, Zweiwegekommunikation zur Steuerung der Tags und eine hohe Anzahl von überwachbaren Tieren/Objekten. Für die globale Beobachtung sind weltraumgestützte Lösungen unabdingbar, um aufgezeichnete Tierdaten über Sender an den Nutzer zu übertragen.

Es ist zu erwarten, dass durch die fortschreitende Miniaturisierung bei gleichzeitig erhöhter Leistungsfähigkeit von elektronischen Bauteilen („sog. Moorsches Gesetz“) über die Zeit leichtere und leistungsfähigere Tags zur Verfügung stehen werden. Dies schließt auch effizientere Energiesysteme (z.B. neuartige Batterien, „energy harvesting“ Verfahren etc.) mit ein.

Wichtig ist es Rahmenbedingungen für eine Infrastruktur des Gesamtsystems festzulegen, welche die Voraussetzungen für die Weiterentwicklung und Optimierung/weitere Miniaturisierung der Tags liefern.

Datenzentren und Datenarchive für wandernde Tiere

Movebank ist eine kostenlos nutzbare Internetplattform zur Darstellung, Bearbeitung, Analyse, Speicherung und Veröffentlichung von Daten über Wanderbewegungen von Tieren. Die Stärke von Movebank liegt in der Verwaltung von sehr großen Datensätzen, wie sie bei der Telemetrierung von Tieren

© Max-Planck-Institut
für Verhaltensbiologie

über einen langen Zeitraum entstehen. Um die Daten nicht nur für eine einmalige Auswertung zu nutzen, sondern sie zusätzlich langfristig für weitere Analysen zur Verfügung zu stellen, ist das Ziel über Movebank die durch Peilsender, Satellitensender und Logger gewonnenen Daten einerseits im Rahmen der Ursprungsprojekte optimal auszuwerten und sie andererseits für weitere Auswertungen und zur allgemeinen Information der Öffentlichkeit langfristig verfügbar zu halten.

Nachfolgende Abbildung 4 zeigt die Zugangsseite von Movebank. Auf einer Karte werden die öffentlich zugänglichen und nicht zugänglichen Studien farblich unterschiedlich dargestellt (grün bzw. grau). Die öffentlichen Studien können direkt eingesehen werden wie in Abbildung 5 beispielhaft für eine vom MPIAB, vormals MPIO geführte Studie mit Weißstörchen gezeigt. Bei den nicht öffentlichen Studien werden nur die Art der Studie und die untersuchten Tiere benannt. Weitere Informationen können beim Urheber der Daten angefragt und von diesem einzeln für den jeweils interessierten Personenkreis freigeschaltet werden.

Movebank bietet Werkzeuge zur grundlegenden Bearbeitung der Lokalisierungsdaten und stellt in zunehmendem Umfang auch Hilfsmittel bereit, um Daten von Biologgern (Beschleunigungssensoren, Körpertemperatur und Herzrate) mit den Lokalisierungsdaten auf einer Karte in Verbindung zu bringen. Ebenso lassen sich Lokalisierungsdaten mit externen Umweltdaten verschneiden oder zur weiteren Bearbeitung direkt in die passenden Formate für ArcGIS, Google Earth und anderen Programme exportieren. Zu den Daten über Wanderbewegungen lassen sich beispielsweise Wetterdaten hinzufügen. So ist es möglich, die Wanderbewegungen mit Windgeschwindigkeit, Windrichtung, Temperatur und weiteren Witterungsparametern zur jeweiligen Zeit am jeweiligen Ort in Verbindung zu bringen. Genehmigungsbehörden, akademische Zeitschriften und Organisationen zur Forschungsfinanzierung legen zunehmend Wert darauf, dass Forschungsdaten archiviert werden und auch später für Auswertungen zugänglich bleiben.

© Max-Planck-Institut
für Verhaltensbiologie

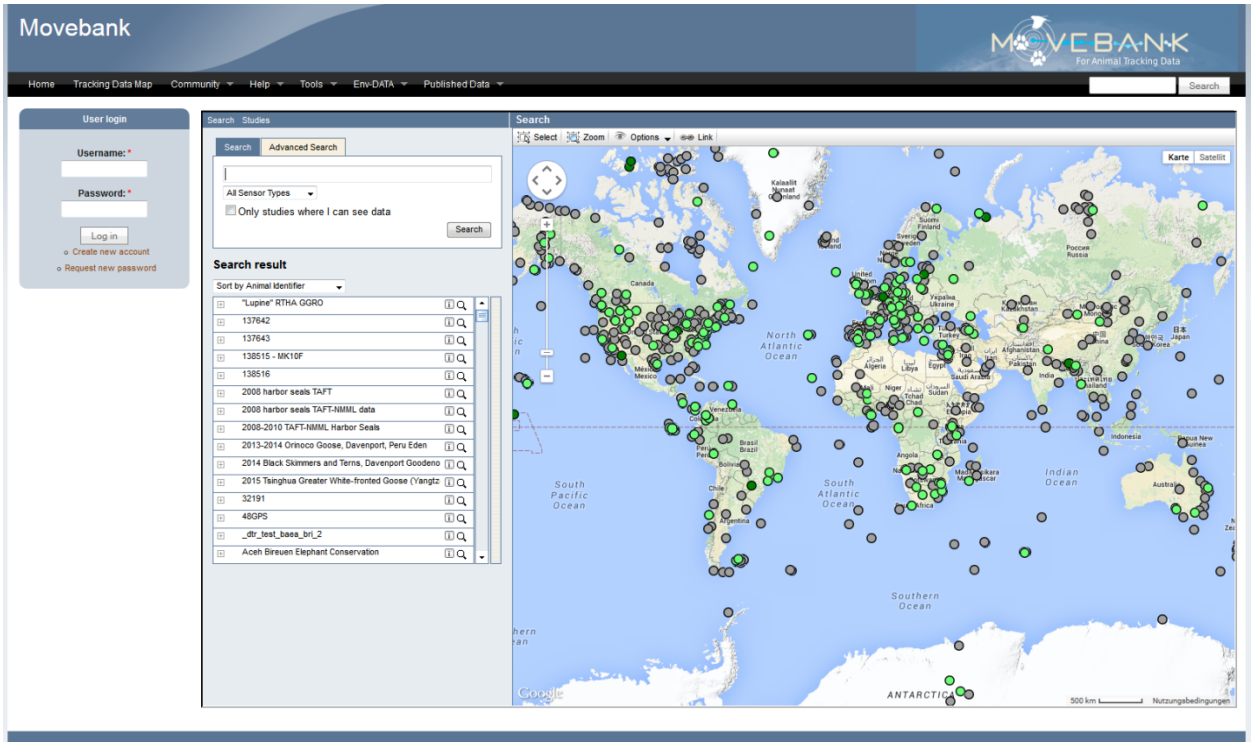

Abbildung 4: **Zugangsseite von Movebank mit Darstellung aller öffentlich zugänglichen (grün) und nicht zugänglichen Studien (grau) auf einer Weltkarte; links die Suchmaske für Studien und das Login für registrierte Nutzer**

Movebank soll eine langfristige Archivierung der meist teuer erhobenen Daten aus Besenderungsprojekten aller Art sicherstellen. Nach einem Review-Prozess, der auch das Vorhandensein der zum langfristigen Verständnis der Daten erforderlichen Zusatzangaben prüft, erhalten akzeptierte Datensätze eine DOI-Nummer („digital object identifier“) und werden dauerhaft einem digitalen Archiv hinzugefügt. Die wird insbesondere dahingehend immer wichtiger für die Wissenschaft, da viele Journale inzwischen Artikel nur akzeptieren, wenn die Daten der Publikation archiviert sind. Über Movebank werden die Daten damit dann auch zur zitierfähigen Quelle für Publikationen. Der jeweilige Nutzer entscheidet bei Movebank, in wieweit auf seine Daten zugegriffen werden kann. Nur das Vorhandensein von Daten wird immer angezeigt. Bei versteckten Datensätzen kann bei Interesse an den Daten beim Inhaber der Daten die Zugänglichkeit angefragt werden.

Im Vergleich dazu setzt Argos kein offenes System ein. Die von den Argos Transmittern an die Satelliten übertragenen Daten werden über ein Antennennetzwerk an die Processing Centers in Largo USA und als Backup in Toulouse, Frankreich übertragen. Nach der Prozessierung werden die Daten den jeweiligen Nutzern übermittelt. Das Wissen über die in der Datenbank verfügbaren Daten liegt nur den Betreibern der Datenbank vor. Das Teilen der über Argos gewonnenen Daten muss vom Nutzer selbst initiiert werden.

© Max-Planck-Institut
für Verhaltensbiologie

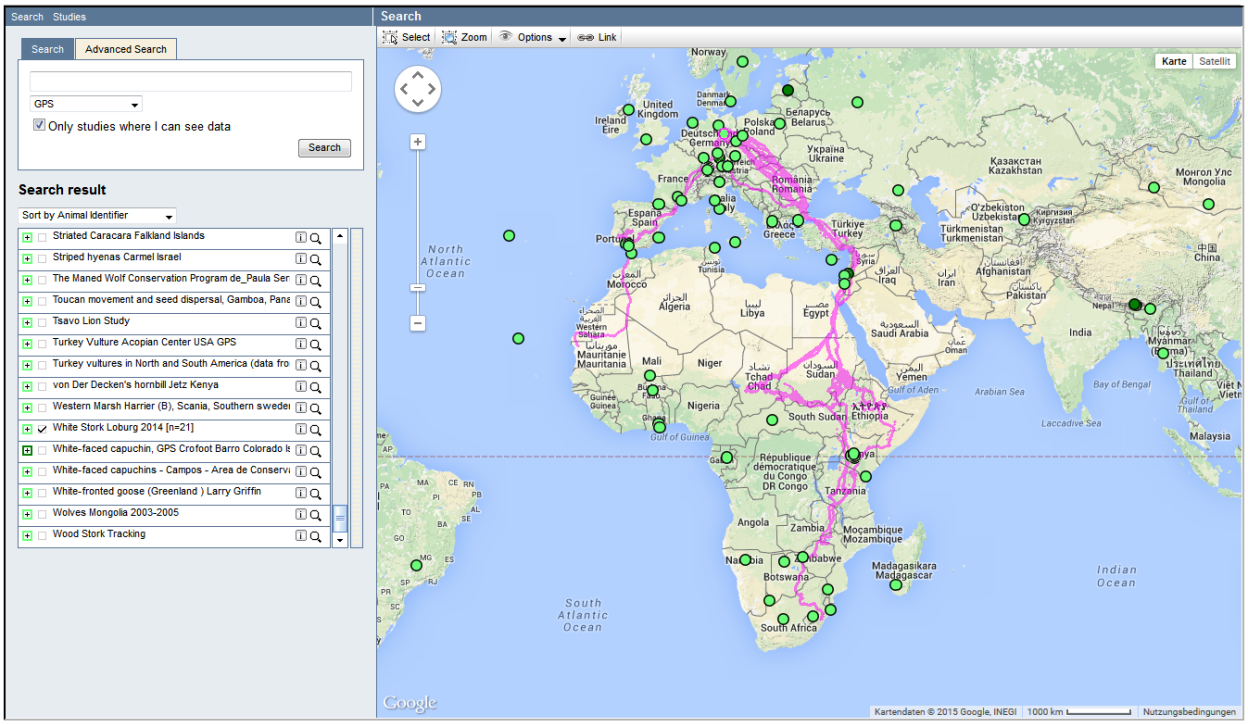

Abbildung 5: **Beispiel der Darstellung der Positionsdaten einer öffentlich zugänglichen Studie von Weißstörchen mit Wanderung östlich und westlich des Mittelmeeres**

Daneben gibt es noch weitere Datenarchive für wandernde Tiere wie die Datenbanken von Beringungszentren in der Meeresbiologie, wie beispielsweise:

- Seaturtle.org mit dem Schwerpunkt der Speicherung von Daten von Meeresschildkröten
- ZoaTrack (http://oztrack.org/) ist eine Datenbank primär für Informationen, die im Bereich von Australien aufgezeichnet wurden.
- WRAM (Wireless Remote Animal Monitoring), eine im Aufbau befindliche Datenbank der Swedish LifeWatch Initiative

Neben den speziellen Datenarchiven für wandernde Tiere existieren Datenbanken, deren Ziel mehr die Integration von unterschiedlichen Informationen im Bereich der Biodiversität ist. Dazu gehören:

- GBIF (Global Biodiversity Information Facility, www.gbif.org), eine internationale Dateninfrastruktur zur Bereitstellung von Informationen über das Leben auf der Erde (die größte weltweite Internet-Datenbank der Biodiversität)
- Map of Life (mol.org)

GBIF und Map of Life sind Web-Services, die im Bereich der Beobachtung von Tieren im Gegensatz zu Movebank nicht die Daten von einzelnen Individuen über einen längeren Beobachtungszeitraum erfassen, sondern nur das singuläre Auftreten von Tieren darstellen. Die Beobachtung eines Tieres zu einem Zeitpunkt wird über einen Punkt erfasst. Damit werden z.B. Verbreitungskarten von Tierarten erstellt.

© Max-Planck-Institut
für Verhaltensbiologie

Es sind bereits Diskussionen im Gange, in wieweit Movebank und seine Dienstleistungen auch über GBIF zugänglich gemacht werden sollten und damit über die Erweiterung der Informationen in GBIF eine Steigerung des Bekanntheitsgrads bzw. über Bewusstseinsbildung des Vorhandenseins der Migrationsdaten erfolgt und die Nutzung dieser Daten über den bereits vorhandenen Personen- bzw. Wissenschaftskreis hinaus erweitert wird.

2.4.1 Vorhabenrelevante Erfahrung

Die internationale wissenschaftliche Zusammenarbeit im Bereich von Tierwanderungen hat eine jahrhundertealte Tradition, vor allem wenn es um Fragen des Vogel- oder Fledermauszugs geht. Das ‚Vogelberingungszentrum' der Max-Planck Gesellschaft, später das ‚Max-Planck Institut für Ornithologie – Radolfzell (MPIO)' und heute das Max-Planck Institut für Verhaltensbiologie (MPIAB) ist aus der weltweit ersten Vogelberingungsstation entstanden, die im russischen Rossiten (jetzt Rybachy) im Jahr 1905 etabliert wurde. Seither wurden hunderttausende von Vögeln mit nummerierten Fußringen ausgestattet und ihr Beringungsort und letztendlicher Fundort registriert. Diese Daten – so rudimentär sie uns heute auch erscheinen mögen – stellen immer noch den global besten Wissenschaftsschatz über Tierwanderungen dar.

Seit der Erfindung der Wildtier-Telemetrie in den 1950er Jahren, ergaben sich für die globale Wissenschaftlergemeinde zum ersten Mal völlig neue, ungeahnte Möglichkeiten der Tierbeobachtung. Die Antragsteller haben durch ihre Forschungen auf dem Bereich des ‚Bio-Logging', d.h. des ‚remote sensing' von Verhaltens- und Physiologiedaten von freilebenden Tieren, Pionierarbeit geleistet. So wurden vom Team des Antragstellers zum ersten Mal die Orientierungs- und Navigationsleistungen von Singvögeln im Freiland während des natürlichen Zugverhaltens studiert, zum ersten Mal Insekten (Libellen) auf dem Zug telemetriert, und zum ersten Mal gleichzeitige Messungen von Flügelschlägen, Herzraten, und Windbewegungen an nachts ziehenden Kleinvögeln durchgeführt. Allerdings mussten hierbei die Singvögel noch vom Boden aus mit Fahrzeugen verfolgt werden.

Aufgrund von langjährigen Erfahrungen mit dem globalen Argos Data Collection System in der Anwendung für die Tierbeobachtung und den wesentlichen Einschränkungen im Hinblick auf Verfügbarkeit, Genauigkeit, hohen Kosten und Limitierungen in der mittelfristigen Ausbaubarkeit wurde die ICARUS Idee entwickelt und vorangetrieben.

Die Aktivitäten zur „Movebank" und die Entwicklung eines Bodentestsystems durch das MPIAB sind wichtige Vorarbeiten im Hinblick auf die Zielstellung und Umsetzung einer ICARUS Mission. Die Movebank (www.movebank.org) wurde entwickelt, um Forschern eine effektive Nutzung ihrer gesammelten Tierbewegungsdaten zu ermöglichen und eine dauerhafte allgemeine Archivierung dieser Daten zu gewährleisten. Movebank wird als wissenschaftliche Datenbank für das ICARUS Bodensegment eingesetzt.

MPIAB hat mit Eigenmitteln ein Boden-Testsystem entwickelt, mit dem grundsätzliche Eigenschaften eines geeigneten Datenübertragungsverfahrens und das Übertragungsverhalten von bewegten Objekten (Tieren) auf eine bewegte Empfangsstation getestet werden können.

© Max-Planck-Institut
für Verhaltensbiologie

Ziel dieser Tests war es eine funktionale Verifikation wichtiger Teilsysteme unter Verwendung eines Codemultiplexing Verfahrens als Feldversuch unter Berücksichtigung realistischer Tier- und Umwelt-randbedingungen.

„ICARUS Space Segment“ und “ICARUS Space Project”

Das MPIAB hatte 2009 einen wissenschaftlichen Antrag für satellitengestütztes Tiermonitoring bei der ESA (ESA Call ILSRA 2009/4/) eingereicht, welcher in der Auswertung 2010 mit „excellent“ hinsichtlich seiner wissenschaftlichen Inhalte bewertet wurde. Darin wurde die ISS als Basis für eine möglichst schnelle technische Implementierung und ein Demonstrator-Experiment vorgeschlagen. Als langfristiges Ziel für ein globales Tiermonitoring System ist eine Satellitenkonstellation identifiziert.

Ende 2011 hat das MPIAB einen Zuwendungsantrag an das DLR für die Untersuchung der Machbarkeit einer digitalen Telemetriestrecke und der dafür notwendigen Simulationen und Analysen der ICARUS Space Segment Anteile auf der ISS gestellt. Für die Entwicklung bis zu einem PDR Status wurde die Freigabe der Mittel ab 01.03.2012 mit einer Laufzeit von 18 Monaten erteilt.

Die Ergebnisse dieser Machbarkeitsstudie haben die Grundlage gelegt für das Folgevorhaben, in welchem der Experimentalbetrieb eines globalen Tierbeobachtungssystems über die internationale Raumstation ISS vorbereitet wird. Hierzu wird die auf der ISS zu akkommodierende Flughardware entwickelt, gefertigt und getestet, auf die ISS verbracht und die Leistungsfähigkeit und Funktionalität des Systems im Flug als notwendige Basis für einen späteren Experimentalbetrieb demonstriert.

Das ISS Demonstratorexperiment wird zum einen die Möglichkeit eines schnellen Funktionsnachweises und zum anderen die Basis für eine wissenschaftliche, im Umfang jedoch eingeschränkte Nutzung erbringen.

Die Arbeiten für das ICARUS Space Project (ICARUS SP) wurden mit dem Kick-Off am 11. September 2013 aufgenommen. Der Abschluss der Fertigung und der Tests der Qualifikations- und Flugmodelle erfolgte mit erfolgreicher Übergabe der Flughardware an RKK Energia im Juli 2017. Im Anschluss erfolgte im Oktober 2017 der Flug des Bordrechners von ICARUS zur ISS. Der Launch der Antenne zur ISS fand am 13.2.2018 statt, die Installation durch die Kosmonauten an der äußeren Hülle des russischen Segments der ISS (Service Modul) wurde am 15. August 2018 durchgeführt.

Die anschließende 4-monatige Commissioning-Phase, in der die Nutzlast in Betrieb genommen wird, hat sich verzögert und wurde Anfang 2020 durchgeführt. Seit September 2020 erfolgt der wissenschaftliche Betrieb. Seither liefert das System zuverlässig die Daten tausender Tiere und ermöglicht so neue Erkenntnisse zu deren Verhalten.

Das Gesamtsystem der Demonstrationsmission von ICARUS auf der ISS ist in nachfolgender Abbildung 6 gezeigt. Im Rahmen des Vorhabens ICARUS Space Project werden vom Gesamtsystem die in Abbildung Abbildung 7 gezeigten Elemente entwickelt.

© Max-Planck-Institut
für Verhaltensbiologie

Das ICARUS On-board Equipment umfasst die Sende- und Empfangsantenne, sowie die im inneren der ISS untergebrachte Elektronikeinheit. In dieser werden die empfangenen Signale decodiert und für die Übertragung zum russischen Kontrollzentrum der ISS prozessiert.

Das Monitoring and Control Centre (MCC) wird von der russischen Seite im Rahmen der Kooperationsvereinbarung entwickelt, beigestellt und betrieben.

Für Testzwecke können die Tiersender durch Simulatoren ersetzt werden. Diese können vorprozessierte Signale von einzelnen und auch einer Vielzahl von Tiersendern an das ICARUS On-board Equipment senden, bzw. das von dort abgestrahlte Downlink-Signal empfangen und verarbeiten. Diese Simulatoren setzen sich aus Standard Elektronikeinheiten zusammen (Laborausrüstung). Sie waren für eine Inbetriebnahme und das Austesten/Optimieren der Flugausrüstung nach der Installation auf der ISS konzipiert, haben aber nicht den für den wissenschaftlichen Einsatz notwendigen Miniaturisierungsgrad.

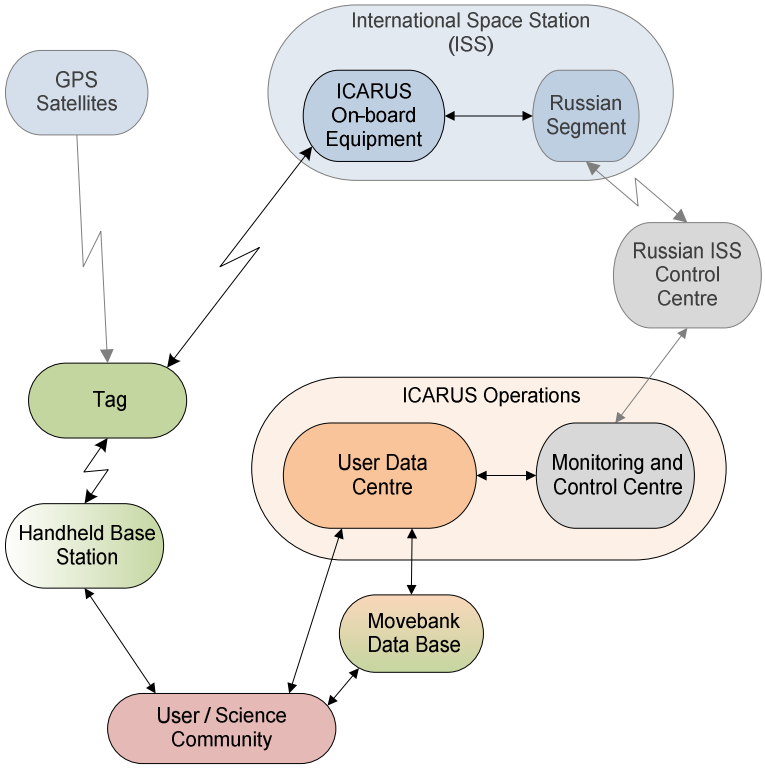

Abbildung 6: **Elemente des ICARUS Gesamtsystems**

© Max-Planck-Institut für Verhaltensbiologie

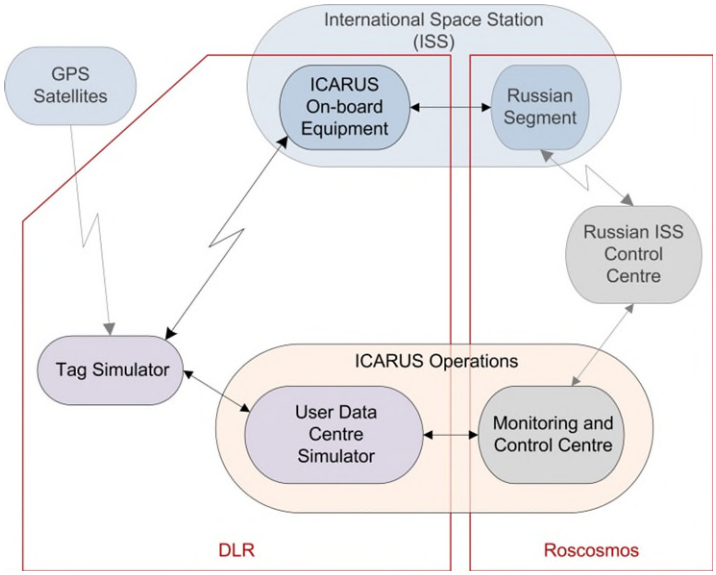

Abbildung 7: **Elemente des ICARUS Space Projects mit Zuordnung zu DLR und Roscosmos entsprechend der deutsch-russischen Kooperationsvereinbarung**

ICARUS – Vorbereitende Satellitentechnologien

Im Vorhaben ICARUS Vorbereitende Satellitentechnologien werden die Voraussetzungen für eine ICARUS Satellitenmission mit mehreren Satelliten zur globalen Beobachtung kleiner Objekte (Tiere) untersucht und vorbereitet. Die für die Umsetzung notwendige Satellitentechnologie einer Zentralavionik (in einer Einheit zusammengefasster Bordrechner und Leistungsversorgung) werden als Entwicklungsmodell (Breadboard) und Engineering Modell unter Berücksichtigung etablierter Standards der Raumfahrt entwickelt, gebaut und getestet. Das Vorhaben wurde in 2013 begonnen und in 2015 abgeschlossen.

Hosted Payload Studie

Im Vorhaben ICARUS Hosted Payload soll der Einsatz der ICARUS Nutzlast als Hosted Payload-Implementierung auf Fremdsatelliten untersucht werden. Dazu soll auf Grundlage des aktuellen ICARUS Demonstrator-Konzepts die Einbindung als Hosted Payload analysiert werden, um anschließend daraus eine Hosted Payload Spezifikation zu erarbeiten. Das Vorhaben wurde Ende 2014 begonnen und Anfang 2017 abgeschlossen.

ICARUS Bodensegment

Die Arbeiten am ICARUS Bodensegment wurden am 1.7.2016 begonnen. Im Rahmen der bereits durchgeführten Arbeiten des ICARUS Bodensegments wurden entsprechend Abbildung 8 ein Betriebs- und Softwarekonzept entwickelt und Teile der dafür notwendigen Software implementiert. Die zu den russischen Kooperationspartnern vorhandenen Schnittstellen 1 sind beim Raumsegment über das Space Segment Interface Control Document abschließend beschrieben. Die Schnittstellen 2-4 konnten grundsätzlich mit RKK Energia im Dezember 2017 vereinbart werden.

© Max-Planck-Institut
für Verhaltensbiologie

Das Nutzerdatenzentrum (UDC) ist eines der Kernelemente des ICARUS Bodensegments. Im Nutzerdatenzentrum wird das Gesamtsystem verwaltet, die ein- und ausgehenden Daten werden verarbeitet und bereitgestellt. Es bildet damit das essenzielle Verbindungsglied zwischen der Raumfahrtinfrastruktur und der Schnittstelle zu den Nutzern und der Wissenschaft.

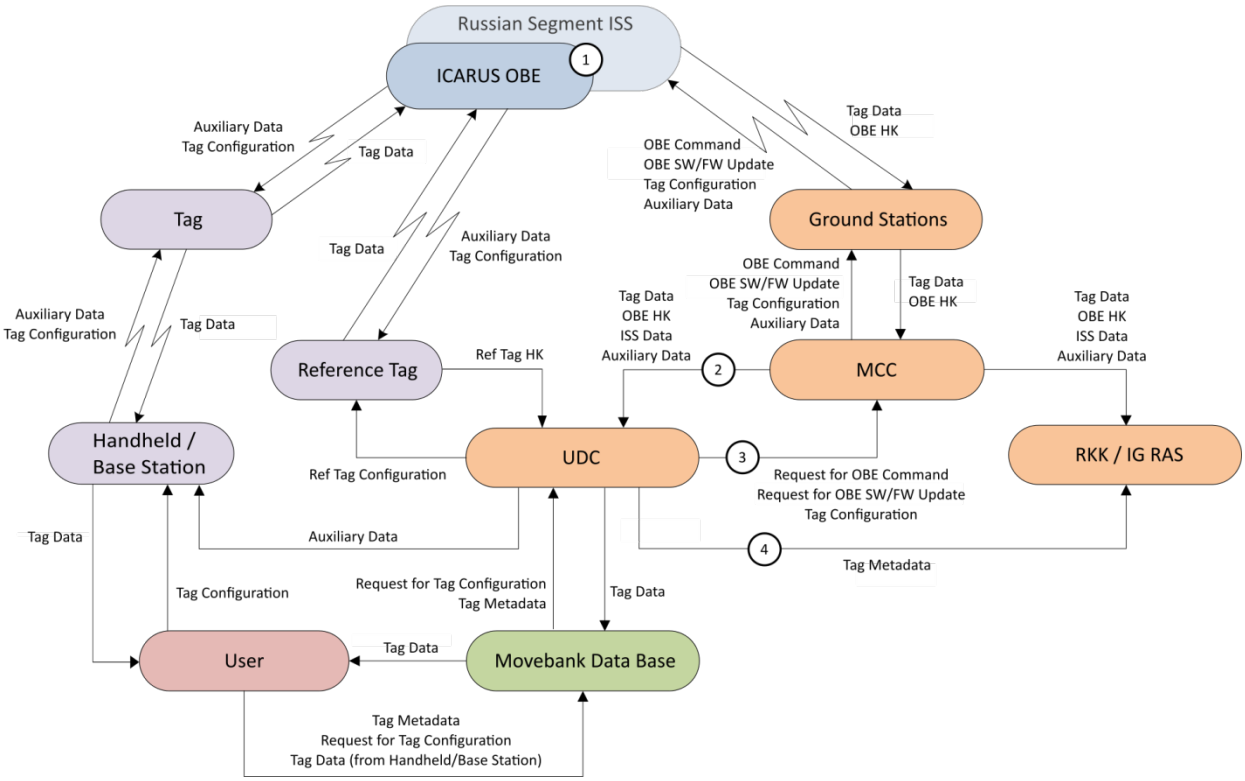

Abbildung 8: Daten- und Kommandoflüsse des ICARUS Gesamtsystems

Für die terrestrische drahtlose Kommunikation mit den Tiersendern (Basic Tag) wird ein Handheld bzw. eine Basisstation eingesetzt.

Das Handheld besteht aus einem Funkgerät und einer App, die auf einem Tablet mit Android Betriebssystem zu installieren ist.

Mit Handgeräten kann der Wissenschaftler den Tiersender vor der Anbringung an das Tier initialisieren und die neuesten Daten für die Berechnung der ISS Kontakte und GPS Ephemeriden in den Tiersender laden. Nachdem die Tiere besendert sind, können mit den Handgeräten terrestrisch Daten aus den Tiersendern ausgelesen werden und Konfigurationseinstellungen in die Tiersender übertragen werden.

Die Basisstation unterscheidet sich vom Handheld dahingehend, dass mit Einsatz einer größeren Antenne eine größere Reichweite der terrestrischen drahtlosen Kommunikation möglich ist. Darüber hinaus kann das Handheld angeschlossen an das Internet remote betrieben werden.

Das Handheld sendet in voreingestellten Intervallen ein Kommando, das von Tiersender, die dieses Kommando empfangen, ausgeführt wird. Das voreingestellte Kommando, das vom Handheld gesendet wird, löst beim Tiersender das Senden eines kurzen Datenpakets aus. Dieses Datenpaket enthält die Identifikationsnummer des Tiersenders, seine letzte aufgezeichnete Position und den Zustand der

© Max-Planck-Institut
für Verhaltensbiologie

Batterie. An Hand der empfangenen Informationen kann das Handheld von den Tiersendern Sensordaten auslesen und die Konfigurationseinstellungen der Tiersender einstellen.

Die wichtigsten technischen Parameter und Funktionen des Handhelds (Funkgerät) sind:

Abmessungen: Länge 18 cm, Breite 8,5 cm, Höhe 4 cm (mit Schutzhülle, ohne Whip-Antenne)

Gewicht (Masse): ca. 360 g (mit Schutzhülle und Whip-Antenne)

Antenne: Whip-Antenne, 190 mm lang

Speicher: Im internen 8 Gbyte großen Speicher werden die von den Tiersendern empfangenen Daten gespeichert.

Stromversorgung: Die Stromversorgung des Handhelds (Funkgerät) erfolgt über eine externe Batterie (Akkumulator), die über einen USB-Anschluss an das Handheld angeschlossen wird (5 ± 0,2 V, 2 A).

Terrestrische Kommunikation: Der Nutzer kann terrestrisch mit einem Tiersender (Basic Tag bzw. Basic Ear Tag) mit dem Handheld drahtlos kommunizieren. Dabei werden Daten vom Tiersender an das Handheld gesendet, bzw. Kommandos vom Handheld an den Tiersender. Die Aufnahmesequenz von Sensordaten und die Auswahl der über die Funkstrecke zu übertragenden Daten kann über Kommandos, die vom Handheld gesendet werden, konfiguriert werden. Sensordaten, die im Speicher des Tiersenders gespeichert sind, können über ein Kommando an das Handheld übertragen werden. Über die Funkstrecke können zusätzlich die zeitlichen Kommunikationsfenster der Kommunikation zwischen Handheld und Tiersender eingestellt werden und der Tiersender zum besseren Auffinden in einen Pinger-Mode kommandiert werden (d.h. kurzzeitiges Senden in regelmäßigen Intervallen, Einschalten der LED).

Allgemeine elektrische Parameter:

Sendefrequenz: 468,1 MHz

Empfangsfrequenz: 402,25 MHz

Sendeleistung: 13-15 dBm

App: Die Handheld-App stellt die Bedienoberfläche für das Handheld-Funkgerät. Die Tiersender des Benutzers werden verwaltet, Konfigurationen können geändert werden und empfangene Daten in einer Voransicht bewertet werden. Der Zugang zu den finalen Daten erfolgt über die ICARUS Datenbank. Über die App werden für die einzelnen Tiersender Kommandos angelegt, die bei Verbindung zum Handheld-Funkgerät an dieses übertragen werden. Mit den Kommandos können Konfigurationseinstellungen des Tiersenders verändert werden, Daten aus dem Speicher angefordert werden und der Tiersender in den Pinger-Modus versetzt werden. Alle übertragenen Kommandos werden vom Handheld-Funkgerät automatisiert bei Kontakt zu den entsprechenden Tiersendern abgearbeitet und die Ergebnisse mit der nächsten Verbindung zur App an diese übertragen.

Nachfolgende Abbildung 9 zeigt das Handheld sowie Die App und den Tiersender.

© Max-Planck-Institut
für Verhaltensbiologie

Abbildung 9: ICARUS Handheld (Funkgerät), ICARUS APP und ICARUS TAG (Tiersender)

Entwicklung der Tiersender

Anfang 2014 hat das MPIAB (vormals MPIO) eine Vorstudie zur Entwicklung eines miniaturisierten Tiersenders beauftragt, in der die Möglichkeit einer eigenständigen Entwicklung eines Funkchips für ICARUS untersucht wurde.

Derzeit wird eine Lösung erarbeitet, die auf bereits existierenden Bauteilen aufbaut.

Folgende Entwicklungsschritte sind bereits erfolgt bzw. werden noch durchgeführt:

- Abschätzungen zur grundsätzlichen Machbarkeit des Tiersenders im Rahmen der Machbarkeitsstudie des Gesamtsystems ICARUS (September 2012 – Juli 2013)
- Vorbereitungsphase eine ICARUS Funkchips (Januar 2014 bis Juli 2014)
- Beauftragung der Entwicklung eines ICARUS Core Modules bestehend aus dem analogen und digitalen Radio, (August 2015 bis Dezember 2016)
- Beauftragung der Entwicklung eines ICARUS Basic Tag (Januar 2017 bis Dezember 2017)

Die größte Herausforderung von ICARUS ist die Entwicklung einer funktionsfähigen Datenverbindung zwischen den Sendern auf den Tieren und dem Empfänger auf der ISS. Ein Tiersender kann mit dem ICARUS-System an Bord der ISS bis zu 800 km Entfernung mit geringem Datenvolumen kommunizieren. Er bestimmt in regelmäßigen Intervallen mittels GPS die genaue Position und erfasst die lokalen

© Max-Planck-Institut
für Verhaltensbiologie

Umgebungstemperaturen und Beschleunigungswerte, die den Wissenschaftlern Hinweise über das Verhalten der Tiere geben. Und das alles mit einem Sender, der weniger als 5 Gramm wiegt und ein Volumen kleiner als 1,5 cm³ hat.

Ziel der ersten Entwicklung des Tiersenders von ICARUS war eine Basisversion (ICARUS Basic Tag), mit der in der ersten Betriebsphase auf der ISS die Funktionsfähigkeit des Systems gezeigt werden kann.

Der Basic Tag bestimmt in regelmäßigen, einstellbaren Intervallen seine Position via GNSS (GPS und GLONASS), zeichnet Daten der Sensoren mit hoher Messgenauigkeit auf und ermittelt so seinen Weg, seine Bewegungen, Ausrichtung und Umgebungsparameter (Luftdruck, Temperatur und Feuchtigkeit).

Die im Basic Tag gespeicherten Daten werden über eine drahtlose Kommunikation an die Handhelds gesendet. Mit den Handhelds können auch die Konfigurationsparameter des Basic Tags eingestellt werden, z.B.:

- Das Sensordaten-Aufzeichnungsschema, Selektion von 16 voreingestellten Konfiguration
- Das Intervall für die Handheld-Suche (regelmäßiges Intervall oder in täglichen Zeitfenstern)

Nachfolgende Abbildung 10 zeigt den Basic Tag und die Baugruppen des Basic Tags (Explosionszeichnung).

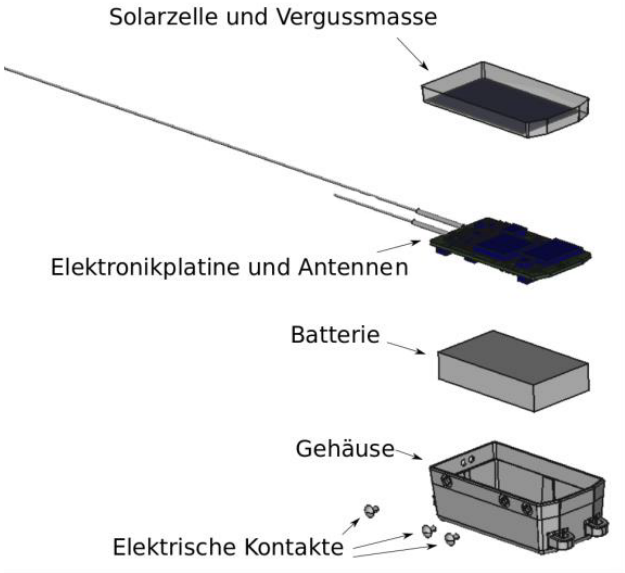

Abbildung 10: Basic Tag Foto, Basic Tag Explosionszeichnung

Die wichtigsten technischen Parameter des Basic Tags sind:

Abmessungen: Länge 26 mm, Breite 15 mm, Höhe 9 mm (ohne Antenne)

Gewicht (Masse): 5 g

Antennen: Zwei flexible Antennen, 200 mm und 50 mm lang; die Antennen ragen aus der Rückseite des hinteren Teils des Basic Tag Gehäuses heraus.

© Max-Planck-Institut
für Verhaltensbiologie

Konstruktion: Die Leiterplatte mit den elektronischen Bauteilen, die Solarzelle und die Batterie sind in ein Kunststoffgehäuse integriert, das die Komponenten von Umgebungsbedingungen wie Feuchtigkeit und mechanischen Belastungen schützt. Für die Befestigung des Basic Tags am Tier sind am Gehäuse vier Ösen angebracht, über die beispielsweise elastische Fäden geführt werden können. Für die Aktivierung des Basic Tags befinden sich am Gehäuse elektrische Kontakte. Eine LED kann über Blinken über den Aktivierungszustand informieren bzw. kann für das Auffinden des Basic Tags eingesetzt werden.

Sensoren: Der Basic Tag bestimmt die Position über einen GPS-Empfänger. Damit kann auch die Geschwindigkeit bestimmt werden. Zusätzliche Sensoren sind ein Beschleunigungsmesser, der eine 3-dimensionale Erfassung von Beschleunigungen des Tags durchführen kann, ein Magnetometer und ein Temperatursensor. Die nicht druckfeste Variante des Basic Tags enthält zusätzlich noch einen barometrischen Drucksensor und einen Feuchtigkeitssensor.

Speicher: Die Sensordaten werden auf einem 512 Mbyte großen Speicher im Basic Tag gespeichert.

Stromversorgung: Die Stromversorgung des Basic Tags erfolgt über einen Lithium-Polymer-Akkumulator mit einer Nennkapazität von 70 mAh. Eine GaAs-Solarzelle ermöglicht das Aufladen des Akkumulators bei Sonneneinstrahlung. Eine Laderegelung schützt den Akkumulator des Basic Tags vor Überladung (over charge protection) und schaltet bei Unterspannung des Akkumulators die Verbraucher des Basic Tags ab (under voltage protection). Der Akkumulator des Basic Tags ist für 500 volle Entlade- / Ladezyklen ausgelegt. Der Basic Tag ermöglicht bei sehr guter Sonneneinstrahlung eine Aufzeichnung von Daten (GPS und Daten der anderen Sensoren) in kurzen Intervallen. Abhängig vom Einsatzgebiet und den damit sich ergebenden Umgebungsbedingungen ergibt sich eine Reduktion der aufgezeichneten Daten. Über Nacht kann die Energie des Akkumulators für die Aufzeichnung von Sensordaten verwendet werden.

Terrestrische Kommunikation: Der Nutzer kann terrestrisch mit dem Basic Tag über ein Handheld kommunizieren. Dabei werden Daten vom Basic Tag an das Handheld gesendet, bzw. Kommandos vom Handheld an den Basic Tag. Die Aufnahmesequenz von Sensordaten und die Auswahl der über die Funkstrecke zu übertragenden Daten kann über Kommandos, die vom Handheld gesendet werden, konfiguriert werden. Sensordaten, die im Speicher das Basic Tag gespeichert sind, können über ein Kommando an das Handheld übertragen werden. Über die Funkstrecke können zusätzlich die zeitlichen Kommunikationsfenster der Kommunikation zwischen Handheld und Basic Tag eingestellt werden und der Basic Tag zum besseren Auffinden in einen Pinger-Mode kommandiert werden (d.h. kurzzeitiges Senden in regelmäßigen Intervallen, Einschalten der LED).

Der Betrieb des Basic Tags ist in Deutschland über die Allgemeinzuteilung von Frequenzen zur Ortung von Tieren zugelassen (Amtsblatt der Bundesnetzagentur für Elektrizität, Gas, Telekommunikation, Post und Eisenbahnen, Nr. 08 vom 2. Mai 2018, Vfg-Nr. 44).

Allgemeine elektrische Parameter:

Sendefrequenz: 402,25 MHz ± 750 kHz

Empfangsfrequenz: 468,1 MHz

Sendeleistung: 6.1 mW

Sendedauer eines Datenpakets (ISS Link): 3.4 s

Temperaturbereich: -10 bis +50 °C

© Max-Planck-Institut
für Verhaltensbiologie

Kommunikation über die ISS: Die Tags und Handhelds wurden von der INRADIOS GmbH entsprechend der Anforderungen des Gesamtsystems ICARUS entwickelt und getestet. Seit der Inbetriebnahme des ICARUS space segments werden die Tags auf der ISS empfangen.

Die Anzahl der in den ersten Jahren des Betriebs von ICARUS eingesetzten wissenschaftlichen Tiersender kann basierend auf den von Argos publizierten Daten wie folgt abgeschätzt werden.

Weltweit werden von Argos 22.000 aktive Transmitter im Monat betrieben. 8.000 der Transmitter werden auf Tieren eingesetzt, d.h. 36%. Die Kosten eines solchen Transmitters belaufen sich auf 3.500 Euro. Unter der Annahme, dass diese Transmitter durchschnittlich 1 Jahr funktionsfähig sind und danach durch neue ersetzt werden, ist allein für besenderte Tiere derzeit ein Budget von mindestens 28 Mio Euro im Jahr vorhanden. Unter der Annahme, dass mit der Verfügbarkeit von ICARUS ca. 20 % dieses Volumens von ICARUS bedient wird, ergibt sich bei einem derzeitigen Preis von 500 Euro pro Tag eine Anzahl von mehr als 10.000 Einheiten in 2020. In den Folgejahren kann von einer Steigerung der Einheiten ausgegangen werden. Nachfolgende Abbildung 11 zeigt die sich ergebende benötigte Anzahl von Tiersendern bis 2022 unter der Annahme einer jährlichen Steigerung der benötigten Einheiten von 30 %. Nicht berücksichtigt sind Tiersender für wissenschaftliche Gruppen, die derzeit mit terrestrischen Systemen arbeiten und zu dem neuen System abwandern, sowie Nutzer aus dem nicht-wissenschaftlichen Bereich für Anwendungen des Trackings kleiner Objekte.

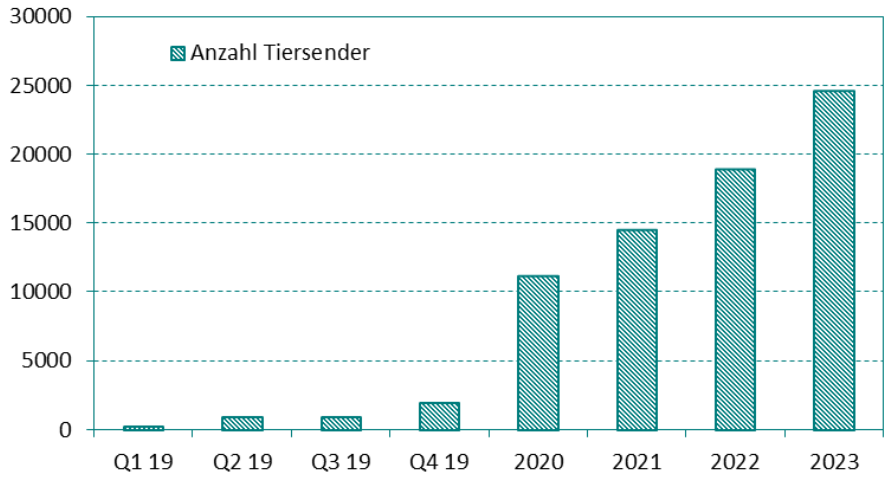

Abbildung 11: Abschätzung der Anzahl der für wissenschaftliche Anwendungen benötigten Tiersender

© Max-Planck-Institut
für Verhaltensbiologie

3 ERZIELTE ERGEBNISSE

3.1 AP 2000 UniBw

Die Ergebnisse im AP2000 (UniBw) sind diesem Abschlussbericht als separates Dokument (UBW-CESR-01_Icarus_Final.pdf) beigelegt.

3.2 AP 3000

Die Ergebnisse im AP 3000 bestanden in der Bereitstellung von ICARUS Überflugs-Signalaufzeichnungen, die zum Test der entwickelten Algorithmen in AP4000 genutzt wurden. Aus diesem Grunde soll an dieser Stelle auf eine detaillierte Beschreibung der Arbeiten im AP3000 verzichtet wurden. Stattdessen werden die Beiträge des AP 3000 im folgenden Abschnitt geeignet dargestellt.

3.3 AP 4000 HTWK Leipzig und INRADIOS

Die Ergebnisse im AP4000 (HTWK Leipzig) sind diesem Abschlussbericht als separates Dokument (ICARUS-KI_AP4000_Abschlussbericht.pdf) beigelegt und enthalten auch die Teile des AP 3000.

3.4 AP 5000 MPI-AB

3.4.1 Bereitstellung biologischer Daten (AP 5100):

Die Ergebnisse im AP 5100 bestanden im Wesentlichen in der Bereitstellung der biologischen Daten, die zur Analyse in den anderen Arbeitspaketen genutzt wurden und gehen teilweise in AP5200 über in welchem die so aggregierten Daten weiterverarbeitet wurden. Jedoch soll im Folgenden das Vorgehen und die Bedeutung der Daten nochmal erläutert werden.

Nach der erfolgreichen Inbetriebnahme des ICARUS-Systems auf dem „Zvezda“-Teilmodul im russischen Segment der Internationalen Raumstation (ISS) wurden in den Jahren 2020 bis 2022 über 4000 Tiere aus mehr als 15 Arten in weltweiten Experimenten mit ICARUS Tiersendern untersucht (Abbildung 12) (1).

© Max-Planck-Institut
für Verhaltensbiologie

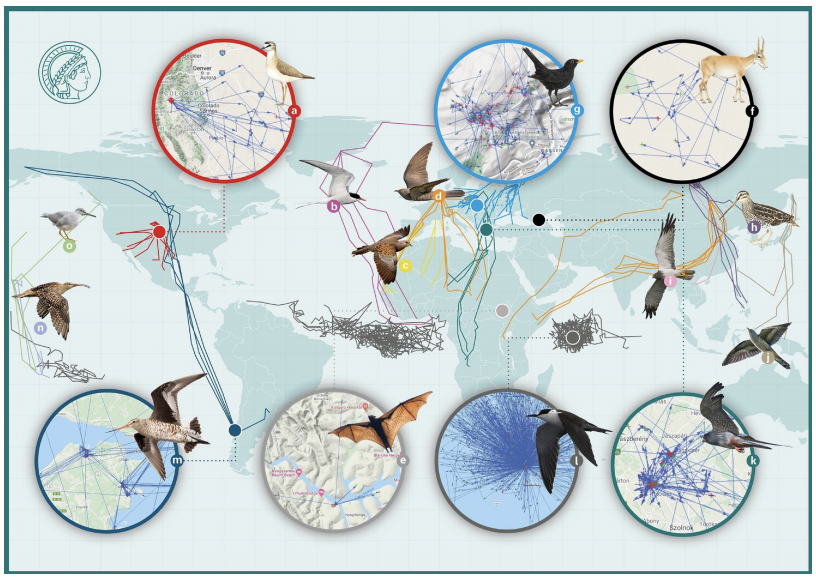

Abbildung 12: Beispiele von mit ICARUS aufgezeichneten Tierbewegungen auf verschiedensten Arten (1).

Die Datenerhebung erfolgt in den meisten Fällen zur Beantwortung wissenschaftlicher Fragestellungen aber auch in der Anwendung in Langzeitprojekten wie Artenschutzüberwachung, Katastrophenprognose oder Anti-Wilderer-Maßnahmen. Dabei wird in Bezug auf die eigentliche Datenerfassung fast immer ein "Deploy & Forget"-Ansatz verfolgt. Zwar haben Wissenschaftler und andere Benutzer spezifische Anforderungen an die Datenerhebung und den anschließenden Transfer der Daten, doch meist wird der angebrachte Tiersender so programmiert, dass er zwar für die Beantwortung der Fragestellung ausreichende Daten liefert. Aber was die tatsächliche Performance betrifft, befindet man sich oft im „Blindflug“, da die vorher unter Laborbedingungen geplanten Einstellungen im Freiland nicht optimiert worden sind.

Als potenzielle Folgen davon entstehen mögliche Datenlücken, die im schlimmsten Fall zu Ausfällen der Sender führen. Diese Sender wären dadurch nicht mehr auffindbar und bereits gesammelte Daten unwiederbringlich verloren, womit der vorherige Akt der Tierbesenderung obsolet wäre.

Um modernste Tiersender also für Fragestellungen im Freiland optimal zu nutzen, braucht es nicht nur von der Hardwaretechnischen Seite neue Entwicklungen, sondern auch das Wissen über die tierspezifischen Anforderungen an die Sender, gepaart mit größtmöglicher Flexibilität in den Einstellungen. Optimalerweise ist es so möglich auch nach dem Ausbringen, die Sender aus der Ferne an sich veränderte Bedingungen anzupassen und sie für eine bestmögliche Datenerhebung „on-the-fly“ zu konfigurieren. Gerade hierfür ist das ICARUS System mit seiner 2-Wege-Kommunikation perfekt ausgestattet. Die große Besonderheit des Systems, besteht zudem durch die fast globale Abdeckung und den regelmäßigen Austausch und Datentransfer mit den Kontrollzentren. Somit können die errechneten Einstellungen jederzeit weiter angepasst werden.

© Max-Planck-Institut
für Verhaltensbiologie

Jeder der ausgebrachten Tiersender liefert wertvolle Daten über das Leben und Schicksal der Tiere, aber auch grundsätzliche Erkenntnisse über die Performance des ICARUS Systems als solches. Die auf dem Sender gesammelten Daten wurden nach der Speicherung mittels ISS Up bzw. Download, Herunterladen über mobile Funkgeräte (Handheld), oder im Falle eines Auffindens des Senders über manuelles Auslesen per Kabel extrahiert. Die verschiedenen Übertragungswege führten zu einer breiten Palette an Datenformaten, weswegen ein einheitliches Schema zur Datenaggregation entwickelt wurde, um diese unterschiedlichen Formate zu vereinheitlichen. Unabhängig von der Art der Übermittlung wurde für ein genaueres Post-Processing und eine anschließende Analyse der Datensätze einzelner Tiere oder Sendertypen die Sender-Daten weiter bereinigt. Um die Integrität der Daten zu gewährleisten, wurden mehrstufige Qualitätssicherungsmaßnahmen implementiert. Dies beinhaltete die Identifikation und Eliminierung von Duplikaten, die Filterung von Übertragungsfehlern und die Überprüfung der Daten auf Vollständig- und Genauigkeit.

Anschließend wurden die so bereinigten Daten in die "Movebank" (https://www.movebank.org) im standardisierten Format hochgeladen. Dort sind sie dann für weitere Prozesse verfügbar und können wie oben erläutert (Punkt: „Datenzentren und Datenarchive für wandernde Tiere“) bereits für eine erste Übersicht auf einer Karte dargestellt werden. Forscher weltweit haben nun Zugriff auf einheitliche und qualitativ hochwertige Daten, was die Zusammenarbeit und den Datenaustausch innerhalb der wissenschaftlichen Gemeinschaft erleichtert. Die standardisierten Daten ermöglichen komplexe Analysen und Visualisierungen, die zuvor aufgrund von Dateninkonsistenzen nicht möglich waren. Dies eröffnet neue Perspektiven für das Verständnis von Tierbewegungen und deren ökologischen Auswirkungen und schafft eine solide Basis für zukünftige Studien und Analysen im Bereich der Ökologie und Verhaltensbiologie.

Die finalen Senderdaten wurden im Anschluss mittels des „Environmental Data Modul“ der Movebank mit beliebigen Umweltdaten annotiert. Diese Umweltdaten stammen aus weltweit verteilten Wetterstationen und wurden dann in großen Datenzentren wie dem European Centre for Medium-Range Weather Forecasts (ECMWF), der European Space Agency (ESA), der National Aeronautics and Space Administration (NASA), der US National Oceanic and Atmospheric Administration (NOAA) zu komplexen Wettermodellen weiterverarbeitet.

Die direkt von den Tiersendern übermittelten Daten, beinhalten zudem wichtige Informationen über das lokale Mikroklima der Tiere, welches mit Hilfe von Temperatur, Luftdruck, Magnetsensoren, Solareintrag ausgiebig beschrieben werden kann.
Von noch größerer Bedeutung sind die biologischen Tierverhaltensdaten, die sich aus GPS-Position und Beschleunigungssensoren ergeben. Diese ermöglichen es Wissenschaftlern nahezu in Echtzeit zu erfahren in welchem Gebiet sich ein Tier gerade aufhält und wie sein aktueller Zustand ist. Zustände fangen bei grundsätzlichen wichtigen Parametern wie tot oder lebendig an, gehen aber durch die Erfassung von Beschleunigungswerten deutlich darüber hinaus. Wir sind zum Beispiel in der Lage mit Hilfe der Sensordaten zuverlässig zwischen Verhaltensweisen wie aktiv, ruhend, schlafend, Migrationsbewegungen oder Unruhe zu unterschieden.

© Max-Planck-Institut
für Verhaltensbiologie

Durch die Etablierung von Tiersendern als „Informations-Plattform“ und die konsequente Einbindung weiterer Sensoren (auch von externen und kommerziellen Anbietern) konnte der Informationsgewinn weiter gesteigert werden. In einer Studie mit 120 freilebenden Amseln, wurde Anhand von implantierten Herzraten- und Körpertemperatur-Sensoren gezeigt, wie gut Tierverhalten, mithilfe physiologischer Messungen und ohne direkte Beobachtungen beschrieben werden kann (Abbildung 13).

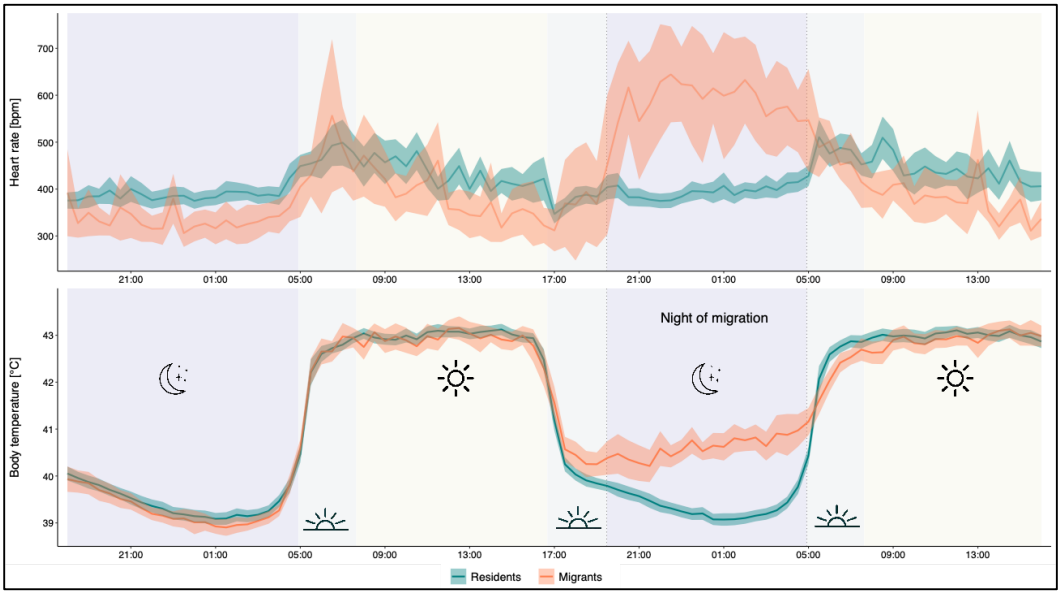

Abbildung 13: **Herzrate und Körpertemperaturprofile bei freilebenden Amseln vor und während Migrationsbewegungen. Hier der direkte Vergleich zwischen sesshaften und ziehenden Individuen (nach Linek et. al. 2024)**

Solche noch nie zuvor im Freiland gesammelten Daten könnten in Zukunft weltweit durch ICARUS zur Verfügung gestellt werden um essentielle Fragen über den Energieverbrauch von Tieren beantworten zu können.

