

TEXTE

137/2023

Umweltschutz in der Arktis – Unterstützung der deutschen Aktivitäten im Arktischen Rat durch eine Pilotstudie zum Monitoring von Kunststoffmüll an arktischen Küsten mittels fernerkundlicher oder luftgestützter Methoden

Endbericht

TEXTE 137/2023

Ressortforschungsplan des Bundesministeriums für
Umwelt, Naturschutz, nukleare Sicherheit und
Verbraucherschutz

Forschungskennzahl 3719 18 201 0
FB001078

Umweltschutz in der Arktis – Unterstützung der deutschen Aktivitäten im Arktischen Rat durch eine Pilotstudie zum Monitoring von Kunststoffmüll an arktischen Küsten mittels fernerkundlicher oder luftgestützter Methoden

Endbericht

von

Schnurawa, Marc; Vilela, Raul; Kersten, Anna
BioConsult SH GmbH & Co. KG, Husum

Schulz, Marcus
AquaEcology GmbH & Co. KG, Oldenburg

Im Auftrag des Umwelt Bundesamts

Impressum

Herausgeber

Umweltbundesamt
Wörlitzer Platz 1
06844 Dessau-Roßlau
Tel: +49 340-2103-0
Fax: +49 340-2103-2285
info@umweltbundesamt.de
Internet: www.umweltbundesamt.de

Durchführung der Studie:

BioConsult SH & Co. KG
Schobüller Straße 36
25813, Husum
Germany

AquaEcology GmbH & Co. KG
Steinkamp 19
26125, Oldenburg
Germany

Abschlussdatum:

April 2022

Redaktion:

Fachgebiet II 2.3 Schutz der Meere und Polargebiete
Rita Fabris (Fachbegleitung)

Publikationen als pdf:

<http://www.umweltbundesamt.de/publikationen>

ISSN 1862-4804

Dessau-Roßlau, Oktober 2023

Die Verantwortung für den Inhalt dieser Veröffentlichung liegt bei den Autorinnen und Autoren.

Abstract: Umweltschutz in der Arktis – Unterstützung der deutschen Aktivitäten im Arktischen Rat durch eine Pilotstudie zum Monitoring von Kunststoffmüll an arktischen Küsten mittels fernerkundlicher oder luftgestützter Methoden

A consistent and Arctic-wide quantification of beach litter is an essential step for the development of a Regional Action Plan (RAP) as intended by the Protection of the Arctic Environment working group from the arctic council (PAME) for 2021. The quantification of beach litter not only gives information on the actual state of pollution, but also allows for setting a baseline, which can be used to validate the possible success of measures implemented in an action plan.

To achieve such a baseline, a uniform methodology is necessary which allows for a cost- and time-efficient monitoring of the Arctic coastlines. Traditional beach litter monitoring should be supported and spatially extended by applying remote sensing techniques, such as satellite imagery or drone surveys. The derivation of a suitable methodology is the major aim of this study. The new methods were tested on several hot spots of beach litter. For this purpose, hot spots were identified before, by analysing existing beach litter data, as well as information on sources and influencing factors (e.g. population density, sewage treatment, etc.). Statistical and modelling approaches were applied, suggesting potential hot spots of beach litter accumulation.

To select a suitable methodology, a literature study was performed comparing the potential of different remote sensing techniques regarding spatial and spectral resolution, time and cost efficiency and their potential for a (semi-) automatic classification. Considering the restrictions of spatial resolution for all remote sensing techniques, this study focuses on macro litter (>2.5 cm). A combination of several methodologies was recommended and performed on beach sections on Greenland and Svalbard, i.e. satellite imagery with high spatial resolution data from drone surveys and results from conventional beach litter surveys applying the OSPAR method.

The drone surveys were evaluated by a manual screening of the drone imagery and the application of machine learning approaches. During the manual screening of the drone imagery, up to 17.5% of the plastic items, identified during the OSPAR (Convention for the Protection of the North Sea and the North-East Atlantic) monitoring, could be detected. The low recovery rate is the result of the litter size distribution with most items <10 cm, the heterogenic beach environment, and the ground sample distance (GSD) (1.4 cm and 3.4 cm for the RGB (Red-Green-Blue) and the visible infrared (VIR) sensor, respectively). A (semi-) automatic classification of beach litter was applied testing machine learning approaches like Random Forest, Support Vector Machine, and Neural Network. The highest overall accuracy (OA) was reached applying Random Forest on VIR imagery with an OA of 90.6%, showing the potential of VIR imagery. Misclassifications of plastic objects applying machine learning algorithms occurred mainly with rocks and wood. As the occurrence of plastic objects was much smaller compared to rocks and wood, wrong assignments had a great impact on the classification maps and plastic was strongly overestimated. To meet up with the complex environmental conditions and the litter size distribution in the Arctic, a sub-centimetre GSD is recommended for future studies in the Arctic. For large areas, the drone-based beach litter monitoring was up to 22-times faster compared to the OSPAR monitoring. For small areas, an OSPAR monitoring could be more time efficient. Anyhow, drone surveys can also be beneficial for small areas, as the beaches in the Arctic are often remote and the time at the beaches is often limited. The results of the WorldView 3 (WV3) imagery showed that beach litter detection with satellite imagery is still limited by its spatial resolution and only large accumulations of litter seem to be detectable. The litter size and the spatial distribution of litter on the monitored Arctic beaches were too low to be identified on the WV3 imagery. A higher spatial resolution or a larger spectral coverage would be required to also detect lower litter accumulations on beaches from satellites. In future studies, sub-pixel detection approaches for beach litter detection should be tested for survey areas with very high litter abundances to determine the minimum coverage of plastics that is required for a successful detection. The results of such an evaluation can further be used to determine the

resolution of satellite imagery needed to detect litter accumulations as found on Greenland and Svalbard.

Kurzbeschreibung: Umweltschutz in der Arktis – Unterstützung der deutschen Aktivitäten im Arktischen Rat durch eine Pilotstudie zum Monitoring von Kunststoffmüll an arktischen Küsten mittels fernerkundlicher oder luftgestützter Methoden

Eine arktisweit einheitliche Erfassung von Strandmüll ist die grundlegende Voraussetzung für die Entwicklung eines regionalen Aktionsplans (RAP) wie von der Protection of the Arctic Marine Environment Arbeitsgruppe des Arktischen Rats (PAME) für 2021 angestrebt. Die Erfassung von Strandmüll gibt dabei sowohl Informationen über den aktuellen Verschmutzungszustand als auch eine Grundlage für die Bewertung des Erfolgs möglicher Aktionspläne.

Um dies zu erreichen, ist eine einheitliche Methodik erforderlich, die eine kosten- und zeiteffiziente Erfassung von arktischen Stränden ermöglicht. Die traditionelle Erfassung von Strandmüll wurde in diesem Projekt durch fernerkundliche Methoden wie Satellitenbilder oder Drohnenerfassungen unterstützt und erweitert. Die Entwicklung einer geeigneten Methodik war das Hauptziel dieser Studie, und die Methodik wurde an ausgewählten Hotspots von Strandmüll auf Grönland und Spitzbergen evaluiert. Zu diesem Zweck wurden zuvor potenzielle Hotspots identifiziert, indem Daten von bereits existierenden Strandmüllkartierungen sowie Informationen zu potenziellen Quellen und weiterer geografischer Faktoren (z. B. Bevölkerungsdichte, Abwasserbehandlung usw.) ausgewertet wurden. Zur Auswertung wurden ein statistischer und ein Modell-basierter Ansatz gewählt.

Für die Entwicklung einer geeigneten Methodik wurde eine Literaturstudie durchgeführt, in der das Potenzial verschiedener Fernerkundungsmethoden hinsichtlich räumlicher und spektraler Auflösung, Zeit- und Kosteneffizienz und der Anwendbarkeit einer (halb-) automatischen Klassifikation verglichen wurde. In Anbetracht der Einschränkungen der räumlichen Auflösung aller Fernerkundungstechniken konzentriert sich diese Studie auf Makromüll (>2,5 cm). Eine Kombination von Satellitenbildern mit Drohnenerfassungen und konventionellen Strandmüllkartierungen wird empfohlen.

Für die Drohnenerfassung wurde eine manuelle Sichtung der Drohnenbilder und eine Anwendung Maschinellen Lernens getestet. Bei der manuellen Sichtung konnten bis zu 17,5% der Plastikobjekte im Vergleich zur OSPAR (Vertrag zum Schutz der Nordsee und des Nordostatlantiks) Erfassung gefunden werden. Die niedrige Erfassungsrate resultierte aus der Größenverteilung der Plastikobjekte mit der Mehrzahl der Objekte <10 cm, der heterogenen Strandumgebung und der Bodenauflösung (ground sample distance: GSD) von 1,4 cm und 3,4 cm für den RGB (Rot-Grün-Blau) - beziehungsweise den VIR (sichtbar - Infrarot) - Sensor. Eine (halb-) automatische Auswertung der Drohnenbilder wurde anhand verschiedener Anwendungen Maschinellen Lernens (*Random Forest, Support Vector Machine, Neuronale Netzwerke*) getestet. Die höchste Gesamtgenauigkeit (overall accuracy: OA) wurde unter Anwendung von Random Forest für VIR-Bilder erreicht mit einer OA von 90,6%. Die häufigste Fehlklassifikation von Plastikobjekten fand mit Steinen und Holz statt. Auf Grund des deutlich geringeren Müllvorkommens im Vergleich zum Vorkommen von Steinen und Holz, führte schon ein geringer Prozentsatz an falsch bestimmten Steinen und Holz zu einer erheblichen Überschätzung des Plastikmülls. Um den komplexen Umweltbedingungen und der Größenverteilung der Plastikobjekte in der Arktis gerecht zu werden, wird für zukünftige Studien eine GSD im Subzentimeter-Bereich empfohlen. Für große Flächen war das drohnenbasierte Strandmüll-Monitoring im Vergleich zum OSPAR-Monitoring bis zu 22-mal schneller, wohingegen für kleinere Flächen das OSPAR-Monitoring effizienter war. Trotzdem können Drohnenerfassungen auch für kleine Gebiete von Vorteil sein, da die Strände in der Arktis oft abgelegen sind und die Zeit an den Stränden begrenzt sein kann. Die Ergebnisse der WorldView 3 (WV3) -Bilder zeigen, dass die Erkennung von Strandmüll mit Satellitenbildern immer noch durch die räumliche Auflösung begrenzt ist und nur große Müllansammlungen

erkennbar sind. Eine höhere räumliche Auflösung oder eine größere spektrale Abdeckung wäre erforderlich, um auch geringere Müllansammlungen an Stränden von Satelliten aus zu erkennen. In zukünftigen Studien sollten Anwendung der Sub-Pixel Klassifikation in Untersuchungsgebieten mit sehr hohem Müllaufkommen getestet werden, um die Mindestpixelabdeckung durch Plastikobjekte zu bestimmen, die für eine erfolgreiche Erkennung erforderlich ist. Die Ergebnisse einer solchen Auswertung können verwendet werden, um die Mindestauflösung von Satellitenbildern zu bestimmen, um Müllansammlungen, wie sie auf Grönland und Spitzbergen vorgefunden wurden, erkennen zu können.

Inhaltsverzeichnis

Abbildungsverzeichnis	13
Tabellenverzeichnis	15
Abkürzungsverzeichnis.....	18
Summary	20
Zusammenfassung.....	27
1 Einleitung.....	34
2 Arbeitspaket 1.....	36
2.1 Konventionelles Strandmüll-Monitoring.....	36
2.1.1 Methoden.....	36
2.1.2 Ergebnisse und Diskussion.....	36
2.1.2.1 Bestehende Monitoring-Protokolle für Strandmüll	36
2.1.2.2 Identifizierung von Hotspots von Strandmüll auf Grönland und Spitzbergen.....	39
2.2 Fernerkundungsgestütztes Monitoring von Strandmüll	41
2.2.1 Methoden.....	41
2.2.2 Einführung in die Fernerkundung	41
2.2.2.1 Elektromagnetisches Spektrum	41
2.2.2.2 Aktive und passive Sensoren	42
2.2.2.3 Spektrale Auflösung und Abdeckung	42
2.2.2.4 Räumliche Auflösung und Flächendeckung.....	43
2.2.2.5 Spektrale Signatur	43
2.2.3 Ergebnisse und Diskussion.....	43
2.2.3.1 Überblick zur Anwendung von Satelliten zur Erfassung von Plastikmüll	43
2.2.3.2 Überblick zur Anwendung von Flugzeug-gestützter Erfassung von Plastikmüll	46
2.2.3.3 Überblick zur Anwendung von Drohnen-gestützter Erfassung von Plastikmüll	47
2.2.3.4 Laufende Literaturrecherche.....	48
2.2.3.5 Klassifikationsmethoden	49
2.2.4 Fazit.....	49
3 Arbeitspaket 2.....	52
3.1 Statistische Analysen zur Identifizierung von Anreicherungen von Strandmüll.....	52
3.1.1 Methoden.....	52
3.1.2 Ergebnisse und Diskussion.....	53
3.2 Modellierungsansatz zur Identifizierung von Anreicherungen von Strandmüll	58
3.2.1 Methoden.....	58