Je nach Tierart und Hintergrundwissen zu den besenderten Individuen können zudem viele weitere Aktivitäten, wie Nahrungssuche, Winterruhe, Brut oder Versorgen der Nachkommen erfasst werden. Ein solcher Detailgrad und die Parallelisierung der Beobachtungen von mehreren tausenden Tieren erlauben uns völlig neue Einblicke in das bisher verborgene Leben der Tiere. So ist es uns unter anderem gelungen bisher unbekannte Energiesparmaßnahmen vor großen Tierwanderungen zu entdecken und bisher angenommenes Textbuchwissen über die Gründe von Tierwanderungen in Frage zu stellen (Abbildung 14).

© Max-Planck-Institut
für Verhaltensbiologie

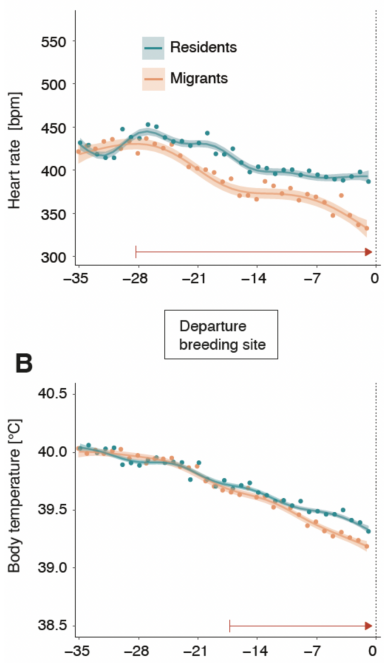

Abbildung 14: **Bisher unbekannte nächtliche Durchschnittswerte von Herzrate und Körpertemperaturprofile bei freilebenden Amseln vor den Migrationsbewegungen. Zu sehen ist eine Reduktion der Energieausgaben bis zu 28 Tage vor der Migrationsbewegung (nach Linek et. al. 2024)**

Die hierbei gewonnen Erkenntnisse spielen eine zentrale Rolle beim Artenschutz und erlauben es uns vorherzusagen, wie Tiere mit dem mittlerweile unvermeidlichen Folgen des Klimawandels umgehen werden und ob bzw. wann sie unseren Schutz bedürfen.

Doch nicht nur langfristig angelegte Studien sind wichtig für Etablierung von erfolgreichem Natur- und Artenschutz. In zahlreichen anderen Ländern spielt die Wilderei von seltenen Tieren eine große Rolle für den Bestand bedrohter Arten. Die Wilderei hat in den letzten Jahren einen verheerenden Einfluss auf bedrohte Tierarten wie zum Beispiel Elefanten und Nashörner gehabt, hauptsächlich getrieben durch den illegalen Handel mit Produkten wie Elfenbein und Nashornhorn. Diese Praktiken haben nicht nur zu einem dramatischen Rückgang der Populationen geführt, sondern auch deren soziale Strukturen und Ökosysteme gestört. Besonders in Afrika sind die Auswirkungen gravierend, wo jährlich Tausende Elefanten und Nashörner illegal getötet werden, trotz internationaler Bemühungen und strenger Schutzmaßnahmen.

Um dem entgegenzuwirken, wurden internationale und lokale Maßnahmen verstärkt die erhöhte Überwachung und Strafverfolgung, Aufklärungskampagnen zur Senkung der Nachfrage und den Schutz von Lebensräumen umfassen. Diese Anstrengungen zielen darauf ab, die genetische Vielfalt zu erhalten und die für viele Gemeinschaften wichtigen Einkommen aus dem Ökotourismus zu sichern. Trotz dieser Bemühungen bleibt die Situation für viele Arten bedenklich und die Forschung zeigt, dass trotz intensiver Einrichtungen und Kontrolle von Schutzgebieten, Ranger oft zu spät eintreffen, um Wilderei zu verhindern. Eine Studie untersucht die Reaktion von Tieren auf Eindringlinge und nutzte deren Verhaltensänderungen als Frühwarnsystem für Wildereiaktivitäten. Dieser Ansatz erhöhte die Effizienz

© Max-Planck-Institut
für Verhaltensbiologie

bei der frühen Erkennung von Wilderern, da Tiere wie Zebras und Antilopen charakteristische Verhaltensweisen zeigten, die eine frühzeitige Entdeckung ermöglichten. Die Ergebnisse unterstreichen die Bedeutung innovativer Technologien und Methoden zur Verbesserung der Reaktionszeiten von Rangern gegenüber Wilderei (2).

Abbildung 15: **Wissenschaftliche Anbringung von ICARUS Ear-Tags als Ohrenmarken an Wildtieren in Namibia.**

Durch den Einsatz des ICARUS Systems und die großflächige Tierbesenderung in Gebieten mit erhöhtem Risiko für Wilderei, eröffnen wir neue Wege, illegale Jagdaktivitäten frühzeitig anhand von Verhaltensänderungen der Tiere zu erkennen. Mit diesem System können lokale Bodenteams effektiv koordiniert werden, um der Wilderei entgegenzutreten. Aktuelle Testläufe sehen vor, bis zu 4000 Tiere in einem überwachten Bereich mit Sendern zu versehen (Abbildung 15). Die Analyse ihres Verhaltens in Bezug auf menschliche Störungen ermöglicht es wertvolle Daten zu sammeln, welche anschließend in die Entwicklung neuer Algorithmen einfließen, um die Erfassung und Verarbeitung dieser Informationen zu verbessern und die Reaktionsmöglichkeiten auf Wilderei zu optimieren.

Andere Anwendungsgebiete sind zum Beispiel auch die Nutzung der biologischen Daten als Frühwarnsystem für Krankheitsausbrüche in der Tierwelt. Die jüngsten Fortschritte haben zu einem Durchbruch in der Überwachung von Wildtierkrankheiten geführt. Moderne Beschleunigungssensoren wie im ICARUS Sender, die an Wildschweinen angebracht werden, zeigen nun deutlich messbare

© Max-Planck-Institut
für Verhaltensbiologie

Verhaltensänderungen, wenn diese Tiere von der Afrikanischen Schweinepest betroffen sind (Abbildung 16) (3). Die Fähigkeit, die täglichen Aktivitätsmuster der Tiere zu überwachen, hat sich als entscheidend erwiesen, um Einblicke in den Gesundheitszustand der Wildschweine zu erhalten und bietet eine wertvolle Ergänzung zu traditionellen Methoden der Krankheitsüberwachung.

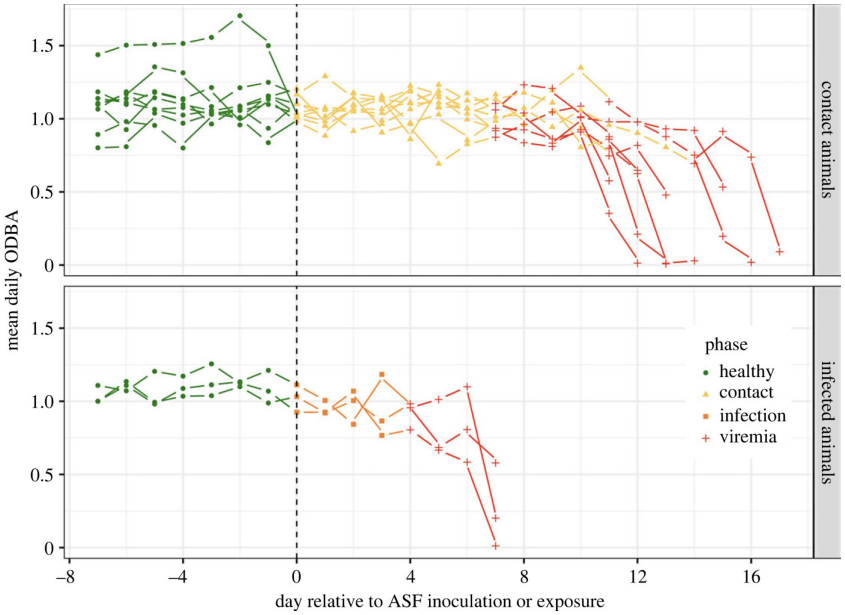

Abbildung 16: Aktivitätsverläufe von mit Krankheitserregern befallenen Wildschweinen und ihren Kontakten (nach (3))

Während diese Sensoren nahezu unsichtbar an den Tieren befestigt werden und ihre Aktivitäten in hoher Auflösung aufzeichnen, eröffnen sie neue Möglichkeiten für den Schutz der kommerziellen Tierhaltung. Das Erkennen der Krankheit in einem frühen Stadium kann zu effektiveren Maßnahmen und zur Eindämmung der Ausbreitung beitragen. Ein solcher Ansatz kann zukünftig nicht nur für die Überwachung der Afrikanischen Schweinepest, sondern auch für andere Tierkrankheiten genutzt werden.

Doch nicht nur die Tier- und Umwelt können durch eine solche kontinuierliche Überwachung von Verhaltensmessungen besser geschützt werden. Ähnlich wie wir die Bewegungsdaten der Tiere nutzen, um illegale Jagdaktivitäten aufzuspüren oder Krankheitsausbrüche zu detektieren, können wir die evolutionär geformten Sinne der Tiere nutzen, um frühzeitige Warnungen vor Umweltkatastrophen zu ermöglichen. In einer breit angelegten Studie (4) wurde entdeckt, dass Tiere wie Kühe, Schafe und Hunde, mit Beschleunigungssensoren ausgerüstet, deutliche Verhaltensänderungen zeigen können, und das bis zu 20 Stunden bevor sich ein Erdbeben ereignet. Die Intensität dieser Verhaltensänderungen scheint dabei mit der Nähe zum Epizentrum des Bebens zusammenzuhängen. Historische Berichte legen nahe, dass Tiere in der Vergangenheit bereits erfolgreich Katastrophen wie Vulkanausbrüche oder Erdbeben vorausgeahnt haben. Indem wir ICARUS Sender in Gefahrengebieten wie zum Beispiel in Erdbeben Risikogebieten auf Tieren aufbringen, können diese nun Daten sammeln, die möglicherweise ungewöhnliche Aktivitäten vor Naturereignissen aufzeichnen. Die wissenschaftliche Analyse der Zusammenhänge zwischen Umweltereignissen und Tierverhalten könnte es uns in Zukunft ermöglichen,

© Max-Planck-Institut
für Verhaltensbiologie

Tiere als lebensrettendes Frühwarnsystem zu nutzen und so dazu beitragen, Menschen rechtzeitig vor drohenden Katastrophen zu warnen.
Das ICARUS-System als vorgeschrittene Technologie im Bereich des Remote Sensing und Edge Computing (5) revolutioniert das Monitoring von Wildtieren durch hochentwickelte Tiersender die sich als Plattform begreifen, um eine Vielzahl von Sensoren und Datenverarbeitungskapazitäten integrieren (Abbildung 17). Die Sender sind bereits jetzt in der Lage, große Datenmengen zu speichern und vorzu prozessieren, was zu einer effizienteren Datennutzung und Energieeinsparung führt.

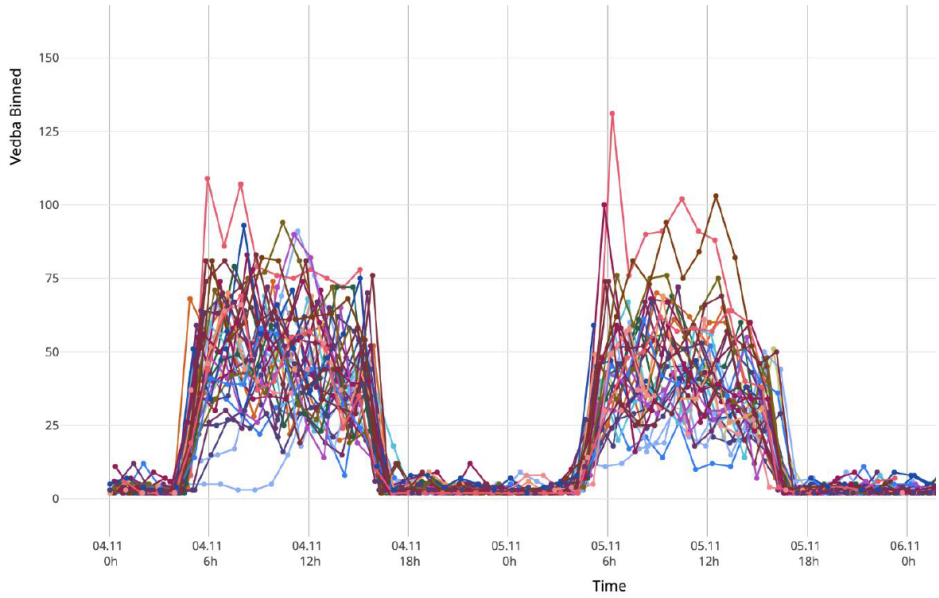

Abbildung 17: **Stündliche Aktivitätsmuster von 20 freilebenden Amseln die von einem ICARUS Tinyfox Battery Sender übertragen worden sind.**

Zudem ermöglichen sie eine Echtzeit-Überwachung und -Intervention, was besonders in schwer zugänglichen oder fernüberwachten Umgebungen von unschätzbarem Wert ist. Die Fortschritte in der miniaturisierten Sensorik und maschinellem Lernen an der Peripherie des Netzwerks erlauben es, komplexe Verhaltensmuster und Umweltinteraktionen der Tiere zu erkennen und daraus Schlüsse für den Naturschutz und die Verhaltensforschung zu ziehen die wie bereits erläutert große Implikationen für Mensch, Tier und Natur haben.

© Max-Planck-Institut
für Verhaltensbiologie

3.4.2 Kombination biologischer Daten mit ICARUS Systemdaten (AP 5200):

Abbildung 18: Ein ausgewachsenes Amselmännchen besendert mit einem ICARUS Tinyfox Battery Sender

Seit Beginn des ICARUS Projektes wurde die Amsel (*Turdus Merula*) am Max-Planck-Institut für Verhaltensbiologie als Modelspezies genutzt und ihm Rahmen der laufenden wissenschaftlichen Forschungsprojekte immer wieder mit neuen Versionen der ICARUS Sender ausgestattet (Abbildung 18). In einer detailierten Fallstudie wurden von 2018 bis 2024 Vergleichsdaten mit weiteren (zurzeit bodengestützten) Systemen (ICARUS Tinyfox Solar, ICARUS Tinyfox Battery, LoRa Solar Tags) erhoben und nun in Referenz zu klassischen ICARUS Sendern gesetzt. Insgesamt wurden in dem genannten Zeitraum 1915 Amseln besendert.

© Max-Planck-Institut
für Verhaltensbiologie

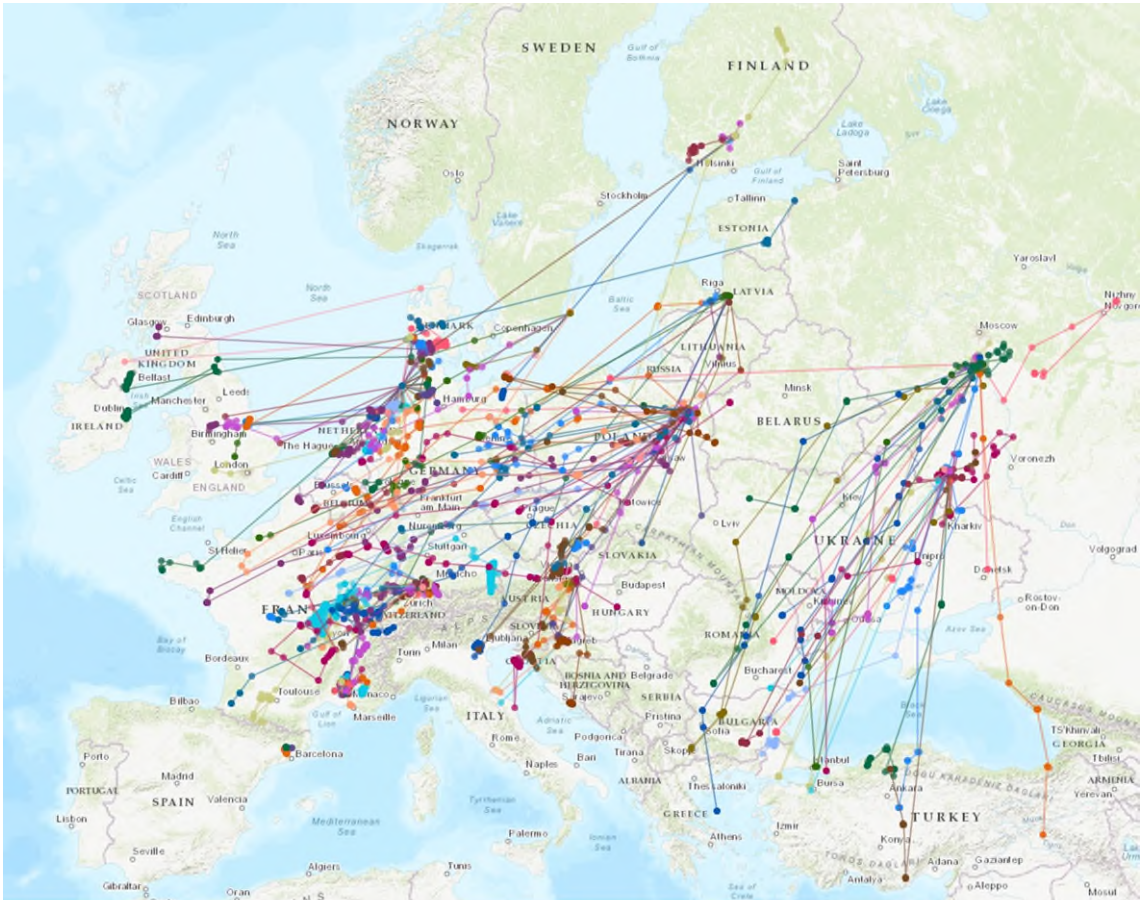

Abbildung 19: **Geographische Darstellung aller von 2020 bis 2024 aufgezeichneten Tierbewegungen von besenderten Amseln.**

Daher ist der zu den Amseln gesammelte Datensatz von 2009-2024, mit umfassenden Aufzeichnungen über die Überwinterungsstrategien verschiedener Populationen in ganz Europa, Morphologie, das Brutverhalten, Herzraten & Körpertemperatur, Bewegungs- und Aktivitätsmustern geradezu prädestiniert, um die Kapazitäten des ICARUS Systems zu evaluieren (Abbildung 19). Dieser Ansatz zielte darauf ab, ein umfassendes Bild der Interaktionen zwischen Tierverhalten und der Leistung der ICARUS-Sender zu zeichnen. Die Integration dieser Daten ermöglichte es, neue Einsichten in die ökologischen und physiologischen Aspekte der Tierbewegungen zu gewinnen und gleichzeitig die technologische Effizienz des ICARUS-Systems zu verbessern.

Hierfür wurden die bekannten biologischen Daten (6–8) mit allen dazugehörigen ICARUS Systemdaten von 2019 bis 2023 kombiniert (Abbildung 20). Systemdaten sind hierbei alles, was die technische Performance der Sender betrifft, also Batterieverläufe und Solareinträge die entscheidenden Einblicke in den Energiehaushalt der Sender liefern, ISS Übertragungsprotokolle, die zeigen welchen Datenmenge zu erwarten ist und andere Sensoren wie zum Beispiel Luftfeuchtigkeit, Luftdruck oder Magnetsensoren.

© Max-Planck-Institut
für Verhaltensbiologie

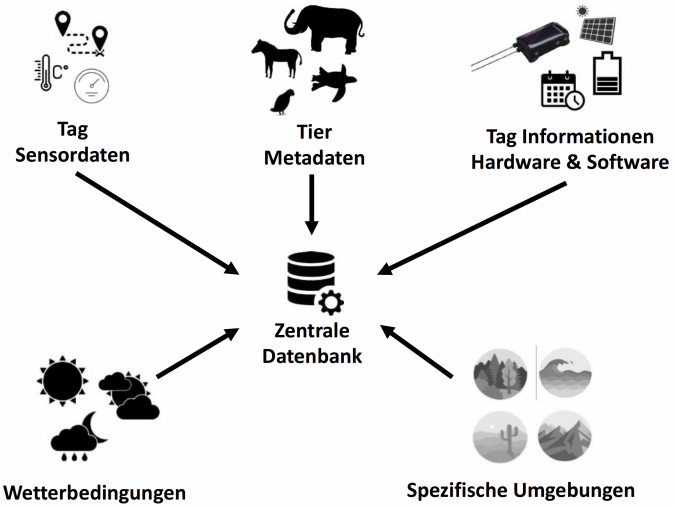

Abbildung 20: **Schematische Darstellung der Zusammenführung von Daten aus verschiedensten Quellen zur ICARUS Sender Evaluation.**

Dieser kombinierte Datensatz liefert nun wertvolle Informationen darüber wie die Umweltbedingungen, bedingt durch den Aufenthaltsort der Tiere, die ICARUS-Sender-Performance beeinflussen. Die Performance, insbesondere der Energiehaushalt und die Qualität der Datenübertragung hängt nämlich nicht nur von zahlreichen tierbiologischen Faktoren, wie die vom Tier gewählten Umgebungen (z.B. schattig im Wald oder sonnig auf einer Freifläche) sondern auch stark von abiotischen Faktoren wie dem Wetter ab.

Regnerische und schattige Tage können dazu führen, dass die vorhandenen Energiereserven nicht in ausreichender Menge durch die angebrachten Solarzellen aufgeladen werden können und so die Batterie zu Neige geht, wodurch der Sender sich ausschaltet. Beispielsweise halten sich Amseln tagsüber, wenn der größte Solareintrag zu erwarten wäre, hauptsächlich unter Büschen und Sträuchern auf, was die wirklich effektive Aufladung der Batterie auf die aktiven Morgen- und Abendstunden limitiert und so ein effektives Haushalten mit der Batteriekapazität erfordert.

Um das genutzte Mikroklima der Tiere mit ihrem generellen Umfeld zu vergleichen, wurden alle bekannten Positionsdaten innerhalb der Movebank mittels Env-Data Modul mit umfassenden Umweltdaten annotiert (Abbildung 21).

© Max-Planck-Institut
für Verhaltensbiologie

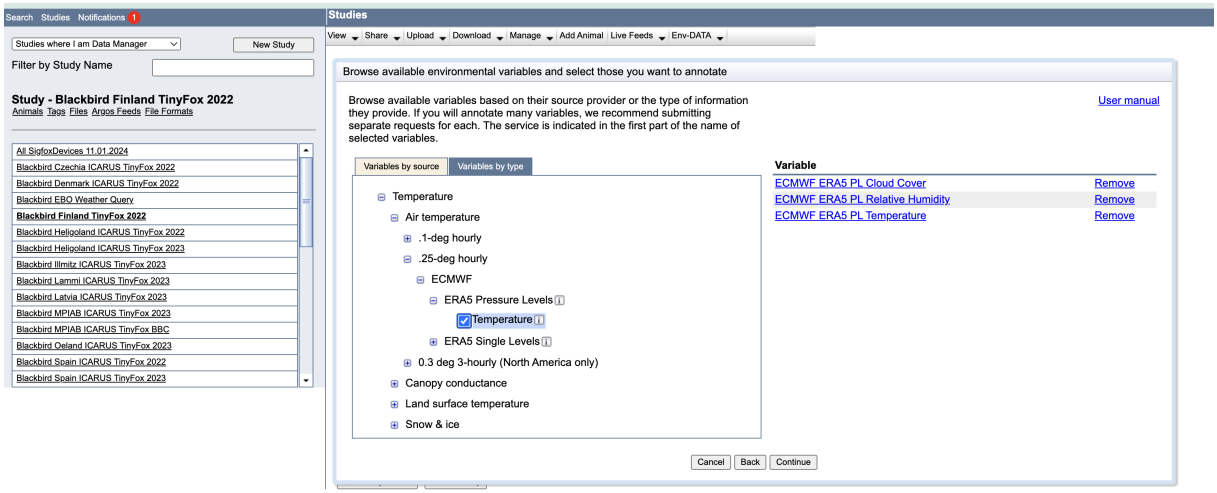

Abbildung 21: Beispielabbildung des Movebank Env-Data Moduls zum Annotieren von Bewegungsdaten mit Umweltparametern

Somit ist es möglich das Verhalten eines Tieres genaustens zu bestimmen und seine Einnischung in Mikrohabitate (9) besser verfolgen zu können.

Um die so erstellen Datensätze übersichtlich und benutzerfreundlich analysieren und für verschiedenste Benutzer zugänglich machen zu können, wurde eine Webapp als innovatives auf Live-Daten basierende Analyse-Tool entwickelt. Diese führt nicht nur die einmal etablierten Workflows des Uploads in die Movebank zum Filtern aus, sondern bereitet sie zusätzlich weiter auf, um erste Kennzahlen zur ICARUS-Sender-Performance und zum Schicksal der Tiere in Echtzeit zu geben. Eine Schlüsselkomponente war die nahtlose Integration der umfangreichen ICARUS-Datenbanken. Diese ermöglichte einen reibungslosen Datenfluss und die unmittelbare Verfügbarkeit aktualisierter Informationen. Mittels verschiedenster Filter- und Einstellungsmöglichkeiten können Wissenschaftler bei unterschiedlichsten Tierarten auf die jeweilen neuesten Daten zugreifen, welche dafür direkt aus der Movebank extrahiert werden. Die Benutzeroberfläche wurde so konzipiert, dass sie intuitiv und zugänglich für Forscher verschiedener Fachrichtungen ist, unabhängig von ihrem technischen Hintergrund. Diese umfasst interaktive Karten, die Tierbewegungen darstellen, sowie Dashboards, die kritische Datenpunkte und -trends hervorheben.

© Max-Planck-Institut
für Verhaltensbiologie

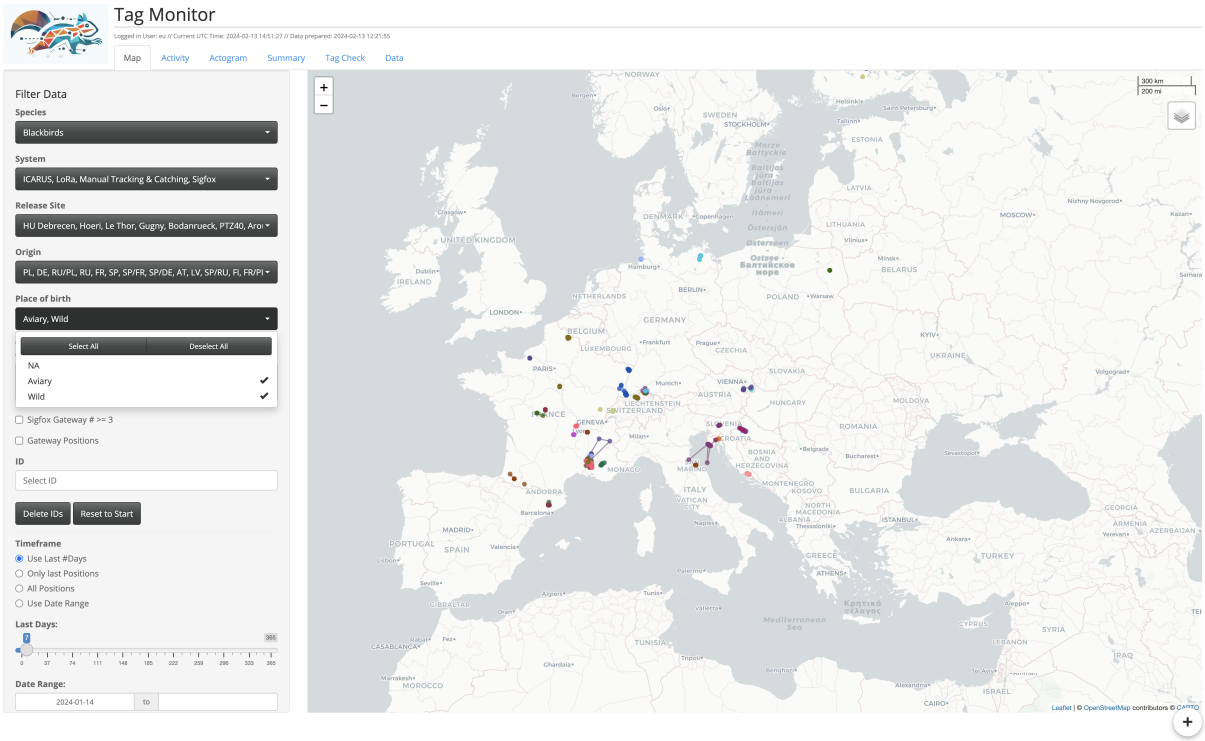

Abbildung 22: **Geografische Livedarstellung mit durch ICARUS besenderten Amseln in der Web-Applikation.**

Abgesehen von der Kartendarstellung (Abbildung 22) der individuellen Aufenthaltsorte über ganz Europa verteilt, können synchron zugehörige Aktivitätslevel dargestellt werden (Abbildung 23). So sind nicht nur Wanderungsereignisse und außergewöhnliche Aktivitäten einzelner Tiere sofort zu erkennen, sondern auch kollektives Verhalten von mehreren Individuen an einem Ort, was auf größere Vorkommnisse hindeuten kann.

© Max-Planck-Institut
für Verhaltensbiologie

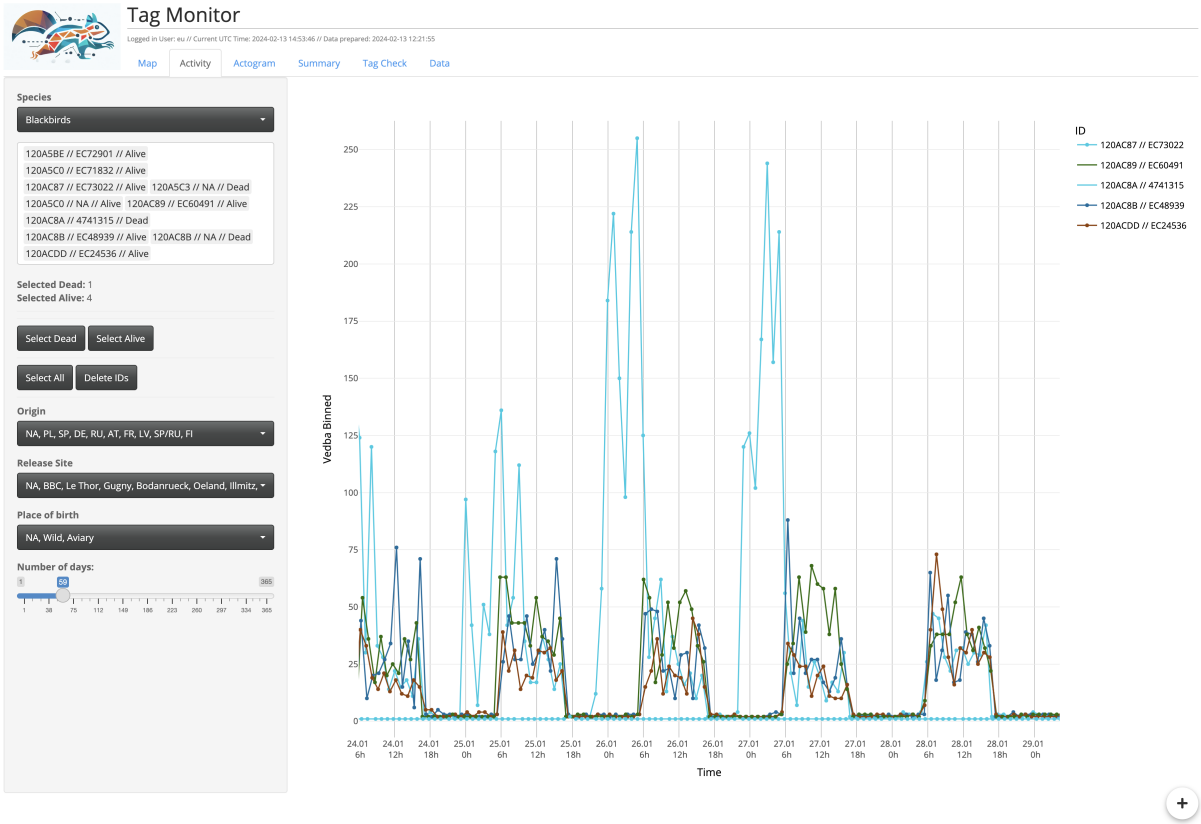

Abbildung 23: **Darstellung der Benutzeroberfläche zur Analyse der Aktivitätslevel von 5 Beispielvögeln in der Web-Applikation.**

Neben einem einfachen Zugriff auf die Rohdaten bietet die Applikation außerdem eine kompakte Zusammenfassung der Performance einzelner Tiere und ihrer Sender. Diese geht über eine Anzeige der zurückgelegten Strecke, Gesundheitszustand, letzte bekannte Position, Alter, Geschlecht, einem Indikator für größere Zugereignisse, also insgesamt biologischer Parameter hinaus und bietet zudem auch eine Zusammenfassung der technischen Performance des individuellen Tiersenders (Batteriezustand, Anzahl der gemessenen Positionen, Tag und Zeit des letzten Kontakts usw.). So ist für den Nutzer jederzeit erkennbar, wenn etwas Außergewöhnliches passiert und ein Eingreifen vor Ort erforderlich sein sollte.
Die statistischen Performance Analysen sind natürlich auch für die Weiter- und Neuentwicklung von verschiedenen Sendertypen von essentieller Bedeutung. Aus diesem Grund gibt es in der Applikation außerdem praktische Übersichten, die zur Produktionskontrolle und Übersicht genutzt werden können, um eine effektive Kommissionierung neuer Sender zu ermöglichen. Dieses Tool markiert einen Meilenstein in der Verarbeitung und Visualisierung von ICARUS-Daten und repräsentiert einen signifikanten Fortschritt in der Art und Weise, wie Forscher und Entwickler mit komplexen Datensätzen interagieren. Eine weitere Integration in das ausgezeichnete „MoveApps“ Projekt (https://www.ab.mpg.de/506555/moveapps-wins-2022-conservation-tech-award) ist weiterhin geplant und wird so eine erhebliche Beschleunigung wissenschaftlicher Arbeit ermöglichen, da Datenerhebungen und anschließende Datenanalyse Hand und Hand gehen und automatisiert ablaufen können.

© Max-Planck-Institut
für Verhaltensbiologie

Mit den gewonnenen Erkenntnissen wurden anschließend verschiedene KI-Analysen getestet und „Gradient Boosted"-Maschine Learning (ML) Modelle trainiert, um die optimalen Einstellungen zur Datenerhebung an Tier- und Habitats-Spezifika anzupassen und die zukünftige ICARUS-Sender-Performance signifikant zu erhöhen. Diese sind fortschrittliche ML-Modelle, die speziell darauf ausgelegt sind, die komplexen Wechselwirkungen innerhalb der gesammelten Daten zu entschlüsseln. Diese Modelle stellten einen Paradigmenwechsel dar, indem sie aus den großen Datenmengen nuancierte Muster extrahieren konnten, die menschlichen Analysten bisher verborgen blieben.

Eine Auslagerung der rechenintensiven Algorithmen vom Sender auf externe Quellen wie Online Applikationen vereinfacht nicht nur den Hard- und Software Aufbau, sondern ermöglicht gleichzeitig eine weitere Miniaturisierung, da verbaute Batterien kleiner werden können, sondern erlaubt zudem die Einbeziehung weiterer externer Datenquellen. Die Integration von beispielsweise aktuellen Wetterprognosen ist hierbei nur eine Anwendungsmöglichkeit von vielen auf dem Weg zu „smarten" Tiersendern.

Insgesamt haben diese Bemühungen zur erfolgreichen Integration biologischer sowie ICARUS-Systemdaten geführt, was ein umfassenderes Verständnis des Verhaltens und der Bewegungsmuster von Tieren erlaubt. Durch die Einbeziehung biologischer und historischer Daten zu den besenderten Tieren und einem stetigen Strom an „Live"-Daten, die regelmäßig in unsere Datenbanken (z.B. Movebank) gespeist werden, konnten wir mittels KI / ML Algorithmen kombiniert mit biologischem Fachverständnis, Sendereinstellungen entwickeln, die optimal an die jeweiligen Tiere und ihre Umgebung angepasst sind. Dies ermöglicht uns das Wohlergehen mit dem ICARUS System besenderter Tiere in Echtzeit zu überwachen. Die geplante Integration von Teilen dieser Arbeit in das „MoveApps"-Projekt wird zudem die wissenschaftliche Forschung und Datenanalyse erheblich vereinfachen und einer breiteren Masse zur Verfügung gestellt.

Das zukünftige „Internet of Animals" kann so von ähnlichen Ansätzen profitieren wie schon im „Internet of Things" im Smart Home Bereich etabliert. Beispielsweise kann der Nutzer Einstellung festlegen, wie konservativ die Berechnungen des Energiehaushaltes geschehen sollen und damit zwischen Langzeitprojekten und kurzen High-Resolution Datenerfassungen auf den Tieren wechseln. Solche intelligente ICARUS Sender sind klassischen Sendern deutlich voraus, da sie eine nie dagewesene Flexibilität in der der Datenerfassung und smartes „Re-scheduling" ermöglichen (Abbildung 24).

© Max-Planck-Institut
für Verhaltensbiologie

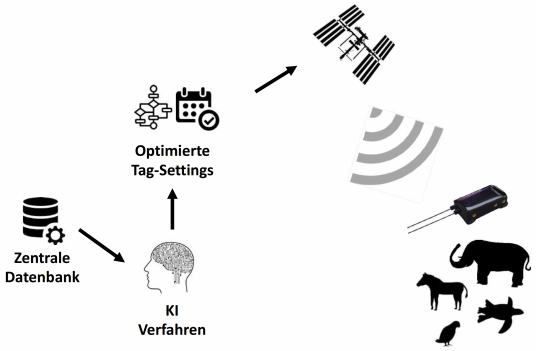

Abbildung 24: **Schematische Darstellung der Anpassung von Sendereinstellungen, die sich bereits im Feld auf Tieren befinden um die Datenerhebung zu optimieren.**

Die zukünftige Verbesserung des ICARUS-Projekts beruht auf der Verschmelzung von fortschrittlichen technologischen Lösungen und tiefgehenden biologischen Erkenntnissen. Das übergeordnete Ziel ist es, ein umfassendes Verständnis der komplexen Dynamiken innerhalb von Ökosystemen zu erwerben und dieses Wissen zum Wohle der Tierwelt, des Umweltschutzes und der Gesellschaft zu nutzen.

© Max-Planck-Institut
für Verhaltensbiologie

4 ZUSAMMENFASSUNG UND AUSBLICK

4.1 Vorkommnisse innerhalb der Projektlaufzeit

An dieser Stelle sollen die wesentlichen Vorkommnisse / Entwicklungen währen der Projektlaufzeit aufgelistet werden, welchen einen maßgeblichen Einfluss auf den Projektplan und Ergebnissen hatte.

- Kostenneutrale Laufzeitverlängerung aufgrund von Personalmangel auf Seite des Unterauftragnehmers HTWK Leipzig. Das Projekt wurde kostenneutral verlängert und endete zum 31.12.2023.

4.2 Notwendigkeit und Angemessenheit der geleisteten Arbeit

Für die grundlegenden Arbeiten im Rahmen bzw. Umfeld von ICARUS stellte das MPI-AB bisher große Mengen von Eigenmitteln zur Verfügung. Zusätzlich benötigte technische Arbeiten, wie in den Aufgaben dieses Vorhabens beschrieben, können jedoch nicht aus Eigenmitteln des MPI-AB finanziert werden, da hier keine Grundlagenforschung im Sinne der Max-Planck-Gesellschaft (MPG) betrieben wird, sondern technische Entwicklungen notwendig sind.

Die Zuwendung ermöglichte die Untersuchung und Entwicklung von essentiell wichtigen KI Technologien, deren Einsatz den Aufbau einer bisher nicht erreichbaren globalen Wissensbasis von wandernden Tieren, deren Verhalten und Interaktion mit anderen Lebewesen ermöglicht. Die weitreichenden Zielsetzungen wären ohne die Zuwendung nicht erreichbar gewesen. Durch die Zuwendung wurde die Entwicklung der genannten Themen so weit beschleunigt, dass belastbare detaillierte Ergebnisse am Ende des Untersuchungszeitraumes vorliegen und in die zukünftige wissenschaftliche Arbeit einfließen können.

Die technische und programmatische Komplexität der im Rahmen des Vorhabens zu bearbeitenden Aufgaben stellten MPI-AB vor große Herausforderungen. Das für die Umsetzung notwendige technische Fachpersonal war bei MPI-AB als Forschungseinrichtung nicht vorhanden und sollte im Rahmen der wissenschaftlichen Zielsetzung des Instituts und der Max-Planck-Gesellschaft auch dort nicht aufgebaut werden. Deshalb mussten die Arbeiten mit dafür geeigneten Ressourcen im Unterauftrag von industriellen Unterauftragnehmer durchgeführt werden.

Unsere gesamte Abteilung am MPI-AB war und ist für die wissenschaftliche Unterstützung des ICARUS Systems zuständig und bereit. Für die technischen Aspekte des ICARUS Bodensegments benötigten wir jedoch weitere Finanzmittel.

© Max-Planck-Institut
für Verhaltensbiologie

5 NUTZEN UND VERWERTBARKEIT DER ERGEBNISSE, ERFOLGSKONTROLLBERICHT

5.1 Wirtschaftliche Erfolgsaussichten mit Zeithorizont

Im Rahmen der Zuwendung wurde der Nachweis erbracht, dass die Ortungsgenauigkeit durch den Einsatz von komplexer Signalverarbeitung und Verfahren des maschinellen Lernens (und auch KI) erhöht werden kann. Eine Vereinfachung bzw. Verkleinerung der Tags erscheint ebenfalls möglich.

Das Ergebnis der Zuwendung ist geeignet

- die Basis für nationale sowie internationale Wissenschaftskooperationen für satellitengestützte Anwendungen auch über eine ICARUS-Anwendung hinaus unter deutscher Führung zu schaffen,
- den Zugang zu strategischen Schlüsseltechnologien im Bereich IoT in Deutschland zu sichern und die Nutzung für verschiedene Anwendergruppen zu ermöglichen.
- Auf wissenschaftlicher Ebene wird ein Zeithorizont von min. 2-4 Jahren für die stabile Etablierung von Kooperationen als erforderlich eingeschätzt. Auf der Basis der Technologieentwicklung dieses Vorhabens und ihrer Umsetzung in einer wissenschaftlichen Mission im Zeitraum der nächsten Jahre können die Voraussetzungen für spätere Verwertungen in nationalen wie internationalen Missionen geschaffen werden.
- Mit den durch die Durchführung des Vorhabens gewonnenen Erkenntnissen ergibt sich ein Wettbewerbsvorteil für die beteiligten Institute und Firmen.
- Die Forschungs- und Entwicklungskompetenz des Instituts und der Firmen wird ausgebaut und gestärkt und somit die technische Konkurrenzfähigkeit gesteigert.

Eine konkrete, direkte kommerzielle Verwertung der durch ICARUS-KI bereitgestellten Ortungsverfahren ist in einem Zeithorizont von 2-4 Jahren möglich.

Zusammen mit dem Vorgängervorhaben - Entwicklung, Bau und Start der ICARUS-Nutzlast - wurde in diesem Vorhaben die technischen Voraussetzung für Algorithmen geschaffen, die ab Sommer 2025 auf einem Kleinsatelliten erprobt werden.

5.2 Die wissenschaftlich-technischen Ergebnisse des Vorhabens

Die für den Test der neuartigen ICARUS-Ortung gesteckten technischen Ziele wurden erfüllt. Weitere wichtige Aspekte waren:

- Ortungsverfahren von Tags, die mit Hilfe von Verfahren des maschinellen Lernens implementiert werden, sind analytischen Ortungsverfahren nicht überlegen bzw. ersetzen diese nicht.
- Die ICARUS Ortungsgenauigkeit ist vor allem von der Genauigkeit der Doppler-Schätzung abhängig. Diese wurde gegenüber dem Implementierungsstand auf der Internationalen Raumstation durch eine komplexere Algorithmik signifikant verbessert. Die nun erzielbaren Ortungsergebnisse durch die Doppler-Messung von Tag Uplink-Signalen erzielt dementsprechend eine zufriedenstellende Genauigkeit.

© Max-Planck-Institut
für Verhaltensbiologie

- Die durch Doppler-Ortung erzielbare Ortungsgenauigkeit beläuft sich auf einen Bereich von einigen hundert Metern bis zu einigen wenigen Kilometern.
- Es konnte gezeigt werden, dass die Ortungsgenauigkeit der untersuchten Doppler-Ortung von der Elevation der Satellitenüberflugtrajektorie abhängt. Eine günstige maximale Elevation, die die mittlere Ortungsgenauigkeit maximiert, liegt im Bereich zwischen 60° – 80°.

5.3 Wissenschaftliche und wirtschaftliche Anschlussfähigkeit

Die gewonnenen technologischen Erkenntnisse können für zukünftige Entwicklungen für Weltraumprogramme eingesetzt werden und setzen die Basis für eine Gewichtsreduktion der Tags.

Es ergeben sich mögliche nationale wie internationale Folgeprojekte, die auf den aus dem Vorhaben gewonnenen Erkenntnissen aufbauen.

Neben den Verfahren, die im Rahmen dieses Vorhabens entwickelt und umgesetzt wurden, gibt es weitere vielversprechende Forschungsergebnisse und Entwicklungen von Technologien, die eingesetzt werden können, z.B. im Bereich von:

- Der Nutzung mehrerer Satelliten zur Verbesserung der Ortungsgenauigkeit
- Einer prototypischen Entwicklung zur Auflösung der ‚Links-Rechts' Unsicherheit der Ortung, gemessen an der Überflugslinie über Grund.
- Künftiger schmalbandiger Doppler-Ortungsverfahren
- Zukünftiger Anwendungen im Bereich der satellitengestützten IoT Funkübertragung

Nach dem erfolgreichen Abschluss des Vorhabens kann nun das aktuelle Forschungsfeld auf die Entwicklung neuartiger Doppler-Tags ausgerichtet werden.

5.4 Verwertbarkeit der Ergebnisse

Die im Vorhaben erarbeiteten Ergebnisse bereiten den Weg für die zukünftige technische Entwicklungen und reichen von kostengünstigen, automatisierten bis hin zu autonomen Tierbeobachtungsdiensten für ein globales Netzwerksystem. Ebenso sind die Ergebnisse nutzbar zum Aufbau eines wissenschaftlich / kommerziellen weltraumbasierten IoT Service, der vielfältige Anwendungen in Gebieten erlaubt, die nicht von terrestrischen Funknetzen abgedeckt werden können.

5.5 Arbeiten, die zu keiner Lösung geführt haben

Sämtliche in diesem Vorhaben durchgeführte Arbeiten führten den ursprünglichen Anforderungen entsprechend, zu einem zufriedenstellenden Ergebnis. Die Ergebnisse der weltraumgestützten Objektortung bieten nicht die gewünschten Ortungsgenauigkeiten, können aber durch die Nutzung der vorgestellten verbesserten Dopplerfrequenzschätzverfahren entsprechend ertüchtigt werden.

© Max-Planck-Institut
für Verhaltensbiologie

5.6 Publikationen

Nachfolgend ein Auszug wissenschaftlicher Publikationen, die im Zuwendungszeitraum 2022 – 2023 im Zusammenhang mit diesem ICARUS Vorhaben veröffentlicht wurden:

1. Jetz W, Tertitski G, Kays R, Mueller U, Wikelski M, Åkesson S, et al. Biological Earth observation with animal sensors. Trends in Ecology & Evolution. 2022 Apr 1;37(4):293–8.

2. de Knegt HJ, Eikelboom JAJ, van Langevelde F, Spruyt WF, Prins HHT. Timely poacher detection and localization using sentinel animal movement. Sci Rep. 2021 Feb 25;11(1):4596.

3. Morelle K, Barasona JA, Bosch J, Heine G, Daim A, Arnold J, et al. Accelerometer-based detection of African swine fever infection in wild boar. Proceedings of the Royal Society B: Biological Sciences. 2023 Aug 30;290(2005):20231396.

4. Wikelski M, Mueller U, Scocco P, Catorci A, Desinov LV, Belyaev MY, et al. Potential short-term earthquake forecasting by farm animal monitoring. Ethology. 2020;126(9):931–41.

5. Yu H, Amador GJ, Cribellier A, Klaassen M, de Knegt HJ, Naguib M, et al. Edge computing in wildlife behavior and ecology. Trends in Ecology & Evolution. 2024 Feb 1;39(2):128–30.

6. Fudickar AM, Schmidt A, Hau M, Quetting M, Partecke J. Female-biased obligate strategies in a partially migratory population. Journal of Animal Ecology. 2013;82(4):863–71.

7. Zúñiga D, Gager Y, Kokko H, Fudickar AM, Schmidt A, Naef-Daenzer B, et al. Migration confers winter survival benefits in a partially migratory songbird. eLife. 2017;6:e28123.

8. Linek N, Brzęk P, Gienapp P, O'Mara MT, Pokrovsky I, Schmidt A, et al. A partial migrant relies upon a range-wide cue set but uses population-specific weighting for migratory timing. Movement Ecology. 2021 Dec 1;9(1):1–14.

9. Paillet Y, Archaux F, du Puy S, Bouget C, Boulanger V, Debaive N, et al. The indicator side of tree microhabitats: A multi-taxon approach based on bats, birds and saproxylic beetles. Journal of Applied Ecology. 2018;55(5):2147–59.

10. Krondorf, Liang, Knopp (2023). Initial Synchronization Procedure and Doppler Pre-Compensation for LEO-SATCOM Terminals. Under Review*: Wiley International Journal of Satellite Communications and Networking*.

5.7 Einhalten der Ausgaben- und Zeitplanung

Die geleistete Arbeit war innerhalb des vorgegebenen Zeit- und Finanzbudgets angemessen.

5.8 Fortschritt auf dem Gebiet des Vorhabens bei anderen Stellen

Aktuell sind uns keine Ergebnisse von anderen Stellen bekannt. Es gibt keine neuen Erkenntnisse über FE-Arbeiten Dritter, die konkrete Relevanz für dieses Vorhaben haben. Es gibt keine Erfindungen / Schutzanmeldungen oder erteilte Schutzrechte von am Auftrag Beteiligten.

© Max-Planck-Institut
für Verhaltensbiologie

Icarus KI Abschlussbericht

AUFTRAGGEBER: MAX-PLANCK-GESELLSCHAFT ZUR FÖRDERUNG DER WISSENSCHAFTEN E.V.

UNTERAUFTRAGNEHMER: UNIVERSITÄT DER BUNDESWEHR MÜNCHEN – INSTITUT FÜR TECHNIK INTELLIGENTER SYSTEME (ITIS GMBH)

Created: Daniel Weinzierl, daniel.weinzierl@unibw.de
Approved: Prof. Andreas Knopp, andreas.knopp@unibw.de
University of the Bundeswehr Munich Institute of Information Technology

Inhalt

1. Einleitung 2
2. Machine Learning Frameworks 3
3. Hardware and Processing Capabilities 4
4. Interferenzmustererkennung und Interferenzmitigation 5
   4.1. Aktueller Stand der Technik 6
   4.2. Interferenzmitigation Beamforming 13
   4.3. Struktur Neuronales Netzwerk 14
   4.4. Komplexitätsanalysis 17
   4.5. Perfomanceanalyse 18
5. Ausblick 19
Referenzen 20

1. Einleitung

Dieser Bericht fasst die wissenschaftlichen Ergebnisse zusammen, die im Rahmen des ICARUS KI Projektes an der Universität der Bundeswehr München erzielt wurden. Die Universität der Bundeswehr München (über die ITIS GmbH) agierte als Unterauftragnehmer und war für die folgenden Arbeitspakete verantwortlich:

- WP2100 Definition und Entwicklung der Systemarchitektur
- WP2200 Interferenzmustererkennung

Der erste Teil des Berichts fokussiert sich auf die erforderliche Software-Infrastruktur, die zur Durchführung von Ortung basierend auf Künstlicher Intelligenz (KI) notwendig ist. Da verschiedene KI-Modelle untersucht werden sollen, muss das System in der Lage sein, verschiedene Arten der KI-Modellimplementierung zu berücksichtigen. Im ersten Schritt muss ein geeignetes KI-Entwicklungsframework ausgewählt werden. Hierzu gibt es eine große Auswahl populärer Frameworks unter der Open-Source-Lizenz. Die beiden am weitesten verbreiteten Framework sind TensorFlow (von Google) und PyTorch (von Facebook), weshalb wir uns hauptsächlich auf diese konzentrieren werden. Da diese jedoch unterschiedliche Eigenschaften haben, z.B. in Bezug auf die Einfachheit der Implementierung, die Verfügbarkeit von visuellen Benutzerschnittstellen und die Ausführungsgeschwindigkeit, werden die Vor- und Nachteile analysiert und letztlich ein Framework ausgewählt. Anschließend wird die für das Projekt am besten geeignete KI-Bibliothek (z.B. Keras) ausgewählt. Diese Bibliothek ermöglicht uns relevante KI-Modelle und Optimierungsalgorithmen effizient zu implementieren. Darauf aufbauend werden die Anforderungen an das System in Bezug auf die Hardware-Ressourcen formuliert. Hinsichtlich der Verarbeitungsleistung gibt es mehrere Lösungen. Architekturen können, abhängig von den Rechenanforderungen des Projekts, auf Graphical Processing Units (GPUs) oder Tensor Processing Units (TPUs) basieren. Daher besteht der nächste Schritt darin, den Rechenbedarf entsprechend der geschätzten Menge der zu verarbeitenden Trainingsdaten und der erwarteten Komplexität des/der zu implementierenden KI-Modelle(s) zu ermitteln. Hierbei muss beachtet werden, dass die Trainingsphase am rechenintensivsten ist. Die Analyse vorab soll zu einer idealen Auswahl von Modellen und zu berücksichtigenden Verarbeitungseinheiten führen. Neben diesen Überlegungen besteht die zu untersuchende Option der Verwendung von KI-Servern für das Training des KI-Modells. Dies kann potenziell bessere und kostengünstigere KI-Modelle ermöglichen. In diesem Fall kann die aktuelle Systemarchitektur für die Ausführung des Modells verwendet werden (weniger rechenintensiv).

Der zweite Teil des Berichts befasst sich mit der Interferenzmustererkennung und Mitigation. Nach der Bestimmung eines geeigneten Modells werden die Hyperparameter (Lernrate etc.) gegen die Trainingsdaten optimiert. Besonders relevant hierbei ist die Auswahl der Datensätze welche ausreichend groß und repräsentativ für reale Signale sein müssen, um ein möglichst robustes KI-Modell zu erhalten. Um ein Gefühl dafür zu bekommen, wie viele Schichten und welche Topologie am besten sind, sind folgende Schritte hilfreich:

- *Untersuchung der Dimensionalität der Eingabedaten: Ist eine Merkmalsextraktion möglich, die die Dimensionalität der Rohdaten reduziert?*
- *Datenbereinigung: Ist eine Interpolation, Extrapolation oder Filterung erforderlich?*

Die Erstellung von Bildern, die Verwendung von Zeitreihendaten oder eine andere Art der Zuordnung kann dazu beitragen, ein tieferes Verständnis der zugrundeliegenden Daten zu erhalten. Abhängig von den Eingabedaten, haben verschiedene Netzwerktopologien ihre Vorteile, aber die Komplexität muss ebenfalls berücksichtigt werden. Die Interpretierbarkeit ist

ein wichtiger Punkt, der unterschätzt wird, wenn es um reale Anwendungen geht. Die Flexibilität und die Möglichkeit einer Online-Erweiterung sind unerlässlich, um ein nahtloses Betriebssystem zu gewährleisten, das sich in Echtzeit aktualisiert. Je nach Ergebnis der KI-Modellleistung kann eine Vorverarbeitung der Daten erforderlich sein. Die Komplexitätsanalyse stellt die benötigten Rechenleistung des neuronalen Netzwerkes in Verbindung mit herkömmlichen Methoden und zeigt am Ende den Performance Vergleich der verschiedenen Ansätze.

2. Machine Learning Frameworks

Im folgenden werden kurz die zwei relevanten Frameworks für Machine Learning vorgestellt und erläutert, dies dient als Entscheidungsgrundlage, welches System sich für Icarus-Anwendung besser eignet.
a) Pytorch: Ein vergleichsweise neues Open-Source-Framework, das auf Torch basiert. Es wurde im Jahr 2017 von der AI-Forschungsgruppe von Facebook entwickelt. Pytorch zeichnet sich durch seine Einfachheit, Benutzerfreundlichkeit, Flexibilität, effiziente Speichernutzung und dynamische Berechnungsgraphen aus.

b) TensorFlow: Ein End-to-End-Open-Source-Framework, das von Google entwickelt und 2015 veröffentlicht wurde. TensorFlow bietet ein flexibles, umfassendes Ökosystem von Community-Ressourcen, Bibliotheken und Werkzeugen.

c) Pytorch vs. TensorFlow: Pytorch verwendet einen Ansatz, der dem klassischen Programmieren in Python ähnlicher ist. Aufgrund seiner Flexibilität, Debugging-Fähigkeiten und kurzen Trainingsdauer ist Pytorch bei Forschern sehr beliebt. TensorFlow hingegen erfreut sich in der Industrie großer Beliebtheit aufgrund seiner besseren Visualisierung und der Vielfalt an trainierten Modellen und Tutorials.

Pytorch führt von Natur aus eine optimale Datenparallelität durch, da es die native Unterstützung für asynchrone Ausführung in Python bietet. TensorFlow hingegen erfordert manuelle Kodierung, um eine vergleichbare Optimierung in diesem Bereich zu erreichen.