3.2.1.1	Datenquellen.....	58
3.2.1.2	Modelle für Partikelbewegungen.....	60
3.2.1.3	Strandungsdichte und Vergleich der Modelle	61
3.2.2	Ergebnisse.....	61
3.2.2.1	Ergebnisse der Müllanlandung für unterschiedliche Modellauflösungen.....	61
3.2.2.2	Vergleich der Ergebnisse zur Müllstrandung.....	63
3.2.3	Diskussion	66
4	Arbeitspaket 3.....	68
4.1	Zusammenfassung der Feldarbeit.....	68
4.2	Methoden	77
4.2.1	OSPAR.....	77
4.2.2	Drohnen Erfassung.....	77
4.2.2.1	Manuelle Sichtung.....	78
4.2.2.2	Statistische Analyse.....	78
4.2.2.3	(Halb-)Automatische Klassifikation	79
4.2.2.4	Bewertung der Genauigkeit.....	82
4.2.3	Satellitenbilder	83
4.3	Ergebnisse und Diskussion.....	84
4.3.1	Ergebnisse der konventionellen Kartierungen	84
4.3.2	Ergebnisse und Diskussion der Drohnenerhebung	88
4.3.2.1	Manuelles Sichten	88
4.3.2.2	Statistische Analyse.....	96
4.3.2.3	(Halb-)Automatische Klassifikation	99
4.3.2.4	Diskussion Drohnenerhebung.....	110
4.3.3	Ergebnisse und Diskussion der WV3-Satellitenbilder	121
5	Arbeitspaket 4.....	127
6	Literaturverzeichnis.....	128
A	Anhang	133
A.1	Koordinaten der OSPAR-Standorte für die Untersuchung von Strandmüll auf Grönland, Spitzbergen und Island.....	133
B	Anhang	135
B.1	Städte und Siedlungen auf Grönland	135
B.2	Deponien und Bergbauaktivitäten auf Grönland.....	136
C	Anhang	137
C.1	Tägliche Strömungsintensitäten aus dem Copernicus-Datenportal	137

C.2	Tägliche Strömungsintensität vom Norwegischen Polarinstitut	138
D	Anhang	139
D.1	Fotos der mit einem GNSS-Empfänger gemessenen Müllobjekte im Untersuchungsgebiet Sisimiut Tag 4, aufgenommen mit einer Digitalkamera	139
D.2	Fotos der mit einem GNSS-Empfänger gemessenen Müllobjekte im Untersuchungsgebiet Sisimiut Tag 5, aufgenommen mit einer Digitalkamera	143
E	Anhang	145
E.1	Anzahl der gefundenen Objekte für jede ermittelte Materialkategorie.....	145
E.2	Größenverteilung aller Plastikmüllobjekte, die kleiner als 1 m ² waren.....	145
E.3	Übersichtstabelle der Modellrangliste nach AIC für die Auswirkungen mehrerer Parameter auf die Wahrscheinlichkeit, die Art eines Plastikobjekts zu identifizieren. Das für die Darstellung gewählte Modell ist fett hervorgehoben.....	145
E.4	Übersichtstabelle der Modellrangliste nach AIC für die Auswirkungen mehrerer Parameter auf die Wahrscheinlichkeit, dass ein Plastikmüllobjekt mit Sicherheit als solches identifiziert werden kann. Das für die Darstellung gewählte Modell ist fett hervorgehoben.	146
E.5	Streudiagramm der Residuen des finalen Modells (id_02), dass die Wahrscheinlichkeit beschreibt, die Art eines Plastikmüllobjekts zu identifizieren.....	146
E.6	Streudiagramm der Residuen des finalen Modells (caertain_02), dass die Wahrscheinlichkeit beschreibt, dass ein Plastikmüllobjekt mit Sicherheit als solches identifiziert wurde.....	147
F	Anhang - Konfusionsmatrizen: (Halb-)automatische Klassifikation.....	148
F.1	Grönland Random Forest v1.....	148
F.2	Grönland Support Vector Machine v1.....	149
F.3	Grönland Neuronales Netzwerk v1a	150
F.4	Grönland Neuronales Netzwerk k v1b	151
F.5	Grönland Neuronales Netzwerk v1c	152
F.6	Grönland Random Forest v2.....	153
F.7	Grönland Support Vector Machine v2.....	154
F.8	Grönland Neuronales Netzwerk v2a	155
F.9	Grönland Neuronales Netzwerk v2b.....	156
F.10	Grönland Neuronales Netzwerk v2c	157
F.11	Grönland Random Forest v3.....	158
F.12	Grönland Support Vector Machine v3.....	159
F.13	Grönland Neuronales Netzwerk v3a	160
F.14	Grönland Neuronales Netzwerk v3b.....	161
F.15	Grönland Neuronales Netzwerk v3c	162

F.16	Spitzbergen Random Forest v1.....	163
F.17	Spitzbergen Random Forest v2.....	163
F.18	Spitzbergen Random Forest v3.....	163
G	Anhang - Spektrales Signal von Drohnen-Referenzdaten auf Spitzbergen	164
G.1	Durchschnittlicher Reflektionswert der Eingangsklassen aus den Referenzdaten von Spitzbergen	164
G.2	Dichtefunktionen der aus den Referenzdaten auf Spitzbergen extrahierten Reflektionswerte	165
G.3	Dichtefunktionen der angewandten Indizes, die aus den Referenzdaten auf Spitzbergen extrahiert wurden	166
G.4	Dichtefunktionen des HSV-Farbraums, die aus den Referenzdaten von Spitzbergen extrahiert wurden	167
G.5	Dichtefunktionen des LAB-Farbraums, die aus den Referenzdaten von Spitzbergen extrahiert wurden	168
G.6	Dichtefunktionen des YcBcR-Farbraums, die aus den Referenzdaten von Spitzbergen extrahiert wurden	169
H	Anhang	170
H.1	Spektrale Reflektionswerte von WV3-Bildern auf Spitzbergen, die die Streuung innerhalb der einzelnen Klassen zeigen	170
H.2	Spektrale Reflektionswerte von WV3-Bildern auf Grönland, die die Streuung innerhalb der einzelnen Klassen zeigen	170

Abbildungsverzeichnis

Abbildung 1:	Box-Whisker-Plots der Gesamtabundanzen von Strandmüll auf Grönland, Island und Spitzbergen.....	40
Abbildung 2:	Standorte von Strandmülluntersuchungen, Häfen, Siedlungen und meteorologischen Stationen auf Grönland	40
Abbildung 3:	Standorte von Strandmülluntersuchungen, Häfen und meteorologischen Stationen auf Spitzbergen	41
Abbildung 4:	Elektromagnetisches Spektrum	42
Abbildung 5:	Elektromagnetisches Spektrum von Kunststoff.....	43
Abbildung 6:	Klassifikation von treibenden Objekten mittels NDVI und FDI	45
Abbildung 7:	Übersicht der Sensoren, die zur Erkennung von Plastikmüll eingesetzt wurden.....	46
Abbildung 8:	Elektromagnetisches Spektrum von Kunststoff mit spektraler Abdeckung von WV3 und MicaSense Altum.....	51
Abbildung 9:	Karte von Grönland mit einer Windrose	54
Abbildung 10:	Karte von Grönland mit einer Windrose	54
Abbildung 11:	Karte von Grönland mit einer Windrose	55
Abbildung 12:	Darstellung der vorherrschenden residualen Strömungen in den Gewässern um Grönland	56
Abbildung 13:	Karte von Spitzbergen mit einer Windrose	56
Abbildung 14:	Kumulierte Verkehrsdichte.....	59
Abbildung 15:	Schematische Darstellung der Einspeisung- und Modellierungszeiträume	60
Abbildung 16:	Anfangs- und Endsituation des LR-Modells.....	62
Abbildung 17:	Ausgangs- und Endsituation des HR-Modells	63
Abbildung 18:	Gestrandete Partikel und Partikeldichte des LR-Modells.....	64
Abbildung 19:	Gestrandete Partikel und Partikeldichte des LR-Modells.....	64
Abbildung 20:	Vergleich der Strandungsdichte der beiden Modelle	65
Abbildung 21:	Residuen des linearen Modells zum Vergleich der Strandungsdichte, die mit dem HR- und dem LR-Modell ermittelt wurde.....	65
Abbildung 22:	Unterschiede zwischen LR und HR.....	66
Abbildung 23:	Kapp Mitra, Landung von WingtraOne - Foto: Geir Wing Gabrielsen.....	69
Abbildung 24:	Untersuchungsgebiet Spitzbergen: Kapp Mitra.....	75
Abbildung 25:	Untersuchungsgebiet Grönland: Nuuk.....	75
Abbildung 26:	Untersuchungsgebiet Grönland: Sisimiut.....	76
Abbildung 27:	Mittlere Materialzusammensetzung des Strandmülls an den Stränden bei Nuuk.....	85
Abbildung 28:	Mittlere Materialzusammensetzung des Strandmülls an den Stränden bei Sisimiut.....	86
Abbildung 29:	Statistische Teststärke für verschiedene Verringerungen der Gesamtabundanzen von Strandmüll. Die Ergebnisse wurden	

	mittels einseitiger Wilcoxon-Rangsummentests für eine Stichprobe mit einem Signifikanzniveau von 0,05 berechnet. 88
Abbildung 30:	Dichtekarte der Flächendeckung und der Anzahl der Plastikmüllobjekte in Kapp Mitra 90
Abbildung 31:	Dichtekarte des Plastikmülls in den Untersuchungsgebieten rund um Nuuk 91
Abbildung 32:	Dichtekarte des Plastikmülls im Untersuchungsgebiet Sisimiut Tag 4 92
Abbildung 33:	Dichtekarte des Plastikmülls im Untersuchungsgebiet Sisimiut Tag 5 93
Abbildung 34:	Räumliche Verteilung der per GNSS-Empfänger markierten Objekte und der bei der manuellen Überprüfung gefundenen Objekte im Untersuchungsgebiet Sisimiut Tag 4 94
Abbildung 35:	Räumliche Verteilung der per GNSS-Empfänger markierten Objekte und der bei der manuellen Überprüfung gefundenen Objekte im Untersuchungsgebiet Sisimiut Tag 5 95
Abbildung 36:	Prozentualer Anteil der Müllobjekte, die während der Drohnenerfassung in bestimmten Gebieten gefunden wurden (n = 8 unterschiedliche, unabhängige Standorte). A: alle Objekte, einschließlich Holz. B: nur Müllobjekte, die nicht als Holz klassifiziert wurden..... 96
Abbildung 37:	Boxplots, die die Verteilung der Objektgröße (als Fläche [cm ²]) für jede Farbkategorie der auf Drohnenaufnahmen gefundenen Plastikabfallobjekte zeigen. 97
Abbildung 38:	Der Einfluss von Größe (Fläche [cm ²]) und Farbe auf die Wahrscheinlichkeit, dass die Art eines Plastikmüllobjekts anhand von Drohnenaufnahmen identifiziert werden kann... 98
Abbildung 39:	Der Einfluss von Größe (Fläche [cm ²]) und Farbe auf die Wahrscheinlichkeit, dass ein Plastikmüllobjekt mit Sicherheit als ein solches identifiziert werden kann. 99
Abbildung 40:	Durchschnittliche Reflektion der Eingangsklassen aus den Referenzdaten von Grönland..... 102
Abbildung 41:	Dichtefunktionen der aus den Referenzdaten auf Grönland extrahierten Reflektionswerte für die Wellenlängen von 475, 560, 668, 717 und 842 nm..... 103
Abbildung 42:	Dichtefunktionen der angewandten Indizes, extrahiert aus den Referenzdaten für Grönland..... 103
Abbildung 43:	Dichtefunktionen des HSV-Farbraums für die Referenzdaten aus Grönland..... 104
Abbildung 44:	Dichtefunktionen des LAB-Farbraums für die Referenzdaten aus Grönland..... 104
Abbildung 45:	Dichtefunktionen des YcBcR-Farbraums für die Referenzdaten aus Grönland..... 105

Abbildung 46:	Vergleich des Referenzdatensatzes mit in situ georeferenzierten Plastikobjekten.....	105
Abbildung 47:	Vergleich des Referenzdatensatzes mit in situ georeferenzierten Plastikobjekten.....	106
Abbildung 48:	Dichtekarte der Flächenabdeckung von Plastikmüll aus manueller Sichtung und aus RF v3	107
Abbildung 49:	Dichtekarte der Flächenabdeckung von Plastikmüll aus manueller Sichtung und aus RF v3	108
Abbildung 50:	Dichtekarte der Flächenabdeckung von Plastikmüll aus manueller Sichtung und aus RF v3	109
Abbildung 51:	Dichtekarte der Flächenabdeckung von Plastikmüll aus manueller Sichtung und aus RF v3	110
Abbildung 52:	Übersicht über die Strandverhältnisse aus früheren Studien zur manuellen Auswertung von Strandmüll auf Drohnenbildern	112
Abbildung 53:	Beispiele für die Strandumgebung auf Spitzbergen und Grönland.....	113
Abbildung 54:	Durchschnittliches Spektralsignal von WV3-Bildern auf Spitzbergen	125
Abbildung 55:	Durchschnittliches Spektralsignal von WV3-Bildern auf Spitzbergen	125
Abbildung 56:	Durchschnittliches Spektralsignal, das aus WV3-Bildern von Spitzbergen für verschiedene Kunststoffbedeckungen extrahiert wurde	126
Abbildung 57:	Durchschnittliches Spektralsignal, das aus WV3-Bildern von Grönland für verschiedene Kunststoffbedeckungen extrahiert wurde	126

Tabellenverzeichnis

Tabelle 1:	Überblick über bestehende Protokolle zum Monitoring von Strandmüll	39
Tabelle 2:	Vergleich von Fernerkundungsplattformen für eine arktisweite Strandabfallüberwachung	49
Tabelle 3:	Aggregierte Daten zur Schifffahrt in den Gewässern um Grönland, beispielhaft angegeben für das Jahr 2016.....	57
Tabelle 4:	Ergebnisse einer Permutationsanalyse der Kovarianz (PERMANCOVA)	58
Tabelle 5	Koordinaten und Eigenschaften der beiden Strandabschnitte von Kapp Mitra, aufgenommen am 11. Juli 2021. Die Koordinaten sind als Universal Transverse Mercator (UTM) – Koordinaten angegeben mit dem Datum WGS84.....	70
Tabelle 6:	Koordinaten und Eigenschaften kartierter Strandabschnitte bei Nuuk und Sisimiut. Koordinaten werden als Universal	