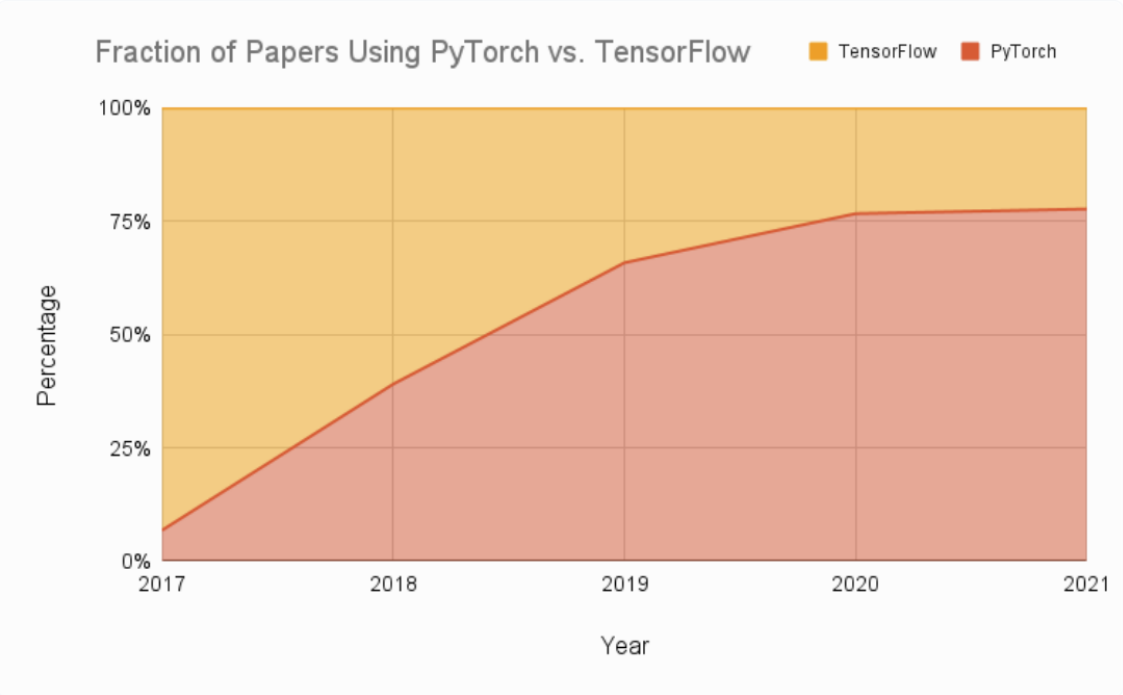

Abbildung 1: PyTorch vs. Tensorflow (O'Connor, 2021)

3. Hardware and Processing Capabilities

Model	418G-X11 (lambdalabs)
Motherboard	X11DPG-OT-CPU
Operating system	Ubuntu 20.04 + Lambda Stack
Software	TensorFlow, PyTorch, Caffe, Keras, CUDA, cuDNN
Processor	2x Intel Xeon Gold 5220R: 24 cores, 2.20 GHz, 35.75 MB cache
GPUs	EDU - 8x RTX 5000 + NVLink
Memory	768 GB
Operating system drive	3.84 TB SSD (SATA)
Extra Storage	3.84 TB SSD (SATA)

Tabelle 1: Hardware Konfiguration

Wie in der Einleitung erwähnt bringt die Verwendung einer dedizierten Recheneinheit für neuronale Netzwerke die Vorteile der Parallelisierung und der effizienteren Berechnung. Hierfür kann der KI-Server der UniBw genutzt werden der kurz vorgestellt wird. Die Grafikkarte hat eine FP16 Leistung von 32,62 TFLOPS. Die endgültige Leistung ist jedoch aufgrund multifaktorieller Abhängigkeiten von Batch-Größe, neuraler Netzwerkstruktur, Datenladestruktur usw. sehr schwer vorherzusagen, eine detaillierte Darstellung die verwendeten neuronalen Netze folgt im Kapitel „Struktur Neuronales Netzwerk“. Das Bussystem, Nvidia Link, kann etwa 100 Gbit/s bereitstellen. Die CPU-Speicherbandbreite beträgt 128 GB/s. Der Engpass hängt von der Größe des Trainingsdatensatzes, der Eingabegröße und der Größe des neuronalen Netzwerks ab. Bei einem großen Trainingsdatensatz mit kleiner Eingabegröße und einem kleinen neuronalen Netzwerk besteht die Herausforderung darin, die Daten zur GPU zu bringen. Bei großen Eingabegrößen und neuronalen Netzwerken ist die GPU, die GPU/CPU-Schnittstelle und die GPU/CPU-Kapazität

der limitierende Faktor. Es ist nicht möglich im Voraus zu entscheiden, welche Architektur in welcher Größe optimal ist. Dies kann nur durch die Verwendung unterschiedlicher Topologien und deren Optimierung hinsichtlich ihrer Parameter erfolgen. Die Schlüsselherausforderung besteht darin, ausreichende Genauigkeit zu erzielen, während das Netzwerk effizient bleibt. Die Verwendung paralleler Datenlader und die Ausnutzung von Daten-Echoing können wichtige Werkzeuge sein, um den Lernprozess zu optimieren.

4. Interferenzmustererkennung und Interferenzmitigation

In den letzten Jahren haben Neuronale Netzwerke aufgrund ihrer Fähigkeit, automatisch Merkmale zu extrahieren und komplexe Beziehungen zu erlernen, erhebliche Fortschritte bei der Interferenzmustererkennung ermöglicht (Ajib, 2020).

Beim Supervised Lernen werden Neuronale Netzwerke mit annotierten Trainingsdaten trainiert, bei denen jedem Eingabemuster ein entsprechendes Ausgabemuster (Label) zugeordnet ist. Im Kontext der Interferenzmustererkennung bedeutet dies, dass die Netzwerke mit bekannten Interferenzmustern trainiert werden. Das neuronale Netzwerk lernt, charakteristische Merkmale aus den Trainingsdaten zu extrahieren und diese Muster den entsprechenden Klassen zuzuordnen. Bei der Klassifizierung neuer, unbekannter Interferenzmuster kann das trainierte Netzwerk dann deren Klasse vorhersagen (Green, 2019).

Im Semi-Supervised Lernen werden Neuronale Netzwerke mit einem Teil der Daten, die Labels enthalten, und einem Teil der Daten, die ungelabelt sind, trainiert. Der Vorteil dieses Ansatzes liegt darin, dass oft leichter verfügbare ungelabelte Daten genutzt werden können, was die Datensammelkosten reduziert. Im Kontext der Interferenzmustererkennung könnte ein neuronales Netzwerk beispielsweise mit einer begrenzten Anzahl von gelabelten Interferenzmustern trainiert werden und danach weitere, ungelabelte Muster hinzugefügt werden, um die Klassifizierungsleistung zu verbessern. (Hong, 2018)

Beim Unsupervised Lernen werden Neuronale Netzwerke ohne vorgegebene Labels trainiert. Das Netzwerk lernt autonom, Strukturen und Muster in den Daten zu entdecken, ohne dass ihm eine Zuordnung zu einer bestimmten Klasse bekannt ist. Im Kontext der Interferenzmustererkennung könnte ein neuronales Netzwerk eingesetzt werden, um ungelabelte Interferenzmuster zu analysieren und automatisch gemeinsame Merkmale und ähnliche Strukturen zu erkennen. Dies könnte zur Identifizierung bisher unbekannter Interferenzquellen oder zur Kategorisierung ähnlicher Muster verwendet werden.

Im folgenden wird untersucht wie Unsupervised Lernen dazu verwendet werden kann Interferenzen zu erkennen und zu kategorisieren. Hierbei erscheint die Annahme, dass das Label unbekannt ist, als das realistische Szenario. Neuronale Netzwerke können genutzt werden, um Interferenzen zu identifizieren und zu kategorisieren. Darüber hinaus wird die Konstruktion der Loss-Funktion, die für den Erfolg dieses Ansatzes entscheidend ist, beschrieben.

Die Loss-Funktion des Neuronalen Netzwerkes ist entscheidend für das Lernen einer effektiven Merkmalsrepräsentation. Im Fall der Interferenzerkennung wird die Loss-Funktion so konstruiert, dass sie den Unterschied zwischen den Eingangssignalen und den rekonstruierten Signalen quantifiziert.

4.1. Aktueller Stand der Technik

Im Folgenden soll eine kurze Einführung in mögliche Anwendungen des maschinellen Lernens im Bereich der RF-Signale gegeben werden.

4.1.1. Modulation

Die Erkennung von Sendern ist entscheidend, um Interferenzen zu vermeiden und die Spektrumzuweisung zu optimieren. Jedes Modulationsschema hat unterschiedliche Anforderungen, daher ist es wichtig, das empfangene Signal korrekt zu analysieren. Dieses Problem wird auch als N-Problem Entscheidungsproblem bezeichnet. Die komplexe Darstellung, bekannt als IQ-Signal, dient als Eingabe. Die N verschiedenen Entscheidungsmöglichkeiten repräsentieren die N-Modulationsschemata.

Eine analytische und fortschrittliche Technik zur Modulationserkennung ist das sogenannte "Cyclic-Moment Features", das auf einer Reihe von verschiedenen m-ten statistischen Ordnungen basiert. Die Entscheidung erfolgt expertenbasiert. (O'Shea, 2016)

Ein anderer Ansatz ist die Verwendung von DNN (Deep Neural Networks), um die Modulationsschemata vorherzusagen. Zum Beispiel haben CNNs (Convolutional Neural Networks) bereits in der Bilderkennung beeindruckende Ergebnisse gezeigt. O'Shea hat auch eine hohe Leistung bei RF-Signalen gezeigt, wo er 11 Modulationen (8 digital, 3 analog) mit einer Gesamtgenauigkeit von etwa 87% über ein SNR von -20 dB bis 20 dB klassifizierte. Der Datensatz wurde durch einen Prozess mit einem residuellen Träger-Random-Walk generiert, der einen residuellen Taktoszillator-Random-Walk und eine nichtkonstante Kanalimpulsantwort mit Gaussischem Rauschen kombinierte. (O'Shea, 2016)

Bisher wurde davon ausgegangen, dass das Modulationsschema bereits in den Trainingsdaten verfügbar ist. Das Ziel in diesem Teil besteht darin zu zeigen, wie neue Modulationsschemata spontan erlernt werden können. Das Problem besteht darin, dass, wenn das Netzwerk mit den neuen Datenmustern trainiert wird, die alten Schemata in der Genauigkeit erheblich abfallen können, dies wird als katastrophales Vergessen bezeichnet. Um dieses Problem zu vermeiden, wird als Verlustfunktion Elastic Weight Consolidation (EWC) verwendet. Es erinnert sich an zuvor trainierte Gewichte und berücksichtigt die Ähnlichkeit zu den zuvor trainierten Aufgaben. (Yi Shi and Kemal Davaslioglu, 2019)

4.1.2. Erkennung von drahtloser Technologie-Interferenz (Klassifikation)

Ähnliche, aber noch bessere Ergebnisse könnten erzielt werden, wenn es darum geht, Interferenzen zu erkennen. Ein Vergleich zwischen Modulationserkennung und Interferenzerkennung findet sich in Tabelle 1. (M. Kulin, 2018)

Die Interferenz wird als ein koexistierender Sender modelliert, der im selben Frequenzband arbeitet. Der Datensatz "Wireless Interference" (Meier, 2017) wurde verwendet, weitere Details dazu finden sich im entsprechenden Datensatz.

Case	Model	SNR	$\mathbf{P}_{avg}$	$\mathbf{R}_{avg}$	F_1 $\mathbf{score}_{avg}$
Mod. recognition	CNN^{M}_{IQ}	High	0.83	0.82	0.79
		Medium	0.75	0.75	0.72
		Low	0.36	0.32	0.30
	$\mathrm{CNN}^{M}_{A/\phi}$	High	0.86	0.84	0.82
		Medium	0.70	0.70	0.69
		Low	0.33	0.29	0.26
	$\mathrm{CNN}^{M}_{\mathcal{F}}$	High	0.71	0.68	0.67
		Medium	0.63	0.6	0.59
		Low	0.28	0.25	0.22
IF identification	CNN^{IF}_{IQ}	High	0.98	0.98	0.98
		Medium	0.95	0.94	0.94
		Low	0.84	0.82	0.81
	$\mathrm{CNN}^{IF}_{A/\phi}$	High	0.99	0.99	0.99
		Medium	0.98	0.98	0.98
		Low	0.87	0.86	0.86
	$\mathrm{CNN}^{IF}_{\mathcal{F}}$	High	0.99	0.99	0.99
		Medium	0.99	0.99	0.99
		Low	0.90	0.89	0.89

Tabelle 2 Leistungsvergleich für trainierten CNN-Klassifikator für drei SNR-Szenarien. (M. Kulin, 2018)

Eine andere Arbeit hat eine Genauigkeit bei der Erkennung von Interferenzen zwischen LTE und Wi-Fi von 99% gezeigt. (DAMILOLA ADESINA)

4.1.3. Autoencoder Interferenzerkennung (Klassifikation)

Die grundlegende Idee besteht darin, dass der Autoencoder versucht, das Original-Eingangssignal zu rekonstruieren. Dadurch weisen Eingabe- und Ausgabesignale ähnliche statistische Eigenschaften auf. Wenn zusätzliche Interferenzen vorhanden sind, würde sich die Statistik zwischen Eingabe und Ausgabe ändern, da der Autoencoder auf reinen Signalen trainiert wurde. Um den Unterschied zwischen Eingabe und Ausgabe zu quantifizieren, wird die Summe des mittleren quadratischen Fehlers (Mean Squared Error, MSE) zwischen den Mustern berechnet.

Die Bewertungsmethoden setzen sich aus verschiedenen Merkmalen des resultierenden Fehlers zusammen. Dazu gehören die Summe der normalisierten Momentabweichung (S1) und der Pearson-Produkt-Moment-Korrelationskoeffizient (S2) zwischen der MSE-Wahrscheinlichkeitsdichtefunktion (PDF) mit und ohne Interferenzen. In der vorliegenden Abbildung sind die statistischen Eigenschaften des MSE für verschiedene Interferenzsignale dargestellt.

Die erreichte Leistung für wahre positive Ergebnisse, also die korrekte Erkennung von Interferenzen, beträgt 81 %. Die verbleibenden 19 % werden durch falsch positive Ergebnisse verursacht, bei denen fälschlicherweise Interferenzen erkannt werden, obwohl sie nicht vorhanden sind. (Miguel Ángel Vázquez, 2021)

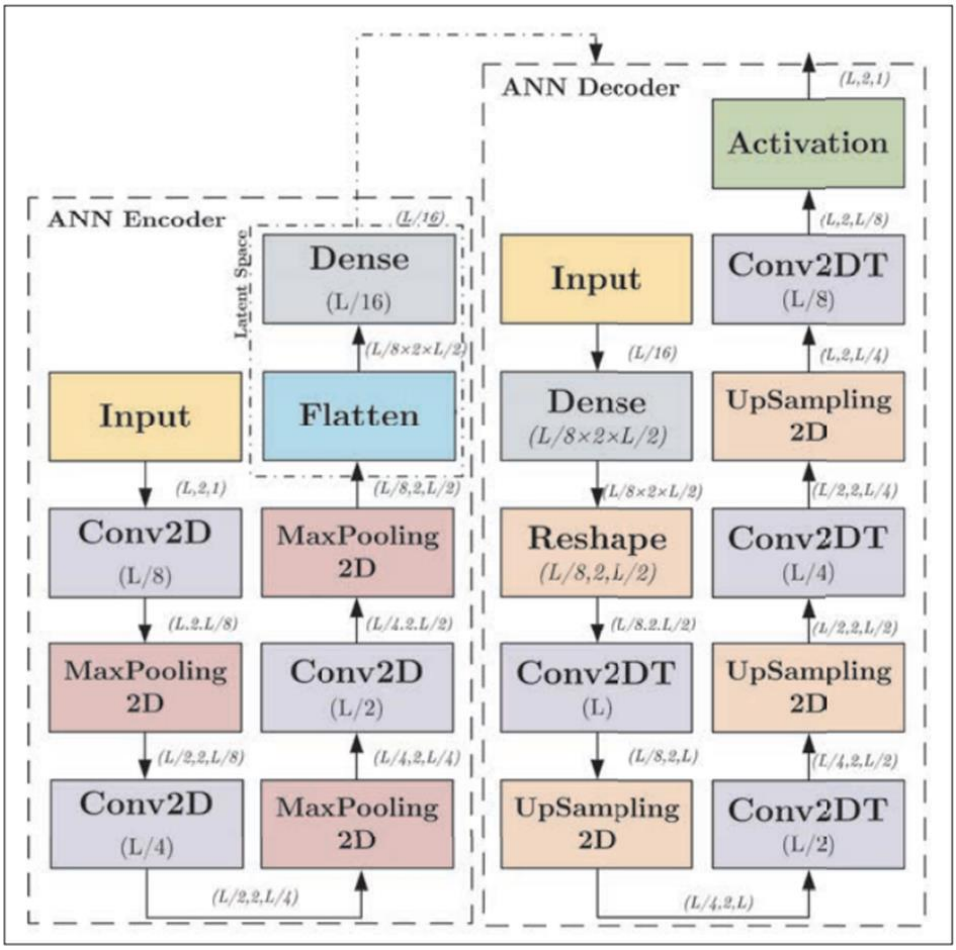

Abbildung 2 Autoencoder für Interferenzerkennung (Brian Shevitski, 2021)

4.1.4. Demodulation (Regression)

Eine weitere Anwendung des Autoencoders besteht darin, ihn als rauschunterdrückenden Demodulator zu verwenden. Zum Beispiel kann ein QPSK-Signal aus dem empfangenen Signal rekonstruiert werden. Abbildung 7 zeigt die Architektur des Modells. Die Verwendung des übertragenen Signals als Ziel und des empfangenen Signals als Eingabe ermöglicht es, das Modell für die Rekonstruktion zu trainieren. (Brian Shevitski, 2021)

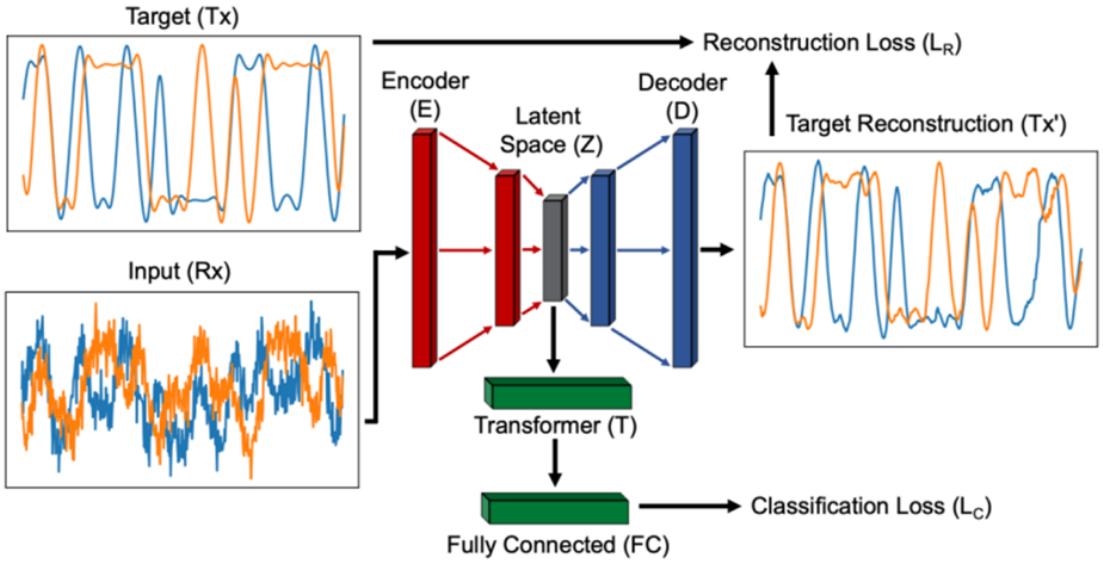

Abbildung 3 Autoencoder für Demodulation. (Brian Shevitski, 2021)

4.1.5. Transfer Learning (Unüberwachtes und Überwachtes Lernen)

In der realen Welt stehen wir manchmal vor dem Problem, dass entweder überhaupt kein Datensatz oder nur ein sehr kleiner Datensatz für eine bestimmte Aufgabe verfügbar ist. Insbesondere beim Einsatz von Neural Networks (NN) sind normalerweise große Datensätze erforderlich, um effektive Modelle zu trainieren. Eine vielversprechende Lösung für dieses Problem bietet das Transfer-Learning, das auf vortrainierten Modellen basiert.

Vortrainierte Modelle können entweder auf synthetischen Daten oder auf realen Daten trainiert werden, die gewisse Ähnlichkeiten mit der Ziel-Aufgabe aufweisen. Der Ansatz von Transfer-Learning besteht darin, die ersten Schichten des vortrainierten Modells beizubehalten, die für die Erfassung der grundlegenden Struktur der Daten verantwortlich sind, und nur die letzten Schichten zu trainieren, die spezifisch für die Aufgabe sind, die wir lösen möchten. Dies führt zu einem schnell konvergierenden Neural Network, das auf sehr kleinen Datensätzen trainiert werden kann.

Die Studie von S. Hoo-Chang (2016) hat gezeigt, dass Transfer-Learning ein vielversprechender Ansatz ist, um mit begrenzten Datenressourcen umzugehen. Durch die Nutzung eines vortrainierten Modells als Ausgangspunkt und die gezielte Anpassung der oberen Schichten auf die spezifische Aufgabe kann das NN von den bereits gelernten Merkmalsrepräsentationen profitieren. Dadurch können auch mit kleinen Datensätzen beeindruckende Leistungen erzielt werden.

4.1.6. Vorbereitung und Feinabstimmung

Der offensichtlichste Ansatz für Transfer-Learning besteht darin, ein Modell zu nutzen, das auf einem Quelldatensatz vortrainiert wurde, und es auf einem anderen Ziel-Datensatz zu evaluieren. Scott Kuzdeba (2021) präsentiert ein Beispiel für die Klassifizierung von RF-Fingerabdrücken, um die Anwendbarkeit dieses Ansatzes zu demonstrieren. Die Untersuchung umfasst verschiedene Populationen von bis zu 10.000 Geräten. Es wurden drei verschiedene Klassifikatoren in Betracht gezogen.

Im ersten Fall wurde das Modell direkt auf einem Super-Set trainiert, und die Validierung erfolgte auf einem Subset (Vollständiger Klassifikator). Im zweiten Fall wurde angenommen,

dass das Subset bekannt ist, und die Daten im Super-Set wurden entsprechend maskiert (Modifizierter Klassifikator). Der letzte Fall basierte auf dem modifizierten Klassifikator und hatte zusätzlich den Vorteil, dass ein kleiner beschrifteter Datensatz aus dem Ziel-Datensatz zur Feinabstimmung der letzten Schichten zur Verfügung stand (Feinabstimmung). Der Quelldatensatz bestand aus Wi-Fi-Signalen, während der Ziel-Datensatz nur die ADS-B-Signale umfasste.

Die Ergebnisse der verschiedenen Klassifikatoren wurden in Tabelle 2 dargestellt. Es stellte sich heraus, dass der Vollständige Klassifikator die besten Ergebnisse lieferte, was aufgrund der großen Ausgabeklasse irgendwie intuitiv ist. Interessanterweise scheint die Genauigkeit auch bei zunehmender Anzahl von Geräten im Ziel-Datensatz konstant zu bleiben, was als signifikantes Ergebnis betrachtet werden kann.

		Test								
		Full Classifier			Modified			Fine-Tuned		
		100	500	1,000	100	500	1,000	100	500	1,000
Train	100	86.3			86.3			86.3	71.6	66.0
	500	78.7	78.4		88.1	78.4		87.4	78.4	71.9
	1,000	74.1	74.8	74.6	88.2	79.6	74.6	88.5	79.2	74.6

Tabelle 3 Leistung der drei verschiedenen Klassifikatoren auf dem Ziel-Datensatz. (Scott Kuzdeba, 2021)

4.1.7. Transfer Learning für unbekannte-bekannte Geräte-Clustering

Dieser Teil beschreibt die Möglichkeit, Geräte in die Kategorien "in der Bibliothek" (IL) und "außerhalb der Bibliothek" (OOL) zu gruppieren. Mit anderen Worten, sind die Geräte im System bekannt oder nicht. Die Datensätze bestehen aus verschiedenen Fällen. Der erste Fall ist "Bekannt Bekannt", hier sind Quell- und Ziel-Daten gleich. Der Fall "Bekannt Unbekannt" wird im Quelldatensatz dargestellt. "Unbekannt Unbekannt" wird im Ziel-Datensatz dargestellt. (Scott Kuzdeba, 2021)

Zunächst zeigt sich, dass die Leistung deutlich steigt, wenn das während des Trainings verwendete "Bekannt Unbekannt" (KUC) mit dem realisierten "Unbekannt Unbekannt" (UUC) übereinstimmt und sich vom "Bekannt Bekannt" (KKC) unterscheidet. Die Verbesserung der Leistung zeigt sich auch dann, wenn das UUC sich vom KKC unterscheidet, unabhängig davon, welches KUC verwendet wird.

Dieses Ergebnis ergibt Sinn, da das KKC Teile der Mannigfaltigkeit belegt, die spezifisch für das KKC-Protokoll sind und daher einzigartige Merkmale aufweisen. In diesem Szenario erzielt die Leistung etwas schlechtere Ergebnisse, wenn das KUC mit dem KKC übereinstimmt, im Vergleich zu dem Fall, in dem es mit dem UUC übereinstimmt. Obwohl diese Beobachtung auf den ersten Blick widersprüchlich erscheinen mag, ist sie gut nachvollziehbar. Wenn alles dasselbe Protokoll ist, führt die hohe Ähnlichkeit in den Merkmalen zu mehr Unklarheiten und Ambiguität.

Die Verwendung des KUC trägt jedoch insgesamt zur Verbesserung der Leistung im Vergleich zur Nichtverwendung eines KUC bei (detaillierte Ergebnisse wurden in dieser Studie nicht gezeigt). Bei der Untersuchung spezifischer Protokolle wurde festgestellt, dass ADS-B, ein

einfacheres Protokoll, weniger Leistungsvarianz im KKC über den Testdatensatz aufweist. Im Gegensatz dazu zeigt Wi-Fi eine deutliche Abnahme der KKC-Leistung, wenn die UUCs ebenfalls Wi-Fi sind. (Scott Kuzdeba, 2021)

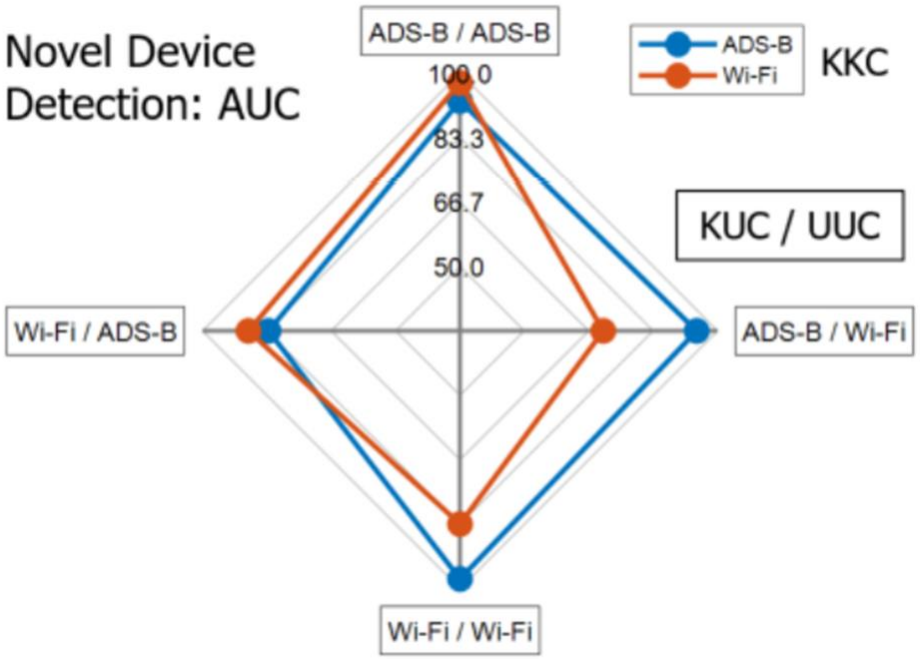

Abbildung 4 AUC-Leistung für die Identifizierung von RF-Fingerabdrücken. (Scott Kuzdeba, 2021)

4.1.8. Generative Adversarial Network (Selbstüberwachtes Lernen)

Generative Adversarial Networks (GANs) bieten eine vielversprechende Methode zur Generierung von RFMaps (Radio Frequency Maps) für die Lokalisierung basierend auf spärlichen Messungen. Die grundlegende Idee besteht darin, aus den spärlichen Messdaten einen kontinuierlichen und reibungslosen RFMap-Bereich zu erstellen. Normalerweise erfordert die Erstellung einer solchen glatten RFMap-Datenbank eine große Anzahl von Messungen. Durch den Einsatz von GANs und Interpolation des Zwischenraums können jedoch vollständige RFMaps generiert werden, selbst wenn nur spärliche Messungen vorliegen.

Das generative adversariale Lernen, welches durch die ersten beiden Deep Neural Networks (DNNs) umgesetzt wird, kann als Prinzip eines Zwei-Spieler-Spiels betrachtet werden, bei dem neue Trainingsverteilungen generiert werden (Z. Li, 2019). Das GAN-Modell besteht aus einem Generator und einem Diskriminator. Der Generator ist bestrebt, synthetische Proben zu erzeugen, während der Diskriminator versucht, zwischen echten und synthetischen Proben zu unterscheiden. Die beiden Netzwerke trainieren sich gegenseitig, und das Ergebnis ist ein Generator, der qualitativ hochwertige synthetische Daten produziert, die den echten Proben ähnlich sind.

Das vorgeschlagene System kann als selbstüberwachtes System betrachtet werden (Kuldeep S. Gill, 2021), da nur eine spärliche Menge an Messungen für die Generierung der RFMaps erforderlich ist. Dies bietet den Vorteil, dass die Datenerfassungskosten erheblich reduziert werden können. Darüber hinaus kann das System kontinuierlich mit neuen eingehenden Daten

aktualisiert werden, um die RFMaps zu verbessern und an sich ändernde Umgebungen anzupassen.

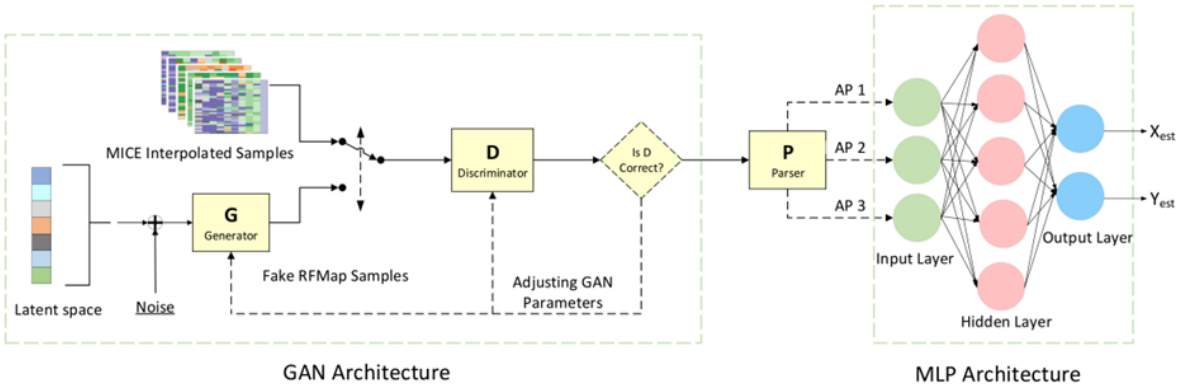

Abbildung 5 Lokalisierung basierend auf RF-Signalen. (Kuldeep S. Gill, 2021)

4.1.9. Unüberwachtes Transfer-Learning

Im Vergleich zum überwachten Lernen verfügt das unüberwachte Lernen nicht über Informationen zu den Zielmarken. Dafür wird ein Prinzip namens Autoencoder eingeführt. Ein Autoencoder besteht aus einem Encoder und einem Decoder. Der Encoder verbindet die Eingabe mit einem latenten Raum, der normalerweise eine niedrigere Dimension als die Eingabe hat. Der Decoder versucht, die ursprüngliche Darstellung aus dem latenten Raum wiederherzustellen.

Die Rekonstruktion erfolgt mit dem sogenannten Rekonstruktionsverlust aus einem unbeschrifteten Datensatz. Nachdem der Autoencoder trainiert ist, wird der Decoder entfernt, und was übrig bleibt, ist der Encoder, der die Eingabe in einen niedrigdimensionalen latente Raum überführt. In einem idealen Fall sind alle relevanten Informationen im latenten Raum dargestellt. Der latente Raum wird dann mit einem Klassifikator (NN, SVM...) verbunden und auf einem kleinen beschrifteten Datensatz trainiert.

Der Quelldatensatz im Experiment besteht ausschließlich aus synthetischen Daten. Die Wi-Fi-Signale wurden mit dem MATLAB-Toolbox WLAN Toolbox erstellt. Die Signale hatten eine Dauer von 1600 IQ-Samples bei 20 Msps. Alle Signale waren entweder 802.11- oder g-Wellenformen und variierten in Codierungsschema und Modulationstyp. Keine RF-Kanäle, keine Front-End-Hardware oder andere Effekte wurden modelliert.

Das Training wurde mit unbeschrifteten Daten aus dem Quelldatensatz durchgeführt. Der Klassifikator wurde mit einem kleinen Datensatz aus dem realen Ziel-Datensatz trainiert. Die folgende Abbildung zeigt den Vergleich, wie Transfer-Learning die Ergebnisse verbessert, wenn das vortrainierte Modell ausschließlich mit synthetischen Daten trainiert und mit einem kleinen echten Datensatz feinabgestimmt wird. Im folgenden wird ein neuronales Netz untersucht, dass zur Interferenzminimierung geeignet ist, dadurch kann man durch optimales Beamforming und Leistungsverteilung eine stabilere Datenübertragung erreichen, zudem kann die Datenrate und die Anzahl der Tags gesteigert werden.

4.2. Interferenzmitigation Beamforming

Um mögliche Interferenzen zu vermeiden wird im folgenden ein Ansatz zur Interferenzvermeidung mittels Beamforming und Leistungsoptimierung vorgestellt. Dieser Ansatz wurde gewählt, da dieser ohne Veränderungen am Sender auskommt, zudem es die Ressourcen am Satelliten optimiert und eine gleichzeitige Auswertung mehrerer Sender auf der gleichen Ressource zulässt. Hierbei wird die Leistung auf die verschiedenen Beams optimal verteilt und die Interferenzen in den einzelnen Beams berücksichtigt. In Abbildung 6 ist dargestellt, wie man durch räumliche Trennung, die Interferenzen reduziert. Es werden verschiedene Beams ausgeformiert und jeweiligen Sendern oder Sendergruppen zugeordnet. Dies führt dazu, dass die Signalverarbeitung am Satelliten getrennt für die jeweiligen Beams erfolgen kann. Die Herausforderung hierbei ist es, die einzelnen Beams so auszuformen, dass die Ressourcen optimal verteilt sind. Durch die vielen unterschiedlichen Parameter die ein nicht konvexes Optimierungsproblem darstellen, kommen herkömmliche Methoden wegen der hohen Komplexität aus zeitlichen und energetischen Gründen nicht in Frage. Im Folgenden wird ein Ansatz anhand eines neuronalen Netzes vorgestellt und mit den herkömmlichen Methoden verglichen.

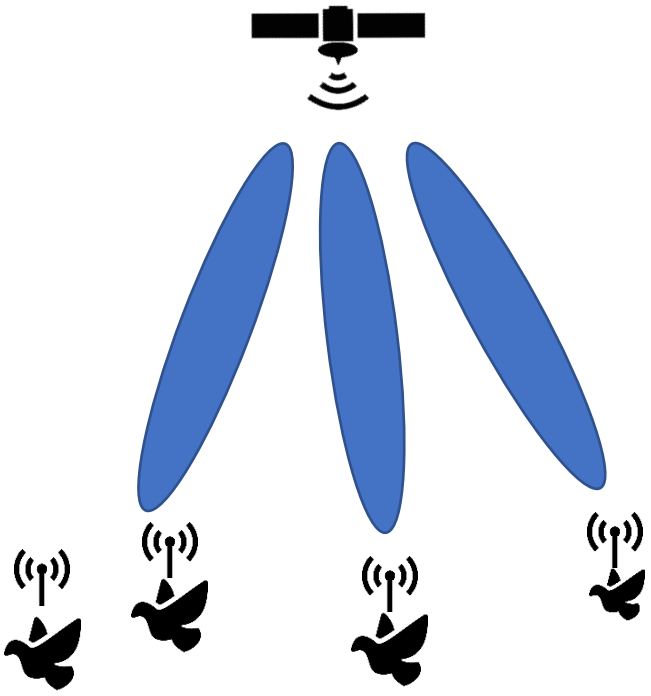

Abbildung 6: Beamforming Interferenzmitigation Strategie

4.3. Struktur Neuronales Netzwerk

In Echtzeit wird ein vollständig verbundenes DNN mit Unsupervised-Learning verwendet, um die intelligente Umsetzung der Nutzlast-Leistungsressourcen-Neukonfiguration durchzuführen. Wie in Abbildung 1 dargestellt, besteht die gesamte NN-Architektur aus zwei vorwärts gerichteten DNN-Modulen, einem Modul für die Ressourcenzuweisung der Nutzlastleistung auf Beam79-Ebene (BpaMod) und einem Modul für die Ressourcenzuweisung der Nutzlastleistung auf Benutzerebene (UpaMod). Insbesondere setzt sich das BpaMod wie folgt zusammen (Y. Zhu, 2022):

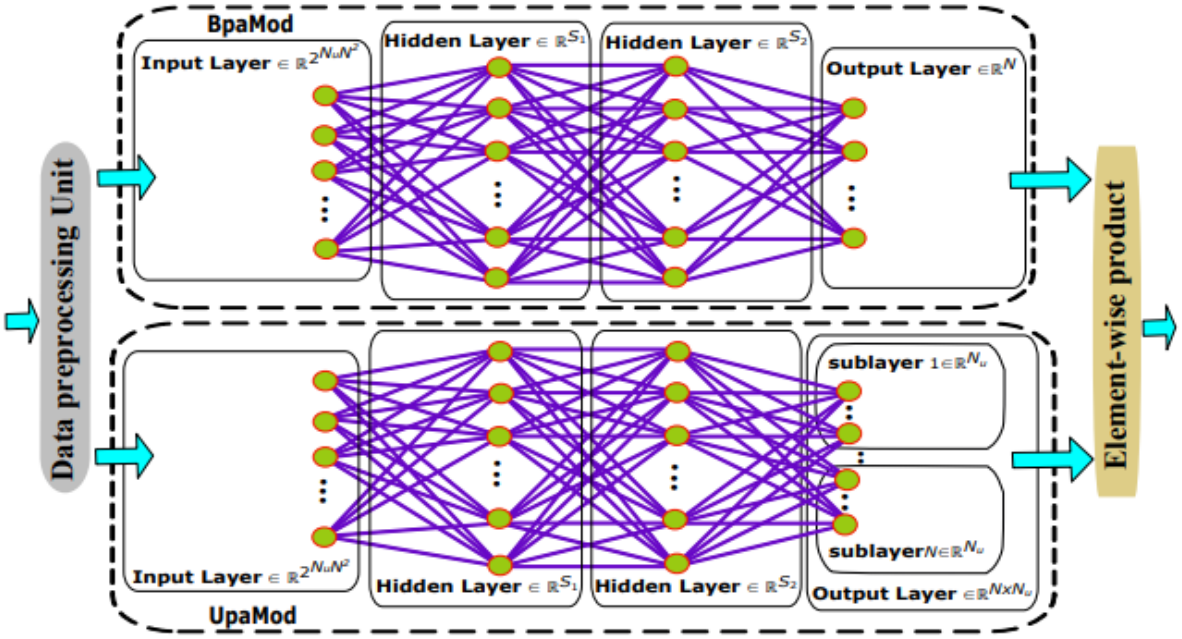

Abbildung 7 Struktur Neuronales Netzwerk

Im BpaMod werden die mehreren Schichten von Neuronen von 0 bis L nummeriert. Dabei empfängt die Eingangsschicht von Neuronen direkte Eingaben außerhalb des Netzwerks, und ihr Ausgabevektor a0 hat die Größe $(2N_u \cdot N2) \times 1$. Als Nächstes wird der Ausgabevektor a0 der Eingangsschicht an die erste versteckte Schicht weitergeleitet. Jede versteckte Schicht verwendet die Rektifizierte Lineare Einheit (ReLU) Funktion $f\ (x) = max(x,\ 0)$ als Aktivierungsfunktion jedes Neurons, die dem neuronalen Netzwerk die gewünschte Nichtlinearität für bessere Leistung bietet.

Anschließend fungiert die Ausgangsschicht als Funktionsapproximator und bestimmt, wie das gesamte Nutzlastleistungs-Budget auf mehrere Strahlen verteilt wird (d. h. sie wird in dieser Arbeit als Ressourcenzuweisung der Nutzlastleistung auf Beam-Ebene bezeichnet). Hierbei wird die lineare Transferfunktion $f(x)$ als Aktivierungsfunktion jedes Neurons für die Ausgangsschicht verwendet.

Parallel dazu, indem dieselben Eingaben einem weiteren DNN-Modul namens UpaMod zugeführt werden, beabsichtigt man, die zugewiesene Nutzlastleistungs-Ressource auf Beam-Ebene unter allen ausgewählten Benutzern pro Strahl zu verteilen (d. h. in dieser Arbeit wird dies als Ressourcenzuweisung der Nutzlastleistung auf Benutzerebene bezeichnet). Um dieses Ziel zu erreichen, kann dieselbe Netzwerkstruktur wie im parallelen BpaMod für den

UpaMod übernommen werden, mit Ausnahme der Ausgangsschicht. Insbesondere hat die Ausgangsschicht N Anzahl an Teilschichten.

Angesichts dessen, dass eine Softmax-Transferfunktion nicht-ganzzahlige Wahrscheinlichkeiten (zwischen 0 und 1) ausgibt und die Summe der Ausgabewahrscheinlichkeiten 1 ergibt, kann die Zuweisung der Nutzlastleistung auf Benutzerebene gut durch eine Softmax-Transferfunktion nachgebildet werden.

Ohne Ground-Truth-Labels werden die Gewichte und Biases der Neuronen im angewandten DNN zunächst durch das Erlernen der verdeckten Struktur seiner Eingabe optimiert. Nachdem die Neuronengewichte und -biases optimiert wurden, wird das trainierte DNN verwendet, um intelligent eine Strategie für die Zuweisung von Nutzlastleistungs-Ressourcen mit dem Testdatensatz vorherzusagen.

Netzwerktraining: Während des Trainingsprozesses müssen die Gewichtsmatrizen der Neuronen und Bias-Vektoren des angewandten DNN sorgfältig abgestimmt werden, um die Leistung des DNN zu optimieren, wie sie durch die Netzwerk-Leistungsfunktion definiert ist (in dieser Arbeit als Verlustfunktion bezeichnet). Zu diesem Zweck wird eine Verlustfunktion speziell für das angewandte DNN angepasst und abgeleitet, indem gleichzeitig die Ziel-Funktion und alle Einschränkungen des Optimierungsproblems $\mathcal{P}1$ berücksichtigt werden. Mathematisch wird die angepasste Verlustfunktion des angewandten DNN wie folgt formuliert:

$$
\begin{aligned}
\text{Loss} = & -\sum_{g\in\mathcal{G}}\sum_{b\in\mathcal{N}_g}\sum_{i\in\mathcal{S}_{b,g}} \varsigma_{b,g}^{(i)} R_{b,g}^{(i)} \\
& + \lambda_1 \sum_{g\in\mathcal{G}}\sum_{b\in\mathcal{N}_g}\sum_{i\in\mathcal{S}_{b,g}} f_{\tanh}\left(\frac{f_{\text{Relu}}(\bar{R}_{b,g}^{(i)} - R_{b,g}^{(i)})}{\bar{R}_{b,g}^{(i)} + \tau}\right) \\
& + \lambda_2 f_{\tanh}\left(\frac{f_{\text{Relu}}(\sum_{g\in\mathcal{G}}\sum_{b\in\mathcal{N}_g}\sum_{i\in\mathcal{S}_{b,g}} p_{b,g}^{(i)} - P_{\text{total}})}{P_{\text{total}} + \tau}\right) \\
& + \lambda_3 \sum_{g\in\mathcal{G}}\sum_{m\in\mathcal{N}_g}\sum_{b\in\mathcal{N}_g}\sum_{i\in\mathcal{S}_{b,g}} f_{\tanh}\left(\frac{f_{\text{Relu}}(\text{PAPC}_{b,g}^{(i),m})}{P_{g,m} + \tau}\right) \\
& + \lambda_4 \sum_{g\in\mathcal{G}}\sum_{b\in\mathcal{N}_g}\sum_{i\in\mathcal{S}_{b,g}}\sum_{k\in[1,i)} f_{\tanh}\left(\frac{f_{\text{Relu}}(-\text{SIC}_{b,g}^{(i)\to(k)})}{\tau}\right)
\end{aligned}
$$

Die Objektfunktion des entsprechenden Optimierungsproblems $\mathcal{P}1$ wird als ihr negatives Äquivalent gesetzt, da die Verlustfunktion vom Trainings-Optimizer minimiert werden soll. Weitere Straffunktionen werden der Objektfunktion hinzugefügt. Jede Straffunktion besteht aus einem Straffaktor λ_i ($i \in [1, 4]$), multipliziert mit einer Schätzung der Verletzung der entsprechenden Einschränkung (d. h. C_i ($i \in [1, 4]$) des Optimierungsproblems $\mathcal{P}1$). Wenn die Einschränkung C_i ($i \in [1, 4]$) verletzt wird, wird die entsprechende Straffunktion erhöht, sodass die Neuronengewichte und -biases des Trainings-DNN gezwungen werden, in die richtige Richtung abgestimmt zu werden, um die Einschränkung zu erfüllen. Die Hilfsfunktion PAPC(i),m b,g = $p(i)$ b,g℘ T mwb,gwH b,g℘m −Pg,m wird ausschließlich zur Vereinfachung der Notation eingeführt. $f$tanh$(\cdot)$ bezeichnet eine Tangens-Hyperbolicus-Funktion, die als

$f_{\text{tanh}}(x) = e^{x}-e^{-x} / e^{x}+e^{-x}$ definiert ist und einem Straffunktionswert einen stark positiven Wert zuweist. Die Konstante $\tau = 10^{-8}$ wird verwendet, um das Problem des Nennwertes null zu eliminieren.

Nachdem die angepasste Verlustfunktion festgelegt wurde, ist das angewandte DNN bereit, auf einem nicht gesehenen Datensatz die Verlustfunktion zu minimieren. Um das angewandte DNN zu trainieren, stehen numerische Optimierungsalgorithmen (z. B. Gradienten- oder Jakobialgorithmen) zur Verfügung, um die Leistung des angewandten DNN zu optimieren. In dieser Arbeit wird der Gradientenabstiegsalgorithmus als Trainingsalgorithmus oder Optimierer für das Training des angewandten DNN verwendet.

Hierbei wird die geeignete Batch-Größe und Lernrate durch Schätzung ermittelt. Basierend auf dem Gradientenabstiegsalgorithmus werden die Gewichtsmatrizen der Neuronen und die Neuronen-Bias-Vektoren pro Iteration in die Richtung aktualisiert, in der die angepasste Verlustfunktion schnell abnimmt (d. h. die entgegengesetzte Richtung des Gradienten). Letztendlich ist das DNN nach dem Training bereit, die Verlustfunktion auf einem nicht gesehenen Datensatz zu minimieren.

4.4. Komplexitätsanalysis

Im Folgenden wird die Rechenkomplexität eines WMMSE-basierten State-of-the-Art Payload-PA-Verfahrens und DNN-basierten Payload-PA-Verfahrens analysiert und verglichen:

• Schritt 1: Die Initialisierung des PA für alle Benutzer hat eine Komplexität von $\mathcal{O}(N_u N)$.

• Schritt 2: Während jeder Iteration erfordert die Berechnung von $f(i)$ b,g für Benutzer i im Strahl b ($b \in \mathcal{N}g$) eine Komplexität von $\mathcal{O}(1)$. Entsprechend ist die Gesamtkomplexität für alle Benutzer $\mathcal{O}(NuN)$.

• Schritt 3: Während jeder Iteration ist die Komplexität für die Berechnung von $\varpi(i)$ b,g für Benutzer i im Strahl b ($b \in \mathcal{N}g$) $\mathcal{O}(1)$. Entsprechend ist die benötigte Gesamtkomplexität für alle Benutzer $\mathcal{O}(N_u N)$.

• Schritt 4: Während jeder Iteration erfordert die Interior-Point-Methode nach der Bewertungsmethode in [90] eine worst-case Komplexität von $\mathcal{O}((N_u N)$^(4.5) log(1/ε^3)) um die ε^3-optimale Lösung für $\mathcal{P}2$ zu suchen.

Daher ist die Gesamt-Rechenkomplexität des Algorithmus 2 $\mathcal{O}(N_u N$+I_{PA}(2$N_u N$+($N_u N$)^(4.5) log(1/ε^3))) ~ $\mathcal{O}(I_{\text{PA}}$ ($N_u N$)^(4.5) log(1/ε^3)), wobei I_{PA} die maximale Anzahl der Iterationen ist, die in Algorithmus 2 benötigt werden.

Als nächstes wird die Rechenkomplexität des DNN-basierten Payload-PA-Verfahrens analysiert:

• In den Phasen der Datenvorverarbeitung: Die Gesamtberechnungskomplexität der Datenvorverarbeitung für das Training und Testen beträgt $\mathcal{O}(2N_u\ N^2)$.

• In den Phasen des Trainings und Testens: Die Berechnung von BpaMod in den Phasen des Trainings und Testens wird von der Matrix-Berechnung dominiert; das heißt: $\mathcal{O}(2N_u N^2 S_l$+$2S^2{}_l(L-1)$+2 $S_l\ N)$, wobei die Berechnungskomplexität des Trainings und Testens als gleich behandelt wird. Ähnlich wird die Berechnung von UpaMod in den Phasen des Trainings und Testens als $\mathcal{O}(2N_u\ N^2 S_l$ + 2 $S^2{}_l$ $(L - 1)$ + $2SlN_u)$ berechnet. Dann wird das elementweise Produkt für die Ausgabe von BpaMod und die Ausgabe von UpaMod durchgeführt, was eine Komplexität von $\mathcal{O}(N_u N)$ hat. Schließlich wird die Berechnung in den Phasen des Trainings und Testens als $\mathcal{O}(4N_u\ N^2 S_l$ + 4 $S^2{}_l$ $(L - 1)$ + 2 S_l $(N_u + N)$ + $N_u N)$ gegeben.

Daher ist die Gesamt-Rechenkomplexität des DNN-basierten Payload-PA-Verfahrens $\mathcal{O}(4\ N_u$ $N^2\ S_l$ + 4 $S^2{}_l$ $(L - 1)$ + 2 S_l $(N_u + N)$ + $N_u\ N$ + 2 $N_u\ N\ N^2)$ ~ $\mathcal{O}(4\ N_u\ N^2\ S_l$ + 4 $S^2{}_l)$.

Daraus lässt sich folgern, dass der DNN-basierte Ansatz deutlich weniger Operationen bei komplexen Payload-PA Problemen als der herkömmliche WMMSE Ansatz.

4.5. Perfomanceanalyse

Die Leistung verschiedener Verfahren wird durch numerische Simulationen bewertet. Die Simulationsplattform wird mit einer 2-Kern-Central Processing Unit (CPU) (d. h. Intel(R) Core(TM) i7 - 7500U) mit einer Lauffrequenz von 2,70 GHz eingerichtet. Das angewandte DNN-Modell wird mit Python 3.7 und TensorFlow programmiert, trainiert und getestet. Der Interior-Point-Algorithmus in der Optimization ToolboxTM von Matlab wird verwendet, um die optimale Neuverteilung der Nutzlastleistungsressourcen $\{p(i)\ b,g\}$ für das Problem $\mathcal{P}1$ zu erhalten. Grundsätzlich nähert sich ein vorwärtsgerichtetes DNN mit mehr Schichten einer unbekannten nichtlinearen Abbildung schneller an. In diesem Zusammenhang beginnt diese Arbeit mit einem DNN mit drei Schichten und erweitert es dann auf vier Schichten, es sei denn, die Leistung des DNN mit drei Schichten ist nicht zufriedenstellend. Somit wird ein DNN mit vier Schichten festgelegt. Die nachfolgende Abbildung zeigt, dass durch Verwendung des Neuronalen Netzwerkes gleiche Ergebnisse wie mit State-of-the-Art Methoden erzielt werden, jedoch mit dem Vorteil, dass weniger Rechenkapazität benötigt wird.

Bisher wurde das DNN-basierte Payload-PA-Verfahren mit der CPU-basierten Plattform und dem vollständigen CSI simuliert. In der Praxis wird angenommen, dass das Training des DNN online durchgeführt wird, indem das Potenzial des unüberwachten Lernens genutzt wird, wobei eine hochleistungsfähige Grafikverarbeitungseinheit (GPU) mit mehreren Laufthreads verwendet wird, um das DNN im Ressourcenkontrollzentrum zu trainieren. Dadurch wird die Rechenzeit des DNN-basierten Verfahrens schnell beschleunigt. Dies bedeutet, dass das DNN-basierte Payload-PA-Verfahren das Potenzial hat, eine Echtzeitoperation mit Online-Training und reduzierter Implementierungskomplexität durchzuführen bei gleichbleibender Performance im Vergleich zur herkömmlichen Methode wie in Abbildung 8 zu sehen ist.

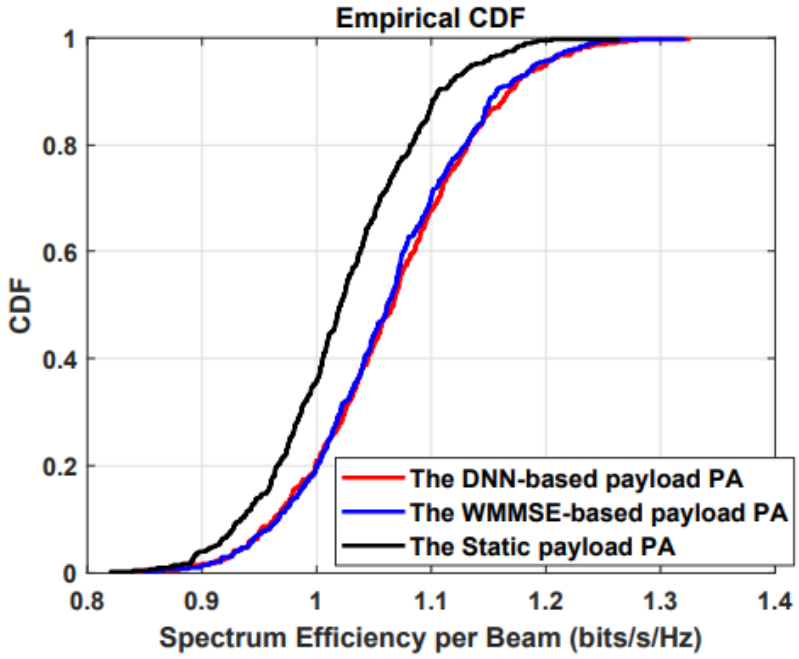

Abbildung 8 Vergleich WMMSE und DNN Methode

5. Ausblick

Die Integration neuronaler Netzwerke zur Interferenzvermeidung stellt zweifellos eine vielversprechende Perspektive dar. Dennoch erfordert es eine sorgfältige Betrachtung, wie dieses Verfahren nahtlos in den alltäglichen Betrieb integriert werden kann. In dieser Hinsicht begegnen wir der Anforderung, reale Daten zu berücksichtigen, welche zusätzliche Herausforderungen mit sich bringen. Diese tatsächlichen Beobachtungen bieten jedoch die einzigartige Möglichkeit, Interferenzmuster zu analysieren. Diese Erkenntnis wurde bei meiner Auseinandersetzung mit der einschlägigen Literatur als vielversprechende Grundlage für KI-basierte Ansätze identifiziert.

Eine präzise Abschätzung des Potenzials der KI ist nur dann realistisch möglich, wenn sie auf realen Daten basiert. Ansonsten besteht die Gefahr, dass das Modell lediglich die Simulationsumgebung erlernt, was die Übertragbarkeit auf die praktische Anwendung einschränken könnte. Daher erlangen Daten aus realen Begebenheiten einen essenziellen Stellenwert, um die Leistungsfähigkeit des neuronalen Netzwerks unter realen Bedingungen zu validieren und zu optimieren.

Die erfolgreiche Integration eines Gesamtsystems in die Satellitenumgebung ist nicht ohne Herausforderungen. Insbesondere muss dabei sorgfältig darauf geachtet werden, dass sämtliche Leistungsbudgets des Satelliten eingehalten werden. Dies ist von entscheidender Bedeutung, um sicherzustellen, dass die Interferenzvermeidungsstrategien effektiv eingesetzt werden können, ohne die grundlegenden Funktionen und Missionen des Satelliten zu beeinträchtigen. Eine wohlüberlegte Abstimmung zwischen den KI-basierten Verfahren und den technischen Kapazitäten des Satelliten stellt hierbei eine Schlüsselherausforderung dar.

Referenzen

Ajib, Y. G. (2020). Radio Frequency Interference Detection using Deep Learning. *IEEE 91st Vehicular Technology Conference*.

Brian Shevitski, Y. W. (2021). *Digital Signal Processing Using Deep Neural Networks.*

DAMILOLA ADESINA, J. B. (n.d.). *Robust Deep Radio Frequency Spectrum Learning for Future Wireless Communications Systems.*

Green, Y. S. (2019). Deep Learning for RF Signal Classification in Unknown and Dynamic Spectrum Environments. *arXiv*.

Hong, H. S. (2018). Learning to Optimize: Training Deep Neural Networks for Interference Management. *IEEE Transactions on Signal Processing*.