	Transverse Mercator (UTM) – Koordinaten angegeben mit dem Datum WGS84.....	72
Tabelle 7:	Übersicht über die Drohnerhebungen auf Spitzbergen und Grönland.....	77
Tabelle 8:	Indizes abgeleitet vom MicaSense Altum-Sensor	80
Tabelle 9:	Farbräume abgeleitet aus den RGB Bändern	80
Tabelle 10:	Die häufigsten Müllkategorien an den beiden Strandabschnitten bei Kapp Mitra, kartiert nach dem OSPAR-Protokoll (OSPAR, 2010). Zahlen in eckigen Klammern geben die OSPAR-Strandmüll-IDs an.	84
Tabelle 11:	Die häufigsten Mülltypen an konventionell kartierten Strandabschnitten bei Nuuk auf Grönland. Zahlen in eckigen Klammern geben OSPAR-Strandmülltyp-IDs an.....	86
Tabelle 12:	Die häufigsten Mülltypen an konventionell kartierten Strandabschnitten bei Sisimiut auf Grönland. Zahlen in eckigen Klammern geben OSPAR-Strandmülltyp-IDs an.....	87
Tabelle 13:	Anzahl der bei der manuellen Überprüfung und der OSPAR-Überwachung vor Ort gefundenen Müllgegenstände	89
Tabelle 14:	Vergleich zwischen der GNSS-Messung von Objekten und dem manuellen Screening.....	96
Tabelle 15:	Größenverteilung der auf den Drohnenaufnahmen gefundenen Müllobjekte. In der Tabelle sind die Minimal-, Median-, Mittel- und Maximalgröße in cm ² aller Objekte, nur von Plastikobjekten und von Plastikobjekten kleiner als 1 m ² aufgeführt.	97
Tabelle 16:	Modellergebnisse zur Abschätzung der Wahrscheinlichkeit, dass der Typ eines Plastikmüllobjekts anhand von Drohnenaufnahmen identifiziert werden kann.	98
Tabelle 17:	Modellergebnisse zur Abschätzung der Wahrscheinlichkeit, mit der ein Plastikmüllobjekt mit Sicherheit als ein solches identifiziert werden kann.	99
Tabelle 18:	Klassifikationsgenauigkeit Grönland	100
Tabelle 19:	Klassifikationsgenauigkeit Spitzbergen	101
Tabelle 20:	Übersicht über die bei der manuellen Überprüfung von Drohnenaufnahmen gefundenen Müllobjekte und die entsprechende Größenverteilung der Objekte, der Strandverhältnisse und der GSD	115
Tabelle 21:	Zeitaufwand für die drohnengestützte Erfassung von Strandmüll	116
Tabelle 22:	Übersicht über die Ergebnisse verschiedener Ansätze des maschinellen Lernens für die Erfassung von Strandmüll mithilfe von Drohnenbildern.	120
Tabelle 23:	Anzahl der Pixel, die zur Extraktion der Spektralinformationen der multispektralen WV3-Bilder verwendet wurden.....	122

Tabelle 24:	Anzahl der Pixel, die zur Extraktion der Spektralinformationen der WV3 SWIR-Bilder verwendet wurden.....	123
-------------	---	-----

Abkürzungsverzeichnis

AE	AquaEcology GmbH & Co. KG
ASTD	Arctic Ship Traffic Data (Daten zum Schiffsverkehr in der Arktis)
AVIRIS	Airborne Visible/ Infrared Imaging Spectrometer
BCSH	BioConsult SH GmbH & Co. KG
CFD	Computational Fluid Dynamics
CLIFRO	R-Paket zum Download und zur Visualisierung der Klimadatenbank von Neuseeland
DLR	Deutsches Zentrum für Luft- und Raumfahrt e. V.
EMODNET	European Marine Observation and Data Network
EMS	Elektromagnetisches Spektrum
EnMap	Environmental Mapping and Analysis Program
FDI	Floating Debris Index
GNSS	Global Navigation Satellite System
GSD	Ground sample distance (räumliche Auflösung)
HELCOM	Kommission für den Schutz der Meeresumwelt der Ostsee (Helsinki-Kommission, HELCOM)
HoG	Histogram of orientated Gradients
HR	Hochauflösend
ICG ML	Intersessional Correspondence Group Marine Litter (OSPAR-Arbeitsgruppe)
IR	Infrarot
ISO	Belichtungszeit
ITRES	ITRES Research Limited
KNN	K-nearest neighbors
LDPE	Polyethylen niedriger Dichte
LR	Niedrige Auflösung
ML	Maximum Likelihood Klassifikator
MSFD	Marine Strategy Framework Directive
MTOW	Maximales Abfluggewicht
NetCDF	Network Common Data Form
NDVI	Normalized Difference Vegetation Index
NIR	Nah-Infrarot
NP	Norwegisches Polar Institute
OA	Orbicon Arctic A/S
OSPAR	Vertrag zum Schutz der Nordsee und des Nordostatlantiks (benannt nach den Vorläufern Oslo-Konvention und Paris-Konvention)
PA	Produzentengenauigkeit
PAME	Protection of the Arctic Marine Environment (Arbeitsgruppe des Arktischen Rates)
PERMANCOVA	Permutational Analyse der Kovarianz

PET	Polyethylenterephthalat
R	Statistiksoftware
RAP	Regionaler Aktionsplan
RF	Random Forest
RGB	Rot-Grün-Blau
ROMS	Regional Ocean Modelling System
SDMTools	R-Paket: Tools zur Modellierung der Artenverteilung
SWIR	Kurzwellen-Infrarot
SVM	Support Vector Machine
UA	Benutzergenauigkeit
UAV	Unbemanntes Luftfahrzeug/Drohne
UBA	Umweltbundesamt
VIR	Sichtbares Infrarot
VIS	Sichtbares Spektrum
VNIR	Sichtbares und nahes Infrarot
WSP	WSP Global
WV3	WorldView 3
WWF	World Wide Fund For Nature

Summary

This study aims to develop a large-scale application for an Arctic-wide consistent and comparable data acquisition of beach litter. Therefore, traditional applications of beach litter monitoring were combined and extended by remote sensing techniques. The developed applications were tested on selected beaches on Svalbard and Greenland and validated by comparing it to a traditional beach litter monitoring approach on the same test sites. Methods of traditional beach litter monitoring were evaluated to select the most suitable approach for this study. The test sites on Svalbard and Greenland were chosen after the identification of potential hotspots of beach litter accumulation applying statistical and modelling approaches. Potential test sites were further evaluated by their remoteness and by the presence of regional logistics facilities.

In work package 1, AquaEcology GmbH & Co. KG (AE) performed a literature study on existing methods of beach litter monitoring. Distinct monitoring methods, such as those by Alkalay et al. (2007), Bravo et al. (2009), Cheshire et al. (2009), Opfer et al. (2012) and OSPAR (2010), were compared. The OSPAR method is applied by the European countries and Greenland, while the protocols of Opfer et al. (2012) and Cheshire et al. (2009) are applied in the United States and Canada, respectively. For this study, the OSPAR method (2010) was applied, as it was found to be the most detailed one among the methods described above. During OSPAR surveys, standard 100 m sections of beach along the coastline are monitored, recording the abundance of macroscopic beach litter. The recorded litter is then collected and removed from the survey sites. The mean total abundance of beach litter on OSPAR beaches on Greenland and Svalbard was analysed for the years 2016 to 2019. On Greenland values ranged from one item at the eastern coast to over 800 items at the western coast. On Svalbard, the mean total abundances of beach litter approximated to 200 items. An analysis of the spatial distribution of beach litter shows the occurrence of high amounts of beach litter on sections of beaches highly exposed to wind and currents indicating that most beach litter is sea-based. Sea-based sources contain mostly shipping and fishing. Several studies confirm shipping and especially fishing as the dominating sources of marine litter in the Arctic (Bergmann et al., 2017; Buhl-Mortensen and Buhl-Mortensen, 2017; Tekmann et al., 2017).

BioConsult SH GmbH & Co. KG (BCSH) conducted a literature study on existing remote sensing techniques for the detection of plastic litter on Arctic beaches in order to develop an application for an Arctic-wide consistent and comparable data acquisition. The literature study focused on three remote sensing platforms: Satellite, airborne and drone (UAV), which were evaluated in terms of spectral and spatial resolution, area coverage, acquisition limitations and costs. Satellite platforms showed high potential for plastic beach litter detection on Arctic beaches permitting the acquisition of large-scale areas with a high spectral coverage. Due to the remoteness of the Arctic and the resulting time and cost intensive logistics of field works, satellite platforms are predestinated for an Arctic-wide monitoring. Several studies (Topouzelis et al. 2019, Biermann et al. 2020, Acuña-Ruz et al. 2018 and Maximenko et al. 2019) have shown the potential of satellite systems for the detection of spectral characteristics of plastics on pixel level. Even though the main limitation remains the relatively coarse spatial resolution of >1 m for multispectral imagery resulting in a potential detectability of objects >1 m². Sub-pixel classification could further increase the object detectability, but this was only tested over sea so far. A further challenge of satellite-based beach litter detection is the high cloud coverage in the Arctic which requires a broad acquisition timeframe and high revisit time. Airborne-based digital surveys for litter detection were conducted in various studies, showing its potential for a visual census of plastic litter as well as for (semi-) automatic classification approaches (Garaba et al. 2018, Garaba et al. 2018b, Moy et al. 2018, Pichel et al. 2012 and Garcia-Garin et al. 2019).

The visual analysis permitted an identification of objects with a size of ten times the spatial resolution. For a (semi-) automatic classification hyperspectral sensors were applied. Garaba et al. (2018b) described a potential detection of objects at sub-pixel scale of 5% of a pixel over sea, resulting in an object size of around 0.025 x 0.06 m. Airborne-based systems show great potential regarding spatial and spectral resolution but are limited due to their relatively high cost, especially for an Arctic-wide acquisition. Costs include instrument-running costs, aircraft/fuel overheads, mobilization and demobilization and personnel and living expenses (Coulter et al. 2007). A rough estimation of area coverage is based on aerial survey experience of BCSH and resulted in an approximate coverage of around 800 km of coastline per day at a flight altitude of 550 m but can vary significantly depending on coastal characteristics. UAVs were successfully applied in various studies of beach litter monitoring for a visual analysis and for (semi-) automatic detection approaches (Martin et al. 2018, Bao et al. 2018). UAVs permit the highest spatial resolution of the three platforms with sub-centimetre acquisition in RGB and 3.4 cm for multispectral sensors. The application of hyperspectral sensors is possible but still very costly. Several studies showed the potential of (semi-) automatic classification over sandy beaches (Martine et al. 2018, Bao et al. 2018) which has still to be confirmed on different beach types. The relatively low costs and the fast acquisition time make UAV surveys particularly interesting on a locale scale and as a support to traditional beach litter monitoring. The main limitation of UAV surveys for an Arctic-wide monitoring of beach litter are a large-scale application and the accessibility of remote areas as well as the climatic limitations (rain or strong winds >30 km/h). In addition to the literature review of the three remote sensing platforms, the applicability of (semi-) automatic classification methods was investigated. For a large-scale application in the Arctic, satellite data are of high interest and thus provide an appropriate classification on pixel level using the spectral characteristics of plastic. Garaba et al. (2020) presented a continuous spectrum of plastic litter identifying wavelength ranges that are characteristic for the presence of plastics (around 931 nm, 1215 nm, 1417 nm, 1732 nm). Sensors covering these wavelength ranges are particularly well-suited for (semi-) automatic detection of plastic litter. Comparing the three platforms with their advantages and limitations, BCSH suggests a combination of at least two platforms to profit from synergistic effects. For this study, BCSH recommends the application of WorldView3 (WV3) satellite imagery and UAV imagery from the multispectral MicaSense Altum sensor. Combining satellite imagery with large aerial coverage but relatively low spatial resolution, with high spatial resolution data from UAV surveys is very promising.

In work package 2, AE and BCSH summarized and acquired the data, necessary for the identification of accumulations of beach litter on Greenland and Svalbard. Orbicon Arctic A/S (OA) gathered and provided data regarding settlements, tourism, harbours, landfills, and mining activities on Greenland. Data availability significantly differed between Svalbard and Greenland. Therefore, data evaluations were different, as well. While hydrodynamic and Lagrangian transport models were available for the waters around Svalbard only, information on shipping, fishing, and tourism could be acquired for Greenland only. The required data included geo-referenced data on settlements, harbours, currents, and wind as well as information on landfills and incineration. AE created geo-referenced shape files of meteorological stations, harbours, and settlements and aggregated ASTD data on shipping and fishing activities to total abundances in the waters of Greenland. Afterwards, AE carried out a statistical analysis to identify drivers of beach litter abundances on Greenland. A permutational analysis of covariance (PERMANCOVA) was calculated with mean abundances of fishing vessels as factor, and numbers of inhabitants, distance to next settlement, distance to next harbour, and overnight stays as covariates. Mean total abundances of beach litter on Greenland, taken from the OSPAR beach litter database, were used as dependent variable. Normality (Kolmogorov-Smirnov test) and homogeneity of variance (Levene test) were given, but autocorrelation could not be excluded definitely. Therefore, the model is assumed to be not or barely biased. The model fit was good

with a measure of determination of 0.83. Fishing and overnight stays could be identified as significant factor and covariate, respectively, which agrees with previous studies on beach litter in the Arctic. Particularly, sea-based sources are often highlighted as dominant input parameter (Bergmann et al. 2017, Kirkfeldt 2016, Tekmann et al. 2017). Further evidence for sea-based sources are wind and data on currents. Abundances of beach litter at the west coast of Greenland are highest where strong westerly or southwesterly winds are dominating. In contrast, beaches with less westerly wind reflect lower abundances. The proximity to larger cities is an additional factor for beach litter accumulation. Evaluating all data, hotspots of beach litter accumulation were expected to be found close to Nuuk and Sisimiut, making them potential beaches to be surveyed in this project. At Svalbard, easterly winds are predominating, indicating lower abundances at the western coast of Svalbard. Highest abundances were found on beach sections exposed to wind and currents in the north of Svalbard (Bergmann et al., 2017).