Kuldeep S. Gill, S. N. (2021). *Three-Way Deep Neural Network for Radio Frequency Map Generation and Source Localization.*

M. Kulin, T. K. (2018). *End-to-End Learning From Spectrum Data: A Deep Learning Approach for Wireless Signal Identification in Spectrum Monitoring Applications.*

Marvin A. Conn, D. D. (2019). *Radio Frequency Classification and Anomaly Detection using Convolutional Neural Networks.*

Meier, M. S. (2017). *Wireless Interference Identification with Convolutional Neural Networks.*

Miguel Ángel Vázquez, P. H. (2021). *Machine Learning for Satellite Communications Operations.*

O'Connor, R. (2021, 12 14). *Assembly AI*. Retrieved from https://www.assemblyai.com/blog/pytorch-vs-tensorflow-in-2022/

O'Shea, T. J. (2016). *Convolutional Radio Modulation Recognition Networks.*

S. Bianco, R. C. (2018). Benchmark Analysis of Representative Deep Neural Network Architectures.

S. Hoo-Chang, H. R. (2016). *Deep convolutional neural networks for computer-aided detection: CNN architectures, dataset characteristics and transfer learning.*

Scott Kuzdeba, J. R. (2021). *Transfer Learning with Radio Frequency Signals.*

W. Lee, O. J. (2020). Intelligent Resource Allocation in Wireless Communications Systems. *IEEE Communications Magazine*.

Y. Zhu, C. A. (2022). Distributed Resource Optimization for NOMA Transmission in Beamforming SATCOM. *IEEE Journal on Selected Areas in Communications*.

Yi Shi and Kemal Davaslioglu, Y. E. (2019). *Deep Learning for RF Signal Classification in Unknown and Dynamic Spectrum Environments.*

Z. Li, J. C. (2019). *Sparsely self-supervised generative adversarial nets for radio frequency estimation.*

AP4000

ICARUS-KI Ergebnisdarstellung für Abschluss-bericht

Autoren: Dr. S. Bittner, Daniel Ehnert, Markus Symmank, Robert Wünsche

Geprüft: Prof. Dr. M. Krondorf

HTWK Leipzig, 25.10.2023, Prof M. Krondorf

INHALTSVERZEICHNIS

Inhaltsverzeichnis 2

Abkürzungsverzeichnis 4

Symbolverzeichnis 5

1 ICARUS-Problembeschreibung 7

1.1 Prinzip der Dopplerortung 7

2 Schätzung des Frequenzversatzes 15

2.1 Modellierung der Übertragungsstrecke 15

2.1.1 Sendermodellierung 16

2.1.2 Kanalmodellierung 16

2.1.3 Empfängermodellierung 16

2.2 Differenzverfahren 17

2.3 FFT-Verfahren 20

2.4 Performancevorhersage der Ortungsverfahren 23

2.5 Auswertung der Schätzgenauigkeit 25

2.6 Einfluss der Frequenzschätzung auf die Ortsschätzung 29

3 Verfeinerung des Ortungsalgorithmus durch Machine Learning 31

3.1 Maschinelles Lernen 33

3.2 Simulierte Überflugdaten 35

3.3 Datenvorverarbeitung 39

3.4 Methoden des Maschinellen Lernens 44

3.4.1 Time Series extrinsic Regression (TSER) 45
3.5 Auswertung der Positionsschätzung 48
4 Ortung mit dem Maximum Likelihood-Verfahren 55
4.1 Schätzgenauigkeit des Maximum-Likelihood Verfahrens 59
5 Symmetrieproblem der Cross-Track-Distanz 70
6 Ergebnisdiskussion 74
Literatur 76

ABKÜRZUNGSVERZEICHNIS

ISS	International Space Station
FFT	Fast Fourier Transformation
CFO	Carrier-Frequency Offset (Trägerfrequenzversatz)
RC-Filter	Raised-Cosine bzw. Angehobener-Kosinus-Filter
RRC-Filter	Root-Raised-Cosine bzw. Wurzel-Kosinus-Filter
SNR	Signal-to-Noise-Ratio, Signal zu Rauschabstand
ISI	Intersymbolinterferenz
CAZAC	Constant Amplitude, Zero Auto Correlation (-Sequenz)
FZC	Frank-Zadoff-Chu (-Sequenz)
LUT	Look-Up-Table
PSD	Spektrale Leistungsdichte, Power-Spectral-Density
8PSK	8-Phase-Shift-Keying
TSF	Time Series Forecasting
TSC	Time Series Classification
TSER	Time Series Extrinsic Regression
SoFR	Scalar on Function Regression
SVM	Support Vektor Maschine
LR	Lineare Regression
RF	Random Forest
XGBoost	Extreme Gradient Boosting
Rocket	Random-Convolutional-Kernel-Transform
ResNet	Residual Network
FCN	Fully Convolutional Network
k-NN	k-Nearest-Neighbour
ED	Euklidische Distanz
DTW	Dynamic Time Warping
CCDF	Complementary Cumulative Distribution Function

SYMBOLVERZEICHNIS

f_d	Dopplerverschiebung
$\dot{f}_d$	Dopplerrate
$\ddot{f}_d$	Dopplerbeschleunigung
h	Orbithöhe
r_x	Along-Track Distanz, Entfernung in Bewegungsrichtung
r_y	Cross-Track Distanz, Entfernung gegen Bewegungsrichtung
T	Position des Sendetags
α	Winkel des Satelliten relativ zum Sender
v_0	Bahngeschwindigkeit des Satelliten
f_c	Sendefrequenz
$f_c{}'$	Am Satelliten beobachtete Sendefrequenz]
f_{sym}	Symbolrate
G	Überfluggebiet
CFO	Carrier Frequency Offset
$s_{\mathrm{FZC}}[k]$	Frank-Zadoff-Chu Sequenz
s	verkettete Frank-Zadoff-Chu Sequenzen
N_{sym}	Signallänge der FZC-Sequenz
r	Roll-Off Faktor
s_{tx}	Sendesignal
y_{rx}	am Empfänger anliegendes Signal
n	Rauschen
z_{rx}	Empfangene Symbole nach dem Heruntertasten
u	freier Parameter
d	Konjugationsparameter
q	Startfrequenz
N_{OS}	Oversampling Faktor
D_{norm}	Abstand der Korrelationspeaks bei CFO=0
t_p	Position des Peaks der Korrelationsmetrik
t_1	Position des ersten Peaks der Korrelationsmetrik
t_2	Position des zweiten Peaks der Korrelationsmetrik
t_{opt}	Startwert Empfangssignal
d_{peak}	Abstand beider Maxima der Korrelationsmetrik
$CFO_{est,Diff}$	geschätzter CFO nach Differenzverfahren
d_f	Frequenzanstieg bzw. Auflösung
$d_{f,norm}$	mit f_{sym} normierte Auflösung
m_1, m_2	Korrelationsmetriken
m_n	Leistungsnormierte Korrelationsmetrik
$\overline{m_n}$	Mittelwert der leistungsnormierten Korrelationsmetrik
L_w	Anzahl verwendeter Nachbarwerte
z_{Diff}	Empfangene Symbole nach dem Differenzverfahren
Δf	Frequenzschätzfehler
Δf_{norm}	mit f_{sym} normierter Frequenzschätzfehler
Δf_{eff}	Effektivwert des Frequenzschätzfehlers
Z_s	Spektrum des empfangenen, heruntergetasteten Signals
N_{FFT}	Anzahl Stützstellen bzw. ausgewertete Frequenzpunkte
z_{FFT}	Empfangene Symbole nach dem FFT-Verfahren
Δf_{max}	Frequenzauflösung im FFT-Verfahren

$\Delta f_{max,normiert}$	mit f_{sym} normierte Frequenzauflösung
σ_f	Standardabweichung des aufgeprägten Rauschens
σ_d	Stanardabweichung der Ortsschätzung
φ	Elevation des Satelliten
φ_{max}	Maximale Elevation
x	Überflugrichtung
y	Position senkrecht zur Überflugrichtung
b	Distanz auf der Erboderbfläche
r	Mittlerer Erdradius
$RMSE$	Standardabweichung (Root Mean Squared Error)
MAE	Mittlerer absoluter Fehler
R^2	Bestimmtheitsmaß einer Regression
S	Zeitreihe
L	Anzahl Parameter
t_L	Zeitstempel
D	Dimension
$\mathcal{D}$	Datensatz
Y	Skalare Zielgröße
W	Zeitreihe
β	Koeffizientenfunktion
ϵ	Rauschen des Datensatzes
Θ	Parametermenge
μ	Mittelwert
σ^2	Varianz
X_n	Zufallsbariable
LL	Log-Likelihood-Funktion
P_{tag}	Position des Senders
$f_{overflight}$	Lineare Funktion eines Satellitenüberflugs
$N_{overflight}$	Anzahl Satellitenüberflüge
P_L	Lotfußpunkt
$P_{est1,2}$	Mögliche Schätzposition
Pos_{est}	Gemittelte Positionsschätzung

1 ICARUS-PROBLEMBESCHREIBUNG

Das ICARUS Satellitenübertragungssystem wurde entwickelt, um die Flugrouten und die Lebensbedingungen von Vögeln auf der Erde zu erforschen. Die Ergebnisse sollen der Verhaltensforschung zur Verfügung gestellt werden, dem Artenschutz dienen und die Ausbreitung von Krankheiten nachvollziehbar machen. Auch ökologische Veränderungen oder Naturkatastrophen können mit diesem System erfasst werden. Im Folgenden wird dargestellt, wie das ICARUS-System funktioniert.

Das ICARUS-System verwendet kleine Transmitter, sogenannte Tags, die von verschiedenen Arten von Vögeln getragen werden und gemessene Daten zur ICARUS-Empfängerstation (ISS) senden. Die Empfängerstation sendet die empfangenen Daten weiter an terrestrische Bodenstationen, von wo aus diese an die entsprechenden Forscherteams weitergeleitet werden.

Das ICARUS-System implementiert einen Uplink und einen Downlink. Der Uplink wird genutzt, um die Sensordaten an die ISS zu übertragen, während der Downlink im Anschluss dafür verwendet werden kann, neue Konfigurationen an den Sender zu schicken. Das Downlinksignal ist ein konstanter Träger, der gespreizte QPSK-Symbole enthält. Der Träger wird verwendet, um den Tag zu aktivieren und eine Zeitsynchronisierung durchzuführen.

Zurzeit sendet ein Tag verschiedene Sensordaten sowie die GPS-Position des Vogels, der den Sender trägt. Die Bestimmung der Position per GPS benötigt jedoch sehr viele Ressourcen in Form von Batterielaufzeit und macht einen großen Teil der verwendeten Hardware aus. Aus diesem Grund soll die Positionsbestimmung des Tags auf ein Verfahren umgestellt werden, welches die Messung des Dopplereffektes nutzt. Untersuchungen zu diesem Ansatz, dem *Doppler-Ranging Empfänger* haben gezeigt, dass eine Positionsschätzung damit möglich ist [2].

Die damit erzielbare Genauigkeit der Positionsschätzung hängt stark davon ab, wie gut der bei der Übertragung entstandene Frequenzversatz korrigiert werden kann. Daher werden Verfahren zur genaueren Schätzung dieses Frequenzversatzes für den *Doppler-Ranging Empfänger* untersucht.

1.1 PRINZIP DER DOPPLERORTUNG

Für die Positionsschätzung werden die Eigenschaften der Dopplerfrequenz und deren zeitliche Ableitung, die Dopplerrate genutzt. Dafür wird zuerst auf die Geometrie des Überflugproblems Bezug genommen und der Zusammenhang zum Dopplereffekt beschrieben. Es werden Gleichungen für den Dopplerversatz f_d sowie seine zeitliche Ableitung, die Dopplerrate $\dot{f_d}$ hergeleitet. Sie werden in der Positionsbestimmung verwendet.

Der Satellit bewege sich in einem Kreisorbit um die Erde, mit einer Höhe von h über dem mittleren Erdradius. Der Sender befinde sich an einem stationären Punkt auf der Erdoberfläche. Jede Bewegung, die der Sender vollführt sei so gering gegenüber der Geschwindigkeit des Satelliten, dass sie zu 0 angenommen werden kann. Eine Skizze des Szenarios ist in Abbildung 1.1 zu sehen. Die Koordinatenachsen r_x und r_y bilden eine an der Erdoberfläche tangentiale Fläche am Nadirpunkt des Satelliten. Der Sendetag ist in Punkt T platziert. Seine Projektion in die Ebene kann in Polarkoordinaten (r, φ) oder in kartesischen Koordinaten $(r_\mathrm{x}, r_\mathrm{y})$ beschrieben werden. r_x bezeichnet den Abstand vom Nadirpunkt in Flugrichtung, r_y stellt den horizontalen Abstand zur Flugbahn dar. Der Satellit bewegt sich relativ zum Sender unter einem Winkel α.

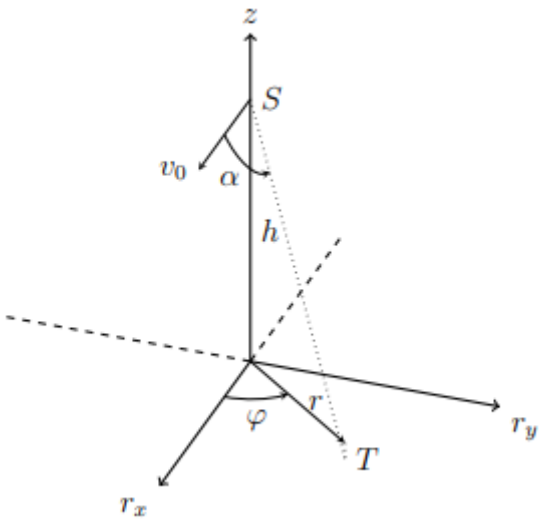

Abbildung 1.1: Skizzierung des Überflugs

Der Satellit bewegt sich mit einer Bahngeschwindigkeit v_0, welche sich durch den Ausgleich zwischen Gravitationskraft und Zentripetalkraft ergibt:

$$G \cdot \frac{M \cdot m}{(R+h)^2} = \frac{m \cdot {v_0}^2}{R+h}, v_0 = \sqrt{\frac{G \cdot M}{R+h}} \tag{1.1}$$

Relativ zum Tag kommt als Bewegung noch die Erdrotation dazu. Diese verändert die Geschwindigkeit des Satelliten relativ zum Boden in Abhängigkeit der Satellitenposition:

$$\vec{v} = \overrightarrow{v_0} - \overrightarrow{\omega_e} \times \overrightarrow{OS} \tag{1.2}$$

Der Punkt O ist dabei das Massezentrum der Erde, der Vektor $\overrightarrow{OS}$ stellt also den Raumvektor vom Massezentrum der Erde zum Satelliten dar. $\overrightarrow{\omega_e}$ ist die Rotation. Da die Erde sich nur um die Polarachse dreht, ist für die Höhe lediglich der Abstand von dieser entscheidend. Dieser ist abhängig von dem momentanen Breitengrad lat. Die Richtung des Bewegungsanteils ist grundsätzlich negative Ostrichtung mit dem Einheitsvektor e_e. Die Gleichung vereinfacht sich also folgendermaßen:

$$\vec{v} = \overrightarrow{v_0} - \omega_e \cdot \cos(lat) \cdot (R+h) \cdot \overrightarrow{e_e} \tag{1.3}$$

In einem lokalen ENU-System besteht die Geschwindigkeit aus zwei Anteilen, die in Ost- und Nordrichtung aufgeteilt sind. Sie teilt sich über den Winkel der lokalen Inklination α_A auf, welche die Bewegungsrichtung des Satelliten im Überflugsgebiet angibt:

$$\vec{v} = v_o \cdot \sin(\alpha_A) \cdot \overrightarrow{e_n} + v_o \cdot \cos(\alpha_A) \cdot \overrightarrow{e_e} - \omega_e \cdot (R+h) \cdot \cos(lat) \cdot \overrightarrow{e_e} \tag{1.4}$$

Betrag und neuer lokaler Inklinationswinkel werden gemäß Vektoraddition berechnet. Die Winkel und Beträge sind in Abbildung 1.2 skizzenhaft dargestellt.

$$\begin{aligned} v = |\vec{v}| &= \sqrt{(v_o \cdot \sin(\alpha_A))^2 + (v_o \cdot \cos(\alpha_A) - \omega_e \cdot (R+h) \cdot \cos(lat))^2} \\ \tan({\alpha_A}') &= \frac{v_o \cdot \sin(\alpha_A)}{v_o \cdot \cos(\alpha_A) - \omega_e \cdot (R+h) \cdot \cos(lat)} \end{aligned} \tag{1.5}$$

Der Betrag der Winkelgeschwindigkeit der rotierten Kreisbewegung wird für jeden lokalen Punkt der Bahn näherungsweise beschrieben, sodass die Bahn geradlinig bleibt. Für kurze Überflugszenarien ist

diese Näherung ausreichend. Die punktuelle Geschwindigkeit v wird dafür durch den Abstand des Satelliten vom Massezentrum der Erde geteilt.

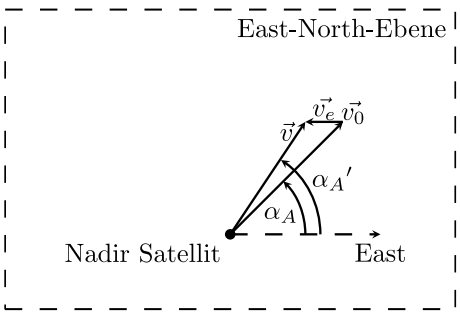

Abbildung 1.2: Definition der lokalen Inklination

$$\omega = \frac{v}{R+h} \tag{1.6}$$

Der Dopplereffekt bei elektromagnetischen Wellen hat relativistische Ursachen, anders als bei Materiewellen, wie zum Beispiel Schallwellen. Die vom Satelliten beobachtete Frequenz $f_c{}'$, welche vom Sender als Frequenz f_c ausgestrahlt wird, stellt sich wie folgt dar:

$$f_c{}' = \frac{\sqrt{1-\frac{{v_0}^2}{c^2}}}{1-\frac{v_0}{c}\cdot\cos\alpha} \tag{1.7}$$

Der Winkel α beschreibt dabei den eingeschlossenen Winkel zwischen Bewegungsrichtung des Satelliten und Richtungsvektor von Satellit zu Sender. Er ergibt sich aus der Definition des Skalarproduktes:

$$\cos\alpha = \frac{\overrightarrow{v_0}\cdot\overrightarrow{SP}}{v_0|SP|} \tag{1.8}$$

Der Richtungsvektor von Satellit zu Sender ergibt sich aus den Koordinatenbeziehungen zu folgendem Wert:

$$\overrightarrow{SP} = \begin{pmatrix} r_x \\ r_y \\ z \end{pmatrix} \tag{1.9}$$

Aus der Abbildung der tangentialen Fläche vom Nadirpunkt auf die Kugelgestalt der Erde ergibt sich die z-Komponente. Sie ist in Abbildung 1.3 graphisch dargestellt:

$$z = -(h + R - \sqrt{R^2 - r^2}) \tag{1.10}$$

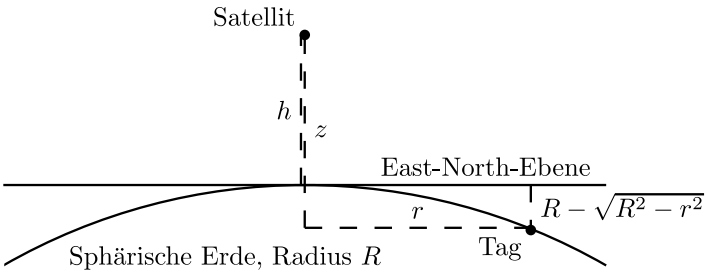

Abbildung 1.3: Skizze zur Definition der z-Koordinate des Richtungsvektors

Mit $\overrightarrow{v_0} = v_0 \cdot \overrightarrow{e_x}$ und (1.8), folgt daraus der Zusammenhang für die Ortsabhängigkeit des Winkels zwischen Geschwindigkeits- und Richtungsvektor:

$$\cos\alpha = \frac{r_x}{\sqrt{r^2 + (h + R - \sqrt{R^2 - r^2})^2}} \tag{1.11}$$

Durch Einsetzen in Gleichung 1.3 lässt sich ein Ortszusammenhang für die Dopplerfrequenz festlegen:

$$f_c{}' = f_c \cdot \frac{\sqrt{1 - \frac{{v_0}^2}{c^2}}}{1 - \frac{v_0}{c} \cdot \frac{r_x}{\sqrt{r^2 + (h + R - \sqrt{R^2 - r^2})^2}}} \tag{1.12}$$

Als Dopplerverschiebung f_d wird der absolute Frequenzversatz zwischen Sender und Empfänger bezeichnet, welcher durch den Dopplereffekt ausgelöst wird:

$$f_d = f_c' - f_c \tag{1.13}$$

Für die Darstellung des Verlaufs der Dopplerparameter wurden Szenarioparameter für die Simulation festgelegt. Diese sind in Tabelle 2.4 eingetragen. Mit der Veränderung der Orbithöhe des Satelliten ändert sich ebenso seine Geschwindigkeit und damit auch die Dopplerverschiebung. Die Mittenfrequenz geht multiplikativ in den Dopplereffekt ein.

Tabelle 1.1: Parameter des beispielhaften Szenarios

Orbithöhe des Satelliten	$h = 400\ \mathrm{km}$
Geschwindigkeit des Satelliten	$v_0 = 7{,}67 \frac{\mathrm{km}}{\mathrm{s}}$
Mittelfrequenz des Senders	$f_c = 405\ \mathrm{MHz}$
Symbolrate und Bandbreite	$f_{sym} = 900\ \mathrm{kHz}$

Betrachtet man das Szenario über die Zeit, so verändert sich die Position des Satelliten. Dadurch werden Abstand und Winkel zum Sender verändert. Die Geometrie ist ausschlaggebend für die Höhe der Dopplerverschiebung, somit ändert auch diese sich zeitlich. In welchem Maß gibt die Höhe der Dopplerrate an. Sie wird folgendermaßen definiert:

$$\dot{f}_d(t) = \frac{df_d}{dt} = f_c \cdot \frac{\sqrt{1 - \frac{{v_0}^2}{c^2}}}{1 - \frac{v_r(t)}{c}} \cdot \frac{\dot{v_r}(t)}{c - v_r(t)} = f_c{}' \cdot \frac{\dot{v_r}}{c - v_r} \tag{1.14}$$

Die Ableitung der Relativgeschwindigkeit ergibt sich aus dem Zeitverlauf der Geometrie. In Abbildung 1.4 ist die Ortsabhängigkeit der Dopplerverschiebung und der Dopplerrate abgebildet. Der Farbwert codiert jeweils die Dopplerverschiebung f_d, welche dem absoluten Frequenzversatz zwischen Empfänger und Sender entspricht bzw. die Dopplerrate $\dot{f}_d$. Der Farbverlauf ändert sich mit der Entfernung des Tags in Flugrichtung sowie senkrecht zur Flugrichtung des Satelliten. Während sich der Satellit in der Mitte bei den Koordinaten $(0{,}0)$ befindet und sich in horizontal positive Richtung bewegt, kann der Tag frei positioniert werden. Repräsentiert ist er in diesem Fall durch das schwarze Kreuz. Die Farbwerte der Dopplerverschiebung, die durch das Festlegen eines bestimmten Frequenzwerts entstehen, haben eine größere Innenwölbung, je größer die Entfernung zur Flugbahn des Satelliten wird. Die Ortsabhängigkeit der Dopplerrate verläuft grundsätzlich negativ und ist betragsmäßig am höchsten, wenn sich der Tag genau unter dem Satelliten an der Nadirposition befindet. Mit steigender Entfernung vom

Tag zum Satelliten verringert sich der Betrag der Dopplerrate. Die Konturlinien stellen nahezu elliptische Bahnen dar und kerben sich entlang der Flugbahn ein, je größer die Entfernung zum Satelliten wird.

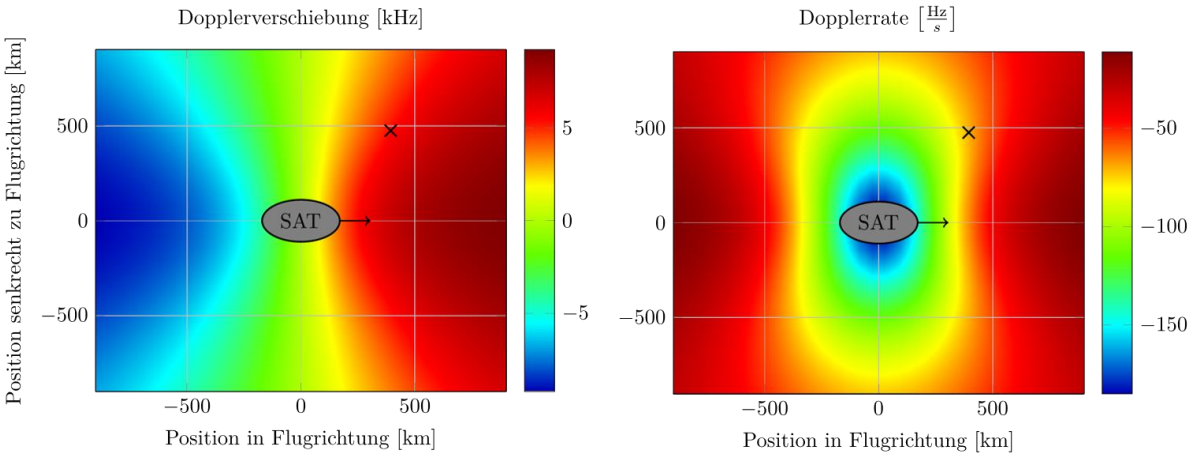

Abbildung 1.4: Ortsabhängigkeit der Dopplerverschiebung und der Dopplerrate

In Abbildung 1.5 ist dargestellt, wie die Position des Tags aktuell ermittelt wird. Die rote Ortskurve der Frequenzverschiebung u und die gelbe Ortskurve der Dopplerrate v werden überlagert. Der Schnittpunkt beider Kurven entspricht der Tagposition. Dabei gibt r_x den Abstand entlang der Flugbahn, die Along-Track Distanz und r_y den Abstand entgegen der Flugbahn, die Cross-Track Distanz im Überflugsgebiet G an.

Die damit erzielbare Genauigkeit der Position hängt stark davon ab, wie gut der bei der Übertragung entstandene Frequenzversatz geschätzt werden kann. Daher werden im ersten Teil Verfahren zur genaueren Schätzung dieses Frequenzversatzes untersucht.

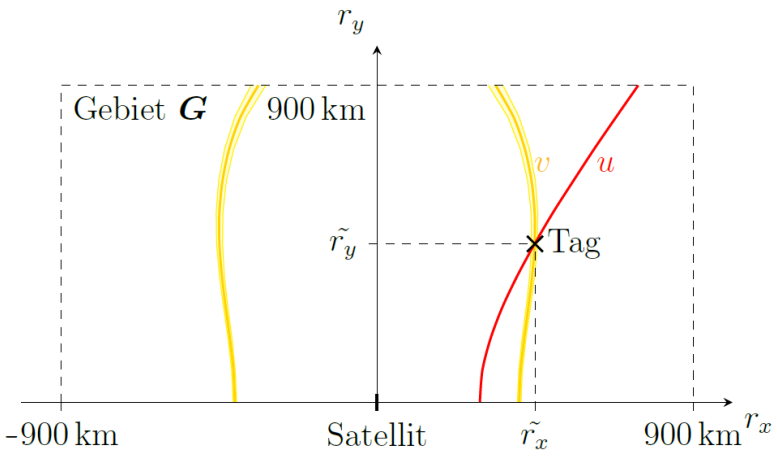

Abbildung 1.5: Ermittlung der Tagposition

Die technischen Herausforderungen, die durch die Umstellung des Verfahrens zur Positionsbestimmung auf die Nutzung des Dopplereffekts entstehen, sind hauptsächlich die folgenden: [1]

- Tag-Übertragungsleistung soll niedrig sein, um die Batterielaufzeit zu verlängern, wodurch das Signal-zu-Rausch Verhältnis (SNR) sehr niedrig wird (-30 bis -20dB)
- Die Signale der Tags werden unkoordiniert gesendet. Um Störungen zu vermeiden, sollen diese untereinander quasi-orthogonal sein
- Das Signal wird eine hohe, nicht vorhersagbare Frequenzverschiebung durch den Dopplereffekt verzeichnen

Da das Dopplerfrequenzsignal auf der Übertragungsstrecke mit Störeffekten belegt wird, müssen diese auf der Empfängerseite zunächst ermittelt und korrigiert werden, bevor der Dopplerfrequenzverlauf für die Ortung eingesetzt wird. Die dafür nötige Zeit- und Frequenzsynchronisation wird in Abschnitt 2 vorgestellt. Die erzielbare Genauigkeit der Positionsschätzung hängt stark von der Qualität des Dopplerfrequenzverlaufs ab. Diese wird maßgeblich davon beeinflusst, wie gut die bei der Übertragung entstandenen Störungen korrigiert werden können. In der Arbeit zum Doppler-Ranging-Empfänger ist bereits ein Frequenzschätzverfahren implementiert, das in dieser Arbeit als $Differenzverfahren$ bezeichnet wird. Es wird ein zusätzliches Verfahren für eine genauere Frequenzschätzung angewendet, welches auf der Fast Fourier Transformation basiert und dementsprechend in dieser Arbeit als $FFT - Verfahren$ betitelt wird. Ziel ist es, die Frequenzschätzung durch das $FFT - Verfahren$ mit höherer Auflösung umsetzen zu können, um auch in der Positionsschätzung genauer werden zu können. Eine Übersicht der angewendeten Frequenzschätzverfahren ist in Abbildung 1.6 zu sehen.

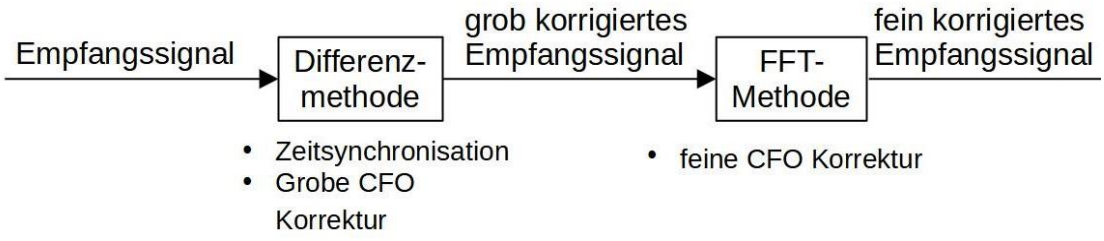

Abbildung 1.6 Übersicht der angewendeten Verfahren in der Dopplerfrequenzschätzung

Implementiert werden die Frequenzschätzverfahren auf der Empfängerseite der Übertragungsstrecke, die in Abbildung 1.7 zu sehen ist. Anschließend an die Verbesserung der Dopplerfrequenzschätzung wird in Abschnitt 2.6 die Auswirkung auf die Genauigkeit des in [2] implementierten Positionsschätzalgorithmus untersucht.

Die weiteren Schätzverfahren ermitteln auf Grundlage der Dopplerfrequenzsignale die zugehörige sogenannte maximale Elevation φ_{max}, deren Bedeutung in Abschnitt 3 erläutert wird. Dafür werden Verfahren des Maschinellen Lernens in Kapitel 3.4 und die Maximum-Likelihood-Schätzung in Kapitel 4 implementiert. Aus der maximalen Elevation werden schließlich die Along-track-Distanz r_x und Cross-track-Distanz r_y ermittelt. Zuletzt wird das bereits erwähnte Symmetrieproblem in der Ortung in Kapitel 5 untersucht.

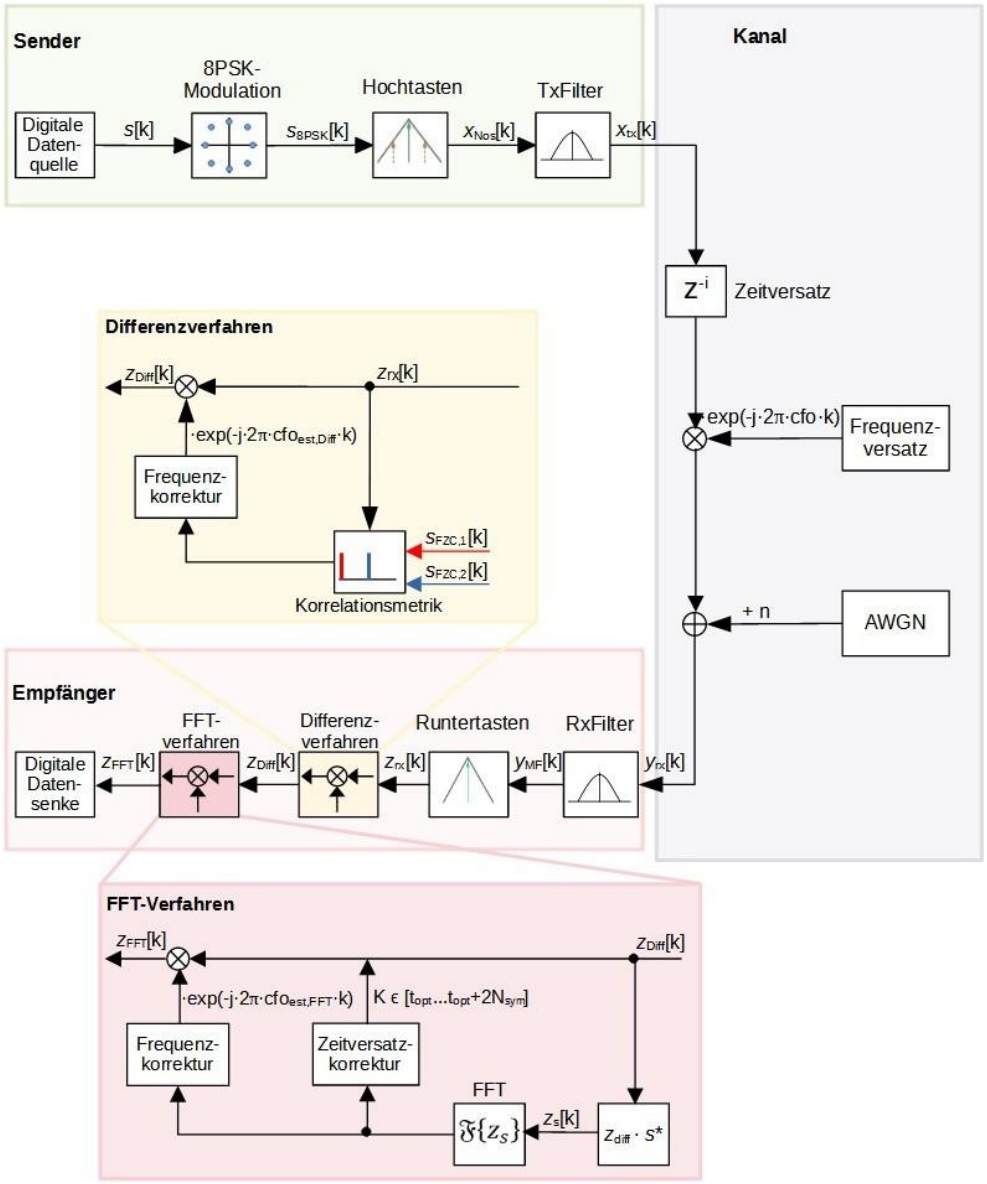

Abbildung 1.7: Schema der Signalverarbeitungsstrecke

Um den Ablauf der Positionsschätzung vom Empfangssignal bis zur tatsächlichen Position des Senders auf der Erde besser nachvollziehen zu können, ist in Abbildung 1.8 ein zusammenfassendes Schema zu sehen. Die Positionsschätzung wird mit einem synthetischen Doppler-Datensatz implementiert, dessen Signalqualität schrittweise reduziert wird und wird anschließend mit real aufgezeichneten Dopplersignalen verschiedener Satellitenüberflüge umgesetzt.

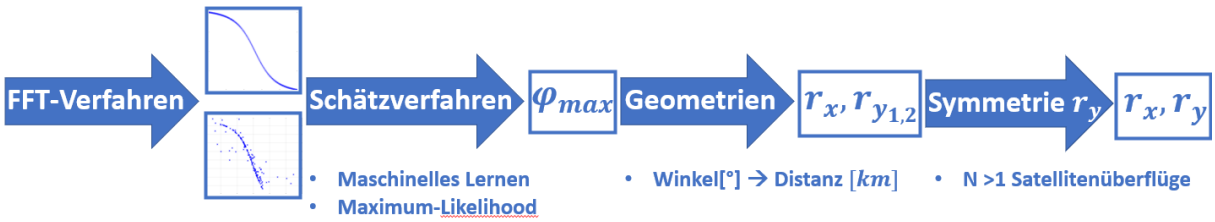

Abbildung 1.8: Übersicht der Arbeitsschritte vom Empfangssignal bis zur geschätzten Position

2 SCHÄTZUNG DES FREQUENZVERSATZES

Es wurde bereits dargelegt, dass die Dopplerfrequenzsignale, die bei einem Satellitenüberflug über ein Gebiet G entstehen, zur Positionsschätzung eingesetzt werden können. Da die Dopplersignale auf Empfängerseite mit Störeffekten versehen vorliegen, gilt es diese zu korrigieren, bevor sie zur Ortung eingesetzt werden. Dafür wird die Signalübertragung in Form einer MATLAB Simulation umgesetzt und ausgewertet. In Abschnitt 2.1 wird die Übertragungsstrecke erläutert. Anschließend werden die Grundlagen der darin zu findenden Zeit- und Frequenzsynchronisation sowie die dafür verwendete Frank-Zadoff-Chu Sequenz in Kapitel 2.2 definiert. Die Erläuterung zum verfeinerten Frequenzschätzverfahren ist in Abschnitt 2.3 zu finden. Die Genauigkeit der Frequenzschätzverfahren und die Auswirkung auf die Ortungsgenauigkeit wird in den Abschnitten 2.4 bis 2.6 ausgewertet.

Die Zeit- und Frequenzsynchronisation des empfangenen Signals ist eine große Herausforderung. Es wird eine Präambel eingesetzt, welche bestimmte Eigenschaften vorweisen muss und deshalb näher erläutert wird. Des Weiteren wird die Algorithmik der darauf basierenden Zeit- und Frequenzschätzung entwickelt.

2.1 MODELLIERUNG DER ÜBERTRAGUNGSSTRECKE

Die Übertragungsstrecke setzt sich aus einem Sender-, Kanal- und Empfängermodell zusammen. Auf der Sendeseite der Übertragungsstrecke wird die Frank-Zadoff-Chu-Sequenz erzeugt und anschließend durch den Kanal verändert. Eine schematische Darstellung ist in Abbildung 2.1 zu finden.

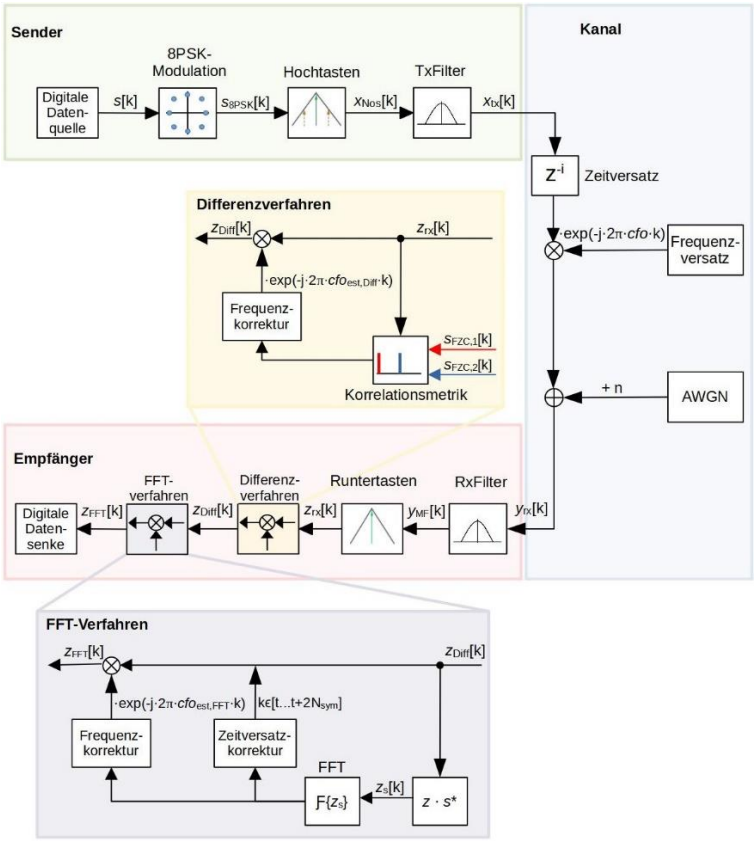

Abbildung 2.1: Umsetzung der Übertragungsstrecke samt Schätzverfahren

2.1.1 Sendermodellierung

Das Sendesignal entspricht der verketteten FZC-Sequenz s. In Abschnitt 2.2 wird es definiert und es wird erläutert, weshalb es sich für die Detektion des Empfangssignals eignet. Das Signal wird auf 8-PSK Symbole gerundet und anschließend mit dem Oversamplingfaktor N_{OS} hochgetastet. Dafür wird Zeropadding angewendet und die erweiterte Funktion wird anschließend mit einem Root Raised Cosine (RRC) Filter pulsgeformt. Es wird ein Roll-Off Faktor von $r = 0{,}3$ verwendet. Das Ergebnis ist das gesendete Signal s_{tx}, welches an das Modell des Kanals weitergegeben wird.

2.1.2 Kanalmodellierung

Im Lauf der Signalübertragung wirken verschiedene Effekte auf das Signal ein. Um diese darzustellen, wurde ein Modell für den Kanal implementiert. Es umfasst die Aufprägung eines CFO und einen Zeitoffset, welcher durch dem Signal vorangestelltes, also führendes Rauschen dargestellt wird. Zusätzlich wird normalverteiltes Rauschen bei Eingabe eines definierten Signal-Rausch-Abstandes hinzugefügt. Auf diese Weise können die Auswirkungen des Dopplereffektes sowie die Signalqualität in die Auswertung eingehen. Der Empfänger wertet das durch den Kanal veränderte Signal aus. Auf diesen Vorgang wird im Folgenden eingegangen.

$$y_{\mathrm{rx}}[k] = s_{\mathrm{tx}}[k - i] \cdot \exp(-\mathrm{j} \cdot 2 \cdot \pi \cdot CFO \cdot k) + n \tag{2-1}$$

2.1.3 Empfängermodellierung

In der Empfängerstufe wird das Signal zuerst mit dem Matched Filter gefaltet. Dies ist ein RRC-Filter mit dem gleichen Roll-Off Faktor wie der des Senders und ergänzt diesen zu einem vollständigen Raised Cosine Filter. Da es sich um einen Nyquistfilter handelt, ermöglicht es Inter-Symbol-Interferenz-freie Abtastung. Es ist gleichzeitig ein Anti-Alias-Filter für das anschließende Heruntertasten auf den Symboltakt. Nach dem Heruntertasten werden die empfangenen Symbole z_{rx} ausgewertet. Beim Heruntertasten wird eine Polyphase ausgewählt und weiterverwendet. Der Rest der empfangenen Daten wird verworfen. Welche Polyphase verwendet wird, wird bei jeder Messung zufällig ausgewählt. Im Samplestrom auf der Empfängerseite sind nur die Hauptabtastwerte entlang einer bestimmten Polyphase von Inter-Symbol-Interferenz befreit. Inter-Symbol-Interferenz (ISI) bedeutet, dass Störungen zwischenzeitlich aufeinander folgenden Sendesymbolen auftreten. Da die Polyphase zufällig ausgewählt wird, ist nicht gewährleistet, dass es sich um ISI-freie werte handelt. Dies hat erheblichen Einfluss auf das SNR der empfangenen Symbole und somit deren Qualität. Je größer der Abstand der ausgewählten Polyphase zur ISI-freien Polyphase ist, desto größer wird der Einfluss durch ISI. Bei einer ISI-freien Polyphase $pol = 1$ weisen die Nachbarphasen zwei und fünf also schlechtere Qualität auf, sind allerdings immer noch besser als die Polyphasen drei und vier. Die Simulation gibt über eine Monte-Carlo Simulation die gemittelte Performance der empfangenen Symbole an, die nur teilweise ISI-frei ausgelesen werden.

2.2 DIFFERENZVERFAHREN

Der Sendetag soll im Lauf des Überflugs ein Signal übertragen, auf deren Grundlage der Satellit dessen Position bestimmen kann. Die Positionsbestimmung des Sendetags benötigt dafür zwei verschiedene Parameter. Für die erste Implementation werden dafür die Dopplerverschiebung und die Dopplerrate genutzt. Für die Bestimmung aus der Signalübertragung werden Symbolfolgen benötigt, deren Eigenschaften den Frequenzversatz in Auswertungsparameter überführen. Als Folgen, die dies erfüllen, werden Franc-Zadoff-Chu (FZC) Sequenzen untersucht.

Bei der Übertragung der Signale ist entscheidend, die Zeit- und Frequenzsynchronisation des empfangenen Signals zu gewährleisten. Die betrachtete Übertragungsumgebung ist geprägt durch starke willkürliche Dopplerverschiebungen und sehr geringe Signal-zu-Rausch Abstände. Daher wird in der ICARUS-Übertragung eine *CAZAC* Sequenz (*„constant amplitude, zero auto correlation“*) für die kreuzkorrelationsbasierte Synchronisation verwendet. Der Vorteil dieser Sequenzen besteht in der Robustheit gegenüber hohen Frequenzversätzen. Eine spezielle CAZAC Sequenz, welche den Anforderungen entspricht, ist die Frank-Zadoff-Chu-Sequenz (FZC). FZC-Folgen haben ebenfalls eine konstante Amplitude und sind äußerst robust gegenüber hohen Frequenzversätzen. Sie weisen eine zyklische Autokorrelation von 0 auf und eignen sich dadurch gut als Präambel. Sie finden unter anderem im LTE-Protokoll als Synchronisationspräambel Anwendung [4–6]. Ihre Autokorrelationseigenschaften bei verschiedenen CFOs ist in Abbildung 2.2 dargestellt.

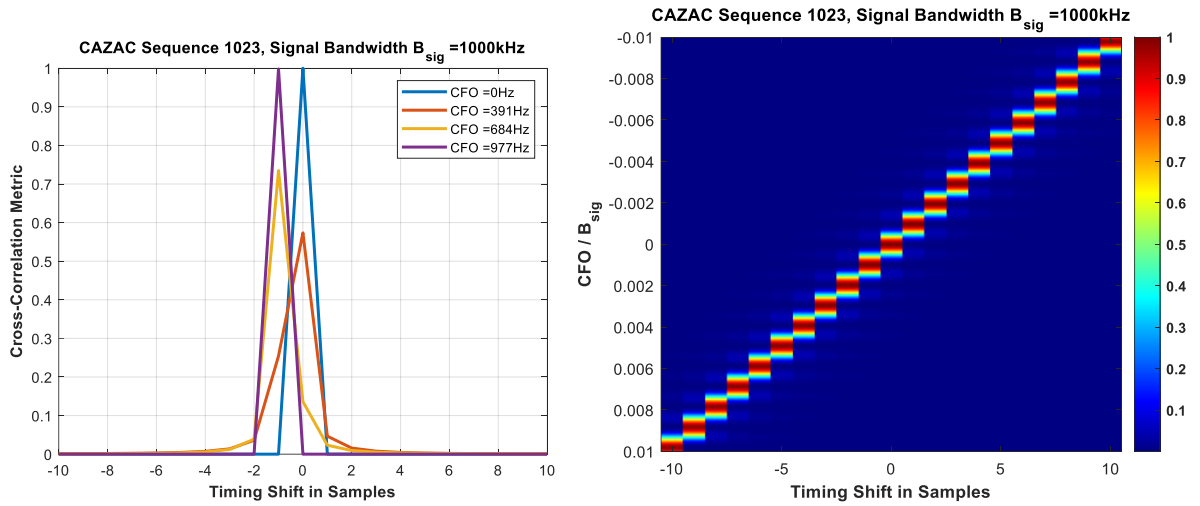

Abbildung 2.2: Kreuzkorrelationsergebnisse einer einzelnen CAZAC-Sequenz für verschiedene CFOs

Die Peakamplitude bleibt gut zu erkennen, selbst wenn ein großer Frequenzversatz auf das Signal aufgeprägt ist. Diese Eigenschaft ist sehr wichtig, da die Amplitude im implementierten Verfahren auch bei hohen Frequenzverschiebungen noch detektierbar bleiben muss. Zusätzlich weist die FZC-Sequenz eine spezifische lineare Zeitverschiebung auf, welche abhängig vom CFO ist. Dieser Zusammenhang kann für die Frequenzschätzung genutzt werden [7]. Klicken oder tippen Sie hier, um Text einzugeben.

Die beiden FZC-Präambeln werden jeweils durch folgende Berechnungsvorschrift erstellt [10]:

$$s_{FZC}[k] = \exp\left(\frac{j \cdot \pi \cdot d \cdot u \cdot k\left(k + c_f + 2q\right)}{N_{sym}}\right), c_f = N_{sym}\ mod\ 2 \qquad (2.1)$$

Die Folge ist eine lineare Chirp-Sequenz. Dabei handelt es sich um ein Signal, dessen Frequenz sich über die Zeit kontinuierlich verändert. Abbildung 2.2 zeigt, in welcher Weise sich die Position des Korrelationspeaks verändert. Dafür wurde auf die originale FZC-Sequenz mit einer Länge von N_{sym} = 1023 ein kleiner Frequenzversatz aufgeprägt und die entstandene Folge anschließend mit der originalen Sequenz kreuzkorreliert.

Die Position des Peaks t_p verschiebt sich linear mit dem Frequenzversatz CFO. Dies geschieht nach folgender Vorschrift [11]:

$$t_p = t - \frac{1}{u} \cdot N_{sym} \cdot \mathrm{CFO} \tag{2.2}$$

Um Startzeitpunkt und Frequenzversatz der Folgen zu ermitteln, ist eine zweite konjugiert komplexe Sequenz erforderlich. Die beiden Sequenzen weisen unterschiedliche Werte u auf. Die beiden Subsequenzen werden im Sender verkettet:

$$s = \left[s_{FZC,1}, s_{FZC,2}\right] \tag{2.3}$$

Die Parameter zur Erzeugung der beiden verketteten Subsequenzen sind in Tabelle 2.1 aufgeführt.

Tabelle 2.1: Downlink beacon sync fields [7]

FZC parameter	Subsequence 1	Subsequence 2
d	-1	1
u	1	1
q	0	0
N_{sym} Uplink	16383 = 2^{14} - 1	16383 = 2^{14} - 1
N_{sym} Downlink	255 = 2^8 - 1	255 = 2^8 - 1

Dabei ergibt der Wert $d = -1$ die Konjugiert komplexe Sequenz der mit $d = 1$ erzeugten Sequenz. Die beiden konjugiert komplexen Sequenzen werden verwendet, um den symmetrischen Zeitversatz zu identifizieren. Der zeitliche Korrelationspeak beider Sequenzen hängt in entgegengesetzter Richtung in gleicher Weise vom CFO ab. Zu sehen ist dieser Effekt in Abbildung 2.2. Während sich der Korrelationspeak der ersten Subsequenz für steigende CFO-Werte in positive Richtung und für negative CFO-Werte in negative Richtung verschiebt, verhält sich der Korrelationspeak für die konjugiert komplexe Subsequenz 2 entgegengesetzt.

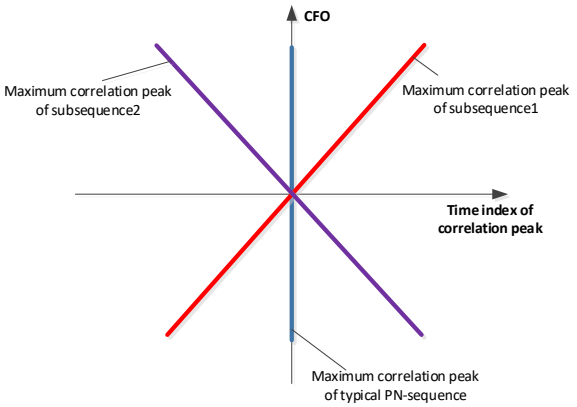

Abbildung 2.3: zeitliche Verschiebung der Korrelationspeaks je CFO [1]

Die gegenläufige zeitliche Verschiebung der beiden Korrelationspeaks stellen die Grundlage für die Zeit- und Frequenzsynchronisation dar. Nach der Detektion des ersten Korrelationspeaks (von Sequenz 1) wird der zweite Korrelationspeak (von Sequenz 2) ermittelt. Der Abstand beider Peaks ist direkt proportional zum im Vorfeld aufgeprägten CFO. In Abbildung 2.3 ist das Auseinanderlaufen bzw. Annähern der Peaks in Abhängigkeit vom Frequenzversatz dargestellt. Für Signale ohne Frequenzversatz entspricht der Abstand D_{norm} der Peaks der Signallänge N_{sym}. Für negative Frequenzverschiebungen verkleinert sich der Abstand, während er für positive CFOs größer wird. Aus der Differenz beider Peaks lässt sich der CFO also ermitteln.

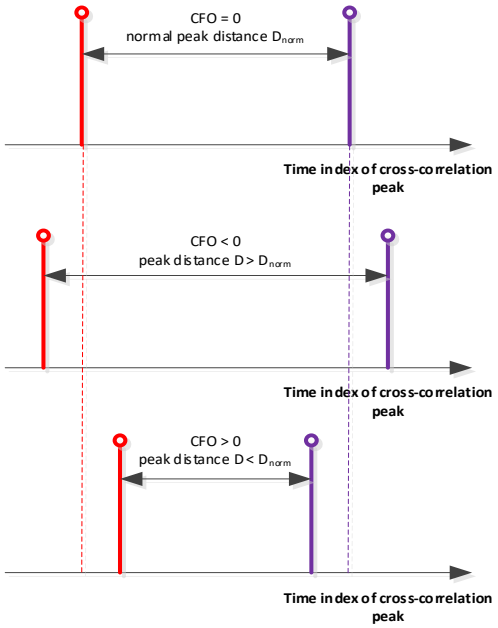

Abbildung 2.4: Abstand der Peaks in Abhängigkeit vom CFO [1]

Der freie Parameter u, welcher ebenfalls in Tabelle 2.1 aufgelistet ist, wird als Wurzel bezeichnet und stellt den Anstieg des Frequenzverlaufes dar. Für jedes ganzzahlige u verschieden von 0 entsteht eine neue orthogonale FZC-Folge. Mit einem u von 1 ändert sich die Frequenz insgesamt um die Symbolfrequenz f_{sym}, welche auf $900\ kHz$ festgelegt ist. Durch Veränderung des Konjugationsparameters q ändert sich das Korrelationsverhalten der Folge nicht. Es wirkt wie ein konstanter Frequenzversatz auf eine Folge gleicher Wurzel. Ein q von 0 legt die Startfrequenz auf $0\ Hz$ fest.

Die Werte der Teilsequenzen liegen alle auf dem komplexen Einheitskreis. Zur Umsetzung der Kreuzkorrelation werden diese jeweils auf den Wert einer 8-PSK Konstellation gerundet, siehe Abbildung 2.4 [12]. Für die komplexe Multiplikation mit einer 8-PSK Konstellation müssen in der Realisierung nur 3 Bit je Element in einer LUT hinterlegt werden, während die hochaufgelöste Multiplikation mit einer originalen FZC-Sequenz eine sehr viel höhere Speicherkapazität erfordern würde. Da die Näherung durch die 8PSK-Konstellation Performancereduzierung in nur sehr geringem Maß bedeutet, wird diese in der Realisierung der Kreuzkorrelation verwendet. Größere Approximationen wie beispielsweise auf QPSK oder 8-PSK Square, um die komplexen Multiplikationen durch vorzeichenbehaftete Additionen zu ersetzen sind je nach Empfängerkomplexität ebenso möglich.

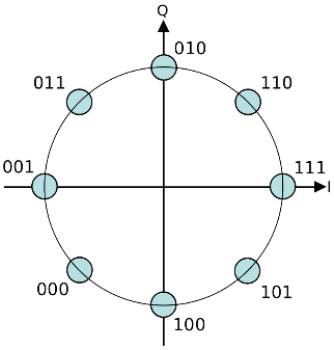

Abbildung 2.5: 8-PSK Konstellation [1]

Der geschätzte Frequenzversatz $f_{d,est}$ ergibt sich aus $d_{peak} = t_2 - t_1 - N_{sym}$, dem Abstand beider Maxima der Korrelationsmetrik entsprechend Abbildung 2.3 und dem Frequenzversatz je Tap bzw. Frequenzanstieg d_f.

$$f_{d,est} = d_{peak} \cdot d_f \tag{2.4}$$

Der Frequenzanstieg d_f definiert, wie hoch der Frequenzversatz ist, wenn der Peak um einen Tap abweicht und entspricht somit der Auflösung des Symboltaktes f_{sym} in Bezug auf die doppelte Signallänge N_{sym}.Es ergibt sich folgende Auflösung

$$d_f = \frac{-f_{sym}}{2 \cdot N_{sym}} = \frac{-900\text{kHz}}{2 \cdot (2^{14} - 1)} = -27{,}4675\ {}^{\text{Hz}}/_{\text{Tap}} \tag{2.5}$$

Der Frequenzanstieg ist negativ definiert, um entsprechend Abbildung 2.3 abzubilden, bei einem Peakabstand kleiner als N_{sym}, eine positive Frequenzverschiebung und bei einem größeren Peakabstand eine negative Frequenzverschiebung zu erhalten. Normiert man die Frequenzauflösung mit der Symbolrate, so erhält man die folgende normierte Auflösung.

$$d_{\mathrm{cfo}} = \frac{d_f}{f_{sym}} = -3{,}0519 \cdot 10^{-5}\ {}^{1}/_{\mathrm{Tap}} \tag{2.6}$$

Der durch das Differenzverfahren geschätzte CFO ermittelt sich also wie folgt:

$$CFO_{\mathrm{est,dif}} = d_{peak} \cdot d_{cfo} \tag{2.7}$$

2.3 FFT-Verfahren

Nach der groben Schätzung des CFO im Differenzverfahren wird eine feinere Schätzung durchgeführt. Dem Verfahren liegt die namensgebende Fast Fourier Transformation zu Grunde. Dabei handelt es sich um ein Verfahren, welches nach der Zeit- und Frequenzsynchronisation im Zeitbereich entsprechend Abschnitt 2 das Signal nun zusätzlich im Frequenzbereich auswerten soll. Am Empfänger liegt folgendes Signal vor.

$$y_{\mathrm{rx}}[k] = s_{\mathrm{tx}}[k-i] \cdot \exp(\mathrm{j} \cdot 2 \cdot \pi \cdot \mathrm{CFO} \cdot k) + n[k] \tag{2.8}$$

Nach der Differenzkorrektur liegt das Signal z_{Diff} vor, welches anschließend für die FFT-Korrektur verwendet wird. Dabei entspricht z_{rx} dem gefilterten und runtergetasteten Empfangssignal y_{rx}:

$$z_{\mathrm{Diff}} = z_{\mathrm{rx}}[\mathrm{k}] \cdot \exp\left(-j \cdot 2 \cdot \pi \cdot \mathrm{CFO}_{\mathrm{est,dif}}\right) \tag{2.9}$$

Das bereits grob korrigierte Empfangssignal z_{Diff} ist weiterhin mit Rauschen $n[k]$ belegt und weist einen Restfehler der groben Frequenzkorrektur auf. Dieser soll im FFT-Verfahren durch eine erneute feinere CFO-Schätzung korrigiert werden. Das grob korrigierte Empfangssignal z_{Diff} wird entsprechend Gleichung (5.2) mit der Sendesequenz s konjugiert komplex multipliziert:

$$z_{\mathrm{s}} = s^* \cdot z_{\mathrm{Diff}} \tag{2.10}$$

Ziel ist es, das Signal auf die reelle Achse zu mischen, um nur noch den aufgeprägten CFO als harmonische Schwingung zu behalten. Skizzenhaft ist dies in Abbildung 2.6 dargestellt. Der weiterhin vorhandene komplexe Anteil wird mit Hilfe der FFT im Spektralbereich sichtbar. Sie wird wie folgt ermittelt:

$$Z_s[n] = \frac{1}{N}\sum_{k=0}^{N-1} z_s[k] \cdot e^{-j2\pi\frac{k\cdot n}{M}} \mid M = 2^p, p \in \mathbb{N} \tag{2.11}$$

Für das FFT-Verfahren ist entscheidend, wie viele Stützstellen verwendet werden, da diese in der Transformation über die Genauigkeit in der Frequenzauflösung entscheiden. In Tabelle 2.2 maximal möglicher Frequenzschätzfehler je Stützstellen ist die maximale Frequenzungenauigkeit Δf_{max} je Stützstellenanzahl angeben.

N_{FFT}	$\Delta f_{max}\ [Hz]$	$\Delta f_{max,normiert}$
2^{14}	$\pm$54,935	$\pm$6.1035·10^{-5}
2^{15}	$\pm$27.4667	$\pm$3.0518·10^{-5}
2^{16}	$\pm$13.7331	$\pm$1.5259·10^{-5}

2^{17}	± 6.8665	$\pm 7.6294 \cdot 10^{-6}$
2^{18}	± 3.4332	$\pm 3.8147 \cdot 10^{-6}$
2^{19}	± 1.7166	$\pm 1.9073 \cdot 10^{-6}$
2^{20}	± 0.8583	$\pm 9.5367 \cdot 10^{-7}$

Tabelle 2.2 maximal möglicher Frequenzschätzfehler je Stützstellen

Um mit dem FFT-Verfahren eine genauere Schätzung realisieren zu können, muss nun die Anzahl der Stützstellen so gewählt werden, dass sich eine höhere Auflösung ergibt. Da das verwendete Signal eine Gesamtlänge von $N_{sym} = 2^{15}$ aufweist, wird dementsprechend eine Mindestanzahl von $N_{FFT} = 2^{15}$ gewählt.

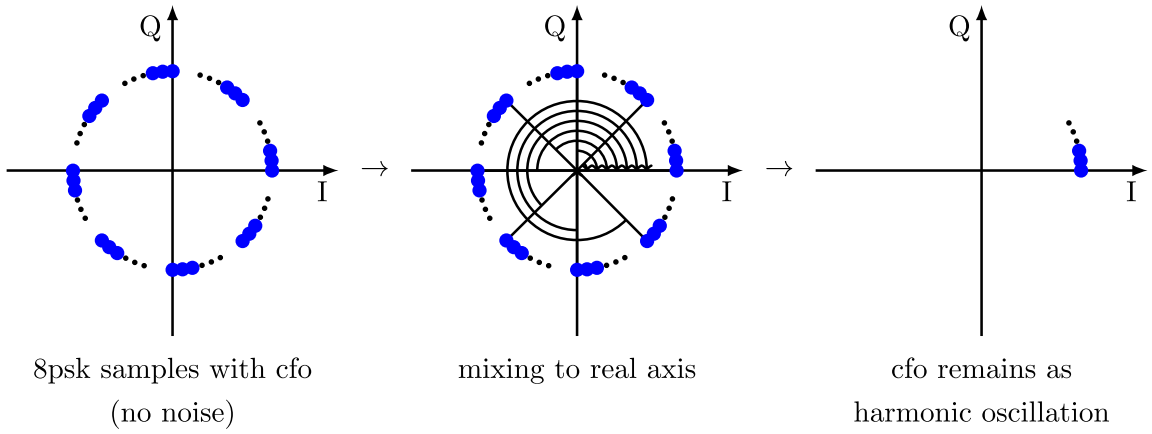

Abbildung 2.6: Mischung des Signals auf die reelle Achse

Abbildung 2.7 zeigt den Frequenzbereich des Signals. Zu sehen ist eine deutliche Spektrallinie, welche der Frequenzabweichung Δf entspricht [13]. Diese bildet den nach dem ersten Verfahren weiterhin vorhandenen Restfehler der Frequenzschätzung ab. Ebenso ist das im Kanal aufgeprägte Rauschen im gesamten abgebildeten Frequenzspektrum zu erkennen.

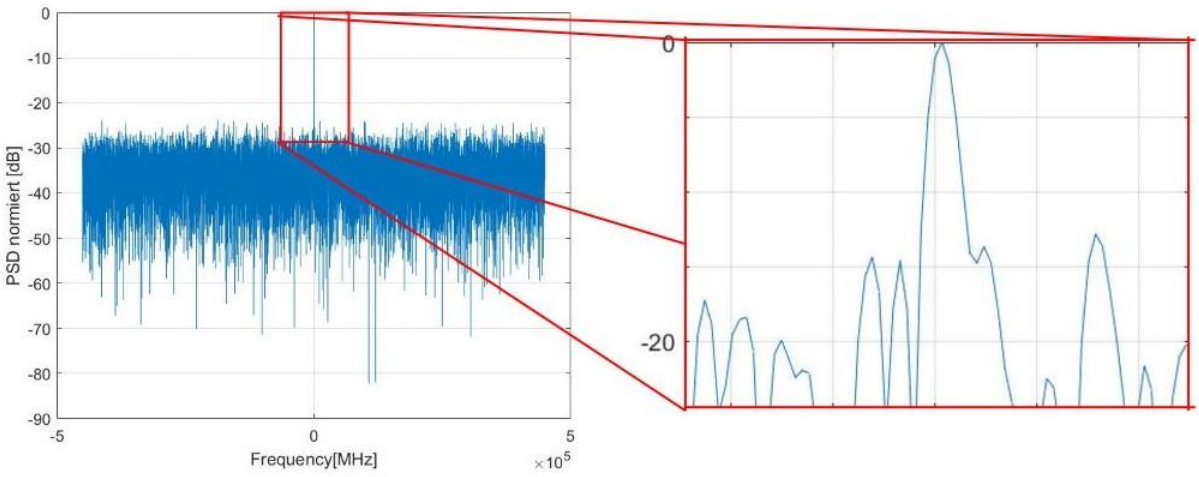

Abbildung 2.7: Signal im Spektralbereich nach Anwendung der FFT

Durch die Fouriertransformation einer diskreten harmonischen Signalfolge entstehen im Spektrum in der Regel mehrere Spektralanteile. Das ist auf die periodische Fortsetzung der Signalfolge mit Periode

N im Zeitbereich zurückzuführen [14]. Um die periodisch fortgesetzten Spektralanteile zu eliminieren, wird für die Frequenzanalyse eine Fensterung (Hanning-Filter) verwendet. Die Fensterung ist zugleich eine Verkürzung des Beobachtungszeitraums im Zeitbereich. Im Frequenzbereich führt diese Verkürzung zu einer Verbreiterung der Spektralfolge durch den sogenannten Leckeffekt. Der Leckeffekt beschreibt das Auftreten von Frequenzanteilen im mit der Fourieranalyse bestimmten Frequenzspektrum, die bei einem theoretisch möglichen unendlich langen Beobachtungszeitraum nicht vorkommen würden. Durch die spektrale Verbreiterung wirkt die Komponente einer Frequenz auf die Umgebung der anderen Frequenzanteile ein, wodurch die Auflösung im Spektrum reduziert wird. Es ist ein Phänomen, der sich nicht vermeiden, aber mit einer optimierten Fensterung durchaus verringern lässt [15, 16]. Auch in Abbildung 2.7 ist zu erkennen, dass es sich bei der vermeintlichen Spektrallinie nicht exakt um eine Linie, sondern um eine durch den Leckeffekt „verschmierte“ Amplitude handelt.

Für die Zeitsynchronisation des Empfangssignals wurde der Startzeitpunkt entsprechend Gleichung (2.8) ermittelt. Da der Startwert t ein gerundeter Wert ist, werden zusätzlich zu dem ausgeschnittenen Signal zwei weitere Signale untersucht. Dabei werden die beiden Nachbarwerte von t, also $t \pm 1$, ebenfalls als potenzielle Startpunkte untersucht, um möglichen Rundungsfehlern und somit falschen Signalausschnitten vorzubeugen. Für die drei verschiedenen weiterverarbeiteten Empfangssignale wird jeweils das Spektrum gebildet und das Maximum bestimmt. Da das Signal mit dem korrekten Startzeitpunkt immer die höchste Amplitude aufweist, wird dieses weiterverwendet. Das hängt damit zusammen, dass die FZC-Sequenz durch eine Verschiebung im Zeitbereich ebenfalls eine Verschiebung im Frequenzbereich erfährt. Da sich die Leistungsdichte des Signals für den Fall des fehlerhaften Startzeitpunkts auf zwei Spitzen verteilt, statt auf eine, sind in diesem Fall die Spitzen niedriger als für den korrekten Startzeitpunkt. In Abbildung 2.9 ist zu erkennen, dass die Amplitude am höchsten ist und es sich hierbei um den korrekten Startwert handelt.

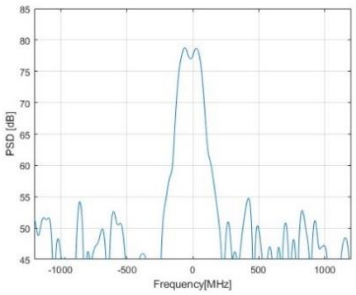

Abbildung 2.8: Spektrum des Signals mit Startzeitpunkt t-1

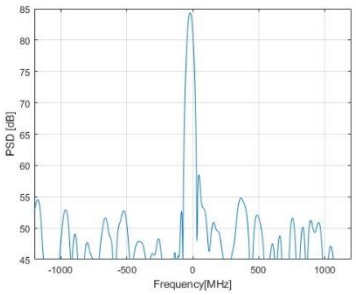

Abbildung 2.9: Spektrum des Signals mit Startzeitpunkt t

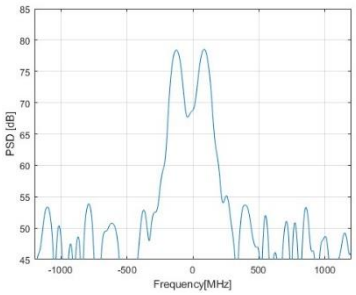

Abbildung 2.10: Spektrum des Signals mit Startzeitpunkt t+1

Nachdem dieses Verfahren für drei verschiedene Signale durchgeführt wurde, wird nun der korrekte Signalausschnitt ausgewählt. Dafür wird das Signal mit der größten Amplitude ausgewählt, da sich darüber das korrekte Signal definieren lässt. Ist der Startzeitpunkt tatsächlich verschoben, so entsteht nicht nur ein Maximum, sondern eine „Doppelspitze“, sodass die Amplitude niedriger ausfällt. Mit Hilfe dieser Vorgehensweise lässt sich die Zeitschätzung zuverlässiger gestalten.

Zur Umgehung des Auflösungsfehlers bei der FFT kann die Frequenztransformation des zeitdiskreten Signals auch frequenzkontinuierlich durchgeführt werden. Diese lässt sich auch als Kreuzkorrelation mit einer variablen harmonischen Schwingung beschreiben:

$$Z_s(\omega) = \frac{1}{N} \sum_{k=0}^{N-1} z_s[k] \cdot e^{-j \cdot 2\pi \cdot \omega \cdot k} \tag{2.12}$$

Das Signal $z_s[k]$ besteht aus einer komplexen harmonischen Schwingung mit aufgeprägtem additivem Rauschen. Für das Spektrum ergibt sich also Folgendes:

$$Z_s(\omega) = \frac{1}{N}\sum_{k=0}^{N-1}\left(e^{j\cdot 2\pi\cdot(cfo\cdot k+\varphi_0)} + n[k]\right)\cdot e^{-j\cdot 2\pi\cdot\omega\cdot k} \tag{2.13}$$

$$Z_s(\omega) = \frac{1}{N}\sum_{k=0}^{N-1}\left(e^{j\cdot 2\pi\cdot((cfo-\omega)\cdot k+\varphi_0)} + n[k]\cdot e^{-j\cdot 2\pi\cdot\omega\cdot k}\right) \tag{2.14}$$

$$Z_s(\omega) = \frac{1}{N}\sum_{k=0}^{N-1} e^{j\cdot 2\pi\cdot((cfo-\omega)\cdot k+\varphi_0)} + \frac{1}{N}\sum_{k=0}^{N-1} n'[k] \tag{2.15}$$

Der erste Teil ergänzt sich dann betragsmäßig zu 1, wenn $\omega = cfo$ gilt. Hier bildet sich das charakteristische Spektrum einer harmonischen Schwingung. Der zweite Term ist ein Rauschterm, dessen Varianz um den Faktor $1/N$ reduziert wird. Im kontinuierlichen Spektrum wird dann das Maximum gesucht. Damit ist der Schätzwert unabhängig einer Auflösung. Dies kann vor Allem in Bereichen größerer SNR für erhöhte Schätzgenauigkeiten sorgen, auf Kosten des Berechnungsaufwands. Im Folgenden wird dies *DTFT-Verfahren* genannt.

2.4 Performancevorhersage der Ortungsverfahren

Die mögliche Performance linearer Algorithmen der Ortungsverfahren lässt sich mittels theoretischer Varianzgrenzwerte über die Cramer-Rao Lower Bound ermitteln. Zu erwarten ist, dass die Ortungsgenauigkeit multiplikativ von der Genauigkeit der CFO-Schätzungen abhängt. Es wird mittels der Ermittlung der Performancegrenzwerte eingeordnet, ob eine Verbesserung der Datengrundlage im Verlauf der Bearbeitung notwendig wird. Die Definition der Cramer Rao Lower Bound geht von einer Likelihood-Funktion aus, welche der Schätzung zu Grunde liegt. In diesem Fall soll vom Zeitverlauf der Dopplerfrequenz auf die Position geschlussfolgert werden. Der Zeitverlauf ergibt sich aus (1.12) und der zeitlichen Bewegung des Satelliten:

$$f_c{}'(t) = f_c \cdot \frac{\sqrt{1-\frac{{v_0}^2}{c^2}}}{1-\frac{v}{c}\cdot\frac{r_x(t)}{\sqrt{r(t)^2+(h+R-\sqrt{R^2-r(t)^2})^2}}} \tag{2.16}$$

Über den Zeitverlauf werden zeitlich diskrete Messungen der Dopplerfrequenz durchgeführt. Es wird davon ausgegangen, dass die Messungen durch normalverteiltes Rauschen verfälscht wird. Damit ergibt sich eine Likelihood-Funktion, einen Frequenzwert X an einem Zeitpunkt t zu messen:

$$l(X,t) = \frac{1}{\sqrt{\sigma^2\cdot 2\pi}}\cdot e^{-\frac{\left(X-f_c{}'(t)\right)^2}{\sigma^2}} \tag{2.17}$$

Die Cramer-Rao Lower Bound definiert sich dann über die Fisher-Information der Schätzungen. Diese definiert sich:

$$I_{m,k}(\theta,t) = -E\left[\frac{\partial^2}{\partial\theta_m\partial\theta_k}\left(\ln\left(l(X,t)\right)\right)\right] \tag{2.18}$$

Die geschätzten Parameter $\theta = \left(r_x, r_y\right)^T$ sind die Position des Tags in Flugrichtung und der Abstand zur Flugbahn. In diesem Fall wird keine zeitunabhängige Zufallsvariable analysiert, sondern eine zeitvariante Größe über einen größeren Zeitbereich gemessen. Das bedeutet, dass die Schätzungen an den einzelnen Positionen kaum eigene Information tragen, sondern lediglich der Zeitverlauf Information besitzt. Dafür wird die Information des Szenarios über das bestimmte Integral im Zeitbereich des Überfluges bestimmt:

$$I(\theta) = \frac{n}{T} \int_{-\frac{T}{2}}^{\frac{T}{2}} I(\theta, t)\, dt \tag{2.19}$$

Die Zahl der Messungen n geteilt durch die gesamte Dauer der Übertragung T ergibt das Inverse der Samplezeit, $1/T_s$. Die untere Grenze der Kovarianz-Matrix dieses Schätzers ergibt sich dann aus dem Inversen der Fisher-Matrix:

$$cov_\theta \geq I(\theta)^{-1} \tag{2.20}$$

Es stellt sich heraus, dass die Varianzgrenzen der Schätzparameter stark vom Abstand des Tags von der Flugbahn abhängen. In Abbildung 2.11 sind diese Abhängigkeiten für die Varianzen der r_x- und r_y-Schätzung, $\sigma_{CRLB,r_x}{}^2$ und $\sigma_{CRLB,r_y}{}^2$ dargestellt.

Auf Grund der starken Abhängigkeit wird die durchschnittliche Standardabweichung in mehreren Abschnitten berechnet, unter 100 km, zwischen 100 und 500 km und zwischen 500 und dem maximalen detektierten Abstand von 900 km. Die Werte werden in Tabelle 2.3 gegenübergestellt. Die Standardabweichungen der Frequenzschätzungen belaufen sich auf Annahmen in Bezug auf Auflösung und Fehlerart bei Differenz- und FFT-Methode beziehungsweise auf die Cramer-Rao Lower Bound der Frequenzschätzung bei einem SNR von $-30\ \mathrm{dB}$ im Fall der DTFT-Analyse.

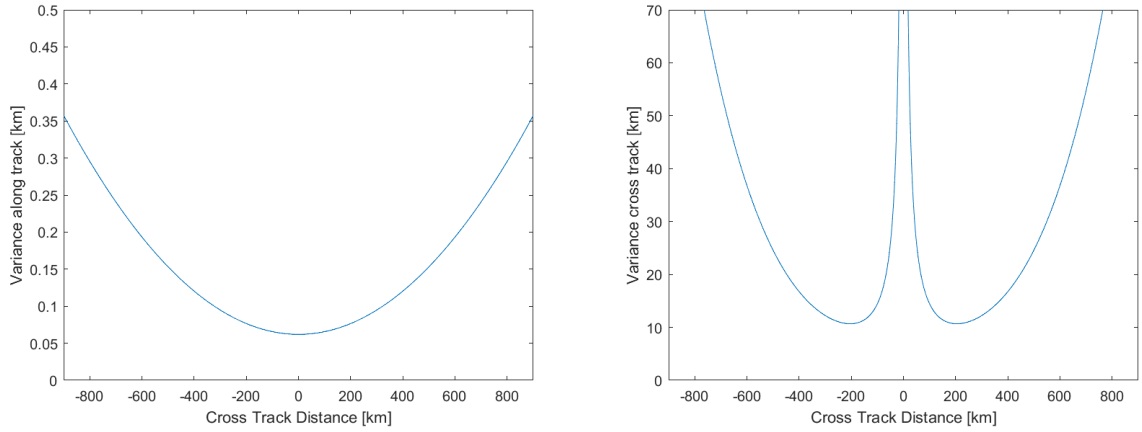

Abbildung 2.11: $\sigma_{CRLB,r_x}{}^2$ und $\sigma_{CRLB,r_y}{}^2$ in Abhängigkeit von r_y

Es zeigt sich, dass ein linearer Schätzer aus der Datengrundlage des Differenzverfahrens keine zufriedenstellenden Ergebnisse produzieren kann. Demnach muss für eine genauere Schätzung die Datengrundlage verbessert, also das Schätzverfahren verfeinert werden. Die vorgestellten Verfahren der FFT- und DTFT-Korrektur können diese verfeinerte Datengrundlage bieten. Das FFT-Verfahren kann den Frequenzschätzfehler theoretisch skalierbar um mindestens Faktor 4, die DTFT-Analyse sogar bis zur Cramer-Rao Grenze der Frequenzanalyse auf 2 Hz im unteren SNR-Segment senken. Damit ist eine Verbesserung um bis zu Faktor 10 möglich. Im Folgenden wird diese Annahme simulativ überprüft.

Tabelle 2.3: Minimale Standardabweichungen in der Ortsschätzung

Frequenzschätzung	σ_f [Hz]	$\sigma_{CRLB,r}$ [km]					
		0..100 km		100..500 km		500..900 km	
		x	y	x	y	x	y
Differenzverfahren	31,7	0,26	7,18	0,32	3,77	0,50	7,55
FFT-Verfahren 2^15	7,93	0,07	1,80	0,08	0,95	0,13	1,89
DTFT-Verfahren	1,87	0,02	0,43	0,02	0,23	0,03	0,45

2.5 AUSWERTUNG DER SCHÄTZGENAUIGKEIT

Das Modell der Übertragungsstrecke wird nun auf Fehlerwahrscheinlichkeiten bzw. Genauigkeit der Frequenzschätzung untersucht. Dafür werden entsprechende Parameter aus den Durchläufen in der Simulation abgespeichert und in der Auswertung betrachtet. Der Frequenzschätzfehler e_f wird entsprechend (2.21) ermittelt. Er entspricht der Differenz des aufgeprägten Frequenzversatzes f_d und des geschätzten Frequenzversatzes $f_{\mathrm{d,est}}$.

$$e_f = |f_d - f_{d,est}| \tag{2.21}$$

Anhand des normierten Frequenzschätzfehlers $e_{cfo} = e_f / f_{sym}$ untersucht, wie genau die Schätzung des aufgeprägten CFOs durch das Verfahren umgesetzt werden konnte. Anschließend wird der Effektivwert gebildet:

$$e_{f,eff} = \sqrt{\frac{1}{N}\sum_{i=1}^{N} {e_{cfo,i}}^2} \tag{2.22}$$

Dabei entspricht N der Anzahl der Iterationen. Die Frequenzschätzung erfolgt für die Näherung der FZC-Sequenz mittels 8-PSK Modulation und einer Signallänge von $N_{sym} = 2^{14} - 1$. In Abbildung 2.12 ist der Effektivwert des Frequenzschätzfehlers sowie die Auflösung der FZC-Schätzung für verschiedene SNR-Werte von $-30dB$ bis $-5dB$ zu sehen.

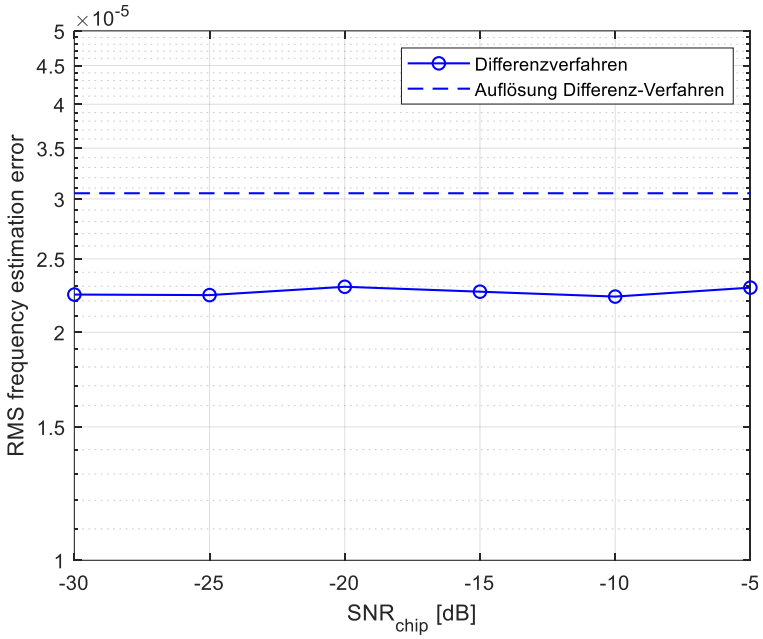

Abbildung 2.12: Effektivwert des Frequenzschätzfehlers für verschiedene SNR

Dabei ist zu erkennen, dass der Frequenzschätzfehler für alle SNR-Werte bei etwa $2{,}2 \cdot 10^{-5}$ liegt, entspricht etwa 19,8 Hz, sich damit im erwarteten Bereich befindet und keine Ausreißer zu verzeichnen sind.

Nach der Schätzung der Frequenz mittels Differenzverfahren wird nun das FFT-Verfahren angewandt. In Abbildung 2.13 ist der Frequenzschätzfehler durch die Frequenz-Schätzung durch das Differenzverfahren, bei einer Signallänge von $N_{sym} = 2^{14} - 1$, vergleichend mit dem zusätzlich angewandten FFT-Verfahren mit $N_{FFT} = 2^{15}$ Stützstellen, normiert dargestellt. Während der Effektivwert des Schätzfehlers des Differenzverfahrens normiert bei etwa $2{,}2 \cdot 10^{-5}$ liegt, verringert sich dieser durch das FFT-Verfahren sichtlich auf $9{,}2 \cdot 10^{-6}$ für das Beispiel von 2^{15} Stützstellen.

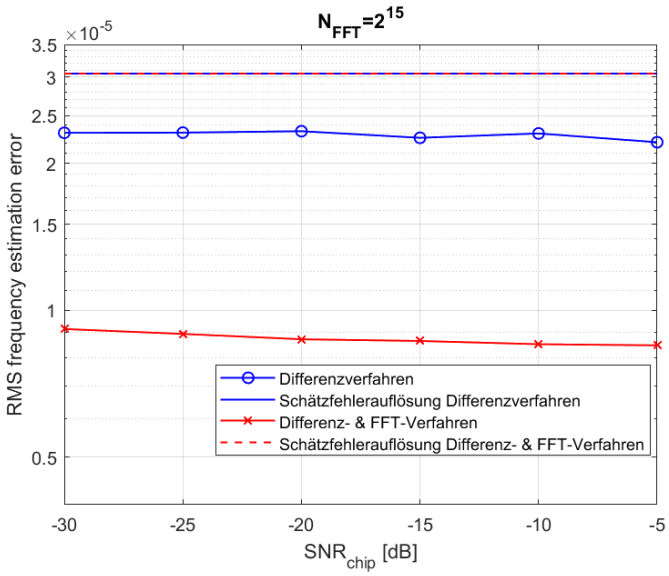

Abbildung 2.13: Frequenzschätzfehler mit bzw. ohne erneute Korrektur durch das FFT-Verfahren

Die Frequenzauflösung für 2^{15} Stützstellen ist genauso groß wie die Auflösung im Differenzverfahren. Durch eine andere Fehlerverteilung sinkt der Fehler jedoch unter die halbe Auflösung. Um den Fehler weiter zu senken, kann für das Verfahren auch eine höhere Stützstellenzahl genutzt werden. Damit wird zwar die Datengrundlage nicht verändert, die Position des realen Spektralpeaks kann jedoch besser genähert werden. In Abbildung 2.14 ist der Effektivwert des Frequenzschätzfehlers des Differenzverfahrens im Vergleich zu den Fehlerwerten des FFT-Verfahrens bei unterschiedlicher Anzahl von N_{FFT} Stützstellen für verschiedene SNR-Werte abgetragen. Die Frequenzauflösung ist für verschiedene N_{FFT} jeweils gestrichelt eingetragen.

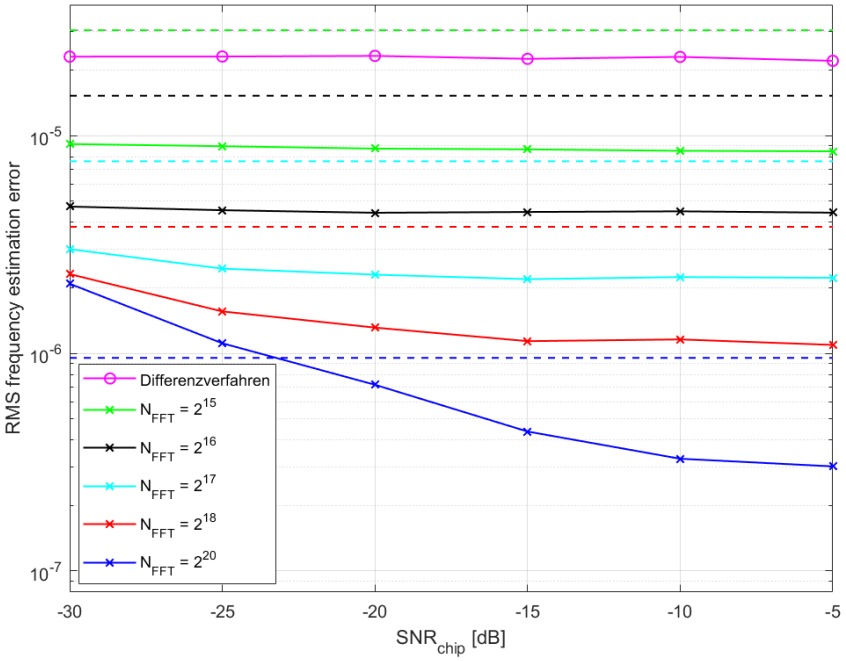

Abbildung 2.14: Frequenzschätzfehler für verschiedene N_{FFT} über SNR_{chip}

Der Frequenzschätzfehler verringert sich bei zunehmender Stützstellenzahl. Wird die Frequenzauflösung des FFT-Verfahrens verdoppelt, halbiert sich der effektive Frequenzschätzfehler. Wird die Frequenzauflösung vervierfacht, so wird auch der effektive Frequenzschätzfehler um ein Vierfaches kleiner. Diese Entwicklung ist vor für höhere SNR, wie etwa -5 und -10 dB zu verzeichnen. Auf diese Weise gelingt für diesen Bereich eine Verringerung des Schätzfehlers von etwa $2.2 \cdot 10^{-5}$ für $N_{FFT} = 2^{15}$ auf etwa $3 \cdot 10^{-7}$ für $N_{FFT} = 2^{20}$. Dieser Effekt ist darauf zurückzuführen, dass der im Frequenzbereich entstandene Peak mit steigender Stützstellenzahl größer aufgelöst werden kann. Zu sehen ist er in den Abbildung 2.15.

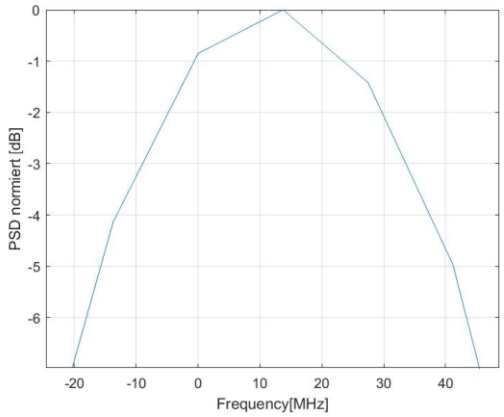

Abbildung 2.15: Peak bei $N_{FFT} = 2^{16}$

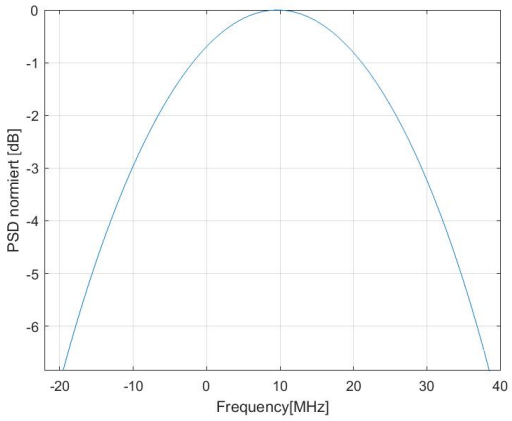

Abbildung 2.16: Peak bei $N_{FFT} = 2^{20}$

Während für $N_{FFT} = 2^{16}$ die Position des Maximums nicht genau ermittelt werden kann, ist der Peak bei einer Auflösung mit $N_{FFT} = 2^{20}$ in Form eines Bogens interpoliert. Dabei lässt sich die tatsächliche Lage des Maximums besser nähern. Die höhere Auflösung macht die Schätzung im Vergleich dazu jedoch auch anfälliger für Rauscheinflüsse. Im Bereich der niedrigeren SNR ist mit höherer Auflösung im FFT-Verfahren deshalb jeweils ein Anstieg des Frequenzschätzfehlers zu erkennen. Das gilt insbesondere für die Auflösung $N_{FFT} = 2^{18}$ sowie $N_{FFT} = 2^{20}$. In diesen Bereichen wird der Einfluss des Rauschens stärker, da es bei gleichzeitig kleiner werdender Auflösung stärker ins Gewicht fällt. Für $N_{FFT} = 2^{20}$ ist es bereits so stark, dass der Frequenzschätzfehler die Auflösung des Verfahrens überschreitet.

Es bleibt also festzuhalten, dass der Frequenzschätzfehler mit steigender Auflösung erheblich verringert werden kann. Während der Effektivwert des Frequenzschätzfehlers durch das Differenzverfahren für eine Signallänge von $N_{sym} = 2^{14} - 1$ bei $1{,}31 \cdot 10^{-5}$ liegt, lässt sich dieser mit Hilfe des FFT-Verfahrens für die Stützstellenanzahl $N_{FFT} = 2^{20}$ auf bis zu $2{,}7 \cdot 10^{-7}$ reduzieren.

Eine auflösungsunabhängige Auswertung durch kontinuierliche Discrete Time Fourier Transform kann die Genauigkeit vor Allem bei besseren Signal-Rausch-Abständen weiter verbessern. Ein Gradient-Ascent Algorithmus, wie er in Abbildung 2.17 skizziert ist, wird dafür genutzt, die Cramer-Rao Bound der Frequenzschätzung sicher zu erreichen. Diese beläuft sich auf:

$$\Delta f_{dtft,rms} = \sqrt{\frac{3 \cdot 1/SNR^2 \cdot {f_{sym}}^2}{2 \cdot \pi^2 \cdot N \cdot (N^2 - 1)}}, N = 2 \cdot N_{sym} \tag{2.23}$$

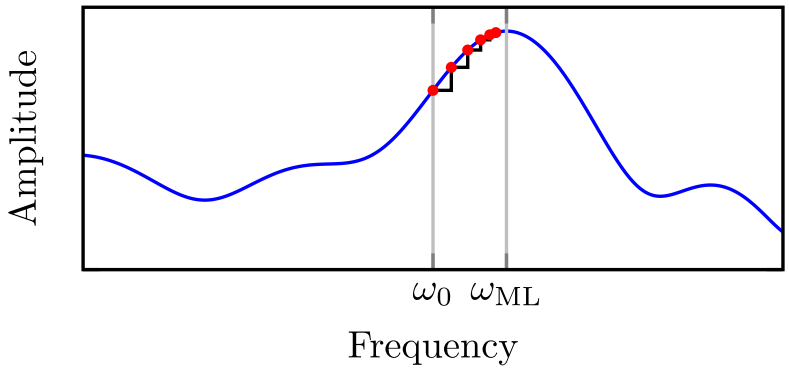

Abbildung 2.17: Gradient-Ascent-Algorithmus zur Schätzung der Frequenz im verrauschten kontinuierlichen Spektrum

2.6 Einfluss der Frequenzschätzung auf die Ortsschätzung

Für die Ortsschätzung auf Grundlage des Dopplereffektes wird der Algorithmus verwendet, welcher in Absatz 1.1 vorgestellt wird. Es wird ein Simulator entwickelt, welcher randomisierte Überflüge erstellt und simuliert, die Frequenzschätzung auf Basis der verschiedenen vorgestellten Frequenzschätzer realisiert und anschließend die geschätzten Frequenzen in Ortsschätzungen umgewandelt. Der Effekt der verfeinerten Frequenzschätzung wird gegenübergestellt.

In Abbildung 2.18 sind Scatter-Plots der Abweichungen zu sehen, die mit den einzelnen Frequenzschätzungen entstehen.

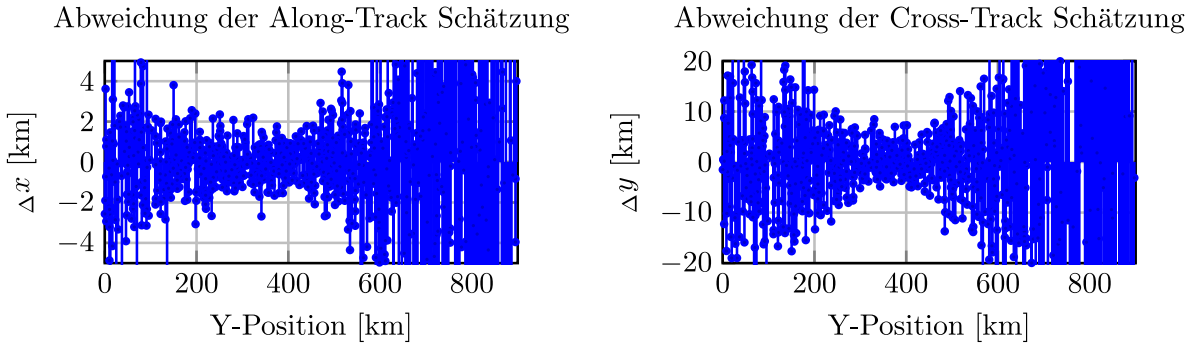

a) Frequenzschätzung Differenzverfahren

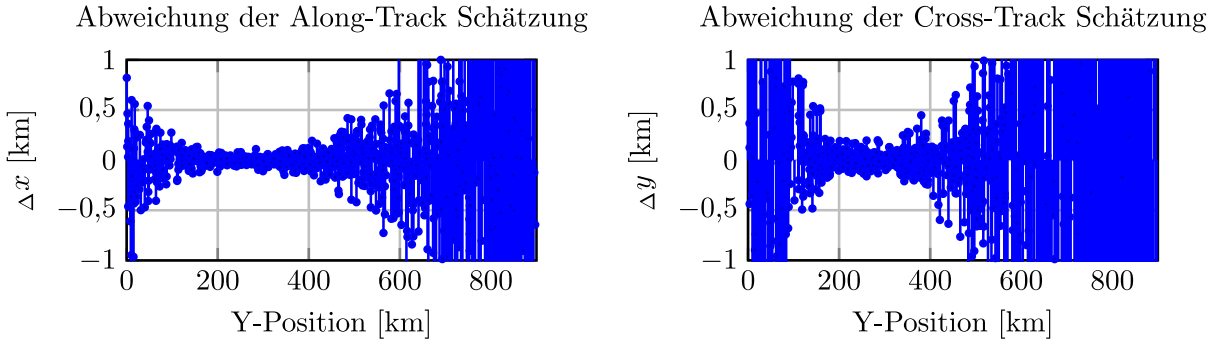

b) FFT-Frequenzschätzung, $N_{FFT} = 2^{17}$

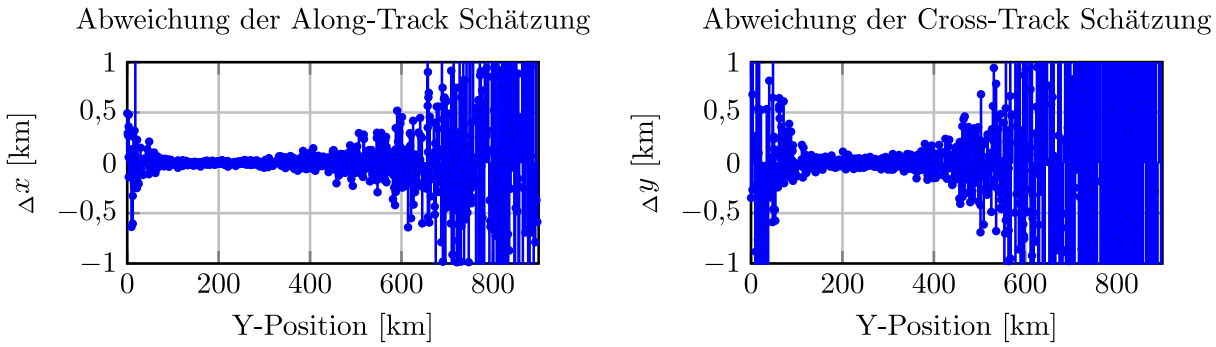

c) DTFT-Frequenzschätzung

Abbildung 2.18: Scatter-Plots der Abweichungen der Distanzschätzung

Man sieht im Vergleich der Diagramme, dass die Streubreite mit Verbesserung der Schätzung abnimmt. Jedes selbst hat jedoch eine charakteristische Form. Nahe der Überflugslinie, bei kleinen Abständen, existiert eine große Streuung. Diese nimmt zuerst ab, um bei etwa 200 bis 300 km ein Minimum zu erreichen. Danach nimmt sie wieder zu. Um den Verlauf besser darstellen zu können, wurden Abstandsschwellen eingeführt und die Streuung in den Teilabschnitten ausgewertet. Tabelle 2.4 stellt die mittleren quadratischen Fehler gegenüber.

Tabelle 2.4: Genauigkeit der Ortsschätzung auf Basis verschiedener Frequenzschätzverfahren

Frequenzschätzung	σ_f [Hz]	σ_d [km]					
		0..100 km		100..500 km		500..900 km	
		x	y	x	y	x	y
Differenzverfahren	20,9	2,59	156	1,12	45,1	19,0	86,8
FFT-Verfahren 2^17	2,02	0,29	32,9	0,08	1,03	3,15	10,7
DTFT-Verfahren	0,40	0,02	14,3	0,04	0,18	2,48	7,42

Zwei Effekte sind in der Tabelle sichtbar: Zum einen ist die Ortsschätzung nahe der Überflugslinie und in großer Entfernung ungenauer. Dies hat den Grund, dass die Empfindlichkeit des Systems in diesem Bereich sehr niedrig ist und dadurch schon kleine Fehler in der Frequenzschätzung zu großen Abweichungen führen. Im mittleren Bereich, von etwa 100 bis 500 km Abstand von der Flugbahn ist die Empfindlichkeit der Kennlinie größer. Damit verringert sich auch der Fehler in diesem Bereich. Kommt man allerdings über diesen Bereich drüber, so reicht der SNR in der Regel nicht mehr für eine sichere Übertragung aus. Damit steigt auch der mittlere quadratische Fehler in diesem Bereich.

3 Ortung mit Methoden des Machine Learning

In Abschnitt 1.1 wurde bereits erläutert, wie die Position des Tags auf Grundlage der Frequenzschätzung ermittelt wird. Nun wird eine weitere Methode untersucht, welche auf Maschinellem Lernen beruht. Das Konzept Maschinelles Lernen beruht auf einem künstlichen System, das anhand von Datensätzen ein statistisches Modell bzw. eine Abbildungsfunktion ermittelt, mit dem es gesuchte Zielparameter vorhersagen oder zuordnen kann.

Dafür wird unter anderem ein Datensatz verwendet, welcher über einen längeren Zeitraum die Überflüge der ISS über dieselbe Messstation erfasst. Dieser Datensatz wird in Abschnitt 3.3 näher erläutert. Da die Überflugdaten des Satelliten aus Sicht der Bodenstation gemessen sind, wird das Ortungsproblem zum Erproben des Maschinellen-Lernen-Ansatzes umgekehrt. Es wird also die Position des Satelliten auf Grundlage seines aufgezeichneten Dopplerverlaufs geschätzt. Der Vorteil dieser Problemumkehrung ist, dass mittels des Zeitstempels eines Überflugs die tatsächlichen Parameter aus den Archivdaten eines Satellitenüberflugs mit dem Schätzwert abgeglichen werden können.

Auf dieser Grundlage wird ein System aufgebaut, dessen Aufgabe es ist, die maximale Elevation eines Satellitenüberflugs zu bestimmen. Die Elevation entspricht dem Erhebungswinkel des Satelliten über dem Horizont bezogen auf den Beobachtungspunkt. Nun wird der Zusammenhang zwischen einem Dopplerverlauf und seiner maximalen Elevation gesucht. Die maximale Elevation ist in diesem Fall eine Rechengröße, welche abhängig von den bereits vorgestellten Maßen ist und ebenfalls repräsentativ für die gesuchte Position des Tags ist. Sie wird nun anstelle der Position in Flugrichtung x bzw. der Position senkrecht zur Flugrichtung y verwendet, da die Archivdaten eines Satellitenüberfluges ebenfalls die maximale Elevation hinterlegt haben, mit der das Schätzergebnis abgeglichen werden kann. Der Zusammenhang zwischen maximaler Elevation und Koordinaten ist in (3.1) bis (3.3) festgehalten.

In Abbildung 3.1 ist ein Überflugszenario dargestellt, welches von der gelb markierten Position auf der Erde beobachtet wird. Ein Satellitenüberflug verläuft in Richtung x und die maximale Elevation el gibt Aufschluss über die Position des Satelliten. Auf dieser Grundlage wird ein Kreis auf der Höhe der Umlaufbahn $h = 425km$ aufgespannt. Da die Überflugrichtung x bekannt ist und der Überflug parallel zu x stattfinden muss, gibt es zwei mögliche Überflugsbahnen. Sie tangieren jeweils die äußersten Punkte des aufgespannten Kreises in x-Richtung, welche jeweils durch ein rotes Kreuz markiert sind. Es liegt also ein Symmetrieproblem in y-Richtung vor.

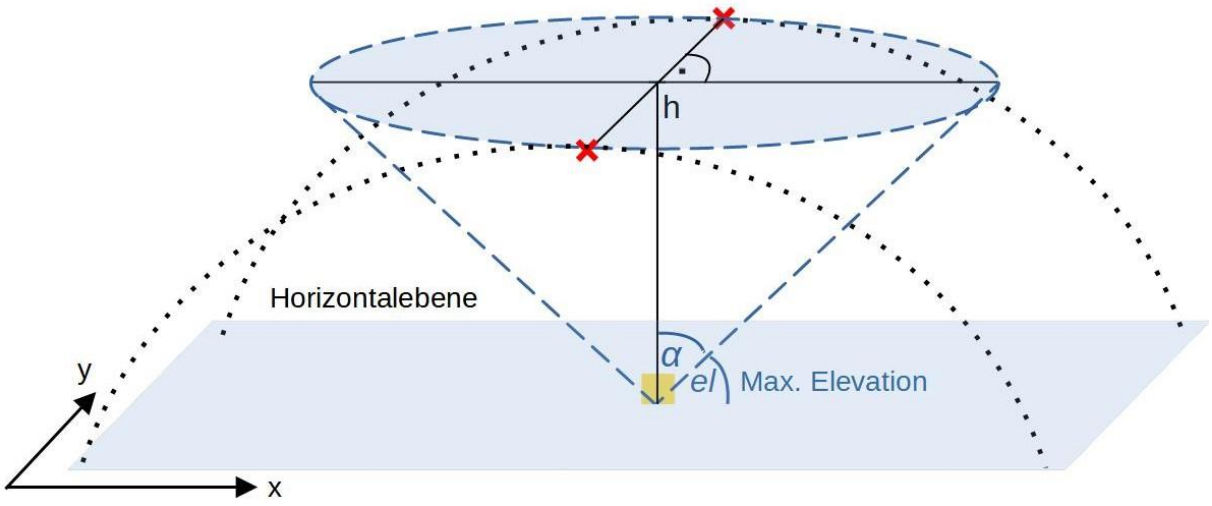

Abbildung 3.1: Geometrien des Überflugs in y-Richtung

Die maximale Elevation kann mit Hilfe trigonometrischer Gleichungen in Koordinaten übertragen werden. Dafür wird die Erde als Kugel genähert und zunächst wird die Distanz a in y-Richtung mit Hilfe des Tangens bestimmt.

$$a = h \cdot \tan(\alpha)\,, \qquad \alpha = 90° - el \tag{3.1}$$

Um die Distanz in ein Maß auf der Erdoberfläche zu transformieren, wird der Winkel β mit Hilfe des Erdradius r und der ermittelten Distanz a wie folgt bestimmt.

$$\beta = \arcsin\left(\frac{a}{r}\right) \tag{3.2}$$

Schließlich lässt sich die Distanz b als Kreisbogen ermitteln.

$$b = r \cdot \beta \tag{3.3}$$

Zur Veranschaulichung sind in Abbildung 3.2 sowie Abbildung 3.3 die Geometrien in x-Richtung skizziert.

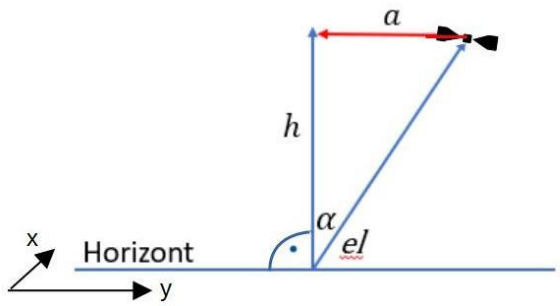

Abbildung 3.2: Geometrien des Überflugs in x-Richtung

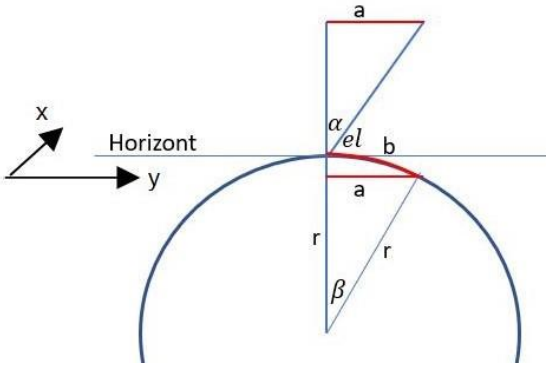

Abbildung 3.3: Übertragung des Distanzmaßes auf die Erdoberfläche

In Abbildung 3.4 ist aufgeschlüsselt, welcher Distanz in y-Richtung die maximale Elevation entspricht. Die maximale Elevation ist in einem Abstand von 1° abgetragen. Während ein steiler Überflug mit einer hohen Elevation einer kurzen Distanz entspricht, lässt sich ein flacher Überflug mit einer maximalen Elevation von $30°$ gemäß (3.1) bis (3.3) in eine Distanz von $y = 737{,}78\ \mathrm{km}$ übertragen. Dabei ist zu erkennen, dass die Distanz in y-Richtung für flachere Überflüge ab etwa $60°$ stärker zunimmt. In Abbildung 3.5 ist der Elevationsfehler übertragen in die Distanz in y-Richtung zu sehen. Für jede ganzzahlige maximale Elevation zwischen $30°$ und $90°$ wurde ein Fehler von $\pm 1°$ angenommen und anschließend in das Distanzmaß übertragen. Wie schon in Abbildung 3.4 zu sehen ist, wird auch hier der Fehler in der Distanz größer, je größer der Abstand zum Überflug, also je kleiner die maximale Elevation ist.

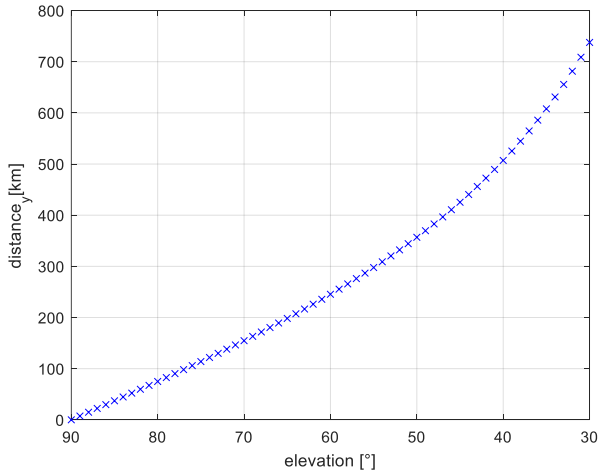

Abbildung 3.4: Zusammenhang der Distanz in y-Richtung und der maximalen Elevation

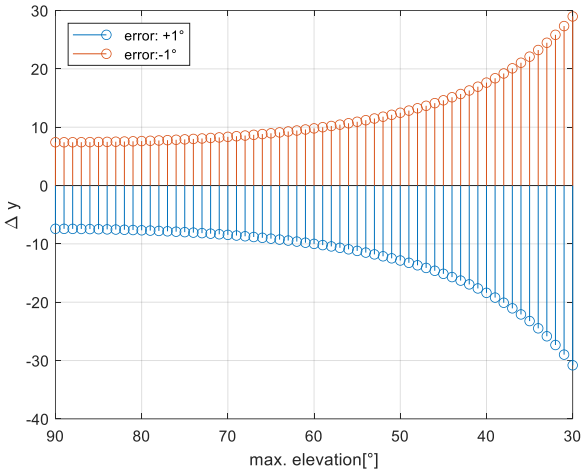

Abbildung 3.5: 1° Elevationsfehler übertragen in Distanzfehler

Zunächst wird allerdings für jeden Überflug der Zusammenhang zwischen Dopplerverlauf und maximaler Elevation untersucht.

Die vorhandenen Überflugdaten umfassen lediglich rund 500 Überflüge. Da dies nicht ausreichend ist und einige Dopplerverläufe erhebliche Störeinflüsse aufweisen, werden zunächst weitere Daten mittels einer MATLAB Simulation erzeugt. Die simulierten Überflugdaten werden in die Betrachtung einbezogen, da sie eine gute Möglichkeit bieten, den Ansatz des Maschinellen Lernens auf ausreichend große Datensätze mit Dopplerverläufen unterschiedlicher Qualität anzuwenden. Auf diese Weise lässt sich untersuchen, ob die Vorhersage auf Basis eines idealisierten Datensatzes zuverlässig funktioniert und inwiefern die Schätzung durch qualitativ schlechter werdende Datensätze ungenauer wird.

In Abschnitt 3.1 wird erläutert, was Maschinelles Lernen bedeutet und warum der Ansatz zur Untersuchung des vorliegenden Problems verwendet wird. Das Erstellen der Simulationsdaten unterschiedlicher Qualität ist in Abschnitt 3.2 zu finden, während der Datensatz der tatsächlich gemessenen Überflüge sowie das Vorgehen zur Datenvorverarbeitung in Abschnitt 3.3 beschrieben ist. Die verwendeten Methoden aus dem Gebiet des Maschinellen Lernens werden in Abschnitt 3.4 definiert und in Kapitel 3.5 erfolgt die Auswertung der Positionsschätzung.

3.1 Maschinelles Lernen

Maschinelles Lernen bedeutet, dass eine Maschine bzw. ein Computerprogramm aus Erfahrung lernen und somit Verhaltensänderung oder Zuordnungen vollziehen kann. Dabei wird ein bestimmtes Leistungskriterium anhand von Beispieldaten optimiert. Es wird ein Modell mit bestimmten Parametern definiert und das Computerprogramm lernt, die Parameter unter Verwendung von Erfahrungswerten zu optimieren. Der Fokus kann darauf liegen, Vorhersagen zu treffen, Wissen aufgrund der Daten zu erlangen oder beides. Ziel ist, dass das Programm auf Grundlage einer Stichprobe Schlussfolgerungen zieht. Für die Konstruktion von mathematischen Modellen, mit denen die Vorhersagen getroffen werden, werden Theorien der Statistik genutzt [17–19].

Lernprozesse von Maschinen werden meist in Klassifikationsprobleme und Regressionsprobleme unterteilt. Während das Lösen von Klassifikationsproblemen bedeutet, bestimmte Parameter Klassen von

Werten oder Kategorien zuzuordnen, sagt eine Maschine für ein Regressionsproblem einen Wert voraus, der auf Grundlage der Eingabedaten ermittelt wird und nicht einer definierten Klasse angehören muss. Die Vorhersage einer maximalen Elevation für einen bestimmten Dopplerverlauf entspricht also einem Regressionsproblem, da die maximale Elevation jeden möglichen Wert zwischen $30°$ und $90°$ annehmen kann. Dass es einen Erwartungsbereich für die Zielgröße gibt, sollte für die Maschine dadurch erkennbar werden, dass alle im Eingangsdatensatz vorliegenden maximalen Elevationen diesem Wertebereich entsprechen. Liegen vorhergesagte Elevationen nicht in diesem Bereich, sollte der Fehler in der Auswertung zu erkennen sein.

In Abbildung 3.6 ist schematisch dargestellt, welche Schritte umgesetzt werden müssen, um von einem Datensatz zu einer Vorhersage mittels Maschinellem Lernen zu gelangen. In der Regel müssen die Rohdaten verarbeitet werden, bevor sie für die Lernalgorithmen verwendet werden können. Handelt es sich um überwachtes Lernen, wird den Daten jeweils ein sogenanntes Label zugeordnet oder ist bereits vorhanden. In diesem Fall ist das die maximale Elevation, welche im Datensatz bereits vorhanden ist. Der Datensatz wird in einen Trainings- und Testdatensatz aufgeteilt. Mit dem Trainingsdatensatz, welcher meist 70-80% der Daten enthält, wird der Lernalgorithmus trainiert und möglicherweise weiter modifiziert. Anschließend wird die Vorhersage der gewünschten Zielgröße mit dem finalen Lernalgorithmus anhand des Testdatensatzes ermittelt, der entsprechend 20-30% der Daten enthält. Es ist ebenso möglich, einen Teil des Datensatzes als Validierungsdatensatz zu nutzen, um die sogenannten Hyperparameter der Lernmethode zu optimieren. Hyperparameter sind die Parameter, welche für den Algorithmus im Vorfeld festgelegt werden müssen und dessen Performance verändern können [20, 21].