In addition to the statistical approach described above, BCSH applied a modelling approach to predict locations around Svalbard with higher probabilities of beaching of macro-plastics. The model approach was only applied on Svalbard, as no high-resolution dataset of sea current was available for Greenland. Therefore, two sets of data on sea currents with different resolutions were applied and the outputs from the models were assessed. Monthly fishing data were used to create input data for the model calculating monthly densities, based on which plastic particles were deployed randomly at sea every 100 km of route. Each monthly dataset was loaded in the current model. Furthermore, two current datasets were used as an input. From the Marine Copernicus website (<https://marine.copernicus.eu>), a dataset with low spatial resolution but large spatial coverage was downloaded and used for simulation of trajectories of plastic particles released according to the monthly fishing intensity. Besides, it was used to feed particles to the higher resolution model. The dataset had a spatial resolution of 0.025°, a spatial extension from -10°W to 60°E and from 55°N to 90°N and a temporal coverage over two years, from August 2008 to August 2010. The second dataset had higher spatial resolution but less spatial coverage and is available on the Norwegian Meteorological Service website (<https://api.npolar.no>). The dataset is available for the years 2005 to 2010 at 800 m resolution but is not covering the full fishing area around Svalbard. Therefore, plastic particles were fed by the lower resolution model. The temporal range was set between August 2009 and August 2010. Wind and wave stoke were not available for the considered area and time frame and therefore not included in this study. The model was performed with OpenDrift v1.0, an open-source Python based framework for Lagrangian particle modelling that is commonly used to predict pathways of floating objects in the ocean (Dagestad et al. 2018). As wind and wave stoke were not available, a 10% uncertainty factor was included in the current. Litter particles of both models that stranded at the end of the study period were used for further statistical analysis. Both models showed similar stranding patterns with highest stranding probability at the Southern- and Western coast. A linear regression model confirmed a significant relation with a measure of determination (R^2) of 0.758 but also showed higher variations among predicted standings in the southern coast. A spatial analysis on significant difference confirmed the results from the linear regression. Both models indicated potential litter accumulation on the West coast of Svalbard, a finding which contrasts with the above-mentioned assumption of low abundances due to easterly winds. One explanation might be that wind and wave data were not incorporated in this study. Abundance data gathered by this studies' fieldwork can improve the model output and should be included in future approaches. For future approaches, BCSH suggests the incorporation of the Leeway configuration which is a more accurate model configuration for big size plastics compared to PlasticDrift. For the application of the Leeway configuration, wind and wave data are required. BCSH recommends the application of the

Copernicus model, which shows similar results and is not limited to the years 2005 to 2010 as is the API model. Additional input parameter such as the type of coast (beach or cliff), the slope of the beach or wave angle incidence could further improve the model.

The expedition to Svalbard lasted from June 25, 2021 to July 17, 2021. A total of two 50 m sections of beach were completely surveyed applying the OSPAR method. Coordinates were determined by means of a high-resolution GPS. The coordinates of single pieces of litter could not be measured because of lacking access to internet and radio. During the stay on Greenland, beach litter surveys were performed near Nuuk and Sisimiut with up to four replicate sections of beach. Travelling to the selected beaches was done by boat with a boat guide. Conventional surveys were carried out applying the OSPAR method (OSPAR, 2010), where the most recent categorization of 2021 was used. Categorization was amended by beach litter types, which are characteristic of the western coast of Greenland. These new litter types were derived from the Strietmann et al. (2021) and are based on the splitting of OSPAR beach litter types, as was similarly done by the Joint Category list of the MSFD. Power analyses on one-sided one-sample Wilcoxon rank sum tests were calculated to estimate how long beach sections have to be for a significant detection of beach litter reduction by as much as 10%, 20%, 30%, 40% and 50%. For this purpose, a significance level of 0.05 was used.

On Svalbard, mean total abundance was as low as 28.5 pieces of litter per 50 m beach. Beach litter consisted of 57.9% plastic, 40.4% wood and 1.7% rubber. The high percentage of plastics agrees well with the results of previous beach litter studies on Svalbard (Bergmann et al., 2017). Among the top-14 litter categories, six are definitely attributable to fishing and shipping. Thereby, the importance of sea-based sources is highlighted, which is in line with the results of previous studies (Bergmann et al., 2017; Weslawski and Kotwicki, 2018).

Near Nuuk and Sisimiut, mean total abundances of beach litter amounted to 116.4 ± 111.9 pieces and $87,3 \pm 33,5$ pieces on a 50 m section of beach, respectively. This was in the same order of magnitude as Strietmann et al. (2021) found on the western coast of Greenland. Material composition was dominated by plastics and processed wood, which again is in line with the results of Strietmann et al. (2021). Beach litter types, which can definitely be assigned to sea-based sources, were the most common among the top-ten litter types. This finding is partly contradictory to the results of Strietmann et al. (2021), who found that domestic waste was predominant. These differences are likely due to the fact that the latter authors partly surveyed beaches in closer vicinity to settlements than in the study at hand. However, the precise distances to settlements are not given in the study of Strietmann et al. (2021). Power analyses gave statistical powers $<50\%$ and $>80\%$ for beaches near Nuuk and Sisimiut, respectively, for beach litter reductions of 50%. At lower reduction rates, statistical power was even lower and thus not sufficient. Therefore, surveyed beach sections should have a minimum length of 200 m, because near Sisimiut, replicate data of four beach sections of 50 m length were used for power analyses. In turn from a logistic point of view, this supports the application of UAVs for beach litter surveys on Greenland.

To evaluate the potential for remote sensing techniques in the Arctic, drone and satellite imagery were acquired.

The drone images were recorded with a WingtraOne drone and two sensors, the Sony QX1 (RGB) and the Micansense Altum (VIR) with a ground sample distance (GSD) of 1.4 cm and 3.4 cm respectively. The drone surveys were conducted before performing the OSPAR survey, to

make sure that litter items were not accidentally moved or buried. A total of eight study sites were monitored, two on Svalbard and six on Greenland. The area coverage varied between 1.31 ha and 33.85 ha with a minimum of two flights per area, one for each sensor. The required flight time per study site was between 06:56 and 49:26 minutes in which 108 to 1877 images were recorded.

The single images were georeferenced with a post-processed kinematics (PPK) approach and used as an input in the photogrammetry software Pix4D mapper version 4.6.4 to produce elevation models, orthophotos and index maps. The orthophotos of the RGB imagery were then screened manually for litter objects within a GIS environment (QGIS version 3.16.6.) with a scale of 1:20. Between 0 and 63 pieces could be detected which is compared to the OSPAR data at maximum 24% and a mean of 14.8% of all found litter objects. Previous studies described a detection of litter objects by manual screening with a detectability between 18% (Merlino et al., 2020) to almost 100% of litter objects (Andriolo et al., 2020; Escobar Sánchez et al., 2021; Gonçalves et al., 2020b). Three factors were identified to explain the variation in detectability between previous studies, which could have led to the relative low recovery rates in this study: The litter size-distribution, the beach environment, and the GSD of the drone footage. The smaller the objects are, the more difficult they are to spot. Therefore, depending on the litter size distribution on the study area, the detectability of objects via manual screening can vary significantly (Martin et al., 2018; Merlino et al. 2020; Lo et al., 2020). On the surveyed beaches in the Arctic, over 70% of the plastic objects detected on drone footage were larger than >10 cm, reflecting the difficulties of detecting smaller objects. Furthermore, the substrate of the beach (sand or gravel) and its heterogeneity (e.g., occurrence of vegetation, wood, or rocks) influence the manual screening. The monitored beaches in the Arctic had a heterogenic beach background with coloured pebbles, vegetation and driftwood which could be mistaken for litter objects and made the manual screening difficult. Merlino et al. (2020) described similar difficulties with small objects and complex beach backgrounds even having a GSD of 0.18 cm. The third parameter, the GSD, is the only one of the above-mentioned parameters that can be directly defined by the operator as it depends on the chosen sensor and the flight altitude. A lower GSD decreases the minimum size of an object sufficient to be identified, but is limited by the applied sensor and may lead to a decrease in area coverage. The detected objects of the manual screening were used to create density maps for each region which could be used as reference for WV3 satellite imagery later. Furthermore, they were used as reference data to test several approaches of (semi-) automatic classification (Random Forest, Support Vector Machine, and Neural Network). The best statistical results for (semi-) automatic classifications were reached applying Random Forest on VIR imagery with an overall accuracy of 90.6% and a F-score of 77%. The corresponding User's Accuracy was 81.5%. Misclassifications of plastics occurred mainly with the classes *rocks* and *wood*. As the plastic object occurrence was much smaller compared to those classes, wrong assignments had a great impact on the classification maps where plastic was strongly overestimated. The difficulty to spectrally differentiate between plastic, wood and rocks could be confirmed by comparing their spectral profiles. Anyhow, the statistic classification accuracy was comparable to previous studies which used better GSDs and had more homogeneous beach backgrounds (Falatti et al., 2019; Gonçalves et al., 2020a,b,c; Papakonstantinou et al., 2021; Wolf et al., 2020).

This study confirms the great potential of (semi-) automatic classification approaches offering a method for a time- and cost-efficient large-scale detection of beach litter using drone imagery. However, the promising statistical results must always be confirmed by the resulting classification maps. In this study, the results showed that a strong overestimation of plastic occurs applying classification approaches that focus on the spectral characteristics alone. The feature spaces of the applied sensors were not able to distinguish between all occurring land

cover classes (e.g. plastics, wood and rocks). Therefore, the spectral coverage of the sensors must be extended, or other structural parameters must be included. The application of an object-based classification could reduce the misclassification of the wood class but would require a higher GSD. Image recognition methods are also promising but require a higher GSD and a large amount of training data. So far, most studies only focused on litter detection and not litter type identification as performed with the OSPAR method. Only Wolf et al. (2020) presented an approach for plastic type identification using image recognition techniques. For a future implementation into ongoing monitoring programmes, this is an essential step, which must be further investigated and developed, considering the required area coverage (limiting the GSD), the beach environment and the litter size distribution for the Arctic.

The WV3 satellite imageries of the study areas were acquired two to eight days before the actual field work covering up to 7500 ha and 23 km of coastline. The imagery included eight spectral bands from visible to NIR with 1.2 m resolution and eight bands in SWIR with 3.7 m resolution. As the occurring plastic objects were of sub-pixel size, a manual screening was not possible. Instead, this study focused on the question whether satellite imagery can identify areas of high beach litter accumulations. Therefore, the density maps of the manual drone screening were used to create a reference data set from which the spectral signal of different land cover classes was extracted. The density maps also helped to identify the plastic coverage per WV3 pixel. Considering all pixels at 1.2 m resolution which were covered by plastic, 95% and 74% of them had a plastic coverage of less than 5% for Svalbard and Greenland respectively. Only a total of 13 pixels were covered by more than 30% of plastic (1x Svalbard and 12x Greenland). For SWIR imagery at 3.7 m resolution, only seven pixels could be identified that were covered by more than 10% of plastic with a maximum between 20% and 30% coverage. Studies of floating marine litter showed that litter could be detected on Sentinel 2 satellite imagery with a plastic coverage in sub-pixel size of 30 – 55% (Biermann et al., 2020; Topouzelis et al., 2019). Sentinel 2 has a similar spectral coverage as WV3 imagery with 12 bands from visible to SWIR. A sub-pixel detection of plastics over open water for objects covering down to 5% of a pixel was described by Garaba et al. (2018b), but only by applying a higher spectral coverage using hyperspectral imagery. The only study applying satellite imagery for beach litter detection was conducted by Acuña-Ruz et al. (2018) using WV3. These authors applied a semi-automatic classification approach on pixel level and could detect litter objects or patches of litter with a minimum size of 1 m² with an overall accuracy up to 88%.

A detection of beach litter on a sub-pixel scale by spectral unmixing of the single pixels of WV3 imagery was not successful in this study. Spectral unmixing intends to identify the percentage of each reference material within a pixel by identifying the proportion of the respective signals. In difference to floating marine litter the background of beach environments was more complex (e.g. vegetation, sand, rocks, wood) and the litter size and spatial distribution were too low. When including SWIR imagery, the sub-pixel size of 30 – 55% as described in Biermann et al. (2020) and Topouzelis et al. (2019), was not reached for any pixel. Compared to Garaba et al. (2018b), the spectral coverage seemed to be insufficient for a sub-pixel detection down to 5%, probably also being influenced by the complex background signals. A classification at pixel level as described by Acuña-Ruz et al. (2018) was not successful as the litter density and the litter size of single objects or patches was not sufficient. Even though high amounts of plastics were observed on Arctic beaches, their spatial distribution was too sparse and the object size too small.

This study investigated the potential application of remote sensing techniques for beach litter monitoring in the Arctic. The results showed the great potential for drone surveys and compared a manual and a (semi-) automatic detection of plastic objects. The integration of VIR sensors could improve the detection accuracy of (semi-) automatic detection, even though the GSD was coarser compared to RGB imagery. Anyhow, the litter size distribution, the complex background

of the beaches, as well as the required high area coverage still pose challenges for beach litter detection. Furthermore, the identification of the detected litter must be further investigated and requires both, a very high GSD and large amount of training data. Satellite imagery is still limited by its spatial resolution. The litter size and its spatial distribution on Arctic beaches were too low to be identified on WV3 imagery. Therefore, a higher spatial resolution or a larger spectral coverage is required to also detect lower litter accumulations on beaches from Satellites.

Applying drone surveys on Svalbard and Greenland, the monitoring time of large areas can be reduced by a factor of 22 compared to an OSPAR monitoring. However, for small areas as a single 50 m transect, a OSPAR monitoring might be faster because of the time required for the data processing of drone imagery. But even when monitoring small areas, drone surveys can be beneficial, as the beaches in the Arctic are often remote and the time at the beaches can be limited. Satellite imagery permit a high area coverage, but the costs of the data acquisition must be further reduced to permit a large-scale application in future.

Zusammenfassung

Das Ziel dieser Studie ist die Entwicklung einer Methode für eine einheitliche und vergleichbare Erfassung von Plastikmüll an arktischen Stränden. Dafür soll die konventionelle Strandmüllfassung durch Fernerkundung unterstützt und erweitert werden. Die entwickelte Methode wurde an ausgewählten Stränden auf Spitzbergen und Grönland getestet. Die Untersuchungsgebiete stellten Strände dar, an denen ein erhöhtes Müllvorkommen aufgrund statistischer Auswertungen und Modellergebnissen erwartet wurde.