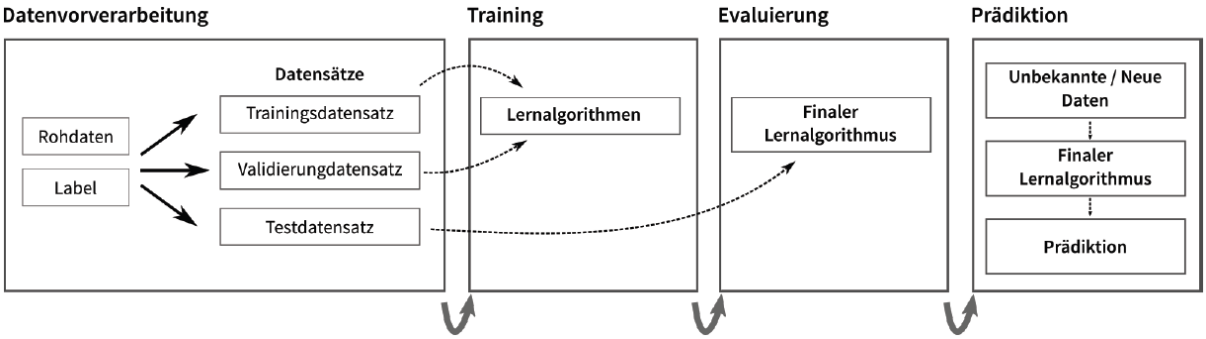

Abbildung 3.6: Vereinfachtes Schema zur Anwendung von Maschinellem Lernen [20, 22]

Ein guter Lernprozess zeichnet sich dadurch aus, dass auf unbekannten Daten, also den Testdaten, die richtige Vorhersage getroffen werden kann. Die Performance der Maschine wird also anhand der Testdaten und den darauf getroffenen Vorhersagen qualitativ bewertet. Dafür können verschiedene Maße angewendet werden. Für Regressionsprobleme wird beispielsweise der mittlere quadratische Fehler betrachtet. Der mittlere quadratische Fehler gewichtet Ausreißer sehr stark, da diese quadratisch eingehen. Dabei definiert N die Anzahl an Messreihen, $y\left(x^{[i]}\right)$ ist das Prädiktionsergebnis auf Grundlage jedes einzelnen Eingangswertes $x^{[i]}$ und $t^{[i]}$ repräsentiert das Label, also die tatsächliche Zielgröße [20, 22].

$$RMSE = \sqrt{\frac{1}{N}\sum_{i=1}^{N}(y(x^{[i]}) - t^{[i]})^2} \qquad n \in [1 \dots N] \tag{3.4}$$

Der mittlere absolute Fehler hingegen bewertet Ausreißer nicht so stark.

$$MAE = \frac{1}{N}\sum_{i=1}^{N} |y(x^{[i]}) - t^{[i]}| \qquad n \epsilon [1 \dots N] \tag{3.5}$$

Der R^2-Score bzw. das Bestimmheitsmaß ist der Anteil der erklärten Varianz. Damit lässt sich für eine Regression bewerten, wie gut Messwerte zu einem Modell passen, das heißt, wie viel Streuung in den Daten durch das vorliegende Regressionsmodell „erklärt“ werden kann. Es wird wie folgt definiert [23].

$$R^2 = 1 - \frac{\sum_{i=1}^{N}(y(x^{[i]}) - t^{[i]})^2}{\sum_{i=1}^{N}(t^{[i]} - \bar{t})^2} \qquad n \epsilon [1 \dots N] \tag{3.6}$$

Die Eignung des Lernalgorithmus für die Prädiktion lässt sich ebenfalls beurteilen, indem die Ergebnisse auf Overfitting und Underfitting untersucht werden. Overfitting entsteht, wenn der Lernalgorithmus eine Hypothesenfunktion h findet, deren Genauigkeit auf den Trainingsdaten größer ist, als seine zukünftige Genauigkeit. Dies kann der Fall sein, wenn zu wenig Daten vorliegen oder diese zu verrauscht sind. Der Algorithmus erlernt dann beispielsweise ebenfalls das Rauschen in den Daten als Systematik. Overfitting kann ebenfalls auftreten, wenn das Modell zur komplex ist und zu viele Parameter aufweist. Viele Modellparameter können auf der einen Seite die gegebenen Beobachtungen sehr genau darstellen, auf der anderen Seite können sie allerdings auch zu einem großen statistischen Fehler und starken Schwankungen führen.

Underfitting hingegen bedeutet, dass der Lernalgorithmus eine Hypothesenfunktion h findet, die weniger komplex als die den Daten zugrundeliegende Funktion ist. Das Modell ist in diesem Fall zu stark vereinfacht und die Haupteffekte werden nicht mehr ausreichend erklärt. Die Genauigkeit auf den Trainingsdaten ist im Falle des Underfittings meist geringer als die zukünftige Genauigkeit. [18, 20, 21, 24]. Abbildung 3.7 stellt Overfitting und Underfitting beispielhaft dar.

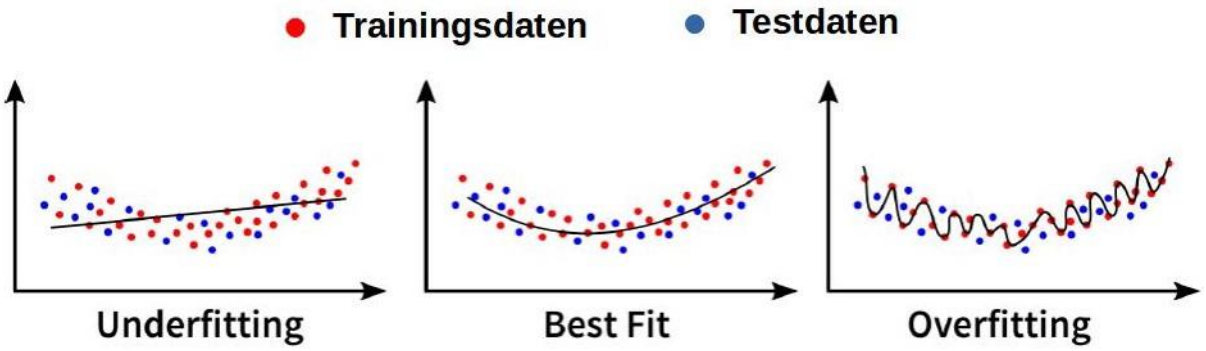

Abbildung 3.7: Beispiele für die Beurteilung der Passgenauigkeit des Modells [22]

Das Gebiet des Maschinellen Lernens bietet eine große Menge an mathematischen und statistischen Modellen, mit Hilfe derer eine Maschine die Abbildungsfunktion ermitteln kann, mit der die Zielgröße aus den Eingangsdaten vorhergesagt wird. Um zu entscheiden, mit welchem Modell die Problemstellung bearbeitet werden soll, wird zunächst der vorliegende Datensatz beschrieben.

3.2 Simulierte Überflugdaten

Die Überflüge werden zunächst mit Hilfe einer Matlab Simulation erzeugt. Diese enthält verschiedene Parameter mittels derer die Qualität der Überflüge der Realität angepasst werden können. Der Datensatz wird zunächst in idealisierter Form erstellt und anschließend schrittweise den tatsächlichen Überflugsmessungen angepasst. In Tabelle 3.1 sind die möglichen Einstellungen und ihre Wertebereiche für den idealen Fall aufgelistet.

Tabelle 3.1: einzustellende Parameter zur Charakterisierung der Überflugsignale

Parameter	Variablenbezeichnung	Wert bzw. Wertebereich
Orbithöhe des Satelliten	h	$425km$
Signalfrequenz	f	$468{,}1MHz$
Zeitauflösung	dt	$1s$
Anzahl simulierte Signale	$N_iterations$	$1 \cdot 10^3$
Aufgeprägtes Rauschen	a_noise	0 Hz
Elevation	ct_range	$[0, 636]$ = Elevation bis $90°$
Länge eines Signals	$length_range$	$250\ s$

Die Anzahl der benötigten Überflugsignale wird mit dem Parameter $N_iterations = 1 \cdot 10^3$ eingestellt, um einen Datensatz zu erhalten, welcher jede mögliche Elevation zwischen $30°$ und $90°$ abdeckt und verschiedene Signale je Elevationswert erzeugt. Beeinflusst wird die Qualität der Signale beispielsweise durch a_noise. Dieser Wert entspricht dem Effektivwert, also der Amplitude des aufgeprägten Rauschens. Je größer er eingestellt wird, desto stärker weicht das Signal von einem idealisierten Dopplerverlauf ab. Die maximale Elevation eines Überflugs liegt im Bereich bis $90°$ und wird durch die Variable ct_range bestimmt. Es hat sich herausgestellt, dass der Dopplerverlauf bei der Messung eines ISS-Überflugs unterschiedlich lang ist und oftmals nicht symmetrisch erfasst wird. Das bedeutet, dass ein Dopplerverlauf, der eigentlich von $+9000Hz$ bis $-9000Hz$ verläuft, bei der Messung beispielsweise lediglich von $9000Hz$ bis $-4000Hz$ aufgezeichnet wurde. Zurückzuführen ist das auf Hindernisse in der Umgebung der Messstation. Da dieses Defizit häufiger auftritt, wird das Signal in der Simulation mit einer Asymmetrie versehen. Zudem weisen die aufgezeichneten Dopplerverläufe unterschiedlich große Lücken im Signalverlauf auf, zu deren Zeitwert die Frequenzwerte nicht erfasst werden konnten. Dieser Informationsverlust wird durch die Parameter N_gap_range sowie gap_length_range nachgebildet. Dadurch werden Signallücken eingefügt, die einen definierten Anteil an Datenverlust erzeugen.

Die erzeugten Überflugdaten setzen sich aus den folgenden Größen zusammen:

- Dopplerfrequenzverlauf [Hz]
- Zeitverlauf [s]
- Maximale Elevation [°]
- Orbithöhe der ISS [m]

Die idealisierten Dopplerfrequenzverläufe zweier Überflüge sind in der folgenden Abbildung beispielhaft gezeigt.

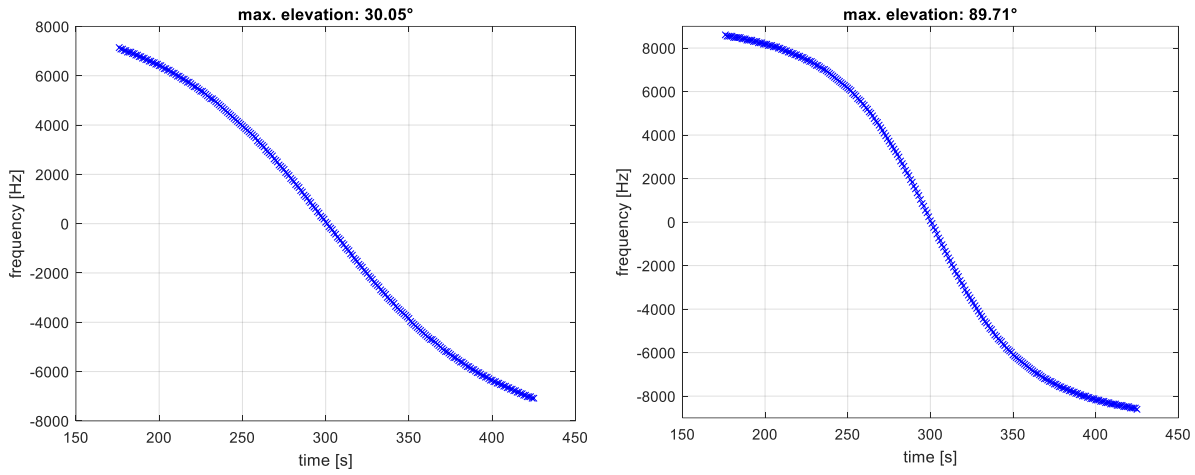

Abbildung 3.8: Dopplerverlauf verschiedener simulierter Überflüge

Der ideale simulierte Datensatz wird nun der Realität angenähert, indem die in Tabelle 3.2 aufgeführten Parameter verändert werden, sodass die Signale schrittweise variable Parameter bzw. Störungen zugefügt bekommen. Im nächsten Schritt wird die Länge der Signale verändert, die Symmetrie verzerrt und ein Zeit- sowie Frequenzversatz eingestellt.

Parameter	Variablenbezeichnung	Wert bzw. Wertebereich
Verzerrung des Aufzeichnungsbereichs des Signals	p_asym	$[30, 60]$ %
Zeitversatz	t_start	$[0{,}150]s$
Frequenzversatz	cfo	$[0{,}300]Hz$

Tabelle 3.2: veränderte Parameter der asymmetrischen Überflüge

Zu sehen ist der Effekt in Abbildung 3.9. Die Signale sind nicht mehr punktsymmetrisch. Besonders deutlich ist der Effekt des Dopplerverlaufs für $\varphi_{max} = 89{,}71°$ zu sehen. Durch den Zeit- und Frequenzversatz ist allerdings nicht nachzuvollziehen, an welcher Stelle sich der Mittelpunkt des Signals befindet. Schließlich ist der Nulldurchgang ebenfalls verschoben worden. Dennoch ist erkennbar, dass der Signalanteil im Bereich der niedrigen Frequenzen gekürzt ist und betragsmäßig nicht die gleichen Frequenzwerte, wie der Verlauf im positiven Bereich erreicht.

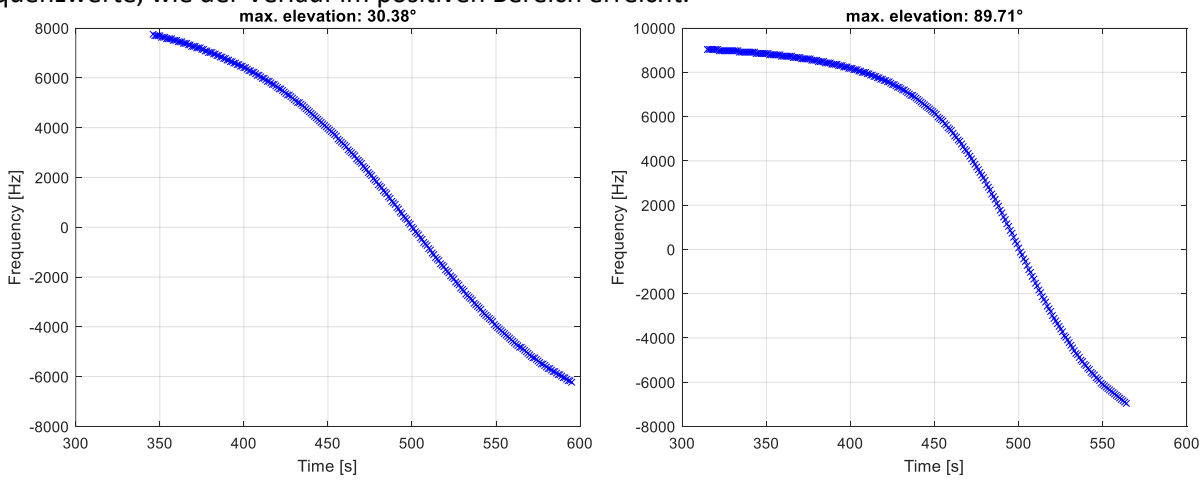

Abbildung 3.9: Dopplerverlauf verschiedener simulierter Überflüge mit Asymmetrien

Da beim Aufzeichnen der tatsächlich gemessenen Überflugdaten regelmäßig einzelne Werte bzw. Signalabschnitte verloren gehen, werden die Ausfälle in den Simulationsdaten berücksichtigt. Jeder Dopplerverlauf kann bis zu 5 Lücken aufweisen, in denen jeweils bis zu 40 Werte fehlen.

Parameter	Variablenbezeichnung	Wert bzw. Wertebereich
Zeitbereich des Nulldurchgangs	N_gap_range	$[0, 5]\ s$
Verzerrung des Aufzeichnungsbereichs vom Messsignal	gap_length_range	$[5, 40]\ s$

Tabelle 3.3: veränderte Parameter der Überflüge mit lückenhaften Dopplerverläufen

In Abbildung 3.10 sind zwei beispielhafte Verläufe zu sehen, die unterschiedlich viele und verschieden große Lücken vorweisen.

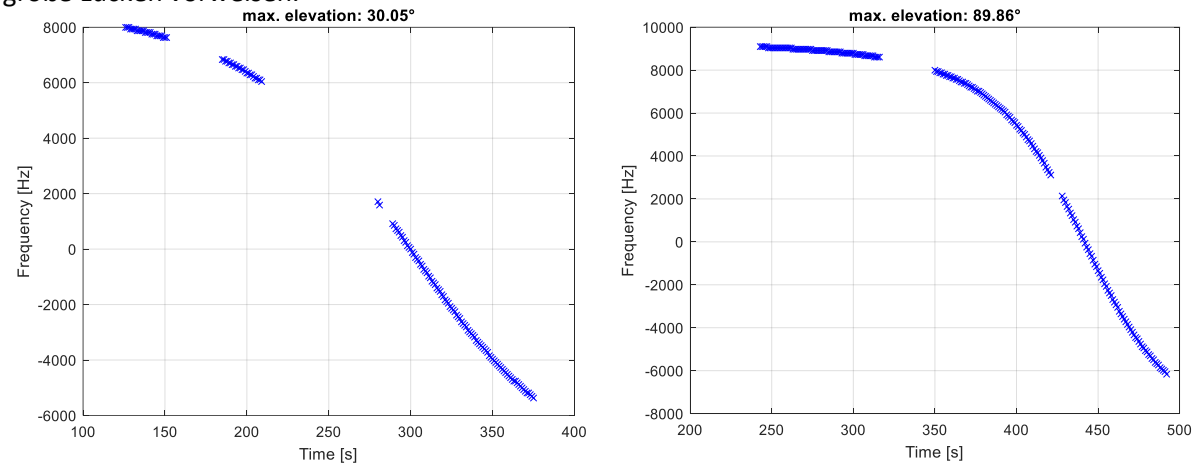

Abbildung 3.10: Dopplerverlauf verschiedener simulierter Überflüge mit Lücken

Die Signalqualität hängt zusätzlich von Rauscheinflüssen ab, welche anhand des Rauscheffektivwertes eingestellt werden, wie in Tabelle 3.4 zu sehen ist. Der Wert von bis zu ± 28 Hz wird in Anlehnung an die Frequenzauflösung des Differenzverfahrens eingestellt. Die Frequenzauflösung des FFT-Verfahrens ergibt eine Abweichung von ± 4 Hz. Daher wird ebenfalls ein Datensatz erzeugt, welcher diesen Betrag aufgeprägt bekommt.

Parameter	Variablenbezeichnung	Wert bzw. Wertebereich
Aufgeprägtes Rauschen 1	a_noise	± 28 Hz
Aufgeprägtes Rauschen 2	a_noise	± 4 Hz

Tabelle 3.4: veränderte Parameter der Überflüge mit Rauscheinflüssen

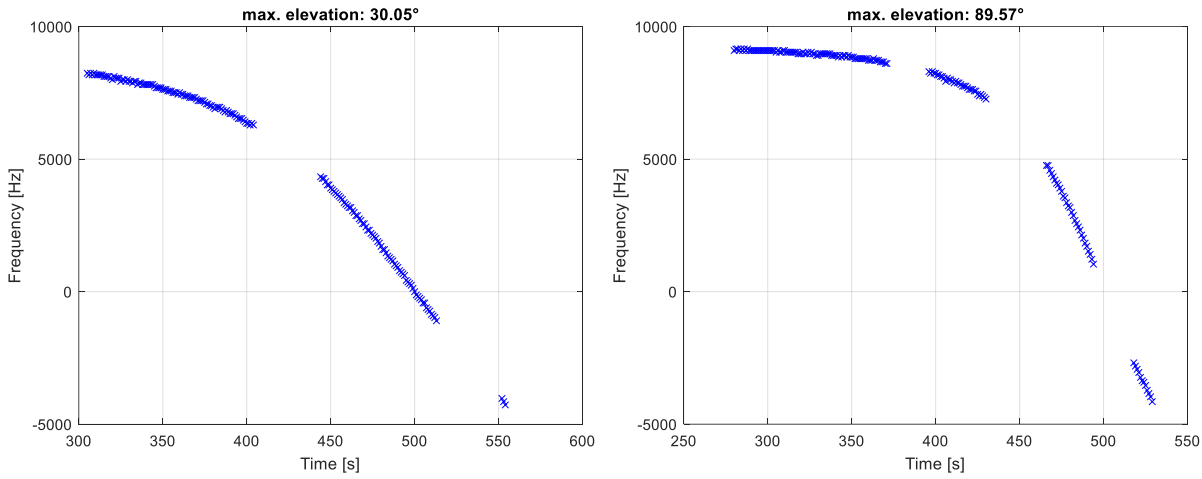

Abbildung 3.11: Dopplerverlauf verschiedener simulierter Überflüge mit aufgeprägtem Rauschen von $\pm 28\ Hz$

Der simulierte Datensatz liegt nun also in fünf verschiedenen Qualitätsstufen vor. Diese Datensätze werden im Folgenden als idealer Datensatz, asymmetrischer Datensatz, lückenhafter Datensatz und verrauschter Datensatz mit aufgeprägtem Rauschen von $\pm 4Hz$ bzw. $\pm 28Hz$ bezeichnet.

3.3 DATENVORVERARBEITUNG

Anschließend an die Simulationsdatensätze wird der tatsächlich gemessene Datensatz zur Schätzung des Elevationswinkels verwendet, welcher den Überflug der ISS über Dresden aufgezeichnet hat. Anhand dieses Datensatzes soll schließlich überprüft werden, ob das Neuronale Netz die maximale Elevation zu realen Bedingungen ausreichend gut vorhersagen kann. Das gemessene Dopplerfrequenzsignal wird als IQ Downlink Signal aufgezeichnet und liegt in einem .tar Format vor, wobei es sich um ein übliches Format handelt, mit dem Dateien, Verzeichnisse oder andere Objekte eines Dateisystems sequenziell in eine einzige Datei geschrieben werden können. Die .tar Files werden mit einem MATLAB-Skript eingelesen und verarbeitet. Aus dem angegebenen Zeitstempel werden die Elevationsdaten sowie die Orbithöhe des Überflugs bestimmt. Da diese Werte für vergangene Überflüge bestimmt werden, ist es nicht möglich, eventuelle Änderungen der Orbithöhe durch Ausweichmanöver der ISS zu berücksichtigen. Die ermittelte Elevation eines Überflugs ist beispielhaft Abbildung 3.12 und das aus dem IQ-Signal extrahierte Dopplerfrequenzsignal ist in Abbildung 3.13 zu sehen.

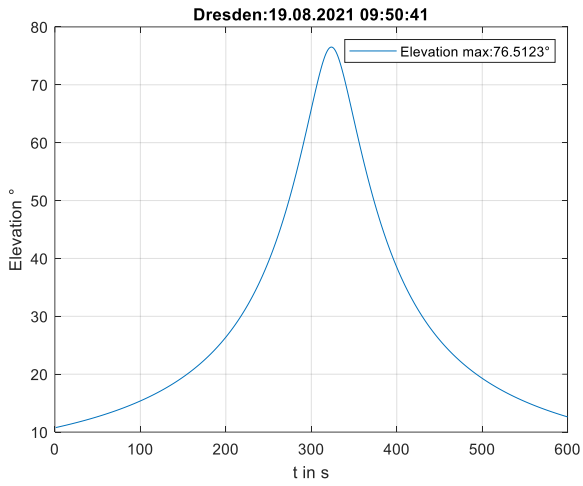

Abbildung 3.12: ermittelte Elevation eines Überfluges

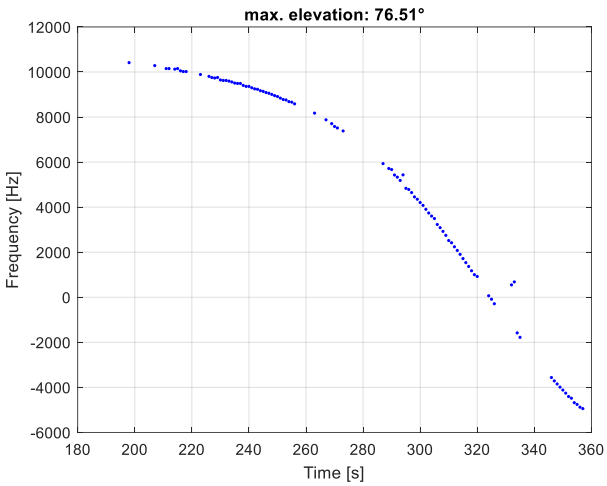

Abbildung 3.13: zugehörige ermittelte Dopplerfrequenzkurve

Bei der Bestimmung der Überflugelevation ist zu berücksichtigen, ob die Überflüge während der Sommer- oder Winterzeit aufgezeichnet worden sind, da dementsprechend die Zeitzonenkorrektur angepasst werden muss.

Nach dem Auslesen und Verarbeiten des .tar-files beinhaltet der Datensatz folgende Parameter:

- Zeitstempel des Überflugs
- Dopplerfrequenzverlauf [Hz]
- Zeitverlauf [s]
- Maximale Elevation [°]
- Orbithöhe der ISS [km]

Die Dopplerfrequenzverläufe zweier Überflüge sind in der folgenden Abbildung beispielhaft gezeigt.

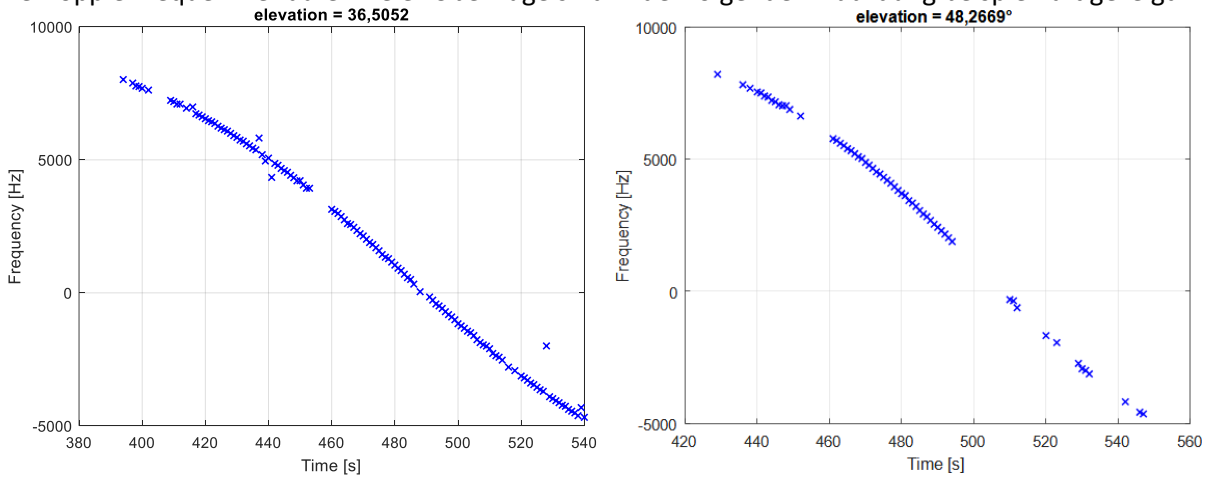

Abbildung 3.14: Dopplerverlauf verschiedener ISS-Überflüge

Der vorhandene Datensatz wird systematisch untersucht, um festzustellen, welche Messungen ausreichend aussagekräftig sind, um sie verwerten zu können.

Es liegen auch Signale vor, die zwar einen Dopplerverlauf erkennen lassen, jedoch Störwerte haben, die je nach Interpretation mehrere Signalverläufe ermöglichen. Die beiden rot markierten Werte in Abbildung 3.15 deuten jeweils einen unterschiedlich flachen Verlauf im höheren Frequenzbereich an.

Da dieser Bereich besonders charakteristisch für verschiedene Entfernungen des Überflugs ist, ist dieser Verlauf nicht eindeutig zuzuordnen.

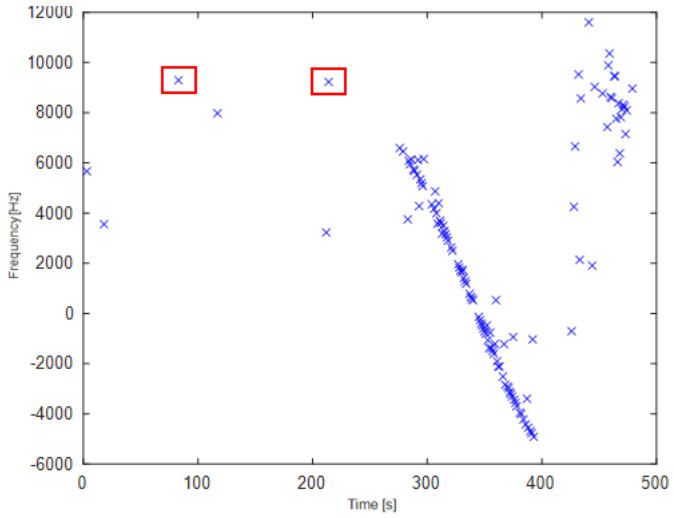

Abbildung 3.15: Bsp. eines Dopplersignals mit uneindeutigem Verlauf

Zur Illustration der Qualitätsunterschiede ist in Abbildung 3.16 eine Auswahl verschiedener Messreihen gezeigt, die keinen Dopplerverlauf aufgezeichnet haben.

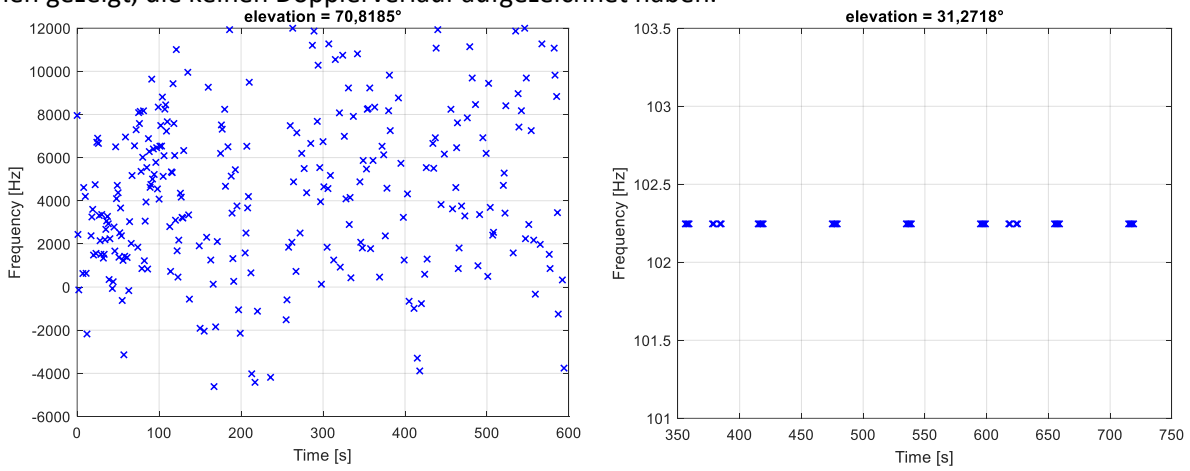

Abbildung 3.16: Auswahl an Messreihen, die keinen Dopplerverlauf abbilden

Um die verrauschten Messreihen aus dem Datensatz zu filtern, werden alle Messreihen auf verschiedene Parameter untersucht. Dafür wird zunächst der gleitende Mittelwert für jede Messreihe gebildet. Für den gleitenden Mittelwert werden jeweils zentriert vier Nachbarwerte, das heißt die zwei Vorangegangenen sowie die zwei Folgenden einbezogen. Einige Beispiele sind in Abbildung 3.17 zu sehen.

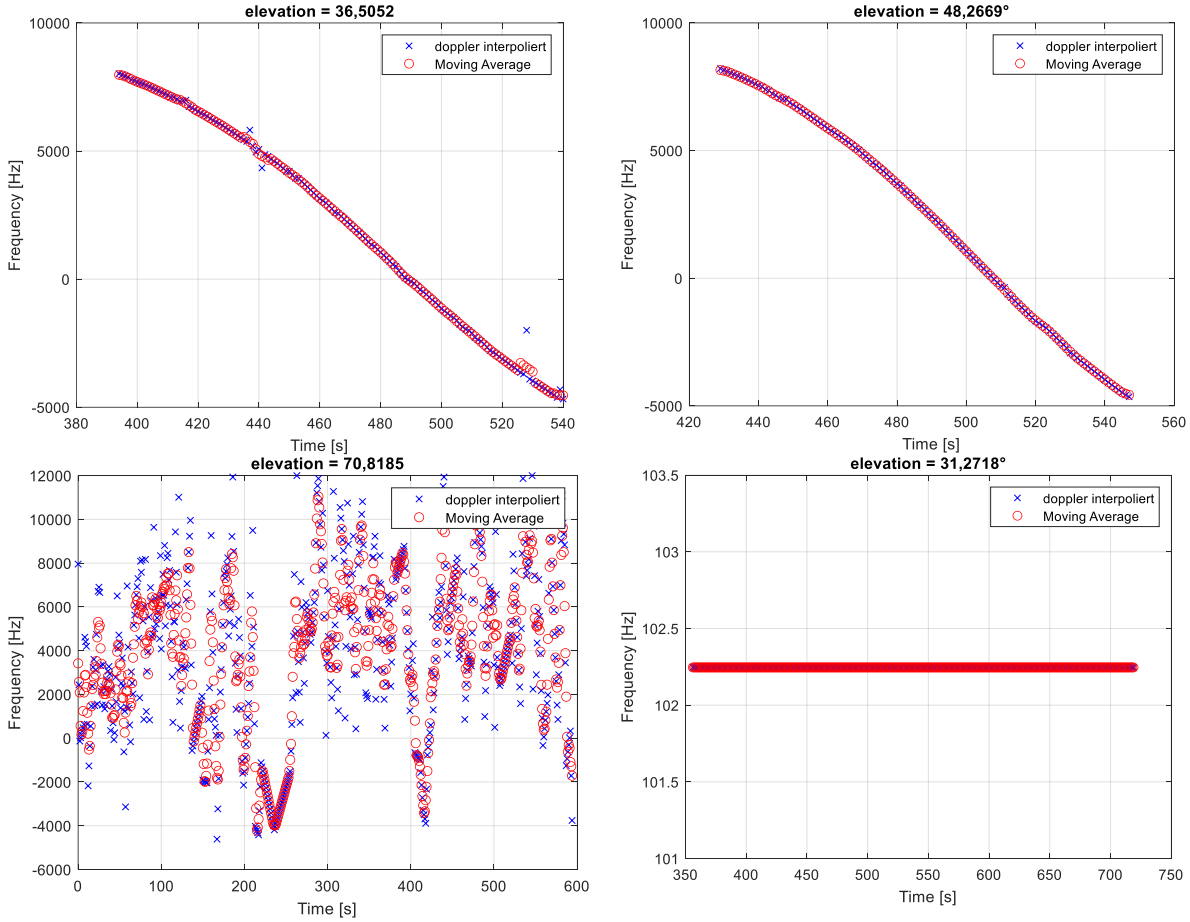

Abbildung 3.17: Moving Average der in Abbildung 3.14 und Abbildung 3.16 vorgestellten Messreihen

Die verrauschten Messreihen werden mit Hilfe der Varianz aussortiert. Die Varianz ${\sigma_{diff}}^2$ je Messreihe wird für die Differenzfunktion ermittelt, welche zwischen der interpolierten Messreihe und dem gleitenden Mittelwert gebildet wird. Übersteigt die Varianz einen Wert von $1 \cdot 10^6$, ist davon auszugehen, dass es sich um ein verrauschtes und somit nicht verwertbares Signal entsprechend Abbildung 3.16 handelt. Die betreffenden Messreihen werden aus dem Datensatz ausgeschlossen. Ein ähnliches Verfahren wird für die konstanten Verläufe angewendet. Um diese auszusieben, wird die Varianz des Frequenzverlaufes betrachtet. Die Varianz eines näherungsweise konstanten Verlaufs ist deutlich niedriger, als die eines Dopplerverlaufs. Daher werden die Messreihen aussortiert, deren Varianz kleiner als $1 \cdot 10^4$ ist.

Tabelle 3.5: Kriterien zur Extrahierung verwertbarer Dopplerverläufe

Kriterium
${\sigma_{diff}}^2 > 1 \cdot 10^6$
${\sigma_{diff}}^2 < 1 \cdot 10^4$

Anschließend werden Dopplerverläufe bearbeitet, welche einzelne Ausreißerwerte beinhalten. Um diese zu identifizieren, wird ein Toleranzbereich entlang des gleitenden Mittelwertes definiert. Außerhalb liegende Werte werden ermittelt und verworfen. In Abbildung 3.18 ist das Vorgehen zu sehen.

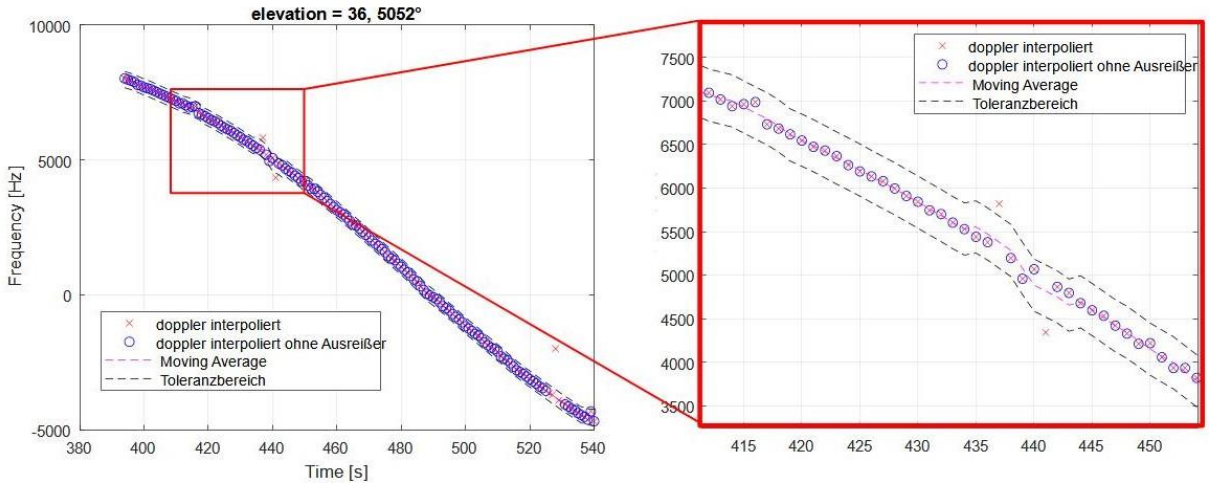

Abbildung 3.18: Toleranzbereich entlang des gleitenden Mittelwerts

Der bereits überarbeitete Datensatz beinhaltet weiterhin Messreihen, welche einen Dopplerverlauf und zusätzlich verrauschte Signalabschnitte vorweisen. Ein Beispiel ist in Abbildung 3.19Abbildung 3.19 zu sehen. Für die Zeitwerte zwischen 230 s und 330 s ist ein Dopplerverlauf zu erkennen, während alle nachfolgenden Werte lediglich Rauscheffekte darstellen. Um den Dopplerverlauf extrahieren zu können, werden auch für diese Messreihe zunächst die Ausreißer entfernt. In Abbildung 3.20 ist das Signal nach dem Aussortieren der ermittelten Rauschwerte zu sehen. Während die Ausreißer im Zeitabschnitt 230 s bis 330 s vollständig erfasst und entfernt werden, funktioniert die Vorgehensweise für den Zeitraum $t > 330$ s nicht zuverlässig. Aus diesem Grund wird das globale Minimum ermittelt und die zeitlich folgenden Rauschwerte verworfen. Der bereinigte Dopplerverlauf ist in Abbildung 3.21 zu sehen.

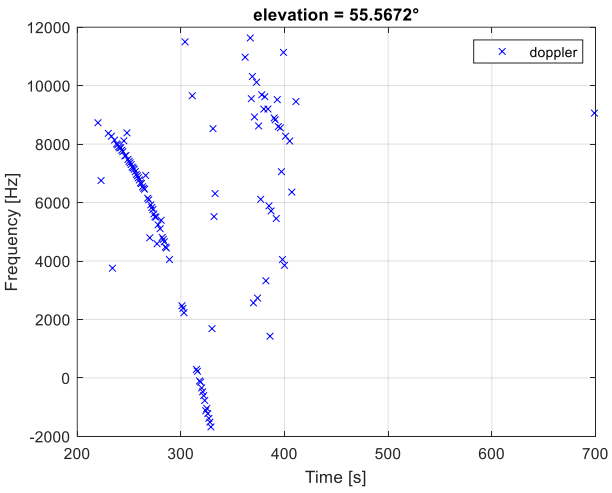

Abbildung 3.19: Messreihe mit auf den Dopplerverlauf folgendes Rauschen

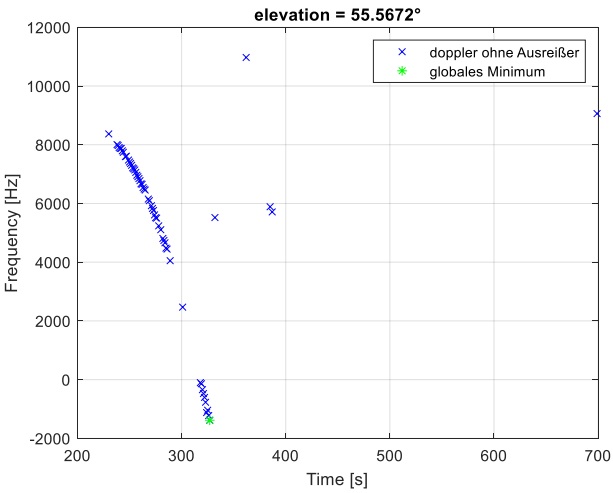

Abbildung 3.20: Messreihe nach dem Aussortieren der identifizierten Ausreißer

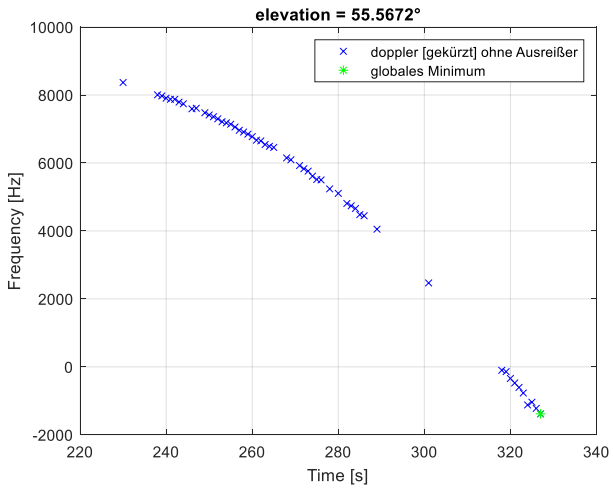

Abbildung 3.21: Messreihe bis einschließlich des globalen Minimums

Um die Problemstellung auf Basis der vier Datensätze aus Abschnitt 3.2 sowie des tatsächlich gemessenen Datensatzes bearbeiten zu können, werden nun geeignete Methoden des Maschinellen Lernens erläutert.

3.4 Methoden des Maschinellen Lernens

Wie bereits erläutert, liegt ein Datensatz vor, welcher sich aus aufgezeichneten Frequenzverläufen zusammensetzt, die charakteristisch für eine maximale Elevation des Überflugs stehen. Die Daten liegen also in Form einer Zeitreihe vor, auf deren Grundlage eine stetige Variable, die maximale Elevation, geschätzt werden soll. Da es sich bei der Dopplerfrequenz um einen nichtlinearen Verlauf handelt, muss auch das Regressionsproblem mit einer Methode bearbeitet werden, die nicht lineare Zusammenhänge verarbeiten bzw. erkennen kann. Auf dem Gebiet der Zeitreihenanalyse wurde in den letzten Jahren sehr viel veröffentlicht. Der Fokus liegt jedoch meist auf dem $Time\ Series\ Forecasting\ (TSF)$, also der Prognose zukünftiger Werte der vorliegenden Zeitreihe oder der $Time\ Series\ Classification\ (TSC)$, dem Vorhersagen eines diskreten Labels, welches die Zeitreihe in bestimmte diskrete Kategorien klassifiziert.

Der Aufgabe, einen kontinuierlichen Parameter zu schätzen, der von einer Zeitreihe abhängig ist, der $Time\ Series\ Extrinsic\ Regression\ (TSER)$, wurden deutlich weniger Veröffentlichungen gewidmet[25]. Dieses Vorgehen ist der $Scalar - on - Function\ Regression\ (SoFR)$ sehr nahe. In diesem Gebiet der Statistik liegen die Daten in der Regel als Zeitreihen vor und werden auf einen skalaren Ausgabewert abgebildet. Aus der Perspektive des Maschinellen Lernens wird dieser Zusammenhang als Regressionsproblem behandelt. Typische Regressionsalgorithmen berücksichtigen den zeitlichen Aspekt der Daten nicht, eignen sich also nicht, um direkt auf Zeitreihen-Datensätze angewendet zu werden. Die TSER-Methode hingegen betrachtet Datensätze, bestehend aus Zeitreihen, als die Merkmale des zu lösenden Problems [25]. Die Ansätze basieren auf TSC-Konzepten, wurden jedoch für Regressionsprobleme umgebaut. Die Veröffentlichung von Tan, Bergmeir et al. wertet eine große Anzahl von Veröffentlichungen zu Datensätzen in Form von Zeitreihen und deren Auswertung durch verschiedene Methoden des Maschinellen Lernens aus. Dabei werden verschiedene Modelle für Regressionsprobleme adaptiert und in Form eines Github-Projektes zur Verfügung gestellt [26]. Im folgenden Abschnitt werden die Time Series Extrinsic Regression sowie die implementierten adaptierten Methoden vorgestellt.

3.4.1 Time Series extrinsic Regression (TSER)

Die TSER-Methode soll nun etwas genauer definiert werden. Eine Zeitreihe S ist eine geordnete Sammlung von L Parametern und zugehöriger Zeitstempel einer Messung.

$$S = \{(s_1, t_1), (s_2, t_2,), \dots, (s_L, t_L)\} \qquad \text{mit } s_i \in \mathbb{R}^D \tag{3-1}$$

Dabei sind $t_1 \dots t_L$ die Zeitstempel für die Messreihen $s_1 \dots s_L$. Die Dimension D gibt die Anzahl der vorliegenden Zielparameter an. In unserem Fall gilt $D = 1$, da wir nur einen Frequenzverlauf samt Zeitstempel vorliegen haben, der auf die maximale Elevation in Form eines Skalars abgebildet wird. Die Aufgabe der $Time\ Series\ Extrinsic\ Regression$ ist nun, ein Regressionsmodell auf Grundlage des Datensatzes zu erlernen. Das TSER-Modell ist eine Funktion $\mathcal{T} \rightarrow \mathcal{R}$, wobei $\mathcal{T}$ eine Klasse von Zeitreihen ist. Der Datensatz $\mathcal{D}$ ist wie folgt definiert:

$$\mathcal{D} = \{(t_1, r_1), (t_2, r_2,), \dots, (t_n, r_n)\} \tag{3-2}$$

Dabei gibt n die Anzahl an Messreihen an, t_i entspricht einer Zeitreihe und r_i ist der kontinuierliche skalare Zielwert.

Für TSER-Probleme können bereits existierende Algorithmen verwendet werden. Sie sind meist angelehnt an Methoden zur Analyse von TSC-Problemen, können aber für TSER-Probleme adaptiert werden. Einteilen lassen sich die Algorithmen in 4 Gruppen: Merkmals-basiert, dictionary-basiert, Distanzbasiert und Deep Learning-Algorithmik [25]. Relevant für den vorliegenden Datensatz sind Algorithmen, die das vorliegende Signal vollständig auswerten. Ansätze hingegen, die Periodizität untersuchen oder Zeitreihen abschnittweise verarbeiten, um einzelne Muster zu identifizieren [27], werden nicht weiter verfolgt. Das betrifft beispielsweise dicitionary-basierte Algorithmen.

Merkmals-basierte Algorithmen extrahieren charakteristische Features, wie beispielsweise Linearität, Autokorrelation oder den Anstieg der Funktionen aus den Zeitreihen. Die Feature Extraktion erfolgt durch die Analyse der gesamten Zeitreihe, der Intervalle einer Zeitreihe oder bestimmter Signalabschnitte. Auf deren Grundlage kann anschließend ein Klassifikations- oder Regressionsmodell trainiert werden. Werden die Zeitreihenwerte des Datensatzes direkt als Merkmale verwendet, geht der zeitliche Zusammenhang der Parameter verloren, da das Modell die Merkmale als unabhängig voneinander interpretiert. Daher werden Merkmale vom Datensatz extrahiert und auf deren Grundlage wird eine Abbildungsfunktion für die skalare Zielgröße ermittelt. Sind die Merkmale extrahiert, können sie für verschiedene klassischen Regressionsmodelle verwendet werden.

Als Klassische Regressionsmodelle werden die Support Vektor Maschine (SVM), die Lineare Regression (LR) und Random Forest (RF) eingesetzt. Die SVM bildet die Daten in einen höher dimensionalen Raum ab, um sie dort mittels einer Kernel Funktion separierbar zu machen. Der RF-Algorithmus hat sich in der Recherche in [25] für verschiedene Klassifikations- und Regressionsmodelle als besonders robust herausgestellt. Im Random-Forest-Algorithmus werden an jedem Decision Tree Entscheidungen auf Grundlage zufällig ausgewählter Merkmale getroffen. Die am häufigsten ermittelte Klasse bzw. Wertebereich bestimmt am Ende die Vorhersage. Für rauschbehaftete Datensätze hat der RF-Algorithmus eine Tendenz zum Overfitting. Extreme Gradient Boosting (XGBoost) nutzt ebenfalls Decision Trees, minimiert dabei jedoch den Fehler von vorherigen Modellen mit Hilfe des Gradient Descent Verfahrens.

Weitere verbreitete Ansätze für die $SoFR$ sind die Funktionalen Linearen Modelle. Ihre Implementierung für $SoFR$-Probleme lässt sich wie folgt definieren [25]:

$$Y_\mathrm{i} = \int_0^1 W_\mathrm{i}(s)\beta(s)ds + \epsilon_\mathrm{i} \tag{3-3}$$

Dabei entspricht Y_i der skalaren Zielgröße, $W_\mathrm{i}(s)$ der funktionalen Form der Zeitreihe, $\beta(s)$ ist die Koeffizientenfunktion und ϵ_i bildet das Rauschen des Datensatzes ab. In der Implementierung von Tan, Bergmeir et al. werden die Lineare Regression sowie eine Ridge Regression umgesetzt. Dabei handelt es sich um die Abbildung von stark korrelierten Parametern auf eine Zielgröße.

Ein weiterer Ansatz wurde von [28] adaptiert. Der Random-convolutional-kernel-transform (Rocket)-Algorithmus nutzt eine große Anzahl an zufälligen Convolutional Kernels und trainiert einen Ridge Regression Klassifikator. Angewendet auf eine Zeitreihe werden Merkmale in Form einer feature map extrahiert. Auch diese Methode ist angepasst worden, um sie ebenfalls für Regressionsprobleme nutzen zu können.

Deep-Learning Algorithmen können sowohl für Klassifikations- als auch für Regressionsprobleme eingesetzt werden. Entscheidend sind die verwendete Aktivierungsfunktion sowie die Loss-Funktion. Für Regressionsprobleme werden geeignete lineare bzw. nicht lineare Aktivierungsfunktionen eingesetzt. Die Loss-Funktion wird mit dem mittleren quadratischen Fehler oder dem mittleren absoluten Fehler ersetzt. Es werden ein Residual Network (ResNet), ein Fully Convolutional Neural Network (FCN) und ein Inception Network eingesetzt. Die Architektur des ResNet ist der Veröffentlichung von Fawaz et al. [29] entnommen und besteht aus drei Convolutional Layern in jedem Block, denen ein Pooling Layer und ein Output Layer folgen.

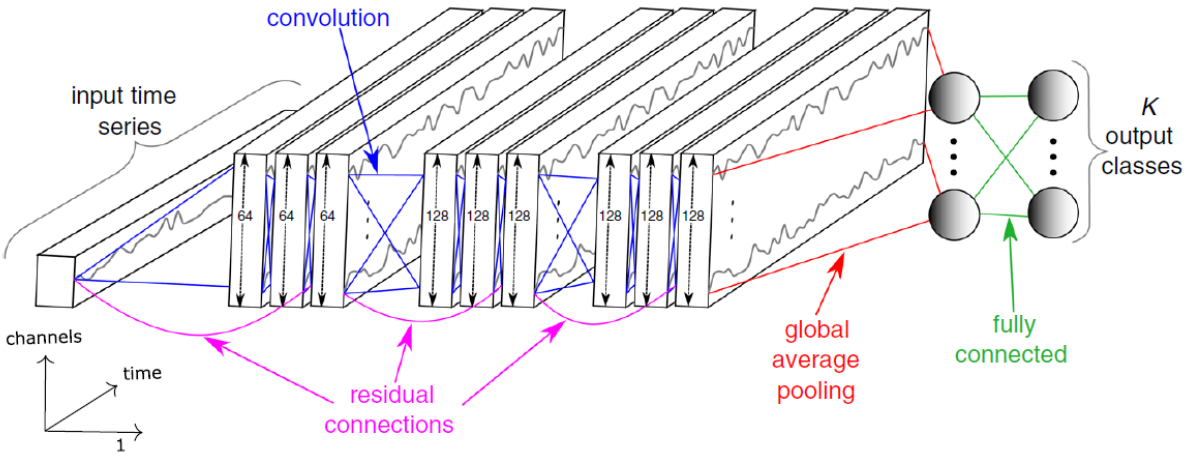

Abbildung 3.22: Architektur des Residual Network [29]

In Abgrenzung zu den typischen Convolutional Networks hat ResNet eine Verbindung zwischen den Convolutional Layern. Das FCN-Netz besteht aus 3 Convolutional Blocks mit Batch-Normierung und einer ReLu-Aktivierungsfunktion. Im letzten Block wird Pooling verwendet und mit einem Softmax-Klassifikator verknüpft. Um die FCN-Methode für Regressionsprobleme einsetzen zu können, wird der Softmax-Klassifikator mit einer linearen Aktivierungsfunktion ersetzt.

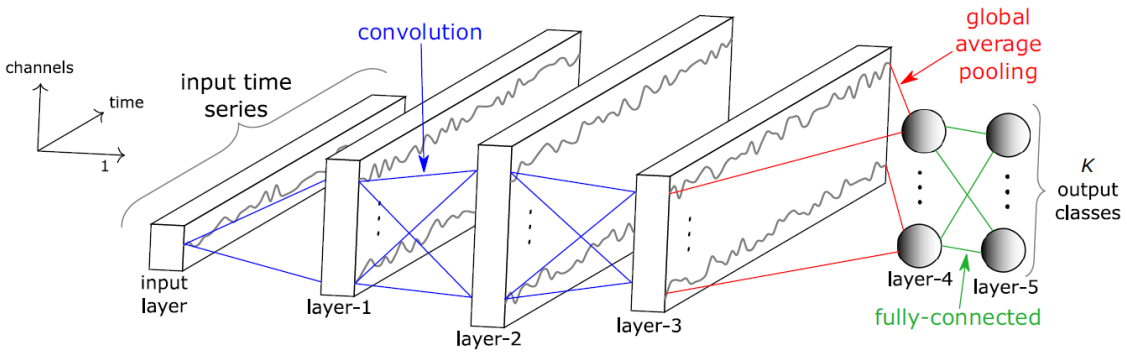

Abbildung 3.23:Architektur des Convolutional Neural Network [29]

Das Inception-Netz setzt sich aus zwei Residual Blocks zusammen, die den Input zum Eingang des nächsten Blocks verbinden. Jeder Block enthält drei Inception Module, in denen jeweils zwei wichtige Elemente verwendet werden. Das Bottleneck Layer reduziert die Dimensionen der Zeitreihe, indem es m Filter verwendet und somit längere Filter als zB. im Residual Network ermöglicht. Das zweite Element kann verschiedene Filter unterschiedlicher Länge auf den Ausgang des Bottleneck Layers anwenden. Schließlich wird Pooling auf den letzten Residual Block angewendet und es folgt ein Fully Connected Layer für die Klassifikation bzw. Regression. Die Architektur der Netze wurde aus diversen Forschungsarbeiten übernommen, die in [28] zu finden sind.

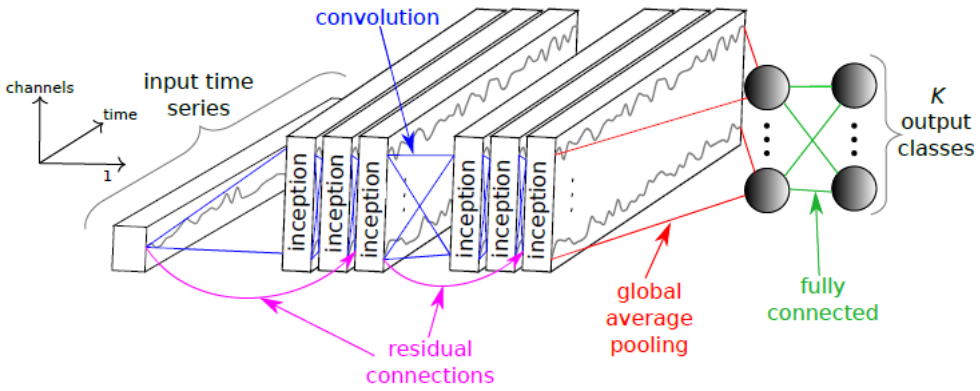

Abbildung 3.24: Architektur des Inception Netzes [30]

Um die Methoden für Regressionsprobleme anwenden zu können, sind die Aktivierungsfunktion und Lossfunktion jeweils angepasst.

Distanz-basierte Algorithmen konzentrieren sich auf die Ähnlichkeit zweier Zeitreihen. Dabei wird die Distanz zwischen zwei Zeitreihen ermittelt und mit Hilfe des k-nearest-neighbour (k-NN) Algorithmus die Zeitreihe ausgewählt, welche die größte Ähnlichkeit, bestimmt durch ein Distanzmaß, aufweist. Da der k-NN-Algorithmus die zeitliche Dimension der Daten nicht berücksichtigt, werden die üblichen Distanzmaße, wie beispielsweise die Euklidische oder die Manhatten-Distanz, durch sogenannte elastische Distanzen ersetzt. Die Euklidischen Distanz (ED) ist in Gleichung (3.4) definiert. Sie bestimmt die Distanz zwischen zwei Zeitreihen P und Q. Dabei definiert D die Anzahl der Dimensionen, die der Anzahl der aufgezeichneten Parameter entspricht, und L gibt die Länge der Zeitreihen an.

$$ED(P,Q) = \sum_{j=1}^{D} \sqrt{\sum_{i=1}^{L} \left(p_i^j - q_i^j\right)^2} \tag{3.4}$$

Die Verwendung der euklidischen Distanz setzt voraus, dass die Zeitsignale mit gleicher Rate aufgezeichnet sind. Ist dies nicht der Fall, können elastische Distanzmaße eingesetzt werden. Ein oft verwendetes Beispiel ist die Dynamic Time Warping (DTW)-Distanz. In der Regel wird die minimale Distanz ermittelt, nachdem die optimale Ausrichtung beider Zeitreihen aneinander ermittelt wurde. Für die vorliegenden Dopplerverläufe ist jedoch kein elastisches Distanzmaß erforderlich, da die Werte mit konstanten Zeitabständen von $1s$ aufgezeichnet sind. Der Distanzbasierte Algorithmus arbeitet mit einer simplen Methode, die manuell in MATLAB implementiert werden kann. In Abschnitt 4 wird das Grundprinzip des Maximum-Likelihood-Verfahrens erläutert und umgesetzt. Die genannten klassischen, linearen und Deep Learning Modelle hingegen werden genutzt, um die Dopplerfrequenzsignale auszuwerten. Dafür wird der Datensatz in das von Tan, Bergmeir et al. verwendete Dateiformat übertragen. Die implementierten Modelle, welche bei Github zur Verfügung gestellt sind [26], können Datensätze in unterschiedlicher Form verarbeiten. Sie ermöglichen die Verarbeitung der Daten mit oder ohne Zeitstempel und können Zeitreihen mit fehlenden Werten sowie unterschiedlichen Längen und verschiedener Anzahl an Parametern oder Zielgrößen verarbeiten. Fehlende Werte werden linear interpoliert. Ein Großteil der Algorithmen optimiert die Hyperparameter, wenn sie aufgerufen werden. In [28] ist aufgelistet, welche Parameter das je Methode betrifft.

3.5 AUSWERTUNG DER POSITIONSSCHÄTZUNG

Zur Auswertung der verschiedenen Modelle wird der idealisierte Datensatz in 70% Trainingsdaten und 30% Testdaten aufgeteilt und eingelesen. Zunächst werden die klassischen Modelle Random Forest (RF), die Support Vektor Maschine sowie XGBoost verwendet. Die Schätzungen sind in den Abbildungen Abbildung 3.25 bis Abbildung 3.27 zu sehen. Wie auch in [25] ausgewertet wurde, erzielt der RF-Algorithmus sehr gute Ergebnisse. Die Support-Vektor-Maschine hingegen bestimmt für alle Signale den gleichen Zielwert. XGBoost ermittelt zwar Positionsschätzungen, weist aber zu große Abweichungen auf. Die akzeptierte Standardabweichung beträgt $\pm 1km$.

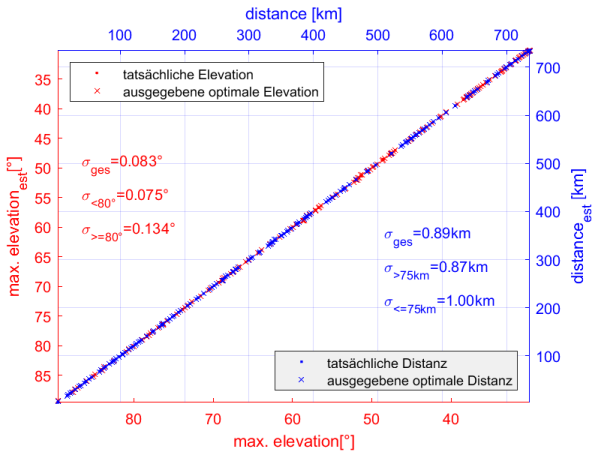

Abbildung 3.25: Schätzung der max. Elevation bzw. Distanz des idealisierten Datensatzes mit Random Forest

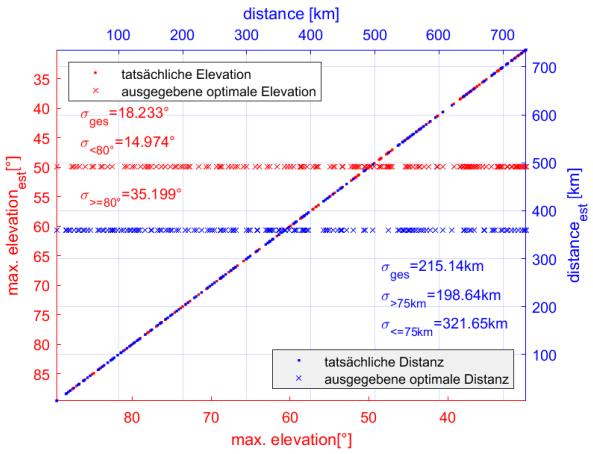

Abbildung 3.26: Schätzung der max. Elevation bzw. Distanz des idealisierten Datensatzes mit der Support Vektor Maschine

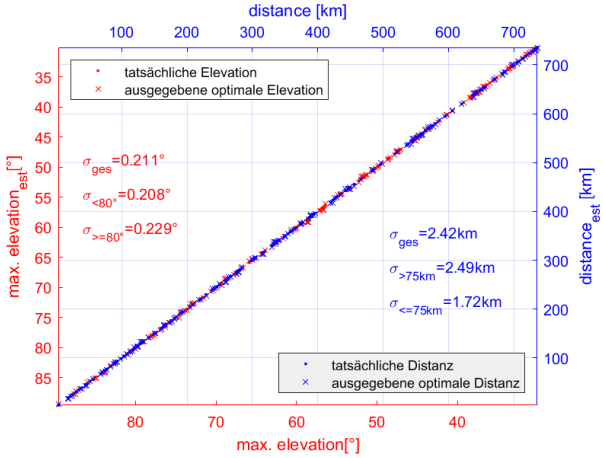

Abbildung 3.27: Schätzung der max. Elevation bzw. Distanz des idealisierten Datensatzes mit „XGboost“

Die Methoden aus dem Bereich des Deep Learning werden in den Abbildungen Abbildung 3.28 bis Abbildung 3.30 ausgewertet. Die Inception-Implementierung erzielt zwar die genauesten Ergebnisse, ist in der Positionsbestimmung aber dennoch nicht ausreichend genau.

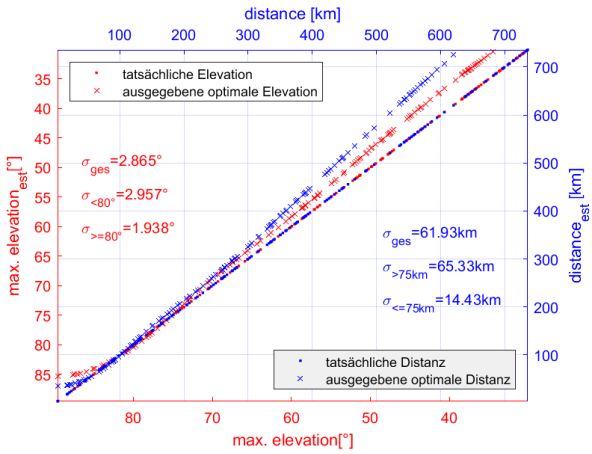

Abbildung 3.28: Schätzung der max. Elevation bzw. Distanz des idealisierten Datensatzes mit FCN

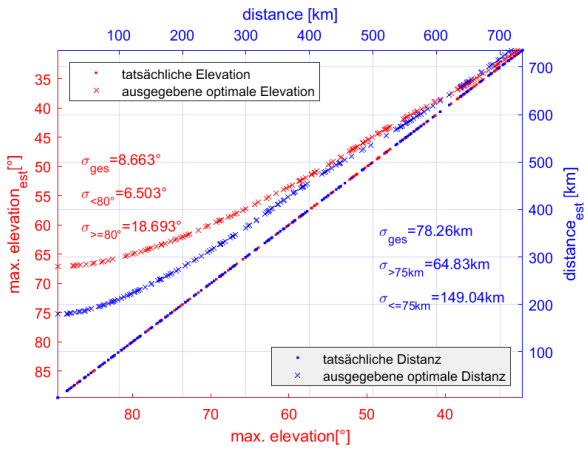

Abbildung 3.29: Schätzung der max. Elevation bzw. Distanz des idealisierten Datensatzes mit ResNet

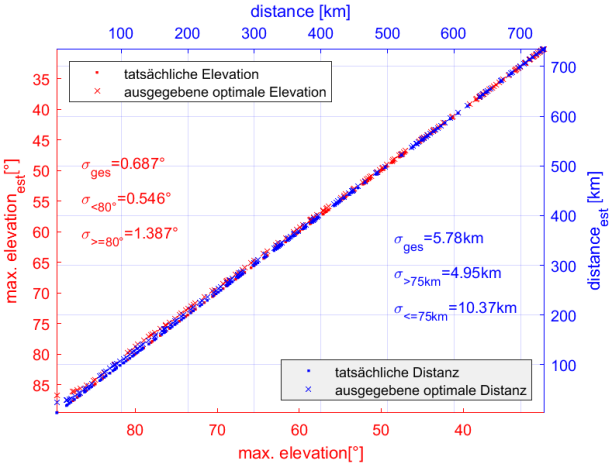

Abbildung 3.30: Schätzung der max. Elevation bzw. Distanz des idealisierten Datensatzes mit Inception

Für die Linearen Modelle ist die Positionsschätzung ebenfalls zu ungenau. Besonders die Lineare Regression weist grobe Schätzfehler auf.

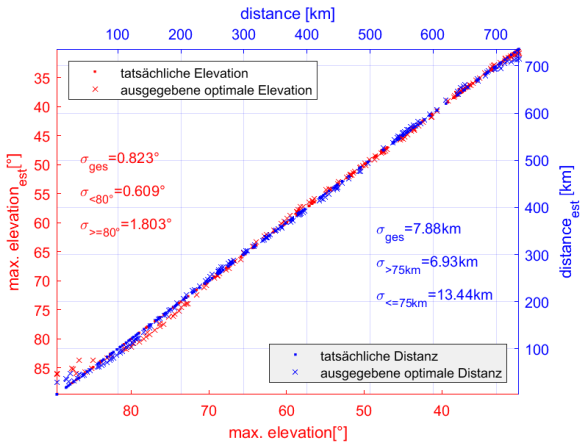

Abbildung 3.31: Schätzung der max. Elevation bzw. Distanz des idealisierten Datensatzes mit Ridge

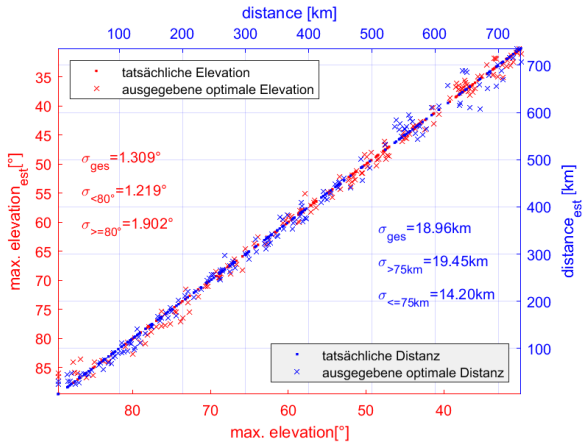

Abbildung 3.32: Schätzung der max. Elevation bzw. Distanz des idealisierten Datensatzes mit Linearer Regression

Der letzte verwendete Algorithmus ist die Rocket-Implementierung. Für Distanzen $> 75km$ erzielt sie die größte Genauigkeit.

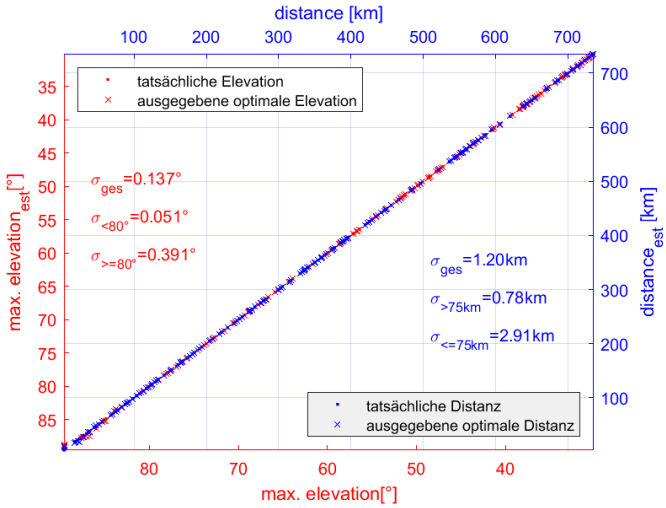

Abbildung 3.33: Schätzung der max. Elevation bzw. Distanz des idealisierten Datensatzes mit Rocket

Vergleichend werden die Schätzergebnisse der verschiedenen Methoden in Form eines Boxplots zusammengefasst. Dabei sind sehr starke Unterschiede in der Schätzgenauigkeit zu erkennen. Die Algorithmen, die die Positionen mit maximal $\pm 1km$ Standardabweichung schätzen, sind der Random-Forest- und Rocket-Algorithmus. Mit der Rocket-Methode kann die Positionsschätzung allerdings nur für Distanzen $> 75km$ zuverlässig genug umgesetzt werden.

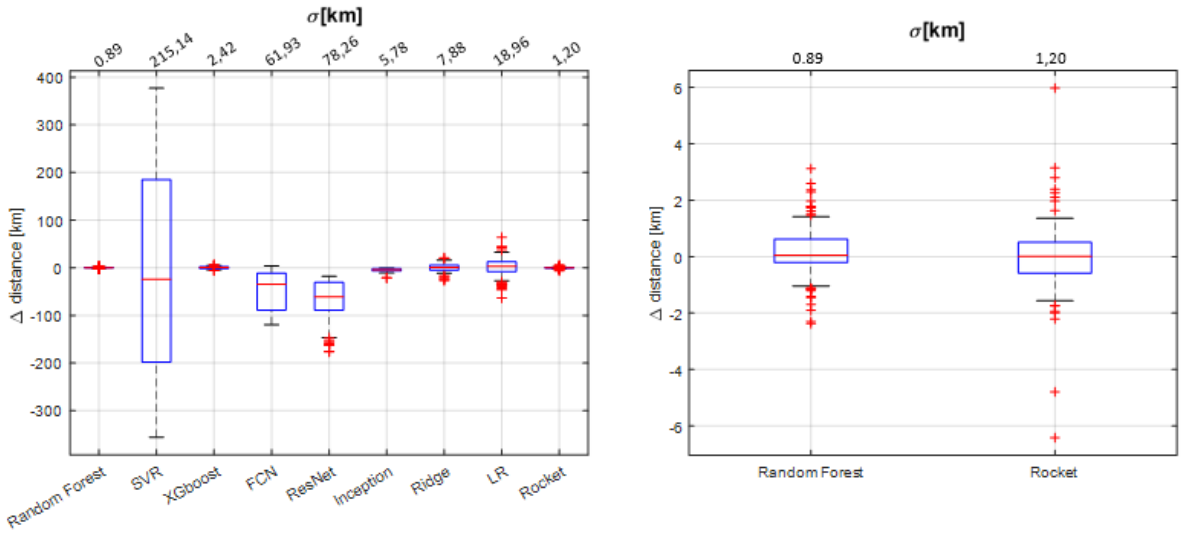

Abbildung 3.34: Vergleich der Schätzgenauigkeit für den idealisierten Datensatz in Form eines Boxplots

Ein Boxplot fasst grundlegende Streuungs- und Lagemaße zusammen. Innerhalb der Box liegen die mittleren 50% der Daten und somit die kleinsten 50% der Schätzfehler. Die Größe der Box visualisiert gleichzeitig die Streuung der Daten, die durch die Differenz der oberen und unteren Begrenzung, bzw. dem oberen und unteren Quartil bestimmt wird. Des Weiteren wird der Median als durchgehender Strich in der Box eingezeichnet. Er unterteilt den Datensatz in jeweils 50% der Daten ein. Er verdeutlicht also, ob die Verteilung des Datensatzes eine Schiefe beinhaltet. Die sogenannten Whisker decken einen Bereich außerhalb der Box ab, der der Länge der Box entspricht. In diesen Bereich fallen sogenannte „milde“ Ausreißer. Für die Datensätze ausreichender Qualität liegen sie im Bereich von $\pm 1km$.

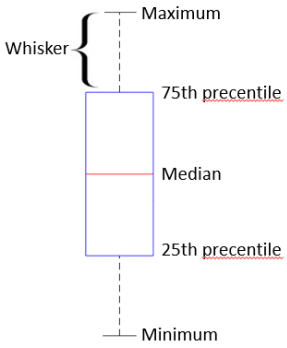

Abbildung 3.35: Schema eines Boxplots

Im nächsten Schritt wird die Qualität der Daten reduziert und die jeweiligen Schätzergebnisse werden miteinander verglichen. Auf diese Weise wird ermittelt, wie viel Datenverlust das Schätzergebnis erheblich beeinflusst. Entsprechend Abschnitt 0 werden schrittweise Asymmetrien von 30% und 40%, Lücken von bis zu 30%, 40%, 50% und 60% der eigentlichen Signallänge eingefügt sowie Rauschen von $\pm 4Hz$ und $\pm 28Hz$ aufgeprägt. Da lediglich die Rocket-Methode für Distanzen $> 75km$ und der Random-Forest-Ansatz ausreichend genaue Ergebnisse erzielen, werden die beiden Verfahren für die Datensätze unterschiedlicher Qualität untersucht.

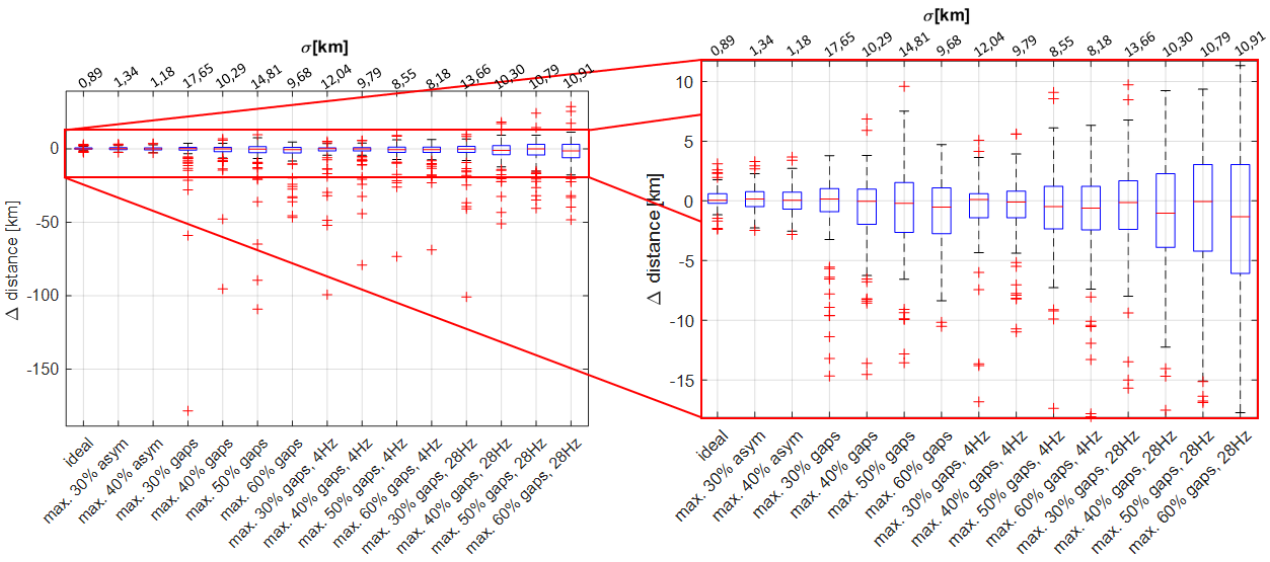

Abbildung 3.36: Schätzgenauigkeit der verschiedenen Datensätze mit Random Forest

Sobald die Qualität des Datensatzes reduziert wird, erzielt Random Forest Methode ungenügend genaue Positionsschätzungen. In Abbildung 3.37 sind die Schätzergebnisse der Datensätze unterschiedlicher Qualität für die Rocket-Methode dargestellt.

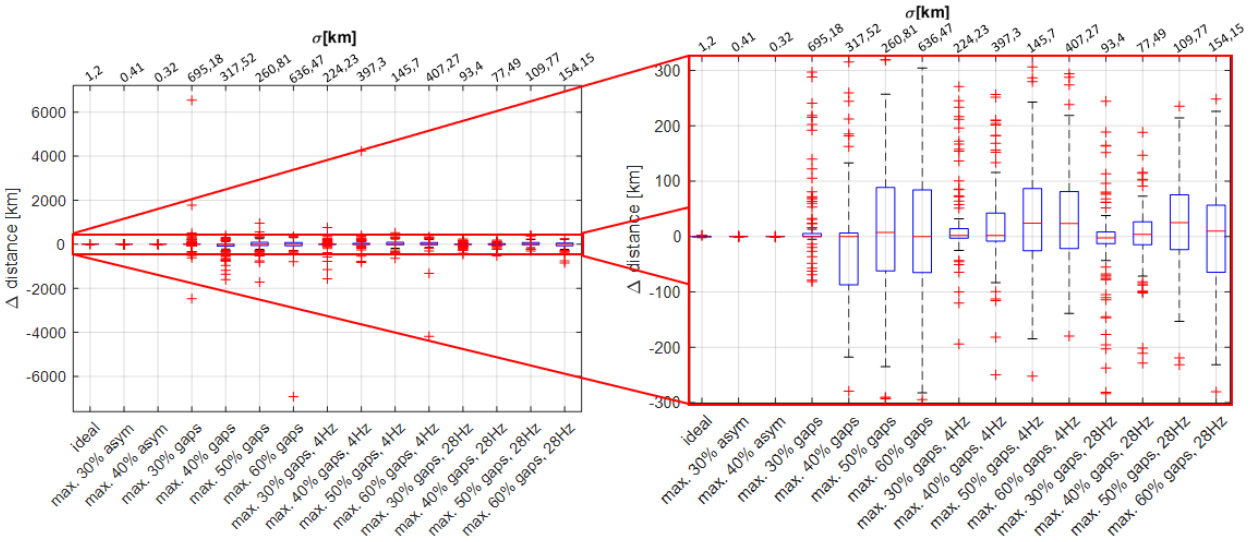

Abbildung 3.37: Schätzgenauigkeit der verschiedenen synthetischen Datensätze mit Rocket

Im Vergleich zur Random-Forest-Methode sind die Abweichungen mit dem Rocket-Verfahren besonders hoch, sobald der Signalverlauf Lücken aufweist. Zuletzt wird die Positionsschätzung für den real gemessenen Datensatz ausgewertet.

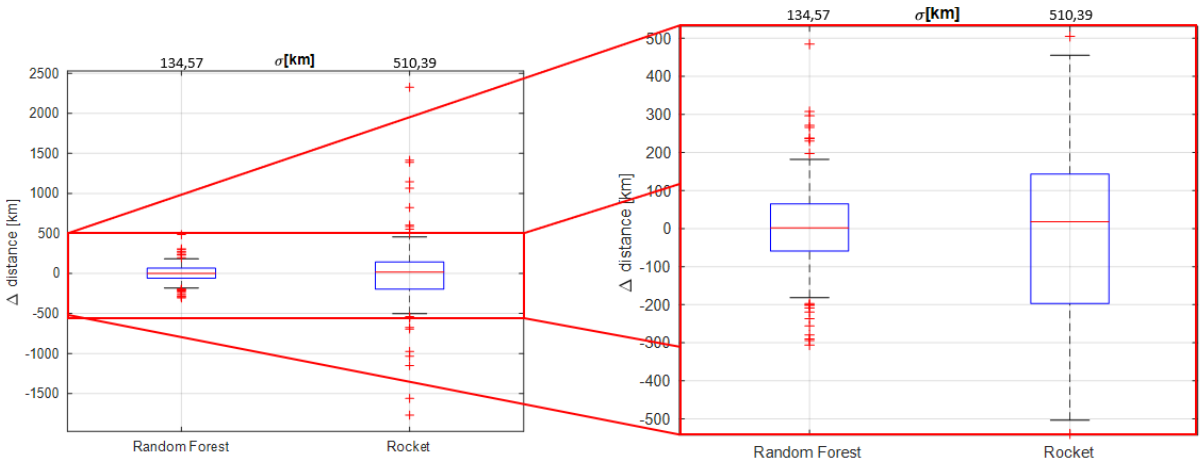

Abbildung 3.38: Vergleich der Schätzgenauigkeit des real gemessenen Datensatzes für Random Forest und Rocket

Die Positionsschätzergebnisse für den real gemessenen Datensatz sind ebenfalls nicht zu verwenden. Da die gemessenen Daten in geringerer Qualität vorliegen als der synthetische Datensatz in verschiedenen Abstufungen, sind die starken Abweichungen erwartbar. Die verwendeten Algorithmen können den Dopplerfrequenzverlauf nicht zuverlässig auf die Zielgröße abbilden, sobald das Dopplersignal Störungen aufgeprägt bekommt.

Aktuell ist die Verarbeitung von Zeitsignalen im Maschinellen Lernen ein Randthema, wenn es sich um Regressionsprobleme handelt [25]. Bei der geringen Qualität des aufgezeichneten Datensatzes ist es naheliegend, dass die Methoden keine zuverlässigen Schätzergebnisse liefern. Dennoch ist auffällig, dass bereits bei geringem Datenverlust erhebliche Abweichungen auftreten. Besonders die Lücken im Datensatz führen zu geringerer Schätzgenauigkeit. Die Lücken in den Zeitverläufen werden einfach linear interpoliert, während es sich bei den Dopplerfrequenzen um nichtlineare Funktionen handelt. Die Methoden, die in der Veröffentlichung adaptiert und zur Verfügung gestellt werden, können also durchaus besser auf den vorliegenden Datensatz ausgelegt werden.

4 ORTUNG MIT DEM MAXIMUM LIKELIHOOD-VERFAHREN

Die Vorhersage der maximalen Elevation bzw. Distanz wird mit den Methoden aus 3.4 nicht ausreichend genau getroffen. Daher wird ein weiterer Ansatz untersucht, welcher den Dopplerverlauf eines Überfluges mit Aufzeichnungen idealisierter Überflüge vergleicht und den plausibelsten Verlauf auswählt. Es wird das *Maximum-Likelihood-Verfahren* angewendet. Um die Zuverlässigkeit dieser Methode zu untersuchen, wird der idealisierte Datensatz verwendet, welcher bereits in Abschnitt 0 erwähnt wurde. Der idealisierte Datensatz wird in MATLAB erstellt und enthält einen Dopplerverlauf für eine bestimmte Überflughöhe und einer maximalen Elevation. Obwohl es sich zunächst nur um einen simulierten Datensatz handelt, wird er dennoch als Messdatensatz bezeichnet, da an dessen Stelle tatsächlich gemessene Überflüge treten werden, sofern sich das Verfahren unter idealisierten Bedingungen bewährt. Ein solcher Dopplerverlauf ist in Abbildung 4.1 zu sehen.

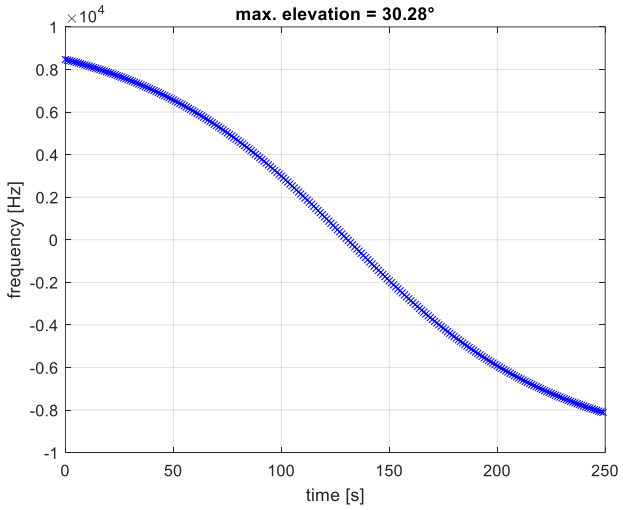

Abbildung 4.1: Beispiel eines idealisierten Dopplerverlaufs für niedrige maximale Elevation

Für die Dopplerverschiebung f_d wird die maximale Elevation des Überflugs sowie die bei der Übertragung des Signals aufgeprägten Frequenz- und Zeitoffsets Δf und Δt zum Zeitpunkt i mit dem Maximum-Likelihood-Verfahren geschätzt.

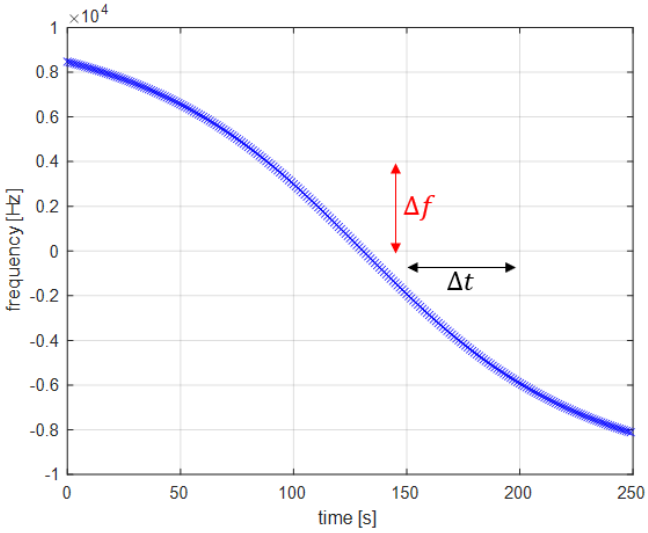

Abbildung 4.2: Offset-Korrektur im Maximum-Likelihood-Verfahren

Da mehrere Parameter zu schätzen sind, werden sie der Parametermenge $\Theta = (\varphi_i, \Delta f_i, \Delta t_i)$ zugeordnet. Es liegt also ein multivariates Schätzproblem vor. Für den zeitvarianten Mittelwert f_d wird eine Normalverteilung angenommen. Die Dichtefunktion einer Normalverteilung ist wie folgt definiert [31]:

$$P(x|\mu,\sigma) = \frac{1}{\sigma\sqrt{2\pi}} \cdot e^{-\frac{(x-\mu)^2}{2\sigma^2}} \tag{4.1}$$

Die Dichtefunktion besagt, dass die Wahrscheinlichkeit, einen Wert x zu beobachten, eine Funktion des Quadrats des Abstands von x und dem Erwartungswert μ, sowie der Varianz σ^2 ist. In diesem Fall entspricht der Erwartungswert μ der Dopplerverschiebung $f_d(\Theta, i)$ zu einem bestimmten Zeitpunkt i in Abhängigkeit der bereits genannten Parameter Θ.

Zur Veranschaulichung ist die Standardnormalverteilung mit den Werten $\mu = 0$ und $\sigma^2 = 1$ in Abbildung 4.3 in schwarz abgebildet. Wird die Varianz größer, flacht die Verteilung ab, es ändert sich der Erwartungswert und die Verteilung verlagert sich.

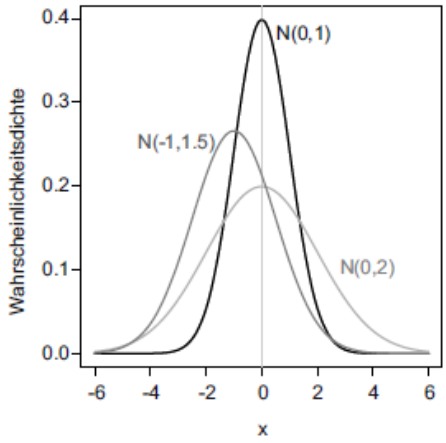

Abbildung 4.3: Wahrscheinlichkeitsdichtefunktion[31]

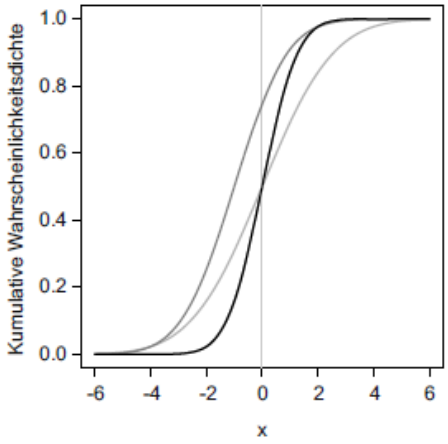

Abbildung 4.4: kumulative Wahrscheinlichkeitsdichte-funktion [31]

Während in Abbildung 4.3 die Wahrscheinlichkeitsdichte abgelesen werden kann, mit welcher ein bestimmter Wert in der Stichprobe vorkommt, ist in Abbildung 4.4 abzulesen, mit welcher Wahrscheinlichkeitsdichte ein gemessener Wert kleiner ist als x.

Die Verteilungsparameter Θ sollten so gewählt sein, dass sie die Passung der Verteilung der Daten maximieren. Da die wahren Werte dieser Verteilungsparameter nicht bekannt sind, müssen sie geschätzt werden. Dabei sollten sie mit zunehmender Anzahl an Datenpunkten auf den wahren Wert zulaufen. Werden die Parameter Θ als Variable aufgefasst, so wird aus der Dichtefunktion eine Likelihood-Funktion. Die Likelihood-Funktion kann als „umgekehrte Wahrscheinlichkeitsdichte“ interpretiert werden. Die Likelihood-Funktion gibt an, wie wahrscheinlich ein Parameter bei gegebenen Daten ist. Dabei wird für mehrere Datenpunkte angegeben, wie plausibel die Verteilungsparameter für den gegebenen Datensatz sind. Es wird diejenige Parameterkombination für eine Verteilung ausgewählt, deren Likelihood-Funktion maximal ist.

Betrachtet man die n unabhängig und identisch normalverteilten Zufallsvariablen $X_1, X_2, \dots X_n$ des gegebenen Datensatzes mit unbekannten Parametern Θ, so besitzt $X = X_1, X_2, \dots X_n$ folgende Wahrscheinlichkeitsdichtefunktion:

$$
\begin{aligned}
P(X|\Theta,i) &= \prod_{i=1}^{n} \frac{1}{2\sqrt{\sigma^2}} \cdot exp\left(-\frac{\left(X_i - f_d(\Theta,i)\right)^2}{2\sigma^2}\right) \\
&= (2\pi\sigma^2)^{-n/2} \cdot exp\left(-\frac{1}{2\sigma^2}\sum_{i=1}^{n}(X_i - f_d(\Theta,i))^2\right)
\end{aligned}
\tag{4.2}
$$

Die Likelihood-Funktion ergibt sich daraus zu

$$
L(X,\Theta,i) = (2\pi\sigma^2)^{-n/2} \cdot exp\left(-\frac{1}{2\sigma^2}\sum_{i=1}^{n}(X_i - f_d(\Theta,i))^2\right) \tag{4.3}
$$

Die Likelihood-Funktion behandelt Θ als Variable und X als Parameter. Da die Einzelergebnisse in der Regel sehr klein sind, wird die Likelihood-Funktion zur besseren Handhabung logarithmiert ermittelt und es entsteht die Log-Likelihood-Funktion.

$$
\begin{aligned}
LL(X,\Theta) &= ln\left[\sigma^{-n}(2\pi)^{-n/2} \cdot exp\left(-\frac{1}{2\sigma^2}\sum_{i=1}^{n}(X_i - f_d(\Theta,i))^2\right)\right] \\
&= -n \cdot \ln(2\pi) - \frac{1}{2\sigma^2}\sum_{i=1}^{n}(X_i - f_d(\Theta,i))^2
\end{aligned}
\tag{4.4}
$$

Anschließend wird das Maximum der Log-Likelihood-Funktion ermittelt, indem die partielle Ableitung nach jedem in Θ enthaltenen Parameter Θ_p gleich 0 gesetzt wird. Die einzelnen Ableitungen werden in einem Gleichungssystem zusammengefasst und gleich 0 gesetzt.

$$
\frac{\partial LL(X,\Theta)}{\partial \Theta_p} = 0 = \frac{\partial}{\partial \Theta_p}\left(-\frac{1}{2\sigma^2}\sum_{i=1}^{n}(X_i - f_d(\Theta,i))^2\right) \tag{4.5}
$$

Zuletzt wird die Ableitung der Summe als Summe ihrer einzelnen Ableitungen dargestellt.

$$
\frac{\partial LL(X,\Theta)}{\partial \Theta_p} = 0 = \sum_{i=1}^{n} -\frac{\partial f_d(\Theta,i)}{\partial \Theta_\mathrm{p}} \cdot \frac{1}{\sigma^2}(X_i - f_d(\Theta,i)) \tag{4.6}
$$

Da $f_d(\Theta,i)$ einem Eintrag der LUT entspricht, ist davon auszugehen, dass die partiellen Ableitungen so ähnlich sind, dass sie zu vernachlässigen sind und die Maximierung der Log-Likelihood-Funktion maßgeblich durch die Differenzbildung bestimmt wird:

$$
LL(X,\Theta) = \sum_{i=1}^{n} -\frac{1}{\sigma^2}(X_i - f_d(\Theta,i)) \tag{4.7}
$$

Auf Grundlage des Maximum-Likelihood-Verfahrens werden nun die maximale Elevation sowie der Frequenz- und Zeitoffsets Δf und Δt geschätzt. Dafür wird eine Look-Up-Tabelle erstellt, in der für verschiedene maximale Elevationen eine charakteristische Dopplerkurve hinterlegt ist. In Abbildung 4.5 sind exemplarisch zwei Dopplerverläufe aus der Look-Up-Table zu sehen. Dabei ist zu erkennen, dass der Anstieg des Dopplerfrequenzverlaufs im Mittelteil des Signals für eine hohe maximale Elevation steiler ausfällt als im Falle einer niedrigen maximalen Elevation. Gleichzeitig ist für den Verlauf einer hohen maximalen Elevation eine stärkere Abflachung in den Randbereichen zu verzeichnen.

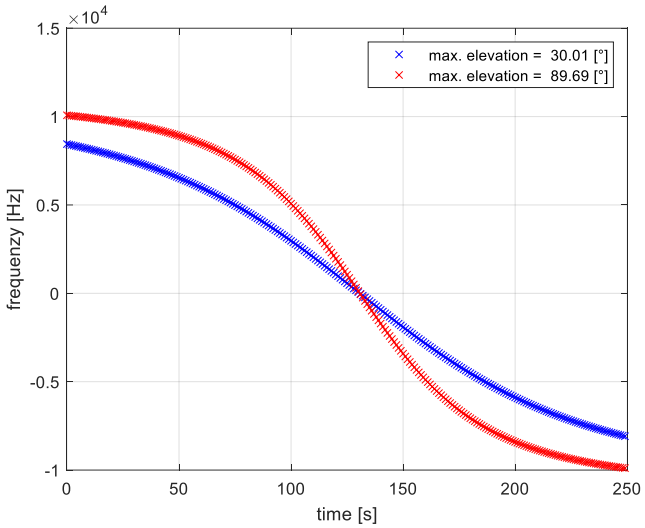

Abbildung 4.5: verschiedene Dopplerverläufe aus der LUT

Das Maximum-Likelihood-Verfahren geht für eine Dopplerkurve, deren maximale Elevation geschätzt werden soll, entsprechend Gleichung (4.6) iterativ alle gespeicherten Dopplerverläufe in der LUT durch. Die Dopplerkurve, welche die größte Ähnlichkeit aufweist, liefert, wie bereits erläutert, die geschätzte maximale Elevation sowie eine Zeit- und Frequenzoffsetkorrektur. In Abbildung 4.6 ist die Differenz, die sich für verschiedene Dopplerverläufe aus der LUT und dem Messsignal ergibt, als blaue Kurve abgetragen. Für eine LUT-Dopplerkurve ergibt sich die geringste Differenz, welche mit einem roten Kreuz markiert ist. Deren zugehörige maximale Elevation entspricht dem Schätzergebnis. In Abbildung 4.7 sind das Messsignal sowie das ausgewählte LUT-Signal zu sehen. Dabei entspricht el_{orig} der Elevation des Messsignals und el_{opt} der geschätzten maximalen Elevation, welche das passende LUT-Signal liefert. Im Kopf der Graphik sind der Betrag der Differenz beider Signale $(diff)$, der Index des ausgewählten LUT-Signals (LUT_{idx}) sowie die ermittelten Frequenz- und Zeitoffset Werte $(cfo, t_{\mathrm{shift}})$ angegeben.

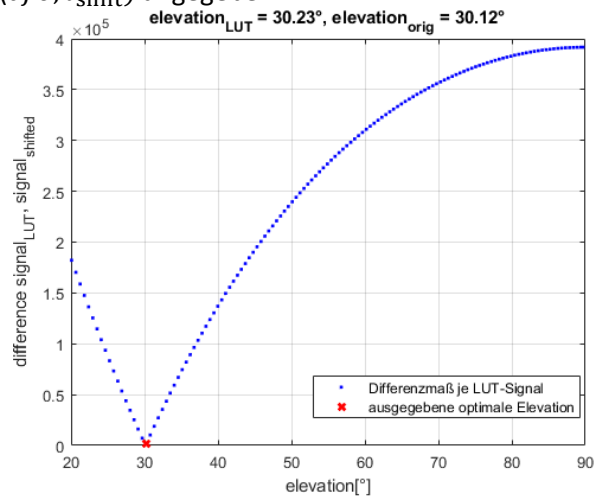

Abbildung 4.6: ermittelte Differenz je LUT-Dopplerkurve

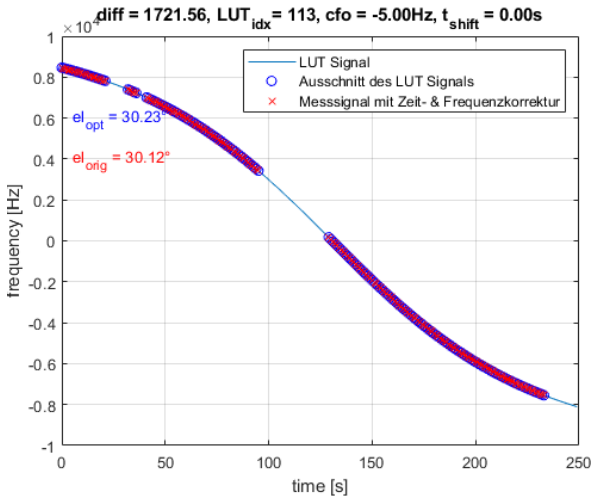

Abbildung 4.7: ermittelte LUT-Dopplerkurve sowie Offset-korrigiertes Messsignal

Die Auswertung der Schätzgenauigkeit für die maximale Elevation je Dopplerverlauf erfolgt für die fünf bereits angeführten Datensätze und ist im folgenden Abschnitt zu finden. Dabei werden Look-Up-Tabellen mit unterschiedlicher Winkelauflösung verwendet. Die Schätzung wird auf Grundlage zweier

LUTs mit einer Winkelauflösung von $\Delta\varphi = 0.5$ sowie $\Delta\varphi = 0.1$ durchgeführt. Während eine grobe Winkelauflösung größere Schätzfehler erzeugt, ist jedoch der Rechenaufwand geringer.

4.1 Schätzgenauigkeit des Maximum-Likelihood Verfahrens

Zunächst wird die Schätzgenauigkeit der maximalen Elevation für den idealen Datensatz ausgewertet. Es wird ebenfalls deren Transformation in die Distanz in y-Richtung entsprechend Abschnitt 3 ausgewertet. In Abbildung 4.8 ist die Schätzung mit einer LUT der Winkelauflösung $\varphi_{LUT} = 0.5$ zu sehen, während in Abbildung 4.9 eine LUT der Winkelauflösung $\varphi_{LUT} = 0.1$ zu Grunde gelegt wurde.

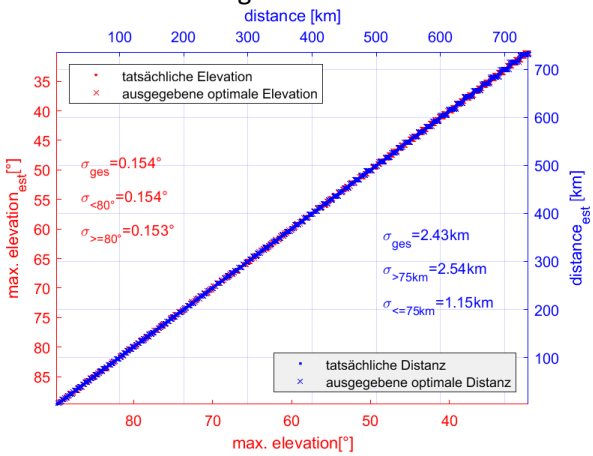

Abbildung 4.8: Schätzung der max. Elevation bzw. Distanz des idealisierten Datensatzes mit $\varphi_{LUT} = 0.5$

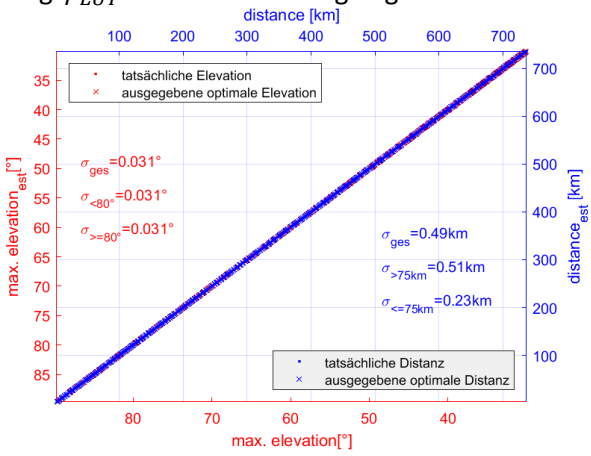

Abbildung 4.9: Schätzung der max. Elevation bzw. Distanz des idealisierten Datensatzes mit $\varphi_{LUT} = 0.1$

Es ist zu erkennen, dass eine feinere Winkelauflösung ein deutlich genaueres Schätzergebnis ergibt. Das Maximum-Likelihood-Verfahren ermittelt unter idealisierten Bedingungen und auf Grundlage einer LUT mit $\varphi_{LUT} = 0.1$ die maximalen Elevationen bzw. den Abstand zur Tag Position mit einer Standardabweichung von $\sigma_{ges} = 0{,}49km$. Ziel ist es, die Tagposition mit einer Abweichung von maximal $1km$ zu ermitteln. Die Positionsschätzung mit der Winkelauflösung $\varphi_{LUT} = 0.5$ hingegen fällt zu ungenau aus. Daher wird die Positionsschätzung im weiteren Verlauf lediglich mit $\varphi_{LUT} = 0.1$ umgesetzt.

Die Qualität des Datensatzes wird nun der Realität angenähert, wie in Abschnitt 3.2 bereits erläutert wurde. Im Vergleich zu Abbildung 4.9 ist kaum eine Erhöhung der Schätzfehler zu verzeichnen. Bei den asymmetrischen Signalen handelt es sich um Dopplerverläufe, deren Verlauf im Bereich der negativen Frequenzen teilweise nicht vollständig aufgezeichnet wurde, wie in Abbildung 4.10 zu sehen ist. Dabei gehen maximal 30% des Dopplerverlaufs verloren.

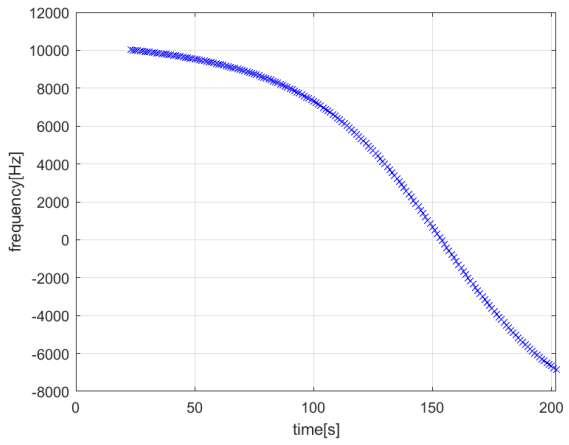

Abbildung 4.10: Bsp. eines asymmetrischen Dopplerfrequenzverlaufs mit bis zu 30% Datenverlust, $\varphi_{max} = 75{,}6°$

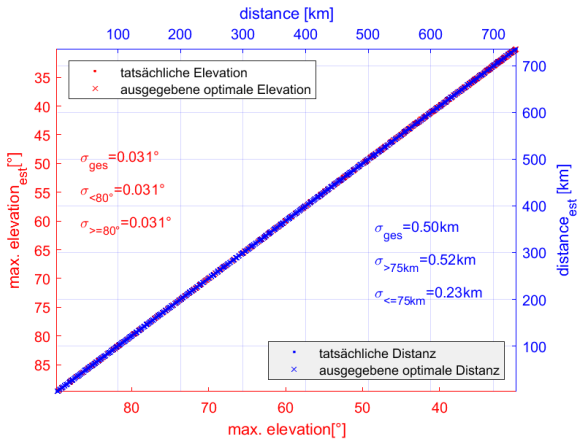

Abbildung 4.11: Schätzung der max. Elevation bzw. Distanz des lückenhaften Datensatzes bis 30% der Signallänge mit $\varphi_{LUT} = 0.1$

In Abbildung 4.11 ist zu erkennen, dass sich der Schätzfehler im Vergleich zu dem des asymmetrischen Datensatzes minimal erhöht hat. Für die höhere Winkelauflösung $\varphi_{LUT} = 0.1$ kann die Position des Tags weiterhin ausreichend genau geschätzt werden.

Anschließend wird der Anteil der nicht erfassten Werte auf bis zu 40% erhöht und die Asymmetrie somit verstärkt.

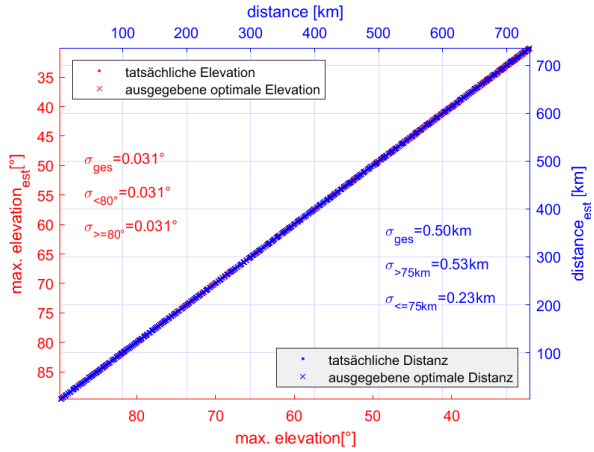

Abbildung 4.12: Schätzung der max. Elevation bzw. Distanz des lückenhaften Datensatzes bis 30% der Signallänge mit $\varphi_{LUT} = 0.1$

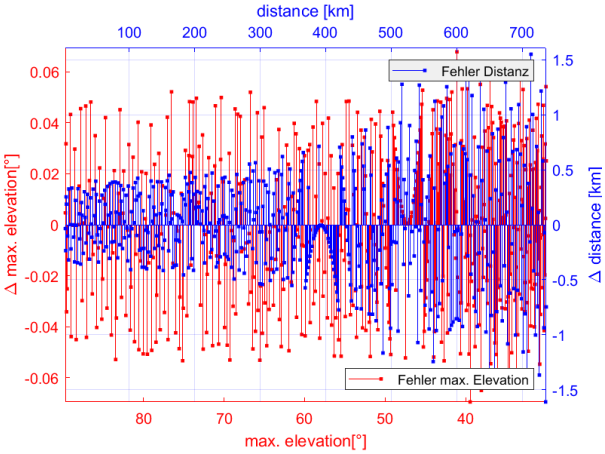

Abbildung 4.13: Schätzfehler der max. Elevation bzw. Distanz des lückenhaften Datensatzes bis 30% der Signallänge mit $\varphi_{LUT} = 0.1$

Die verstärkte Asymmetrie hat kaum Einfluss auf das Schätzergebnis. Die Positionsschätzung weist ebenfalls eine Standardabweichung von etwa $\sigma_{ges} = 0{,}5km$ auf. In Abbildung 4.13 ist der Absolute Fehler der Schätzung zu sehen. Während die Abweichung der maximalen Elevation für alle Elevationen in einem ähnlichen Bereich liegt, steigt die Abweichung der Distanz mit zunehmender Entfernung. Dieser Effekt entspricht der Bestimmung des zu erwarteten Schätzfehlers in Abbildung 3.5 und tritt bei allen bisher untersuchten Datensätze auf. Datensätze guter Signalqualität weisen mit $\sigma_{\leq 75km} = 0{,}23km$ für den Nahbereich geringere Schätzfehler auf als für große Entfernungen. Verschlechtert sich die Signalqualität, ist ein umgekehrter Effekt zu erwarten, da die Dopplerverläufe für große max. Elevationen eine stärkere Ähnlichkeit untereinander aufweisen und somit schwieriger zugeordnet werden können.

Im nächsten Schritt wird die Qualität der Datensätze weiter eingeschränkt und miteinander verglichen. Auf diese Weise wird ermittelt, wie viel Datenverlust das Schätzergebnis erheblich beeinflusst. Daher werden schrittweise Lücken von bis zu 30%, 40%, 50% und 60% der eigentlichen Signallänge eingefügt.

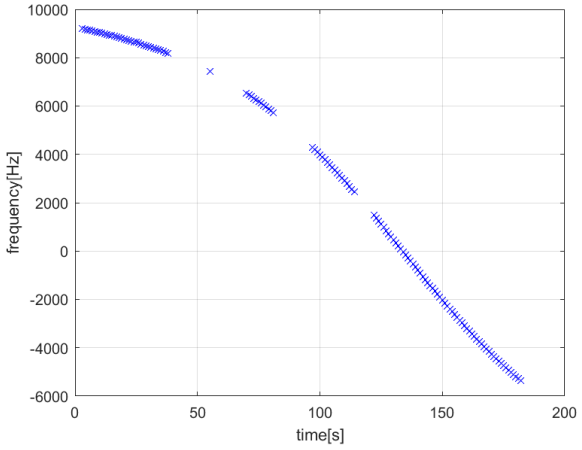

Abbildung 4.14: Bsp. eines lückenbehafteten Dopplerfrequenzverlaufs mit bis zu 50% Datenverlust, $\varphi_{max} = 41{,}2°$

In Abbildung 4.14 ist beispielhaft ein solcher Verlauf abgebildet.

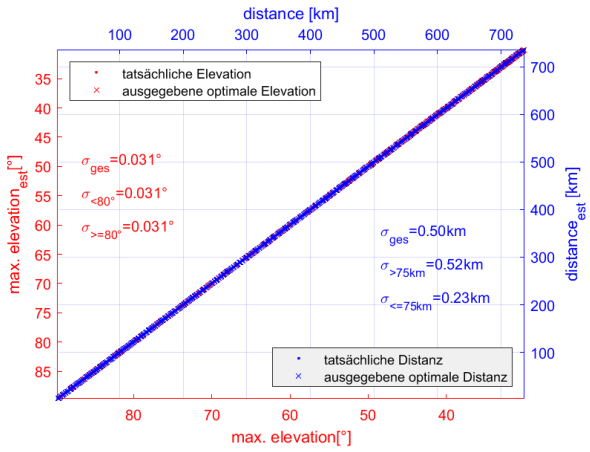

Abbildung 4.15: Schätzung der max. Elevation bzw. Distanz des lückenhaften Datensatzes bis 30% der Signallänge mit $\varphi_{LUT} = 0.1$

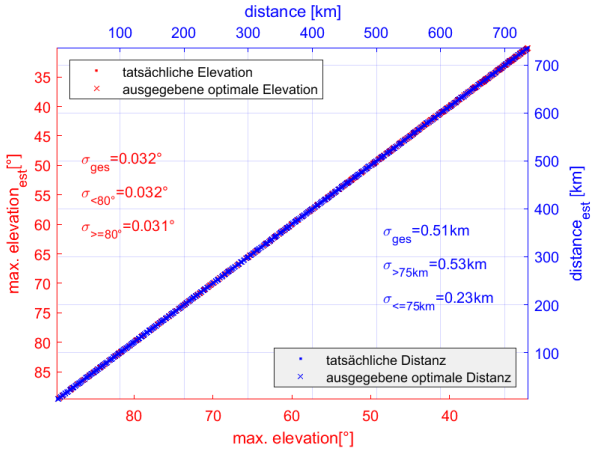

Abbildung 4.16: Schätzung der max. Elevation bzw. Distanz des lückenhaften Datensatzes bis 40% der Signallänge mit $\varphi_{LUT} = 0.1$

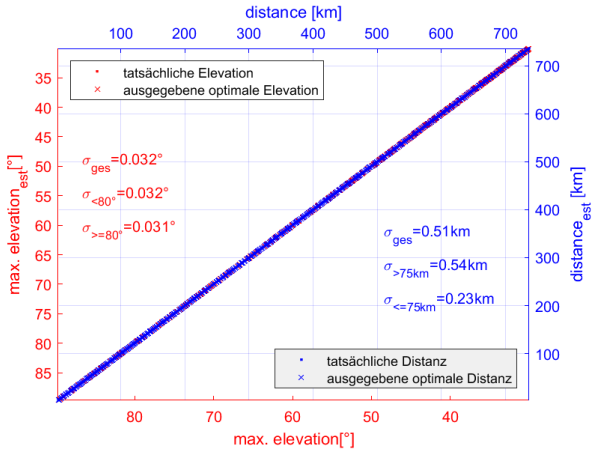

Abbildung 4.17: Schätzung der max. Elevation bzw. Distanz des lückenhaften Datensatzes bis 50% der Signallänge mit $\varphi_{LUT} = 0.1$

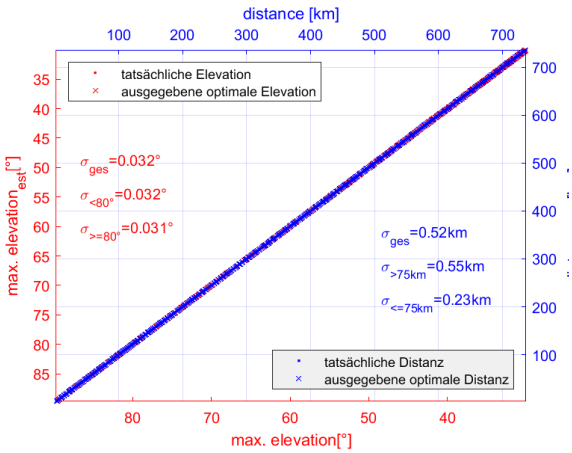

Abbildung 4.18: Schätzung der max. Elevation bzw. Distanz des lückenhaften Datensatzes bis 60% der Signallänge mit $\varphi_{LUT} = 0.1$

Die Schätzergebnisse für lückenbehaftete Dopplerverläufe steigen mit zunehmendem Anteil an Datenverlust minimal an, schätzen die Tagposition aber weiterhin ausreichend genau.