In Arbeitspaket 1 hat AquaEcology GmbH & Co. KG (AE) eine Literatursuche zu bestehenden Methoden der Strandmüllfassung durchgeführt. Verschiedene Methoden, wie die von Alkalay et al. (2007), Bravo et al. (2009), Cheshire et al. (2009), Opfer et al. (2012) und OSPAR (2010) wurden miteinander verglichen. Die OSPAR Methode wird von den europäischen Ländern und Grönland verwendet, das Protokoll nach Opfer et al. (2012) von den USA und das Protokoll nach Cheshire et al. (2009) von Kanada. Für diese Studie wurde die OSPAR Methode (2010) ausgewählt, weil sie die detaillierteste und ausgereifteste Methode darstellt. Im Zuge einer OSPAR Erfassung wurden 100 m lange Strandsegmente entlang der Küste nach Müll untersucht und die Anzahl der Objekte erfasst. Der erfasste Müll wurde gesammelt und vom Untersuchungsgebiet entfernt. Die durchschnittliche Gesamtanzahl von Müll an OSPAR Stränden auf Grönland und Spitzbergen wurde für die Jahre 2016 bis 2019 ausgewertet. Auf Grönland reichte die Anzahl von einzelnen Müllteilen bis zu über 800 Fundstücken, die an einzelnen Strandabschnitten der Westküste gefunden wurden. Auf Spitzbergen lag der Wert der durchschnittlichen Gesamtanzahl bei etwa 200 Fundstücken. Eine räumliche Auswertung ergab eine hohe Ansammlung von Strandmüll an Orten, die exponiert für Wind und Strömung waren. Dies deutet auf einen großen Einfluss von Müll aus seebasierten Quellen hin, der zu großem Teil von der Schifffahrt und der Fischerei stammt. Die Bedeutung der Fischerei als Quelle von Plastikmüll in der Arktis wurde in anderen Studien bestätigt (Bergmann et al., 2017; Buhl-Mortensen and Buhl-Mortensen, 2017; Tekmann et al., 2017).

BioConsult SH GmbH & Co. KG (BCSH) hat eine Literatursuche zu bestehenden Anwendungen der Fernerkundung zur Erfassung von Strandmüll durchgeführt. Die Literatursuche hat einen Schwerpunkt auf die drei Fernerkundungsplattformen Satellit, Flugzeug und Drohne (UAV) gelegt und sie anhand ihrer spektralen und räumlichen Auflösung, der abdeckenden Fläche, Einschränkungen bei der Erfassung und ihrer Kosten verglichen. Die Ergebnisse der Literatursuche ergaben ein großes Potential von Satelliten für die Detektion von Strandmüll in der Arktis, da sie eine großflächige Erfassung bei einer breiten spektralen Abdeckung ermöglichen. Satellitenerfassungen sind prädestiniert für eine Kartierung in unzugänglichem Gelände, die ansonsten hohe Kosten und einen großen Zeitaufwand an Feldarbeit mit sich bringen würde. Zahlreiche Studien haben bereits das Potential von Satellitenerfassung für die Erfassung von spektralen Eigenschaften von Plastik gezeigt (Topouzelisa et al. 2019, Biermann et al. 2020, Acuña-Ruz et al. 2018 and Maximenko et al. 2019). Die größte Einschränkung stellt die relativ grobe räumliche Auflösung dar. Im Multispektralbereich liegt sie bei >1 m und somit bei einer Pixelgröße von 1 m^2 . Dadurch sind selbst auf Pixelbasis nur Objekte ab einer Größe von 1 m^2 erkennbar. Eine Klassifikation auf Sub-Pixel Ebene wurde bislang nur über Wasser getestet. Eine weitere Einschränkung ist die hohe Wolkenbedeckung in der Arktis, die ein grobes Erfassungszeitfenster und eine hohe Wiederbesuchsrate des Satelliten nötig macht.

Auch Flugzeugerfassungen eignen sich für die Detektion von Plastikmüll. Zahlreiche Studien haben Strand- / und Meeresmüll mit Flugzeugen erfasst und die Daten sowohl visuell als auch (halb-) automatisch ausgewertet (Garaba et al. 2018, Garaba et al. 2018b, Moy et al. 2018, Pichel et al. 2012 and Garcia-Garin et al. 2019). Die visuelle Auswertung ermöglichte die Erfassung von Objekten der zehnfachen Pixelgröße. Garaba et al. 2018b beschreiben zudem eine mögliche

Erfassung von Plastikmüll über Wasser in Hyperspektralbildern. Eine (teil-) automatische Klassifikation ermöglicht eine Erfassung von Objekten im Sub-Pixel Bereich, die 5% eines Pixels abdecken und damit eine Erfassung von Objekten in der Größenordnung von 0,025 m x 0,06 m. Flugzeugetfassungen ermöglichen eine hohe räumliche Auflösung bei einer großen spektralen Abdeckung. Die größte Einschränkung sind jedoch die relativ hohen Kosten insbesondere für eine Arktis-weite Erfassung. Die Kosten beinhalten Instrumente, Flugzeug und Treibstoff, Mobilisierung und Personalkosten (Coulter et al. 2007). BCSH schätzt die räumliche Abdeckung einer Flugzeugetfassung pro Tag auf etwa 800 km Küstenlinie ein bei einer Flughöhe von 550 m. Dieser Wert ist als grobe Einschätzung zu verstehen und kann abhängig von den Küsteneigenschaften signifikant variieren.

Auch UAVs wurden bereits erfolgreich für die Erfassung von Strandmüll verwendet. Sowohl visuelle als auch (teil-) automatische Methoden kamen zum Einsatz, wobei (teil-) automatische Klassifikationen bisher nur über Sandstränden durchgeführt wurden (Martin et al. 2018, Bao et al. 2018). UAVs ermöglichen die höchste räumliche Auflösung der drei Methoden mit Auflösungen <1 cm im RGB und 3,4 cm für Multispektral Sensoren. Der Einsatz von Hyperspektral-Sensoren ist möglich, jedoch noch sehr kostenintensiv. Die geringen Kosten und die schnelle Durchführbarkeit einer Befliegung machen UAVs vor allem für kleinräumige Erfassungen und als Unterstützung konventioneller Strandmüllfassung interessant. Die größte Einschränkung sind die Kosten einer großflächigen Anwendung und die schwierige Anwendung in unzugänglichem Gelände. Weitere Einschränkungen sind Regen und starker Wind (>30 km/h)

Zusätzlich zu den drei Fernerkundungsplattformen wurde die Möglichkeit einer (teil-) automatischen Erfassung untersucht. Für eine Arktis-weite Erfassung von Strandmüll bieten sich Satellitendaten an und somit eine (teil-) automatische Erkennung auf Pixelebene anhand der spektralen Eigenschaften von Plastik. Garaba et al. (2020) haben die spektralen Eigenschaften von Plastik untersucht und charakteristische Wellenlängenbereiche identifiziert (um 931 nm, 1215 nm, 1417 nm und 1732 nm). Sensoren, die diese Bereiche abdecken, sind für eine (teil-) automatische Erkennung von Plastikmüll sehr geeignet. BCSH spricht sich nach vorausgegangener Literatursuche für die Kombination von mindestens zwei Plattformen aus, um von Synergieeffekten zu profitieren. Für diese Studie empfiehlt BCSH eine Kombination aus WorldView3 (WV3) Satelliten Daten und UAV-Aufnahmen eines MicaSense Altum-Sensors. Die Kombination aus flächendeckenden Satellitendaten mit hoher spektraler Abdeckung und UAV-Daten mit sehr hoher räumlicher Auflösung wird als vielversprechend angesehen.

In Arbeitspaket 2 haben AE und BCSH Daten zusammengestellt, die nötig sind, um potenzielle Ansammlungen von Strandmüll auf Grönland und Spitzbergen zu erkennen. Die benötigten Daten umfassen georeferenzierte Informationen zu Siedlungen, Häfen, Strömungen und Wind, sowie von Deponiegeländen und Müllverbrennungsanlagen. AE hat zudem georeferenzierte Daten im Format Shapefile zu Meteorologischen Stationen, Häfen und Siedlungen erstellt und die Daten zur Schifffahrt und Fischerei in der Arktis (ASTD) zu Gesamthäufigkeiten für West- und Ost-Grönland aggregiert. Im Anschluss hat AE eine statistische Analyse durchgeführt, um die Ursachen von Strandmüll Ansammlungen auf Grönland zu untersuchen.

Dafür wurde eine permutationale Analyse der Kovarianz (PERMANCOVA) berechnet. Als unabhängige Variablen wurden Fischerei, Einwohnerzahl, Entfernung zu Siedlungen, Entfernung zum nächsten Hafen und Übernachtungen gewählt. Die durchschnittliche Gesamtanzahl an Müll von OSPAR-Stränden auf Grönland wurde als abhängige Variable festgelegt. Die Ergebnisse zeigen, dass Normalität und Varianzhomogenität gegeben waren, jedoch eine Autokorrelation nicht endgültig ausgeschlossen werden konnte. Das Modell gilt somit als nicht, beziehungsweise wenig verzerrt („biased“). Das Bestimmtheitsmaß nimmt mit 0,83 einen sehr guten Wert an. Die Analyse ergibt einen signifikanten Einfluss von Fischerei und Tourismus auf das Aufkommen

von Strandmüll. Vor allem die Ergebnisse bezüglich Fischerei stehen in Übereinstimmung mit zahlreichen Studien, die auf den Einfluss von seebasierten Quellen auf Strandmüllansammlungen hinweisen (Bergmann et al. 2017, Kirkfeldt 2016, Tekmann et al. 2017). Weitere Hinweise auf erhöhte Mengen an Strandmüll geben Wind- und Strömungsdaten. Strände, die besonders exponiert gegenüber Strömungen und auflandigem Wind sind, weisen die höchsten Aufkommen von Strandmüll auf. Zudem scheint die Nähe zu größeren Städten einen Einfluss zu haben. Die Analyse ergibt, dass hohe Ansammlungen in der Nähe von Nuuk und Upernavik zu erwarten waren. Auf Spitzbergen dominieren östliche Winde. Somit wurden geringe Abundanzen an der Westküste erwartet. Große Mengen an Strandmüll wurden im Norden Spitzbergens festgestellt, an Stränden, die sehr gegenüber Wind und Strömung exponiert sind. (Bergmann et al., 2017).

BCSH hat zudem einen Modell-basierten Ansatz genutzt, um Küstenabschnitte auf Spitzbergen zu identifizieren, die eine hohe Wahrscheinlichkeit für Ansammlungen von Strandmüll aufweisen. Dafür wurden zwei Strömungsdatensätze mit unterschiedlicher räumlicher Auflösung verwendet. Monatliche Dichteverteilungen von Fischerei wurden als Grundlage genommen, um einen Datensatz von Plastikpartikeln auf See zu erstellen. Dabei wurde für jeden Monat eine zufällige Verteilung von Plastikpartikeln für Abschnitte je 100 km erstellt. Die monatlichen Datensätze dienten als Eingabedaten der Modelle. Ein Datensatz mit geringer räumlicher Auflösung, aber großer Flächenabdeckung wurde von der Marine Copernicus Website (<https://marine.copernicus.eu>) heruntergeladen und für eine Simulation der Verbreitungswege der Plastik Partikel benutzt. Des Weiteren dienten die Ergebnisse als Grundlage für das Modell mit einer hohen räumlichen Auflösung. Der Datensatz der Marine Copernicus Website hat eine räumliche Auflösung von 0.025° , eine räumliche Ausdehnung zwischen -10°W bis 60°E und von 55°N bis 90°N , und eine zeitliche Abdeckung von zwei Jahren, von August 2008 bis August 2010. Der zweite Datensatz stammt von der Homepage des Norwegian Meteorological Service (<https://api.npolar.no>) und hat eine hohe räumliche Auflösung, jedoch eine geringe Flächenabdeckung. Der Datensatz ist für die Jahre 2005 bis 2010 verfügbar und hat eine räumliche Auflösung von 800 m, deckt jedoch nicht das gesamte Fischereigebiet rund um Spitzbergen ab. Als Simulationszeit der Anwendung wurde für beide Modelle der Zeitraum zwischen August 2009 und August 2010 gewählt. Daten zu Wind und Wellen waren für das Untersuchungsgebiet in dem Untersuchungszeitraum nicht verfügbar und konnten deshalb nicht in diese Studie integriert werden.

Das Modell wurde mit OpenDrift v1.0 gerechnet, einer Open-Source-Python-basierten Anwendung für Lagrange-Partikelmodellierung, die oft zur Bestimmung von Verbreitungswegen schwimmender Objekte im Ozean verwendet wird (Dagestad et al. 2018). Auf Grund der fehlenden Wind- und Wellen-Daten wurde ein Unsicherheitsfaktor von 10% verwendet. Beide Modelle zeigten eine ähnliche Verteilung der gestrandeten Partikel mit einer hohen Strandungswahrscheinlichkeit an der südlichen und westlichen Küste von Spitzbergen. Ein lineares Regressionsmodell bestätigte die Übereinstimmungen der beiden Modelle mit einem Bestimmtheitsgrad (R^2) von 0,758., zeigte jedoch große Unterschiede an der südlichen Küste. Beide Modelle deuten auf eine hohe Wahrscheinlichkeit von Strandmüll-Ansammlungen an der Westküste Spitzbergens hin, was im Gegensatz zur Annahme von niedrigen Ansammlungen auf Grund der dominierenden Ost-Winde steht. Eine Erklärung kann die fehlende Windkomponente des Modells geben. Das im Zuge der Feldarbeit ermittelte Strandmüllvorkommen kann dazu dienen, die Modellergebnisse weiter zu verbessern und sollte in zukünftigen Anwendungen mit einbezogen werden. Für zukünftige Modelle empfiehlt BCSH zudem die Einbeziehung der Leeway-Konfiguration, die im Vergleich zu PlasticDrift eine genauere Modellkonfiguration für

große Plastikpartikel darstellt. Für die Anwendung der Leeway-Konfiguration werden jedoch Wind- und Wellendaten benötigt. BCSH empfiehlt zudem die Anwendung des Copernicus-Modells, das verglichen mit dem API-Modell zu ähnlichen Ergebnissen kommt und nicht auf die Jahre 2005 bis 2010 beschränkt ist. Zusätzliche Eingabeparameter wie Küsteneigenschaften (Strand oder Klippe), die Neigung des Strandes oder der Welleneinfallswinkel können das Modell weiter verbessern, übersteigen jedoch den Rahmen dieser Studie.