In Abschnitt 2 wurde bereits erläutert, dass die Ortungsgenauigkeit von der Genauigkeit der Frequenzschätzung abhängt. Da das verfeinerte Schätzverfahren der Dopplerfrequenz mit einer Auflösung von $N_{FFT} = 2^{18}$ arbeitet und eine Auflösung von $\pm 4Hz$ ermöglicht, wird entsprechendes Rauschen aufgeprägt. Ein beispielhafter Dopplerverlauf ist in Abbildung 4.19 zu finden.

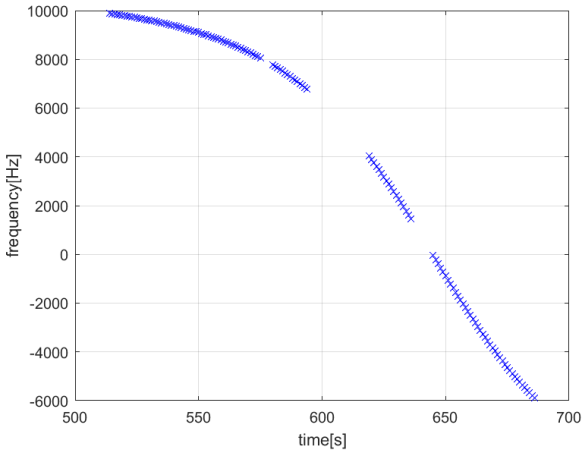

Abbildung 4.19: Bsp. eines Dopplerfrequenzverlaufs bei aufgeprägtem Rauschen von $\pm 4Hz$ und bis zu 50% Datenverlust, $\varphi_{max} = 64{,}1°$

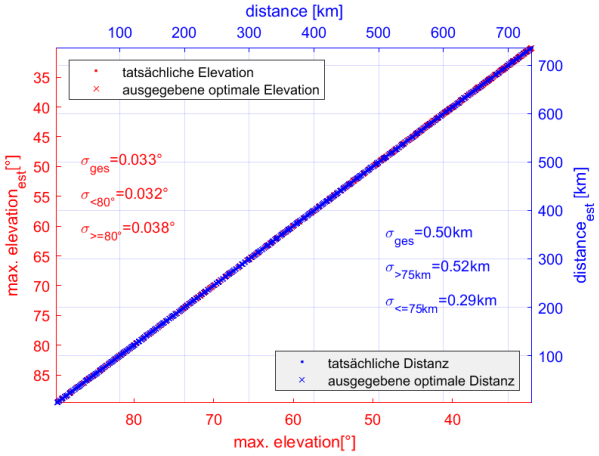

Abbildung 4.20: Schätzung der max. Elevation bzw. Distanz bei aufgeprägtem Rauschen von $\pm 4Hz$ und bis zu 30% Datenverlust mit $\varphi_{LUT} = 0.1$

In den Abbildung 4.20 und Abbildung 4-21 ist zu sehen, dass die Schätzfehler besonders für kurze Distanzen im Vergleich zu den Abbildung 4.15 und Abbildung 4.16 bei einem Rauscheinfluss von $\pm 4Hz$ leicht verstärkt werden.

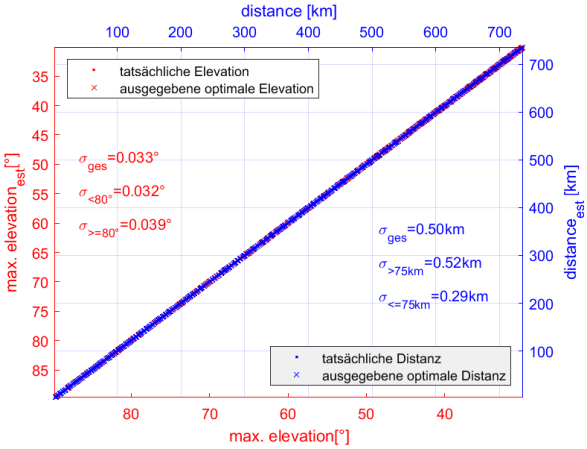

Abbildung 4-21: Schätzung der max. Elevation bzw. Distanz bei aufgeprägtem Rauschen von $\pm 4Hz$ und bis zu 40% Datenverlust mit $\varphi_{LUT} = 0.1$

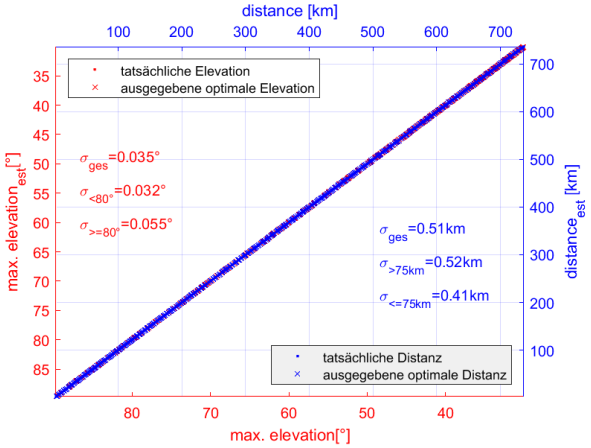

Abbildung 4-22: Schätzung der max. Elevation bzw. Distanz bei aufgeprägtem Rauschen von $\pm 4Hz$ und bis zu 50% Datenverlust mit $\varphi_{LUT} = 0.1$

Steigt der Datenverlust auf bis zu 50% bzw. 60%, ist eine weitere Erhöhung der Schätzfehler für kurze Distanzen zu verzeichnen. An dieser Stelle ist der Punkt erreicht, an dem die Signalqualität nicht mehr ausreichend gut ist, um die Dopplerverläufe für $\varphi_{max} \geq 80°$ gemäß dem Maximum-Likelihood-Verfahren korrekt zuzuordnen.

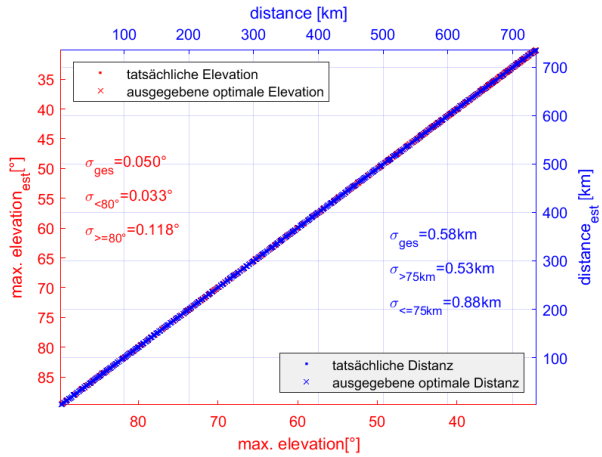

Abbildung 4.23: Schätzung der max. Elevation bzw. Distanz bei aufgeprägtem Rauschen von $\pm 4Hz$ und bis zu 60% Datenverlust mit $\varphi_{LUT} = 0.1$

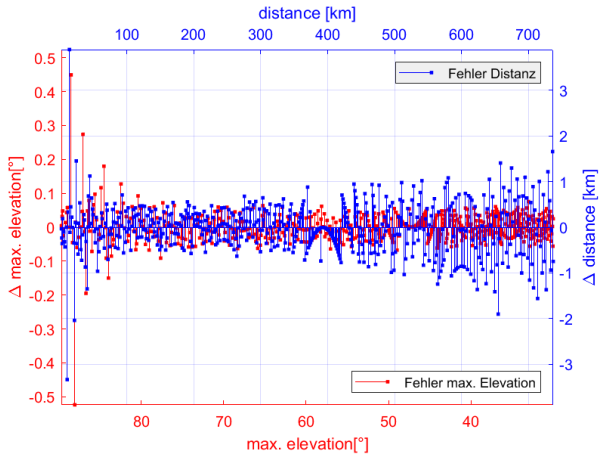

Abbildung 4.24: Schätzfehler der max. Elevation bzw. Distanz bei aufgeprägtem Rauschen von $\pm 4Hz$ und bis zu 60% Datenverlust mit $\varphi_{LUT} = 0.1$

In Abbildung 4.24 ist zu sehen, wie der Schätzfehler für kurze Distanzen stark erhöht ist. Für diesen Bereich lässt sich die Positionsschätzung nicht mehr ausreichend genau umsetzen.

Die grobe Dopplerfrequenzschätzung mit Hilfe des Differenzverfahrens nutzt, wie in Abschnitt 2.2 erläutert, eine Präambel der Länge 2^{15} und erreicht eine Genauigkeit von etwa $\pm 28Hz$ in der Frequenzschätzung. Daher wird das gleichverteilte Rauschen im nächsten Schritt auf $\pm 28Hz$ erhöht. In Abbildung 4.25 ist beispielhaft ein Signal mit erhöhtem Rauschen zu sehen.

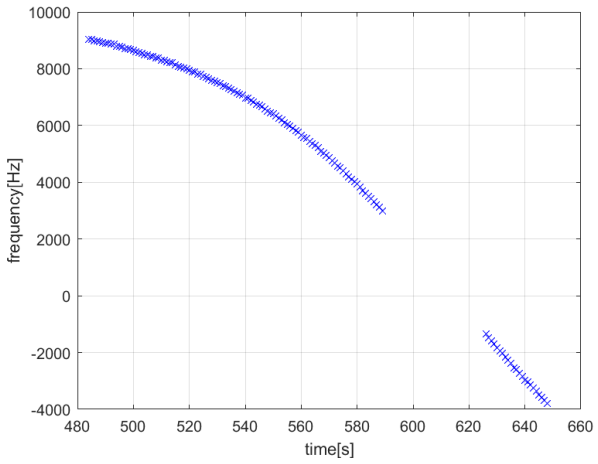

Abbildung 4.25: Bsp. eines Dopplerfrequenzverlaufs bei aufgeprägtem Rauschen von $\pm 28Hz$ und bis zu 50% Datenverlust, $\varphi_{max} = 64{,}1°$

Die Schätzung der max. Elevation bzw. Distanz bei leicht erhöhtem aufgeprägtem Rauschen ist in den folgenden Abbildungen zu sehen.

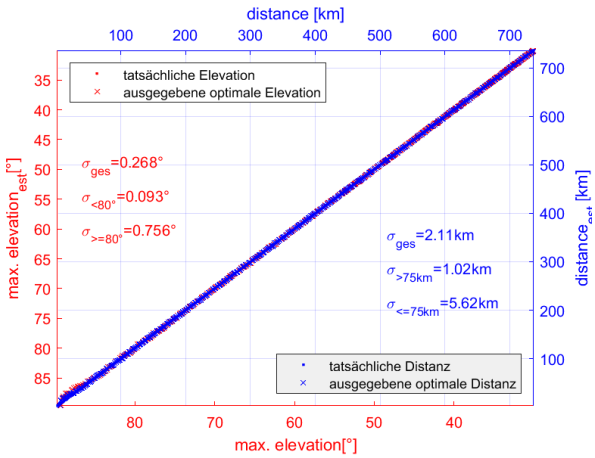

Abbildung 4.26: Schätzung der max. Elevation bzw. Distanz bei aufgeprägtem Rauschen von $\pm 28Hz$ und bis zu 30% Datenverlust mit $\varphi_{LUT} = 0.1$

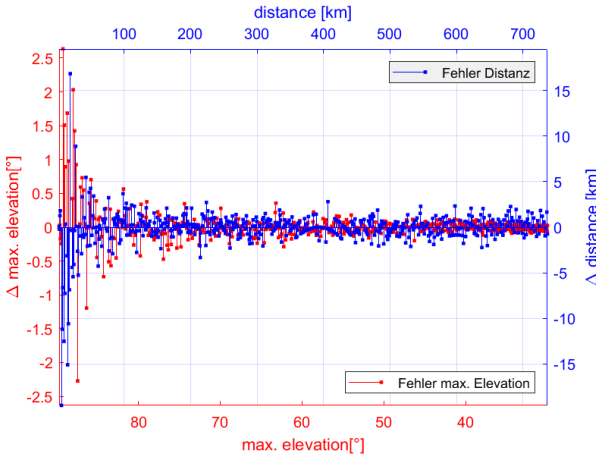

Abbildung 4.27: Schätzfehler der max. Elevation bzw. Distanz bei aufgeprägtem Rauschen von $\pm 28Hz$ und bis zu 30% Datenverlust mit $\varphi_{LUT} = 0.1$

Mit Erhöhung des Rauschens auf $\pm 28Hz$ verschlechtert sich die Positionsschätzung deutlich. Bereits bei geringem Datenverlust sind die Schätzfehler in allen Entfernungen zu hoch für eine zuverlässige Positionsbestimmung. In Abbildung 4.26 ist für Distanzen $\leq 100km$ bereits eine signifikante Abweichung zu sehen und ist in Abbildung 4.27 in Form des absoluten Fehlers näher aufgeschlüsselt. Zum Vergleich wird der Anteil des Datenverlusts weiter erhöht und anschließend ausgewertet.

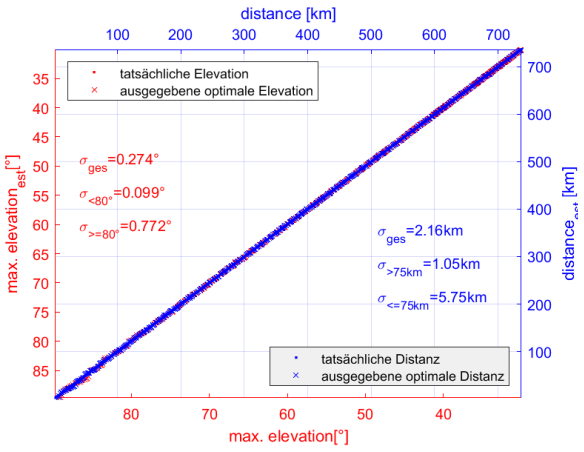

Abbildung 4.28: Schätzung der max. Elevation bzw. Distanz bei aufgeprägtem Rauschen von $\pm 28Hz$ und bis zu 40% Datenverlust *mit* $\varphi_{LUT} = 0{,}5$

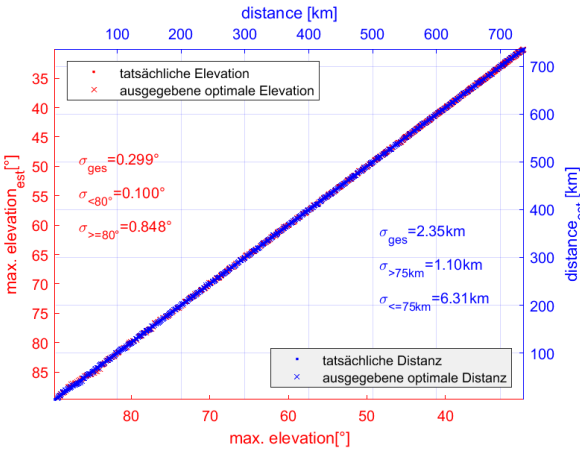

Abbildung 4.29: Schätzung der max. Elevation bzw. Distanz bei aufgeprägtem Rauschen von $\pm 28Hz$ und bis zu 50% Datenverlust *mit* $\varphi_{LUT} = 0{,}1$

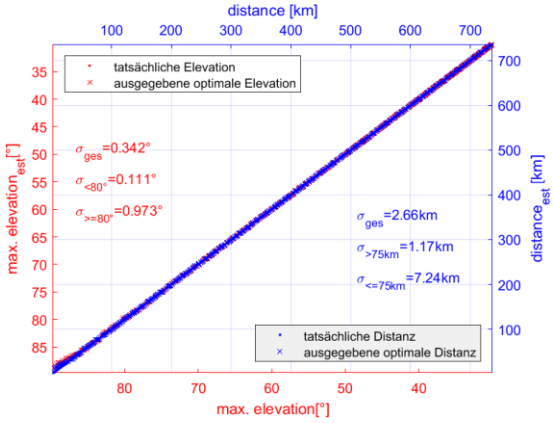

Abbildung 4.30: Schätzung *der max. Elevation bzw. Distanz bei aufgeprägtem Rauschen von* $\pm 28Hz$ und bis zu 60% Datenverlust *mit* $\varphi_{LUT} = 0{,}1$

Der erhöhte Datenverlust resultiert in steigende Schätzfehler. Bei geringerer Signalqualität hat der Anteil des Datenverlusts also einen direkten Einfluss auf die Schätzfehler. Für die synthetischen Signale ohne Rauscheinfluss hingegen spielt der Datenverlust eine wesentlich geringere Rolle.

Es bleibt festzuhalten, dass eine höhere Winkelauflösung $\varphi_{\mathrm{LUT}} = 0{,}1$ entscheidend bessere Positionsschätzungen ermöglicht. Anhand der qualitativ unterschiedlichen Datensätze zeigt sich, dass besonders das Zusammenspiel aus Rauscheinflüssen und Lücken in den Dopplerverläufen die Positionsschätzung erschweren. Bei additivem Rauschen wird die Positionsschätzung mit steigendem Datenverlust fehleranfälliger. Die Genauigkeit der Positionsschätzung ist für aufgeprägtes Rauschen von $\pm 4Hz$ für Distanzen $\geq 100km$ ausreichend genau, für nähere Distanzen hingegen sollte der Datenverlust maximal 50% betragen. Bei verstärkten Rauscheinflüssen ($\pm 28Hz$) ist die Positionsschätzung unabhängig vom Datenverlust nicht ausreichend genau. In Abbildung 4.31 ist die Auswertung der verschiedenen Datensätze in Form von Boxplots vergleichend dargestellt.

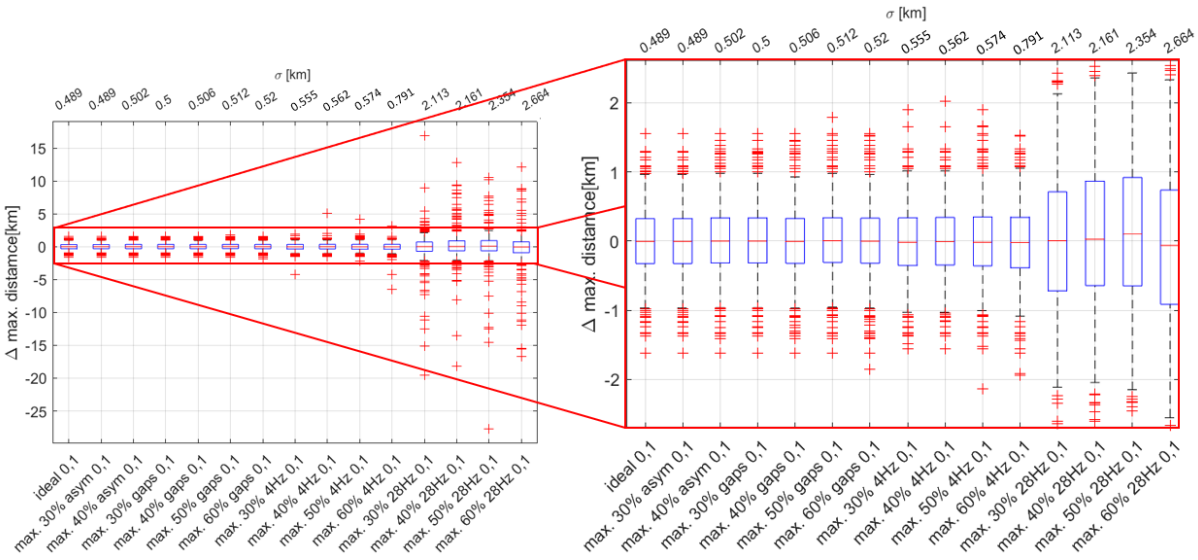

Abbildung 4.31: Vergleich der Schätzgenauigkeit für die qualitativ verschiedenen Datensätze in Form eines Boxplots

Die Positionsschätzung kann für die Datensätze mit aufgeprägtem Rauschen von $\pm 4Hz$ und einem Datenverlust von maximal 50% zu bzw. besserer Signalqualität ausreichend genau umgesetzt werden.

Das Maximum-Likelihood-Verfahren wird nun auf die real aufgezeichneten und vorverarbeiteten Messdaten angewendet, die in Abschnitt 3.3 beschrieben sind. In Abbildung 4.32 ist die Positionsschätzung mit der Winkelauflösung $\varphi_{\mathrm{LUT}} = 0{,}5$ zu sehen.

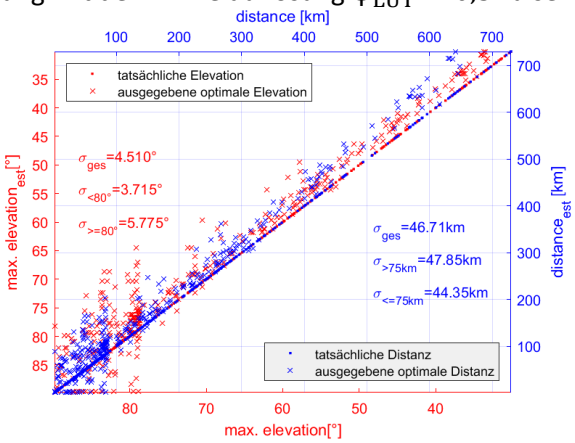

Abbildung 4.32: Schätzung der max. Elevation bzw. Distanz der aufgezeichneten Messdaten mit $\varphi_{LUT} = 0{,}5$

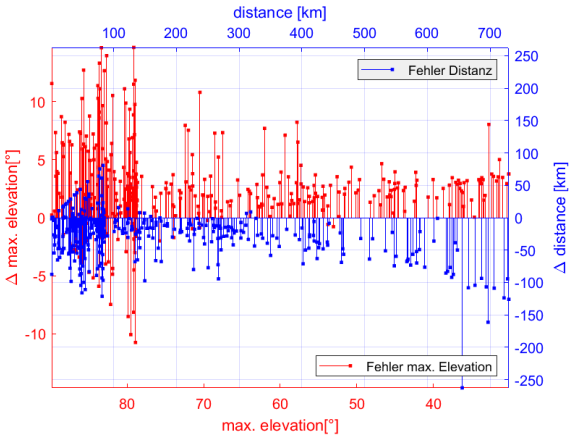

Abbildung 4.33: Schätzung der max. Elevation bzw. Distanz der aufgezeichneten Messdaten mit $\varphi_{LUT} = 0{,}5$

Dabei fällt auf, dass die Positionsschätzung nicht mehr zuverlässig arbeitet. Die Schätzfehler sind stark gestiegen und ermöglichen keine zuverlässige Positionsschätzung mehr. Zum Vergleich wird das Verfahren ebenfalls mit der höheren Winkelauflösung $\varphi_{\mathrm{LUT}} = 0{,}1$ umgesetzt. Die Ergebnisse sind in Abbildung 4.34 zu finden.

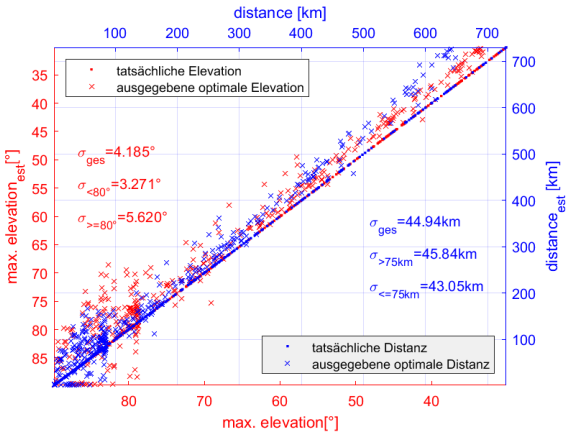

Abbildung 4.34: Schätzung der max. Elevation bzw. Distanz der aufgezeichneten Messdaten mit $\varphi_{LUT} = 0{,}1$

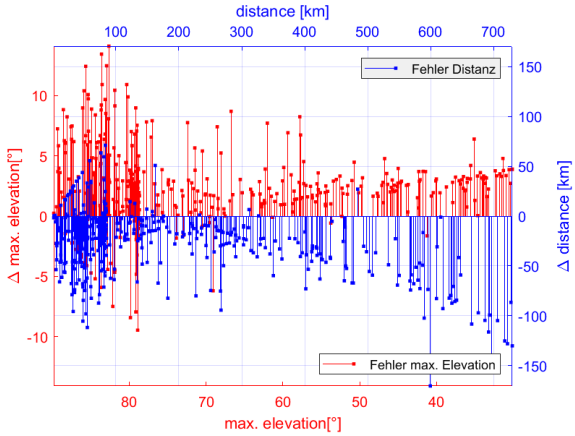

Abbildung 4.35: Schätzung der max. Elevation bzw. Distanz der aufgezeichneten Messdaten mit $\varphi_{LUT} = 0{,}1$

Das Maximum-Likelihood-Verfahren erzielt auch mit $\varphi_{\mathrm{LUT}} = 0{,}1$ keine verwendbaren Ergebnisse. Es ist davon auszugehen, dass die aufgezeichneten Dopplerfrequenzverläufe keine ausreichende Qualität besitzen und somit nicht eindeutig zugeordnet werden können. Gleichzeitig ist das Maximum-Likelihood-Verfahren aufgrund der Distanzbildung anfällig für Ausreißer, falls diese in der Datenvorverarbeitung nicht aussortiert werden konnten.

Im Vergleich zu den Methoden aus dem Maschinellen Lernen erzielt das Maximum-Likelihood-Verfahren für den idealisierten Datensatz mit $\varphi_{\mathrm{LUT}} = 0{,}1$ genauere Schätzergebnisse. Die Schätzung bleibt bei einer Reduzierung der Signalqualität bis zu einem aufgeprägten Rauschen von $\pm 4Hz$ und einem Datenverlust von maximal 50% ausreichend zuverlässig. Die Rocket- Methode und der Random-Forest-Ansatz hingegen verarbeiten die Datensätze mit reduzierter Qualität nicht genügend genau.

Die aufgezeichneten Messsignale sind mit keiner der Methoden ausreichend genau geschätzt, die Abweichung fällt jedoch auch mit der Maximum-Likelihood-Methode geringer aus. In Tabelle 4.1 sind die Ergebnisse zusammengefasst.

Datensatz	σ_{km} Random-Forest-Methode	σ_{km} Rocket-Methode	σ_{km} Maximum-Likelihood-Verfahren
idealisiert	0,89	1,2	0,489
max. 30% Asymmetrie	1,34	0,41	0,489
max. 40% Asymmetrie	1,18	0,32	0,502
max. 30% Lücken	17,65	695,18	0,5
max. 40% Lücken	10,29	317,52	0,506
max. 50% Lücken	14,81	260,81	0,512
max. 60% Lücken	9,68	636,47	0,52
max. 30% Lücken $\pm 4Hz$	12,04	224,23	0,555
max. 40% Lücken $\pm 4Hz$	9,79	397,3	0,562
max. 50% Lücken $\pm 4Hz$	8,55	145,7	0,574
max. 60% Lücken $\pm 4Hz$	8,18	407,27	0,791
max. 30% Lücken $\pm 28Hz$	13,66	93,4	2,113
max. 40% Lücken $\pm 28Hz$	10,30	77,49	2,161
max. 50% Lücken $\pm 28Hz$	10,79	109,77	2,354
max. 60% Lücken $\pm 28Hz$	10,91	154,15	2,664
real gemessen	134,57	510,39	44,94

Tabelle 4.1: Zusammenfassung der Standardabweichungen für die verschiedenen Datensätze und Methoden

Im nächsten Abschnitt wird untersucht, inwiefern das in Abschnitt 3 erläuterte Symmetrieproblem gelöst werden kann. Da die Maximum-Likelihood-Methode deutlich bessere Schätzergebnisse liefert, werden lediglich die Ergebnisse dieses Ansatzes in Abschnitt 5 beleuchtet.

5 SYMMETRIEPROBLEM DER CROSS-TRACK-DISTANZ

Aus der maximalen Elevation wird die Cross-Track-Distanz ermittelt. Die Distanzangabe des Tags zum Satelliten in y-Richtung weist entsprechend Abbildung 5.1 einen Symmetriefehler auf. Es wird dabei nicht definiert, ob sich der Tag aus Sicht des passierenden Satelliten auf der linken oder rechten Seite befindet. Aus diesem Grund werden nun zusätzliche Überflüge und darauf basierende Positionsschätzungen für den gleichen Tag hinzugezogen. Es wird untersucht, inwiefern sich die Positionsschätzung verbessern lässt, wenn diese auf Grundlage mehrerer Überflüge über einen statischen Tag gemittelt wird. Dafür wird eine Tagposition im Überfluggebiet G festgelegt, die für alle Überflüge gilt. Der Tag ändert also seine Position während dieser Überflüge nicht.

$$P_{\text{tag}} = (x, y) \tag{5.1}$$

Über den statischen Tag fliegen nun N Satelliten, die jeweils dessen Position schätzen. In Abbildung 5.1 sind beispielhaft $N = 2$ Überflüge zu sehen, die jeweils eine Position in der Nähe von P_{tag} sowie eine entlang der Überflugbahn gespiegelte zweite Position schätzen.

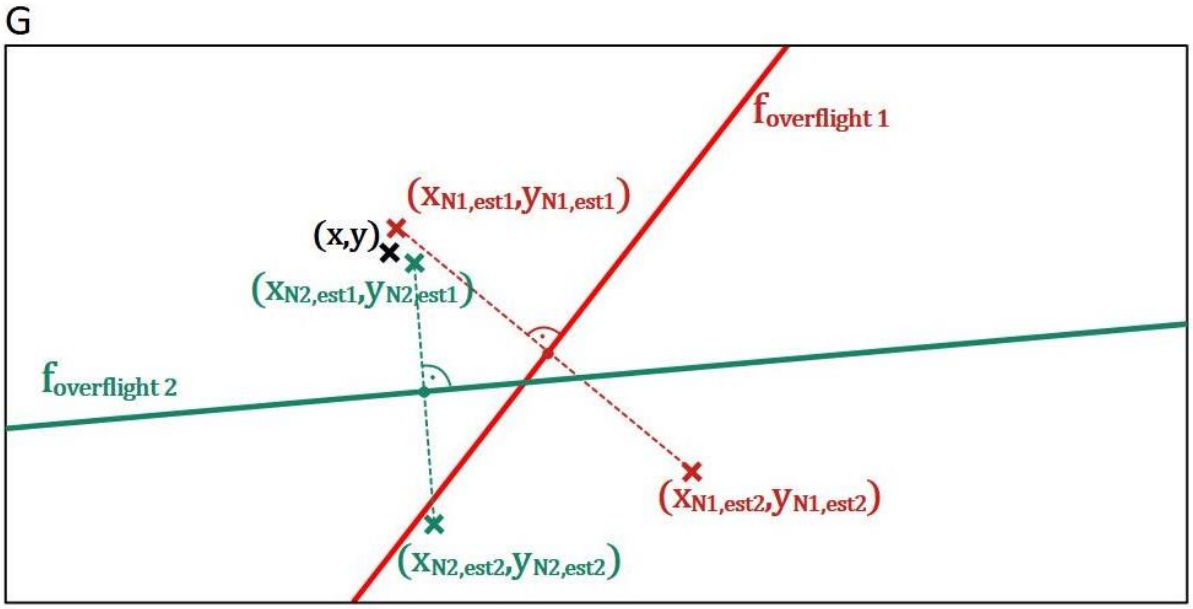

Abbildung 5.1: Überflugszenario mit $N = 2$

Mittels einer MATLAB Simulation werden N randomisierte Satellitenüberflüge in Form einer einfachen linearen Funktion über die Position P_{tag} erzeugt:

$$f_{overflight} = mx + n \tag{5.2}$$

Dabei werden der Anstieg m und der Offset n randomisiert aus einem definierten Wertebereich gewählt.

Parameter	Wertebereich
m	$[-5, 5]$
n	$[100, 800]km$

Tabelle 5-1: Wertebereiche für die Parameter der simulierten Überflüge

Anschließend wird die in Kapitel 4 ermittelte Varianz der Schätzgenauigkeit verwendet, um die Schätzung der tatsächlichen Tagposition für die Überflüge zu simulieren.

$$x_{\text{est},1} = x + x_\sigma \cdot \cos(\alpha)$$
$$y_{\text{est},1} = y + y_\sigma \cdot \sin(\alpha) \tag{5.3}$$

Die Position (x, y) wird mit einer Abweichung x_σ bzw. y_σ in eine zufällig ausgewählte Richtung versehen. Die Abweichung x_σ sowie der Winkel α werden ebenfalls randomisiert aus einem definierten Wertebereich siehe Tabelle 5.2 gewählt. Die Varianz definiert, wie genau die Positionsschätzung ausfällt. Auf diese Weise wird die erste Schätzposition $P_{est,1} = (x_{\text{est},1}, y_{\text{est},1})$ bestimmt.

Parameter	Wertebereich
x_σ	$[1, \sigma]km$
α	$[1, 360]°$

Tabelle 5.2: Wertebereiche für die Parameter der Positionsabweichungen

Anschließend wird die Spiegelkoordinate ermittelt, indem zunächst der Lotfußpunkt ermittelt wird. Dafür wird die Distanz zwischen der geschätzten Position und jedem Punkt der Überflugbahn gebildet. Anschließend wird die kürzeste Distanz ermittelt. An dieser Stelle befindet sich der Lotfußpunkt.

$$P_L = (x_L, y_L) = argmin\left((f_{x_i,overflight} - x_{est,1})^2 + (f_{y_i,overflight} - x_{est,1})^2\right) \tag{5.4}$$

Der Lotfußpunkt wird genutzt, um mittels Vektoraddition die Spiegelkoordinate $P_{est,2}$ zu bestimmen.

$$x_{est,2} = x_{est,1} - 2 \cdot (x_{est,1} - x_L)$$
$$y_{est,2} = y_{est,1} - 2 \cdot (y_{est,1} - y_L) \tag{5.5}$$

Zu jedem Überflug liegen also nun zwei mögliche, an der Überflugachse gespiegelte, Tagpositionen $P_{est1,2}$ vor. In Abbildung 5-2 ist zu sehen, dass die Position des Tags, schwarz markiert, fünffach aus unterschiedlicher Richtung überflogen wird. In der MATLAB Simulation hat jeder Überflug den Lotfußpunkt in Form eines Sterns sowie die beiden an der Überflugachse gespiegelten Koordinatenpunkte als Kreuze markiert.

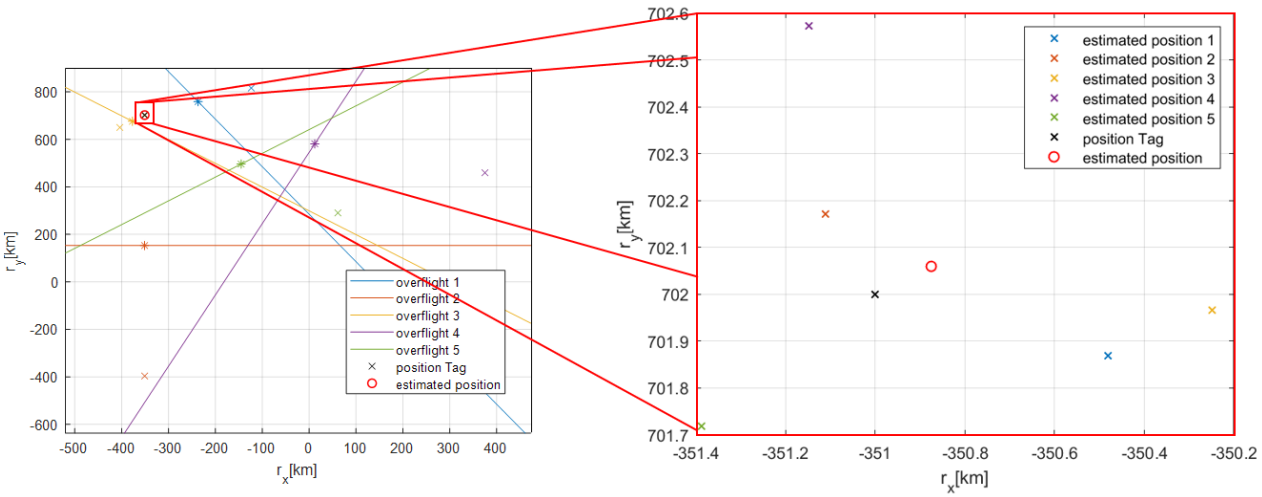

Abbildung 5-2: Positionsschätzung eines statischen Tags durch N=5 Überflüge

Für die geschätzten Tagpositionen wird nun überprüft, ob sich in der näheren Umgebung weitere geschätzte Positionen befinden. Befindet sich die geschätzte Position in der Nähe des Tags, sind weitere $N_{overflight} - 1$ geschätzte Tagpositionen in der Nachbarschaft zu erwarten. Handelt es sich um die Spiegelkoordinate, so wird die geschätzte Tagposition höchstwahrscheinlich isoliert vorliegen. Die nähere Umgebung wird definiert als das Zweifache der definierten Varianz in x- bzw. y-Richtung:

$tol_x \leq \lvert 2 \cdot \sigma_{ges} \rvert$
$tol_y \leq \lvert 2 \cdot \sigma_{ges} \rvert$

Tabelle 5.3: Toleranzbereich, indem nach weiteren geschätzten Positionen gesucht wird

Auf diese Weise lässt sich je Überflug auswerten, welche der beiden Koordinaten in die Auswertung der Tagposition einbezogen wird. Die zweite mögliche Position wird verworfen. Aus den $N_{overflight}$ ermittelten Tagpositionen wird nun ein Mittelwert gebildet, welcher als geschätzte Tagposition verwendet wird. In Abbildung 5-2ist das Schätzergebnis in Form eines roten Kreises markiert.

$$Pos_{est} = \frac{1}{N} \sum_{k}^{N_{overflight}} (x_{est}, y_{est})_k \tag{5.6}$$

Für dieses Verfahren wird die Anzahl der Überflüge $N_{overflight}$ variiert, um auszuwerten, inwiefern die Positionsschätzung mit steigender Anzahl von Überflügen genauer wird. Allerdings wird die Auswertung auf einige ausgewählte Datensätze und das Maximum-Likelihood-Verfahren beschränkt. Es wird der idealisierte Datensatz (1) ausgewertet sowie der mit $\pm 4Hz$ Rauschen versehene Datensatz mit maximal 50% Datenverlust (2). Während Datensatz (1) die beste erreichbare Positionsschätzung aufweist, ergibt Datensatz (2) Positionsschätzungen im akzeptablen Bereich von bis zu $\pm 1\mathrm{km}$ Schätzfehlern und weist dabei schlechtere Signalqualität auf. Zusätzlich wird der real aufgezeichnete Datensatz in die Auswertung einbezogen.

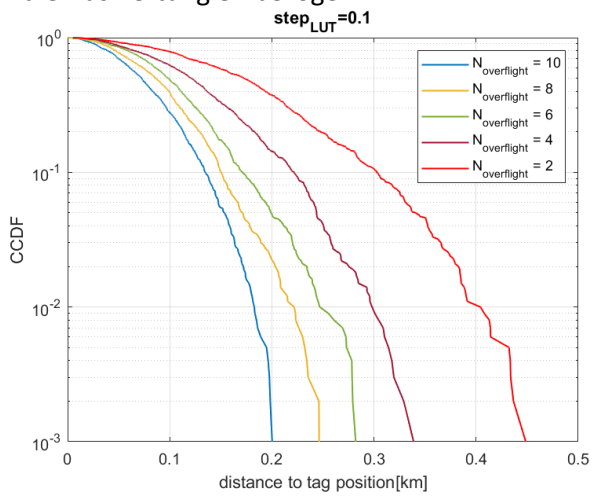

Abbildung 5.3: CCDF-Kurve des idealen Datensatzes mit $\varphi_{LUT} = 0{,}1$

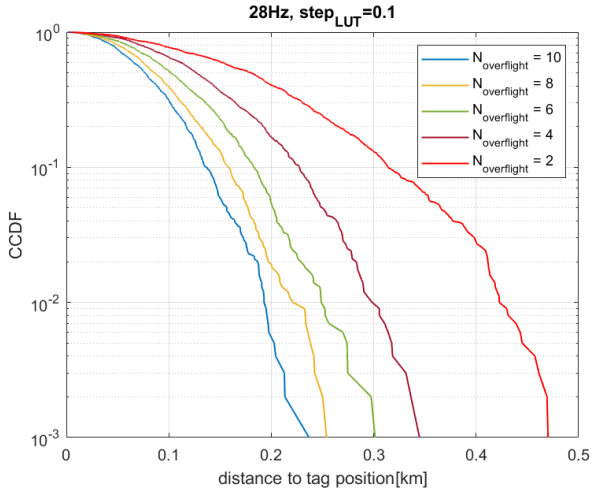

Abbildung 5.4: CCDF-Kurve bei aufgeprägtem Rauschen von $\pm 4Hz$ und bis zu 50% Datenverlust mit $\varphi_{LUT} = 0.1$

Aus den CCDF-Kurven lässt sich jeweils ablesen, mit welcher Wahrscheinlichkeit ein Schätzfehler einer bestimmten Größenordnung auftritt. In Abbildung 5.3 lässt sich für 10 Satellitenüberflüge beispielsweise ablesen, dass 10% der Positionsschätzungen eine Genauigkeit von etwa $0{,}135km$ erreichen und alle Positionsschätzungen maximal einen Schätzfehler von etwa $0{,}2km$ aufweisen. Dabei ist für jeden zusätzlichen Überflug eine Steigerung der Schätzgenauigkeit zu verzeichnen. Das gleiche gilt für

die Auswertung von Datensatz (2) in Abbildung 5.4. Es sind zwei Überflüge notwendig, um dem Symmetrieproblem begegnen zu können und jeder weitere Überflug verbessert die Schätzergebnisse. In Abbildung 5.5 ist die Complementary Cumulative Distribution Function für die aufgezeichneten Messdaten zu sehen.

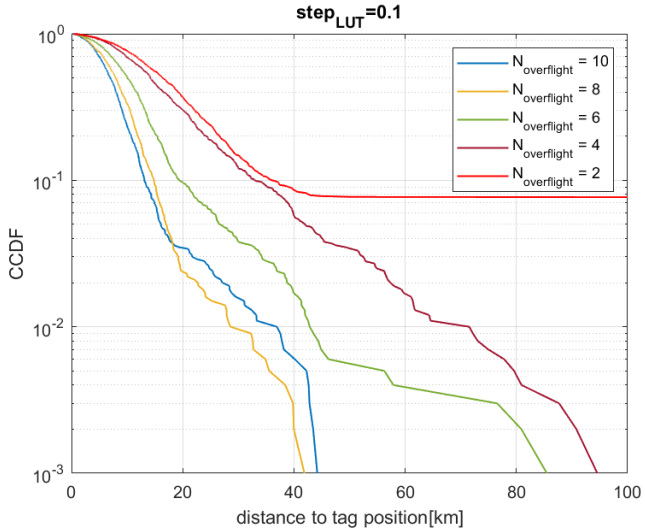

Abbildung 5.5: CCDF-Kurve der aufgezeichneten Messdaten mit $\varphi_{LUT} = 0{,}1$

Für den realen Messdatensatz sind die Abweichungen sehr stark. Die Standardabweichung aus Abbildung 4.34 wird erst ab $N_{overflight} = 8$ Überflügen erreicht.

6 ERGEBNISDISKUSSION

Da die Genauigkeit der Positionsschätzung maßgeblich von der Frequenzsynchronisation abhängt, wurde im Rahmen dieser Forschungsarbeit untersucht, inwiefern die Genauigkeit der Dopplerfrequenzschätzung erhöht werden kann. Hierzu wurde eine Signalverarbeitungsstrecke simuliert, welche die im Kanal aufgeprägten Störungen auf der Empfängerseite mittels verschiedener Verfahren erkennt und korrigiert. Um den weiterhin vorhandenen Frequenzfehler genauer ermitteln und somit auch korrigieren zu können, wird zusätzlich zum in [2] bereits implementierten Differenzverfahren ein Schätzverfahren realisiert, welches mit Hilfe der $Fast\ Fourier\ Transformation$ umgesetzt wird. Dabei verbessert sich die Frequenzauflösung von etwa $\pm 28Hz$ auf $\pm 4Hz$. Die verbesserte Frequenzschätzung wird genutzt, um die Qualität des Dopplerfrequenzsignals auf Empfängerseite zu erhöhen.

Anschließend werden die Dopplersignale in Form eines synthetischen Datensatzes für die Positionsschätzung genutzt. Mit Hilfe von Methoden speziell für Zeitreihen aus dem Maschinellen Lernen sowie dem Maximum-Likelihood-Verfahren wird die maximale Elevation jedes Dopplerverlaufs ermittelt. Aus der maximalen Elevation wird die Cross-Track-Distanz ermittelt. Ziel ist es, die Positionsschätzung mit einer Standardabweichung von maximal $\pm 1km$ umzusetzen. Aus einer Auswahl verschiedener Methoden des Maschinellen Lernens schätzen die Rocket-Methode für eine Distanz von $> 75km$ und die Random-Forest- Methode die Cross-Track-Distanz ausreichend genau. Wird die Qualität des Datensatzes reduziert, werden die Abweichungen zu groß. Mit dem Maximum-Likelihood-Verfahren wird anhand des idealisierten Datensatzes eine Schätzgenauigkeit von $\sigma_{ges} = 0{,}49km$ erreicht. Im Vergleich zur Ortsschätzung in [2] sowie den Methoden des Maschinellen Lernens ist dies eine Verbesserung. Der Ortungsalgorithmus bleibt für die Maximum-Likelihood-Methode bei einer Reduzierung der Signalqualität bis zu einem aufgeprägten Rauschen von $\pm 4Hz$ und einem Datenverlust von maximal 50% ausreichend zuverlässig. Die Ortungsalgorithmen wurden ebenfalls auf Grundlage des real aufgezeichneten Datensatzes ausgewertet. Die Ergebnisse sind jedoch mit beiden Schätzverfahren nicht verwendbar. Die Random-Forest- und Rocket-Methode erzielen eine Standardabweichung von $\sigma_{ges,RF} = 134{,}57km$ bzw. $\sigma_{ges,Rocket} = 510{,}39km$ und das Maximum-Likelihood-Verfahren schätzt mit einer Standardabweichung von $\sigma_{ges} = 45km$. Die aufgezeichneten Dopplerfrequenzverläufe weisen starke Unregelmäßigkeiten auf, denen in diesem Verfahren nicht angemessen begegnet werden kann. Zurückzuführen ist dies zum Teil auf den Standort des Empfängers. Durch die Lage in einem Kessel und benachbarte Hindernisse ist die Signalqualität erheblich eingeschränkt. Auf der anderen Seite hat sich gezeigt, dass das Maximum-Likelihood-Verfahren sehr gute Positionsschätzungen liefert, sofern die vorliegenden Datensätze ausreichende Qualität aufweisen. Entscheidend allerdings ist, die aufgezeichneten Daten in besserer Qualität nutzen zu können. Auf Grundlage von uneindeutigen Signalverläufen ist die Ortung nicht möglich, da auch die Methoden des Maschinellen Lernens die verschiedenen Signalqualitäten nicht adaptieren kann. Die Methoden aus dem Maschinellen Lernen weisen bereits bei geringem Datenverlust erhebliche Abweichungen in den Schätzungen auf, bieten jedoch noch einige Möglichkeiten, die Modelle besser auf den vorliegenden Datensatz auszulegen. Ein Ansatzpunkt für die Verbesserung der Schätzung kann also sein, die Parameter der Modelle zu spezifizieren.

Des Weiteren wurde untersucht, inwiefern sich das Symmetrieproblem ausräumen lässt, da die Cross-Track-Distanz relativ zum Empfänger nicht angibt, ob sich die Position rechts oder links befindet. Dabei hat sich gezeigt, dass mindestens zwei Überflüge notwendig sind, um die Distanz in eine Position überführen zu können und die Genauigkeit der Schätzung mit jedem weiteren Überflug steigt. In der Arbeit wurde lediglich der Fall des statischen Tags untersucht. Ebenfalls interessant ist die Untersuchung einer gerichteten Bewegung sowie einer randomisierten, chaotischen Bewegung des Senders.

LITERATUR

[1] Prof. Dr.-Ing. Marco Krondorf, „LEO Beam Acquisition“, 13. März 2020.

[2] Daniel Ehnert, „Implementierung eines Doppler Ranging Empfängers“, 18. Okt. 2021.

[3] Steffen Bittner, „Das Internet der Tiere“, S. 64–70.

[4] Marco Krondorf, „ICARUS Doppler Ranging Empfänger“, 15. Nov. 2021.

[5] Marco Krondorf, „AI Algorithms for ICARUS Tag Weight Reduction: AI-based Doppler Ranging for ICARUS tag positioning“, 30. Mai 2021.

[6] M. Krondorf, M. Goblirsch, R. de Gaudenzi, G. Cocco, N. Toptsidis und G. Acar, „Towards the implementation of advanced random access schemes for satellite IoT“, *Int J Satell Commun Network*, Jg. 38, Nr. 2, S. 177–199, 2020, doi: 10.1002/sat.1331.

[7] ERKAN ÇANKAYA, „USE OF THE AMBIGUITY FUNCTION TECHNIQUE FOR TARGET DETECTION IN PHASE CODED CONTINUOUS WAVE RADARS“, 2005.

[8] Institute of Electrical and Electronics Engineers, *2007 IEEE Radar Conference: Waltham, [Boston], MA, 17 - 20 April 2007*. Piscataway, NJ: IEEE Service Center, 2007.

[9] S. Sesia, I. Toufik und M. Baker, Hg., *LTE - The UMTS Long Term Evolution*. Chichester, UK: John Wiley & Sons, Ltd, 2011.

[10] R. Love und V. Nangia, „Uplink Reference Signals“ in *LTE - The UMTS Long Term Evolution*, S. Sesia, I. Toufik und M. Baker, Hg., Chichester, UK: John Wiley & Sons, Ltd, 2011, S. 327–342, doi: 10.1002/9780470978504.ch15.

[11] D. Chu, „Polyphase codes with good periodic correlation properties (Corresp.)“, *IEEE Trans. Inform. Theory*, Jg. 18, Nr. 4, S. 531–532, 1972, doi: 10.1109/TIT.1972.1054840.

[12] Splash, *8-PSK Gray Codiert.* [Online]. Verfügbar unter: https://commons.wikimedia.org/wiki/File:8PSK_Gray_Coded.svg.

[13] G. Cui, Y. He, P. Li und W. Wang, „Enhanced Timing Advanced Estimation With Symmetric Zadoff-Chu Sequences for Satellite Systems“, *IEEE Commun. Lett.*, Jg. 19, Nr. 5, S. 747–750, 2015, doi: 10.1109/LCOMM.2015.2411610.

[14] R. Isermann, *Identifikation dynamischer Systeme: Grundlegende Methoden,* 2. Aufl. Berlin, Heidelberg, New York, London, Paris, Tokyo, Hong Kong, Barcelona, Budapest: Springer, 1992.

[15] Marco Krondorf, „Elektronische Nachrichtenübertragung“, 2020.

[16] A. Neubauer, *DFT - Diskrete Fourier-Transformation*. Wiesbaden: Vieweg+Teubner Verlag, 2012, S. 115.

[17] „Modelle von periodischen Signalen und ihre Identifikation“ in *Mechatronische Systeme*, Berlin, Heidelberg: Springer Berlin Heidelberg, 2008, S. 375–410, doi: 10.1007/978-3-540-32512-3_8.

[18] „Oppenheim_Schafer_Zeitdiskrete Signalverarbeitung“, S.853.

Berichtsblatt

1. ISBN oder ISSN	2. Berichtsart Schlussbericht
3a. Titel des Berichts Projekt ICARUS - KI	
3b. Titel der Publikation Auszug der Publikationen, siehe Bitte im Schlussbericht unter Punkt 6.7	

4a. Autoren des Berichts (Name, Vorname(n)) Müller Uschi	5. Abschlussdatum des Vorhabens 31.12.2023
4b. Autoren der Publikation (Name, Vorname(n))	6. Veröffentlichungsdatum 24.02.2024
	7. Form der Publikation Siehe Schlussbericht, 6.7

8. Durchführende Institution(en) (Name, Adresse) Max Planck Institut für Verhaltensbiologie Am Obstberg 1 D-78315 Radolfzell	9. Ber.Nr. Durchführende Institution
	10. Förderkennzeichen 50WB2235
	11a. Seitenzahl Bericht 49
	11b. Seitenzahl Publikation Siehe Schlussbericht, 6.7
13. Fördernde Institution (Name, Adresse) Deutsche Raumfahrtagentur im Deutschen Zentrum für Luft- und Raumfahrt e.V. Königswinterer Str. 522-524 53227 Bonn	12. Literaturangaben Siehe Schlussbericht, 6.7
	14. Tabellen 5
	15. Abbildungen 24

16. Zusätzliche Angaben – keine -

17. Vorgelegt bei (Titel, Ort, Datum)
---

18. Kurzfassung

Das ICARUS Experimentalsystem liefert als weltraumgestütztes IoT Kommunikationssystem auf der ISS seit März 2021 wissenschaftlich hochinteressante Daten über weltweite Tierbewegungen. Das ICARUS System soll durch den Einsatz von KI in zweierlei Hinsicht massiv verbessert werden:
- Die Kommunikationswahrscheinlichkeit der miniaturisierten Tags hängt offenbar sehr stark von den jeweils vorherrschenden Umweltbedingungen ab, z.B. ob ein Tier sich vorwiegend im Unterholz, Schilf, Wald, Feld oder der Luft aufhält. Weiterhin beeinflußt das Wetter sowie das Tierverhalten den Energiehaushalt der Tags, die primär auf Solarenergie angewiesen sind. Wetter, Tierverhalten und Umweltbedingungen beeinflussen sich aber auch gegenseitig stark. Durch Einsatz von KI kann das optimale Einsatzprotokoll für die Tier-Tags aus der hochdimensionalen Kombination der oben genannten dynamischen Faktoren ermittelt werden. Hierzu sollen die in der Movebank gesammelten Daten der Tiere mit den Daten aus dem ICARUS User Data Center kontinuierlich verrechnet werden. KI-Algorithmen können dann die besten Kombinationen aus Energieverbrauch der Tags (v.a. durch GPS-Messungen) und Energieeintrag berechnen und Datenaufnahmemuster vorschlagen. Diese Muster werden unmittelbar auf den im Feldeinsatz befindlichen Tags eingestellt (durch Programmierung über die ISS an die Tags) und können so experimentell verifiziert werden. Die neu gewonnenen Daten fließen dann unmittelbar wieder in die KI-Berechnungen ein und optimieren die vorgeschlagenen Muster weiter.
- Der größte Energietreiber im ICARUS System ist die Eigenbestimmung des GPS-Ortes durch die Tier-Tags. Bisher ist GPS-Ortung im ICARUS System notwendig, da die Tags zur Voraussage der Orbit-Zeiten der ISS ihren eigenen Standort am Boden genau kennen müssen. Zudem ist diese Standortbestimmung biologisch-wissenschaftlich von hoher Wichtigkeit, auch um das Habitat der Tiere zu kennen (siehe Punkt a). Durch Einsatz von KI kann die energieaufwendige GPS-Ortung durch energieeffiziente Doppler-Ortung ersetzt werden. Dies hat den fundamentalen Vorteil, dass dann die ICARUS Tags der nächsten Generation massiv verkleinert werden können, sowohl im derzeitigen ICARUS-Experimentalsystem als auch hinsichtlich zukünftiger, zusätzlicher Payloads.

19. Schlagwörter
ICARUS, Space Segment, Space Project, Hosted Payload, User Data Center, Movebank, AnimalTracker App, Basic Tag, Handheld, KI, IoT-Internet of Things Ground to Space, Internet der Tiere, MoveApps

20. Verlag ----------	21. Preis ----------

Document Control Sheet

1. ISBN or ISSN	2. Type of Report Final Report
3a. Report Title Project ICARUS KI	
3b. Title of Publication Extract of publications, please see final report, 6.7	

4a. Author(s) of the Report (Family Name, First Name(s))	5.End of Project
Müller, Uschi	31.12.2023
	6. Publication Date 24.02.2024
4b. Author(s) of the Publication (Family Name, First Name(s)) Please see final report, 6.7	7. Form of Publication please see final report, 6.7

8. Performing Organization(s) (Name, Address)	9. Originator's Report No.
Max-Planck Institute of Animal Behavior Am Obstberg 1 D-78315 Radolfzell	10. Reference No. 50WB2235
	11a. No. of Pages Report 49
	11b. No. of Pages Publication please see final report 6.7
13. Sponsoring Agency (Name, Address) Deutsche Raumfahrtagentur im Deutschen Zentrum für Luft- und Raumfahrt e.V. Königswinterer Str. 522-524 53227 Bonn	12. No. of References please see final report, 6.7
	14. No. of Tables 5
	15. No. of Figures 24

16. Supplementary Notes none

17. Presented at (Title, Place, Date)

———

18. Abstract

As a space-based IoT communication system on the ISS, the ICARUS experimental system has been providing highly interesting scientific data on global animal movements since March 2021. The ICARUS system is to be massively improved in two respects through the use of AI:
- The communication probability of the miniaturized tags apparently depends very much on the prevailing environmental conditions, e.g. whether an animal is predominantly in the undergrowth, reeds, forest, field or air. Furthermore, the weather and animal behavior influence the energy balance of the tags, which are primarily dependent on solar energy. Weather, animal behavior and environmental conditions also strongly influence each other. By using AI, the optimal deployment protocol for the animal tags can be determined from the high-dimensional combination of the dynamic factors mentioned above. For this purpose, the animal data collected in the Movebank will be continuously offset against the data from the ICARUS User Data Center. AI algorithms can then calculate the best combinations of energy consumption of the tags (mainly through GPS measurements) and energy input and suggest data recording patterns. These patterns are set directly on the tags in the field (by programming via the ISS to the tags) and can thus be verified experimentally. The newly acquired data then flows directly back into the AI calculations and further optimizes the suggested patterns.
- The biggest energy driver in the ICARUS system is the self-determination of the GPS location by the animal tags. Until now, GPS positioning has been necessary in the ICARUS system because the tags need to know their own exact location on the ground in order to predict the orbit times of the ISS. In addition, this location determination is of great biological and scientific importance, also in order to know the habitat of the animals (see point a). By using AI, energy-intensive GPS positioning can be replaced by energy-efficient Doppler positioning. This has the fundamental advantage that the ICARUS tags of the next generation can then be massively reduced in size, both in the current ICARUS experimental system and with regard to future, additional payloads.

19. Keywords

ICARUS, Space Segment, Space Project, Hosted Payload, User Data Center, Movebank, AnimalTracker App, Basic Tag, Handheld, KI, IoT-Internet of Things Ground to Space, Internet der Tiere, MoveApps

20. Publisher ___	21. Price ____