Die Expedition nach Spitzbergen dauerte vom 25. Juni, 2021 bis zum 17. Juli, 2021. Insgesamt wurden zwei 50 m-Abschnitte eines Strandes bei Kapp Mitra vollständig nach der OSPAR-Methode kartiert. Die Koordinaten wurden mittels eines hochauflösenden GPS bestimmt. Die Koordinaten einzelner Müllteile konnten mangels Zugangs zu Internet und Funk nicht gemessen werden. Während des Aufenthaltes auf Grönland wurden in der Nähe von Nuuk und Sisimiut Strandmüllerhebungen durchgeführt mit bis zu vier Replikat-Strandabschnitten. Die Anreise zu den ausgewählten Stränden erfolgte per Boot mit einem Bootsführer. Herkömmliche Erhebungen wurden nach der OSPAR-Methode (OSPAR, 2010) durchgeführt, wobei die aktuelle Kategorisierung von 2021 verwendet wurde. Die Kategorisierung wurde um Strandmülltypen ergänzt, die für die Westküste Grönlands charakteristisch sind. Diese neuen Mülltypen wurden aus dem Strietmann et al. (2021) abgeleitet und basieren auf der Aufteilung der OSPAR-Strandmülltypen, wie dies in ähnlicher Weise durch die Joint Category-List der Meeres-Strategie-Rahmenrichtlinie erfolgt ist. Power-Analysen für einseitige Wilcoxon-Rangsummentests mit einer Stichprobe wurden gerechnet, um abzuschätzen, wie lang Strandabschnitte sein müssen, um eine signifikante Verringerung der Strandverschmutzung um bis zu 10%, 20%, 30%, 40% und 50% zu erkennen. Hierfür wurde ein Signifikanzniveau von 0,05 verwendet.

Auf Spitzbergen lag die durchschnittliche Gesamtabundanz bei 28,5 Müllteilen pro 50 m Strand. Der Strandmüll bestand zu 57,9% aus Plastik, zu 40,4% aus Holz und zu 1,7% aus Gummi. Der hohe Plastikanteil stimmt gut mit den Ergebnissen früherer Strandmülluntersuchungen auf Spitzbergen überein (Bergmann et al., 2017). Unter den Top-14-Müllkategorien waren sechs eindeutig der Fischerei und der Schifffahrt zuzuordnen. Dadurch wird die Bedeutung von seebasierten Quellen hervorgehoben, was mit den Ergebnissen früherer Studien übereinstimmt (Bergmann et al., 2017; Weslawski und Kotwicki, 2018). In der Nähe von Nuuk und Sisimiut betrug die durchschnittliche Gesamtabundanz an Strandmüll $116,4 \pm 111,9$ Teile bzw. $87,3 \pm 33,5$ Teile auf einem 50 m langen Strandabschnitt. Dies lag in der gleichen Größenordnung, wie von Strietmann et al. (2021) an der Westküste Grönlands gefunden wurde. Die Materialzusammensetzung wurde von Plastik und verarbeitetem Holz dominiert, was wiederum mit den Ergebnissen von Strietmann et al. (2021) übereinstimmt. Unter den Top-Ten-Mülltypen waren solche am häufigsten, die eindeutig seebasierten Quellen zugeordnet werden können. Dieser Befund steht teilweise im Widerspruch zu den Ergebnissen von Strietmann et al. (2021), die feststellten, dass Hausmüll an der Westküste von Grönland überwiegt. Diese Unterschiede sind eventuell darauf zurückzuführen, dass die letztgenannten Autoren zum Teil in größerer Nähe zu Siedlungen kartierten als in der vorliegenden Studie. Die genauen Entfernungen zu Siedlungen sind in der Studie von Strietmann et al., 2021 jedoch nicht angegeben. Die Power-Analysen ergaben Teststärken $<50\%$ und $>80\%$ für Strände in der Nähe von Nuuk bzw. Sisimiut für eine Verringerung des Strandmülls um 50%. Bei niedrigeren Reduktionsraten war die statistische Teststärke noch geringer und damit nicht ausreichend. Kartierte Strandabschnitte sollten daher eine Mindestlänge von 200 m aufweisen, wie anhand der Poweranalysen an Daten von vier 50 m-langen Strandreplikaten in der Nähe von Sisimiut gezeigt werden konnte. Aus

logistischer Sicht unterstützt dies wiederum den Einsatz von Fernerkundungsdaten für Strandmüllerhebungen auf Grönland.

Um das Potenzial von Fernerkundungstechniken für Strandmüllerfassungen in der Arktis zu untersuchen, wurden Drohnen- und Satellitenbilder erfasst bzw. erworben.

Für die Drohnenerfassung wurde eine WingtraOne Drohne mit zwei Sensoren benutzt, die Sony QX1 (RGB) und die Micasense Altum (VIR) mit einer *ground sample distance* GSD von 1,4 cm bzw. 3,4 cm. Die Drohnenflüge fanden im Vorfeld des OSPAR Monitorings statt, damit Müllobjekte nicht versehentlich bewegt oder verschüttet werden. Insgesamt wurden acht Untersuchungsgebiete befliegen, zwei auf Spitzbergen und sechs auf Grönland. Die dabei erfassten Flächen umfassten zwischen 1,31 ha und 33,85 ha. Es fanden pro Gebiet mindestens zwei Flüge, eine pro Sensor, statt. Die Flugzeit pro Untersuchungsgebiet lag zwischen 06:56 und 59:26 Minuten, wobei zwischen 108 und 1877 Bilder aufgenommen wurden. Die einzelnen Bilder wurden mit Hilfe von *post-processed kinematics* (PPK) zentimetergenau georeferenziert. Anschließend wurden in der Photogrammetrie-Software Pix4D mapper Version 4.6.4 Höhenmodelle, Orthofotos und Indexkarten erstellt. Die Orthofotos des RGB Sensors wurden in einer GIS-Umgebung (QGIS version 3.16.6.) mit einem Maßstab von 1:20 manuell gesichtet, wobei alle gefundenen Müllobjekte als Polygone markiert wurden. Insgesamt wurden zwischen 0 und 63 Müllobjekte erfasst. Im Vergleich zur OSPAR Erfassung wurden im Mittel 14,8% der Müllobjekte gefunden mit einem Maximalwert von 24%. Frühere Studien zur Strandmüllerfassung mit Drohnen konnten zwischen 18% (Merlino et al., 2020) und nahezu 100% der Müllobjekte detektieren (Andriolo et al., 2020; Escobar Sánchez et al., 2021; Gonçalves et al., 2020b). Für die große Variabilität wurden drei Faktoren identifiziert, die auch für die vergleichsweise niedrige Erfassungsrate in dieser Studie verantwortlich sein können: Die Größenverteilung der Müllobjekte, Strand- und Umgebungsparameter und die GSD der Drohnenbilder. Je kleiner Müllobjekte sind, desto schwieriger ist es, sie auf den Drohnenbildern zu erkennen. Deshalb ist die Erfassungsrate von Müllobjekten stark abhängig von der Größenverteilung der Müllobjekte vor Ort (Martin et al., 2018; Merlino et al. 2020; Lo et al., 2020). Auf den Drohnenbilder der erfassten Strände in der Arktis wurden zu einem Großteil (> 70%) Müllobjekte gefunden, die größer als 10 cm waren, was die Schwierigkeit der Erfassung kleinerer Objekte bestätigt. Des Weiteren wird die manuelle Sichtung erheblich durch das Strandsubstrat (sandig oder steinig) und die Heterogenität (Vorkommen von Vegetation, Holz oder Steinen) beeinflusst. Die Strände auf Grönland und Spitzbergen waren zum Großteil heterogen mit farbigen Steinen, Vegetation und Treibholz, die alle mit Müllobjekten verwechselt werden konnten. Merlino et al. (2020) beschrieb ähnliche Schwierigkeiten bei der Erfassung kleiner Müllobjekte auf heterogenen Stränden, selbst bei einer GSD von 0,18 cm. Der dritte Parameter, die GSD ist der Einzige, der direkt beeinflusst werden kann und hängt maßgeblich von dem verwendeten Sensortyp und der Flughöhe ab. Ein niedriger GSD-Wert verringert die Minimalgröße eines Objektes, die notwendig zur deren Erfassung ist, kann aber auch zu einer niedrigeren Flächenabdeckung führen.

Die während der manuellen Sichtung erfassten Objekte wurden zur Erstellung einer Dichtekarte verwendet und dienten als Referenz für die Auswertung der WV3 Satellitenbilder. Außerdem wurden sie benutzt, um verschiedene Anwendungen des Maschinellen Lernens (*Random Forest*, *Support Vector Machine*, *Neural Networks*) zu trainieren und zu validieren. Die besten statistischen Ergebnisse wurden mit Random Forest und VIR-Drohnenbildern erzielt und ergaben eine Gesamtgenauigkeit (OA) von 90,6% bei einem F-score von 77%. Die dazugehörige Benutzergenauigkeit (UA) betrug 81,5%. Vor allem Steine und Holz wurden häufig fälschlicherweise als Plastik klassifiziert. Da das Müllvorkommen deutlich kleiner als das Vorkommen von Steinen und Holz war, führte schon ein geringer Prozentsatz an falsch bestimmten Steinen und Holz zu einer erheblichen Überschätzung von Plastikmüll. Die

Schwierigkeit der Algorithmen, Plastik von Steinen und Holz auf Basis der spektralen Eigenschaften zu unterscheiden, wurde durch einen Vergleich der jeweiligen spektralen Kurven bestätigt. Vergleicht man nur die statistischen Ergebnisse der Klassifikationsgenauigkeit mit früheren Studien, konnten trotz größerer GSD und heterogeneren Stränden, vergleichbare Ergebnisse erzielt werden (Falatti et al., 2019; Gonçalves et al., 2020a,b,c; Papakonstantinou et al., 2021; Wolf et al., 2020).

Diese Studie bestätigt das große Potential (halb-) automatischer Klassifikationsmethoden für eine zeit- und kosteneffiziente, großflächige Erfassung von Strandmüll in der Arktis mit Hilfe von Drohnenbildern. Trotz der vielversprechenden statistischen Ergebnisse müssen diese jedoch stets durch die Ergebnisse der Klassifikationskarten bestätigt werden. Die Ergebnisse der Drohnen-gestützten Klassifikation in der Arktis zeigen dabei eine starke Überschätzung des Plastikvorkommens. Anhand der spektralen Eigenschaften des Drohnensensors war es nicht möglich, alle vorkommenden Materialien voneinander zu unterscheiden (u.a. Plastik, Holz und Steine). Daher muss die spektrale Abdeckung der Sensoren erweitert, oder andere Strukturparameter mit einbezogen werden. Die Anwendung von Objekt-basierten Klassifikationsmethoden könnte die Unterscheidbarkeit von Holzobjekten und Plastik verbessern, benötigt jedoch eine bessere GSD. Auch Verfahren der automatischen Bildererkennung sind vielversprechend, sie benötigen jedoch auch eine niedrigere GSD und eine sehr große Anzahl an Trainingsdaten. Neben einer Mülldetektion sollte langfristig auch eine Identifikation der Strandmüllobjekte angestrebt werden. Bisher wurde eine solche nur durch Wolf et al. (2020) mit Hilfe von Bilderkennungstechniken erprobt. Für eine Integration in bestehende Monitoring Programme ist die Identifikation der erfassten Müllobjekte jedoch essenziell und sollte mit einem Fokus auf die Arktis-spezifischen Anforderungen (die benötigte Flächenabdeckung und dadurch limitierte GSD, die Strandparameter und die Größenverteilung der Müllobjekte) weiter erprobt werden.

Für die Erprobung von Satellitenbildern wurden WV3-Bilder zwei bis acht Tage vor der Feldarbeit aufgezeichnet. Die erfassten Satellitenbilder erstrecken sich über eine Fläche von bis zu 7500 ha bei einer Küstenlänge von bis zu 23 km. Die WV3 Bilder deckten dabei acht spektrale Bänder im sichtbaren bis NIR Bereich mit einer Auflösung von 1,2 m und acht Bänder im SWIR Bereich mit 3,7 m Auflösung ab. Da die vorkommenden Plastikobjekte im Sub-Pixel Bereich lagen, war eine manuelle Sichtung nicht möglich. Stattdessen wurde untersucht, ob Müllansammlungen mit Hilfe der spektralen Eigenschaften detektiert werden können. Die Dichtekarten der manuellen Drohnensichtung wurden als Referenzdaten genutzt, und die spektralen Eigenschaften der vorkommenden Materialien wurden untersucht. Die Dichtekarten dienten des Weiteren dazu die Plastikabdeckung der einzelnen Pixel zu bestimmen. Unter Einbezug aller Pixel mit einer Auflösung von 1,2 m, die ein Plastikvorkommen aufwiesen, wurden 95% bzw. 74% (Spitzbergen bzw. Grönland) dieser von weniger als 5% Plastik abgedeckt. Insgesamt wurden lediglich 13 Pixel identifiziert, die eine Plastikabdeckung von mehr als 30% aufweisen (1x Spitzbergen und 12x Grönland). In den WV3 SWIR Bildern (Auflösung von 3,4 m) wurden sieben Pixel identifiziert, die mehr als 10% Plastik enthielten bei einer maximalen Abdeckung zwischen 20% und 30%. Vorherige Studien zu schwimmendem Meeresmüll zeigten, dass Müllobjekte, die bis zu 30% - 55% eines Pixels abdeckten, auf Sentinel 2-Satellitenbildern erkannt werden konnten (Biermann et al., 2020; Topouzelis et al., 2019). Sentinel 2 weist dabei eine ähnliche spektrale Abdeckung wie WV3 auf mit 12 Bändern vom sichtbaren bis zum kurzwelligen-Infrarot (SWIR) Bereich. Garaba et al. (2018b) beschrieben zudem eine Sub-Pixel Erfassung von Plastikmüll über offenem Wasser für Objekte, die bis zu 5% eines Pixels abdecken. Dies erfolgte jedoch unter Verwendung einer höheren spektralen Abdeckung mit Hilfe eines Hyperspektralsensors. Die bisher einzige publizierte Erfassung von Strandmüll mit Hilfe von Satellitenbildern wurde von Acuña-Ruz et al. (2018)

durchgeführt. Die Autoren verwendeten WV3 Bilder für eine (halb-) automatische Erfassung von Plastikmüll auf Pixelebene und konnten Müllobjekte in einer Größenordnung von ca. 1 m² mit einer Gesamtgenauigkeit (OA) von 88% erfassen.

Die Erfassung von Strandmüll auf Sub-Pixel Ebene durch spektrales Entmischen der WV3 Bilder war in dieser Studie nicht erfolgreich. Beim spektralen Entmischen soll der Anteil der einzelnen Referenzmaterialien innerhalb eines Pixels identifiziert werden, indem der Prozentsatz der jeweiligen spektralen Signale am Gesamtsignal des Pixels identifiziert wird. Im Gegensatz zu Studien, die Meeressmüll erfasst haben, waren die Hintergrundsignale der Strände zu komplex (u.a. Vegetation, Sand, Steine und Holz), und die Größe der Müllobjekte sowie die Mülldichte waren zu gering. Bei Einbezug der SWIR Bilder konnte eine Sub-Pixel Abdeckung von 30% - 55% wie in Biermann et al. (2020) and Topouzelis et al. (2019) nicht erreicht werden. Verglichen zu Garaba et al. (2018b) scheint die spektrale Abdeckung nicht groß genug gewesen zu sein, um Sub-Pixel mit bis zu 5% Plastikabdeckung zu erkennen. Für eine Klassifikation auf Pixelebene, wie in Acuña-Ruz et al. (2018) beschrieben, waren die Größe der Müllobjekte sowie die Mülldichte zu gering.

In dieser Studie wurde die Anwendung von Fernerkundungsmethoden zur Erfassung von Strandmüll in der Arktis untersucht. Die Ergebnisse zeigen dabei ein großes Potenzial für Drohnenerfassungen. Die Anwendung eines VIR-Sensors wurde erfolgreich erprobt und es konnte damit eine höhere Gesamtgenauigkeit (OA) im Vergleich zur Anwendung von RGB Bildern erreicht werden, obwohl die GSD der RGB-Bilder niedriger war. Dennoch stellen die Größenverteilung der vorkommenden Müllobjekte, die heterogene Strandumgebung, sowie die geforderte hohe Flächenabdeckung eine große Herausforderung dar. Neben der reinen Erfassung von Müllobjekten muss in Zukunft zudem ein Fokus auf der Identifikation der Objekte liegen. Diese benötigt jedoch eine stark verbesserte GSD und eine große Anzahl an Trainingsdaten. Eine Erfassung von Strandmüllansammlungen mit Hilfe von Satellitenbildern ist auf Grund der räumlichen Auflösung stark eingeschränkt. Die Größe der in Grönland und Spitzbergen vorkommenden Müllobjekte sowie die Mülldichte waren zu gering, um diese auf WV3 Satellitenbildern zu erkennen. Eine höhere räumliche Auflösung oder eine größere spektrale Abdeckung wären erforderlich, um auch geringere Müllansammlungen an Stränden mit Hilfe von Satelliten zu erkennen.

Die Auswertung der Drohnen Daten auf Spitzbergen und Grönland haben gezeigt, dass die Zeit, die für eine großflächige Erfassung von Strandmüll benötigt wird, durch den Einsatz von Drohnen um bis zu 22-fach reduziert werden kann im Vergleich zu einer Strandmüllfassung nach OSPAR. Für kleine Flächen, wie ein einzelnes 50 m Transekt, kann eine Erfassung nach OSPAR jedoch schneller sein. Grund dafür ist die Zeit, die für die Datenprozessierung benötigt wird. Trotzdem können Drohnenaufnahmen auch zur Erfassung kleiner Gebiete von Vorteil sein, da die Strände in der Arktis oft abgelegen sind und die Zeit an den Stränden begrenzt sein kann. Satellitenbilder ermöglichen eine hohe Flächenabdeckung, wie sie in der Arktis benötigt wird. Jedoch müssen die Kosten der Datenerfassung weiter gesenkt werden, um eine kosteneffiziente und großflächige Anwendung in Zukunft zu ermöglichen.

1 Einleitung

In den letzten Jahrzehnten ist die Verschmutzung der Meere durch Müll weltweit zu einem großen Umweltproblem geworden. Zahlreiche Studien, die in Meeresgebieten durchgeführt wurden, haben sich auf zeitliche und räumliche Trends anthropogener Meeresabfälle konzentriert, insbesondere auf Plastikmüll (Browne et al., 2010; Galgani et al., 2000; Howell et al., 2012; Ribic et al., 2010). Meeresmüll hat negative Auswirkungen auf Meerestiere, indem sich Wirbeltiere und wirbellose Meerestiere in weggeworfenen und verlorenen Fanggeräten und anderen Kunststoffabfällen verfangen (Bullimore et al., 2001; Fowler, 1987; Gregory, 2009; Matsuoka et al., 2005; Pichel et al., 2012; Votier et al., 2011) sowie durch die Nahrungsaufnahme von Mikro- und Mesoplastik (Browne et al., 2008; van Franeker et al., 2011). Aufgrund ihrer Persistenz und der damit verbundenen langen Lebensdauer können Treibgutgegenstände auch als Vektor für invasive Arten dienen (Barnes und Fraser, 2003; Barnes und Milner, 2005; Majer et al., 2012). In mehreren internationalen Abkommen zum Schutz der Meere ist Strandmüll zu einem Indikator für die Gesamtverschmutzung der Meeresgewässer durch Müll geworden (OSPAR, 1992, MSFD, 2008, 2010). In der Vergangenheit wurden mehrere Methoden entwickelt, um die Menge an Strandmüll zu quantifizieren (Alkalay et al., 2007; Bravo et al., 2009; Cheshire et al., 2009; Opfer et al., 2012; OSPAR, 2010). Diese Verfahren erfordern die Anwesenheit von Kartierenden an Stränden, die auf Müll untersucht werden sollen, und sind daher in abgelegenen Gebieten, wie z.B. an arktischen Küsten, die für Strandbesucher kaum zugänglich sind, nicht effizient oder praktikabel. Das vorliegende Projekt wurde begonnen, um diese Problematik zu adressieren und die Möglichkeit einer arktisweiten Überwachung von Strandmüll unter Verwendung von Fernerkundungstechniken zu untersuchen.

Dieses Projekt gliedert sich in vier Arbeitspakete:

- ▶ Arbeitspaket 1: Literaturrecherche zu möglichen Verfahren zur Erkennung von Strandmüll, einschließlich fernerkundungsbasierter Techniken
- ▶ Arbeitspaket 2: Identifizierung potenzieller Hotspots für die Ansammlung von Strandmüll
- ▶ Arbeitspaket 3: Test und Validierung der entwickelten Methodik an ausgewählten Stränden mit hohem Strandmüllaufkommen
- ▶ Arbeitspaket 4: Teilnahme an wissenschaftlichen Konferenzen

In diesem Projekt wurden Fernerkundungstechniken zur Quantifizierung von Strandmüll entwickelt und an Strandabschnitten auf Grönland und Spitzbergen getestet. Dazu mussten zunächst Strände mit hohem Strandmüllaufkommen identifiziert und ausgewählt werden, um eine ausreichend hohe Anzahl an Müllteilen zu gewährleisten, die für das Training und Testen von Algorithmen zur automatischen Bilderkennung und Landnutzungsklassifikation notwendig sind.

In Arbeitspaket 1 führte BioConsult SH & Co. KG (BCSH) eine Literaturrecherche zu Fernerkundungstechniken zur Detektion von Plastikmüll an arktischen Stränden durch, wobei die drei Hauptplattformen Satellit, Flugzeug und Drohne (UAV) miteinander verglichen wurden. Abschließend gab BCSH eine Empfehlung für die in dieser Studie anzuwendende Methode.

In Arbeitspaket 1 und 2 hat AquaEcology GmbH & Co. KG (AE) geeignete Strandabschnitte auf Grönland und Spitzbergen identifiziert. Daten zu Strandmüllmengen aus früheren Studien sowie Informationen über die treibenden Variablen im Zusammenhang mit einer möglichen Anreicherung von Strandmüll, wie Daten zu Wind, Strömungen, Siedlungen, Häfen, Tourismus,

Fischerei und Schifffahrtsaktivitäten wurden erhoben und für diesen Zweck verwendet. Diese Daten wurden als Eingabevariable für ein statistisches Modell verwendet, das die Unterschiede der Gesamthäufigkeit von Strandmüll an der Küste Grönlands erklärt. BCSH führte einen Modellierungsansatz als zusätzlichen Indikator für Bereiche mit potenzieller Ansammlung von Strandmüll durch; zwei Modelle wurden für das Gebiet rund um Spitzbergen angewandt. Neben dem Hauptziel der Identifizierung potenzieller Hotspots zielte das Modell darauf ab, die wichtigsten Eingabeparameter zu identifizieren, die zur Vorhersage der Müllansammlung erforderlich sind, und zu vergleichen, wie unterschiedliche Modellauflösungen die Modellergebnisse beeinflussen.

In Arbeitspaket 3 führten AE und BCSH mit Unterstützung von Orbicon Arctic (OA) und dem Norsk Polar Institute (NP) an ausgewählten Strandabschnitten Strandmüllerhebungen durch. Parallel dazu wendete BSCH Fernerkundungstechniken an, indem Drohnen- und Satellitenbilder für verschiedene Strandabschnitt aufgenommen worden. Schließlich wurden die Fernerkundungstechniken anhand der Ergebnisse der Strandmüllerhebungen kalibriert und validiert. Aufgrund der vorliegenden Covid-19-Situation wurde die geplante Feldarbeitssaison 2020 in den Sommer 2021 verschoben.

2 Arbeitspaket 1

2.1 Konventionelles Strandmüll-Monitoring

2.1.1 Methoden

AE hat eine Literaturstudie zu Methoden zur Überwachung von Strandmüll weltweit und in der Arktis durchgeführt. Strandmülldaten wurden von Bergmann et al. (2017) sowie von Weslawski und Kotwicki (2018) entnommen. Aus diesen Daten wurden georeferenzierte Shapefiles generiert. Darüber hinaus wurden OSPAR-Strandmülldaten von Island, Spitzbergen und Grönland von der online-OSPAR-Strandmülldatenbank (<https://www.mcsuk.org/ospar/>) heruntergeladen. Deskriptive Statistiken zu OSPAR-Strandmülldaten wurden mit der Open-Source-Software R (<https://cran.r-project.org>) berechnet. Während Strandmülldaten aus dem Internet heruntergeladen und Veröffentlichungen entnommen wurden, wurden Informationen zu potenziellen Verursachern von Strandmüll teilweise von den Projektpartnern Orbicon Arctic A/S (OA) und dem Norsk Polar Institute (NP) bereitgestellt.

2.1.2 Ergebnisse und Diskussion

2.1.2.1 Bestehende Monitoring-Protokolle für Strandmüll

Weltweit gibt es eine Reihe unterschiedlicher Methoden zur Überwachung von Strandmüll, wie z. B. die von Alkalay et al. (2007), Bravo et al. (2009), Cheshire et al. (2009), Opfer et al. (2012) und OSPAR (2010).

Alkalay et al. (2007) erfassten ausschließlich Plastikteile und kartierten Transekte senkrecht zur Strandlinie. Als Grundlage für einen einfachen Strandverschmutzungsindex wurde die Menge an Plastikteilen mit einer Größe von mehr als 2 cm gewählt. Die Kartierungen werden alle zwei Wochen durchgeführt. Um eine optimale Charakterisierung der Strandverschmutzung zu erreichen, werden Transekte von 10 m Breite untersucht. Es wird davon ausgegangen, dass 10-m-Transekte die Verschmutzung des Strandes zuverlässig darstellen. Um das Zählverfahren zu erleichtern, werden Transekte in 5 Streifen von 2 m Breite unterteilt. Strände werden morphologisch als Segmente definiert, die jeweils durch die gleichen Strandeigenschaften gekennzeichnet sind (sandig/kiesig, schmal/breit, offen/von Klippen begrenzt usw.). Um Verzerrungen auszuschließen, wird der genaue Untersuchungsort nicht festgelegt. Die Kartierenden wählen ihn nach dem Zufallsprinzip aus, bevor sie den Strand betreten (z. B. durch Auswahl einer Anzahl von Schritten). Sobald der Standort erreicht ist, wird dieser Abschnitt als repräsentativ für die Strandverschmutzung angenommen. Die Strandmüllsdichte wird in [Teile/m²] angegeben. Die Ergebnisse für das Auftreten von Müll an den Küsten werden wie folgt bewertet:

- ▶ 0–0,1 Teile/m² – sehr sauber – kein Müll zu sehen,
- ▶ 0,1–0,25 Teile/m² – sauber – großflächig kein Müll zu sehen,
- ▶ 0,25–0,5 Teile/m² – moderat – einige Müllteile sind zu erkennen,
- ▶ 0,5–1 Teile/m² – schmutzig – viel Müll am Ufer,
- ▶ Mehr als 1 Teil/m² – extrem schmutzig – der größte Teil des Ufers ist mit Plastikmüll bedeckt.

Bravo et al. (2009) kartierten zufällig ausgewählte Strände entlang der chilenischen Küste. Diese Autoren verwendeten die Dichte pro Quadratmeter als Verschmutzungsindikator und stellten fest, dass Plastikteile und Zigarettenskippen die am häufigsten vorkommenden Strandabfälle sind. Die meisten der bisher untersuchten Orte waren Sandstrände, aber einige waren auch Kiesstrände; felsige Ufer wurden nicht kartiert. Mehrere Transekte werden vermessen. Diese Transekte verlaufen senkrecht zur Küstenlinie, d.h. von der Niedrigwasserlinie bis zum Dünenfuß. Auf jedem Transekt werden mindestens zwei Stationen kartiert (zwischen zwei und sechs Stationen, je nach Breite des Strandes). Jede Station umfasst eine Fläche von 3 m x 3 m, die durch Seile oder ein Maßband begrenzt wird. Alle Arten von Strandabfällen innerhalb dieser 9 m² werden gezählt und klassifiziert. Bei Bravo et al. (2009) werden keine Angaben zur Kategorisierung von Abfällen gemacht. Die Mengen an Strandabfällen werden als Dichten [m⁻²] angegeben.

Ähnlich wie bei der OSPAR-Methode (2010), erfolgt bei Cheshire et al. (2009) die Strandauswahl nach Kriterien wie Zugänglichkeit, Strandreinigungsaktivitäten und Nachbarschaft zu potenziellen Quellen. Die grundlegende Stichprobeneinheit für Strandmüllerhebungen ist ein Strandsegment. Die Kartierenden untersuchen dieselben Stichprobeneinheiten über einen längeren Zeitraum (z.B. alle drei Monate über einen Zeitraum von fünf oder mehr Jahren). Es werden Probenahmeinheiten von 100 – 1000 m empfohlen. Bei allgegenwärtigen Gegenständen wie Zigarettensmüll können auch kleinere Probenahmeinheiten verwendet werden, die jedoch nicht Teil der Standardmethodik sind. Diese Untereinheiten sollten 10 m breite Streifen von der Wasserlinie bis zur Rückseite des Strandes sein. Die Mindestfrequenz der Probenahme sollte jährlich sein. Es wird empfohlen, die Standorte alle drei Monate zu kartieren. Cheshire et al. (2009) empfehlen die Verwendung von Fluxraten (d.h. Nettoablagerungsraten [d-1 m⁻²]) von 77 Müllarten als Maß für die Verschmutzung.

Das Verfahren von Opfer et al. (2012) stützt sich auf eine zufällige Auswahl von Strandtransekten und unterscheidet insgesamt 43 Müllarten. Diese Methode erfordert mehrere Kriterien für die Strandauswahl, wie Substrat, Zugänglichkeit, Mindestlänge und Reinigungsaktivitäten. Opfer et al. (2012) unterscheiden Akkumulationserhebungen und Bestandserhebungen. Für Akkumulationserhebungen wird empfohlen, die Kartierung bei Ebbe durchzuführen. Um das gesamte Gelände von der Wasserkante bis zur Rückseite der Küstenlinie abzudecken, sollten die Kartierenden den Strand parallel oder senkrecht zum Wasser durchqueren. Sie sollten den Strand in einem vorher festgelegten Laufmuster durchqueren, bis das gesamte untersuchte Gebiet von Strandmüll gereinigt ist. Bei der Erfassung der Mülldichte werden Teile berücksichtigt, die in der längsten Dimension über 2,5 cm lang sind. Für die Kartierungen ist es vorgeschrieben, Abschnitte von 100 m Länge in 5-m-Transekte zu unterteilen. 20 Transekte werden kartiert. Jedes 5-m-Transekt sollte von der Wasserkante bis zur Rückseite der Küstenlinie verlaufen. Unter den 20 Transekten werden vier nach dem Zufallsprinzip für Feldstudien ausgewählt. Bei den Kartierungen wird kein Müll vom Strand entfernt.

Die detailliertesten Richtlinien und Kategorisierungen zur Überwachung von Strandmüll finden sich in OSPAR (2010). An 129 Strandabschnitten von 100 m Länge, die an die Nordsee und den Nordostatlantik grenzen, werden seit 2001 in regelmäßigen Abständen von drei Monaten Strandmüllerhebungen mit einer Kategorienliste von 121 Müllarten durchgeführt. Ein Teil der OSPAR Strandmüll-Datenbank wurde von Schulz et al. statistisch ausgewertet. (2013, 2015a, 2015b, 2017, 2019). Diese Autoren machten einen ersten Vorschlag für ein Bewertungssystem, das sowohl auf Häufigkeiten als auch auf Trends von Strandmüllarten und übergeordneten Kategorien basiert. In der OSPAR Intersessional Correspondence Group Marine Litter (ICG ML) führte die Diskussion um eine geeignete Bewertungsmethode zu der von Schulz et al. (2017, 2019) vorgeschlagenen Methode.

Im Einzelnen werden OSPAR-Strandmüllerhebungen wie folgt durchgeführt, wobei die in das Monitoringprogramm aufgenommenen Strände nach den unten aufgeführten Kriterien ausgewählt werden:

- ▶ Aus Sand oder Kies bestehend und dem offenen Meer ausgesetzt,
- ▶ Ganzjährig für Kartierende zugänglich,
- ▶ Entfernung von Strandmüll ist leicht möglich,
- ▶ Eine Mindestlänge von 100 Metern und wenn möglich über 1 km Länge,
- ▶ Ganzjährig frei von „Gebäuden“,
- ▶ Idealerweise keiner anderen Müllsammlung unterworfen.

In arktischen Regionen ist die Zugänglichkeit von Stränden jedoch auf die Sommersaison beschränkt. Idealerweise werden Erhebungen im Abstand von etwa drei Monaten im Winter (Mitte Dezember–Mitte Januar), Frühjahr (April), Sommer (Mitte Juni–Mitte Juli) und Herbst (Mitte September–Mitte Oktober) durchgeführt. Bei den Kartierungen wird die Häufigkeit von makroskopischem Strandmüll (Teile > 2,5 cm in ihrer längsten Dimension) auf standardmäßigen 100-m-Strandabschnitten entlang der Küste erfasst. Der gesamte Müll wird gesammelt und während der Untersuchung aus dem kartierten Bereich entfernt.

Auf der Ebene einzelner Müllkategorien werden Daten über die Menge an Müll an einem bestimmten Küstenabschnitt erfasst. Mülltypen sind identifizierbare Müllteile wie Plastikflaschen, Tetrapak-Behälter, Getränkedosen aus Metall, Gummihandschuhe usw. Jedes Müllteil wird einem von 121 verschiedenen Mülltypen zugeordnet. Darüber hinaus werden Mülltypen nach ihrem Material (z. B. Kunststoff/Styropor, Gummi, Stoff/Textil, Papier/Karton, Holz, Metall, Glas und Keramik) oder ihrer Verwendung (Hygiene) in verschiedene Kategorien eingeteilt. Weiterhin wird jedem Mülltypen ein bestimmter Verwendungszweck zugeordnet, z.B. Verpackung, Gebrauchsgegenstand, Konsum und Industrie.

Weltweit gibt es mehrere Methoden der Strandmüllerhebung. Europäische Länder und Grönland wenden die OSPAR-Methode an, während in den Vereinigten Staaten das Protokoll von Opfer et al. (2012) angewendet wird. In Kanada wird das Protokoll von Cheshire et al. (2009) verwendet.

Der Hauptvorteil des Protokolls von Alkalay (2007) ist seine Einfachheit, die seine Anwendung in Citizen-Science-Projekten ermöglicht. Dies gilt auch für das Protokoll von Bravo et al. (2009). Das Fehlen einer detaillierten Kategorisierung einschließlich Angaben zu Zweck und Quelle ist jedoch nachteilig. Der Hauptvorteil des Protokolls von Opfer et al. (2012) ist die Unterteilung in Bestandserhebungen und Akkumulationserhebungen. Es werden jedoch keine Angaben zur Erhebungsfrequenz gemacht und bei den Kategorisierungen fehlen die Zuordnung zu Quellen und Zwecken. Unter den fünf vorgestellten Protokollen verfügen die von Cheshire et al. (2009) und OSPAR (2010) über die detailliertesten Kategorisierungen, die eine Quellenzuordnung von Strandmüll ermöglichen. Darüber hinaus enthalten diese beiden Protokolle detaillierte Vorschriften für die Auswahl der Standorte und die Frequenz der Erhebungen.

Die Projektpartner einigten sich auf die Verwendung der OSPAR-Methode (2010), die unter den oben beschriebenen Methoden die detaillierteste Kategorisierung aufweist. Die OSPAR-Erfassung ist standardisiert, genauso wie die Auswertung und Bewertung der erfassten OSPAR-Strandmülldaten (Schulz et al., 2017, 2019). Das OSPAR-Protokoll ist weit verbreitet und wurde auch von anderen regionalen Meereskonventionen wie der Kommission für den Schutz der Meeresumwelt der Ostsee (Helsinki-Kommission, HELCOM) und der Barcelona-Konvention

übernommen. Innerhalb der EU basiert die weitere Verfeinerung der Strandmüllkategorisierung zu einer gemeinsamen Kategorienliste auf der OSPAR-Kategorisierung. Das OSPAR-Protokoll wurde zudem in der Vergangenheit auf Grönland und Spitzbergen bereits angewendet. Somit sind die Ergebnisse der geplanten Erhebungen mit historischen Daten vergleichbar. Tabelle 1 gibt einen Überblick über die bestehenden Methoden zum Monitoring von Strandmüll.

Tabelle 1: Überblick über bestehende Protokolle zum Monitoring von Strandmüll

Methoden	Auswahl an Stränden	Kategorisierung	Gemessener Parameter	Datenauswertung
Alkalay et al. (2007)	Keine Angaben gemacht	Kunststoffe und Nicht-Kunststoffe	Dichte pro Quadratmeter	Index der Strandverschmutzung
Bravo et al. (2009)	Nach dem Zufallsprinzip	Einfache Kategorisierung	Dichten pro Quadratmeter	-
Cheshire et al. (2009)	Stratifizierte Zufallsauswahl von Stränden	77 Kategorien	Netto-Ablagerungsraten	-
Opfer et al., (2012)	Stratifizierte Zufallsauswahl von Transekten	43 Kategorien	Abundanzen	-
OSPAR (2010)	Stratifizierte Zufallsauswahl von Strandabschnitten	121 Einzelkategorien, 8 Materialkategorien und weitere Zweck- und Verwendungskategorien	Abundanzen	Schulz et al. (2017, 2019)

2.1.2.2 Identifizierung von Hotspots von Strandmüll auf Grönland und Spitzbergen

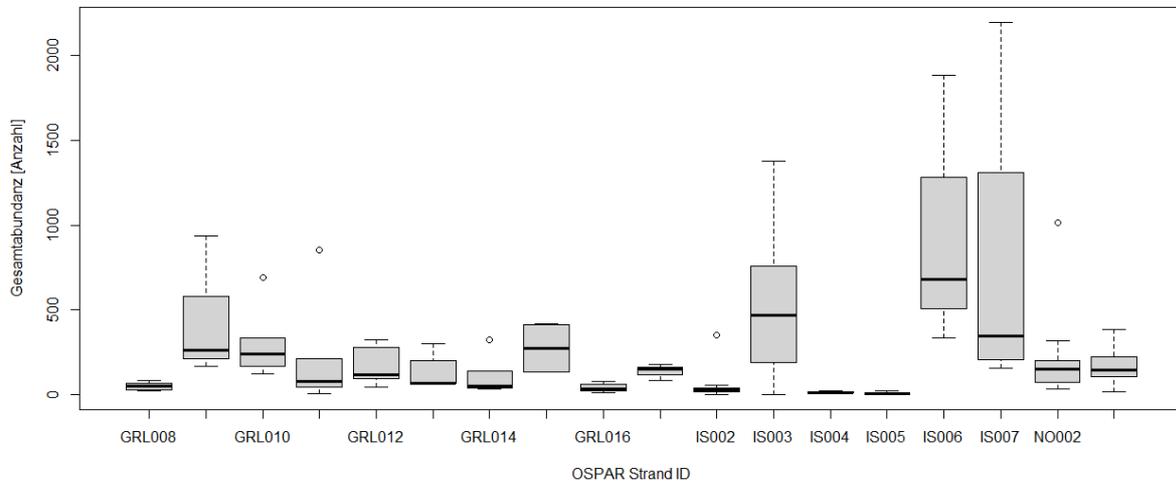
Zwischen 2016 und 2019 schwankte die durchschnittliche Gesamthäufigkeit von Strandmüll an 17 OSPAR-Stränden auf Grönland von einem Müllteil in abgelegenen Gebieten an der Ostküste bis zu mehr als 800 Müllteilen am Strand von Upernavik an der Westküste (Abbildung 1, Abbildung 2, A.1). An den beiden OSPAR-Stränden auf Spitzbergen waren die mittleren Gesamtmengen an Strandmüll im gleichen Zeitraum weniger variabel als auf Grönland und lagen in der Größenordnung von ca. 200 Müllteilen pro 100 m Strandabschnitt.

Auf Spitzbergen wurden die von Weslawski und Kotwicki (2018) erhobenen Gesamtmengen an Strandmüll in [Teile ha⁻¹] angegeben, mit maximal elf Teile ha⁻¹ (Abbildung 3). Mengen an Strandmüll aus Bergmann et al. (2017) reichten von 9 bis 524 g m² (Abbildung 3). Die unterschiedlichen Einheiten von Strandmüll erschweren den Vergleich zwischen den Datensätzen erheblich. Standardisierungen der Strandmüllmengen konnten nur für jeden Datensatz separat vorgenommen werden (Abbildung 3). Allerdings waren die Mengen an Strandmüll an der Nordküste tendenziell höher als an der Westküste von Spitzbergen. Über die Menge an Strandmüll im südlichen und östlichen Teil von Spitzbergen liegen keine Angaben vor. Daher ist bei der Interpretation von Strandmülldaten Vorsicht geboten.

Im Allgemeinen war die Menge an Strandmüll an Abschnitten von Stränden, die Ostwind und Strömungen ausgesetzt waren, hoch (Abbildung 3, Bergmann et al., 2017). Im Gegensatz dazu war die Menge an Strandmüll an Küsten, die vor Ostwind und Strömungen an der Westküste geschützt sind, gering (Weslawski und Kotwicki, 2018). Dies steht im Einklang mit anderen Studien zu Meeresmüll in der Arktis (Bergmann et al., 2017; Buhl-Mortensen und Buhl-Mortensen, 2017; Tekmann et al., 2017). Aufgrund der Nähe zu potenziellen Meeresquellen

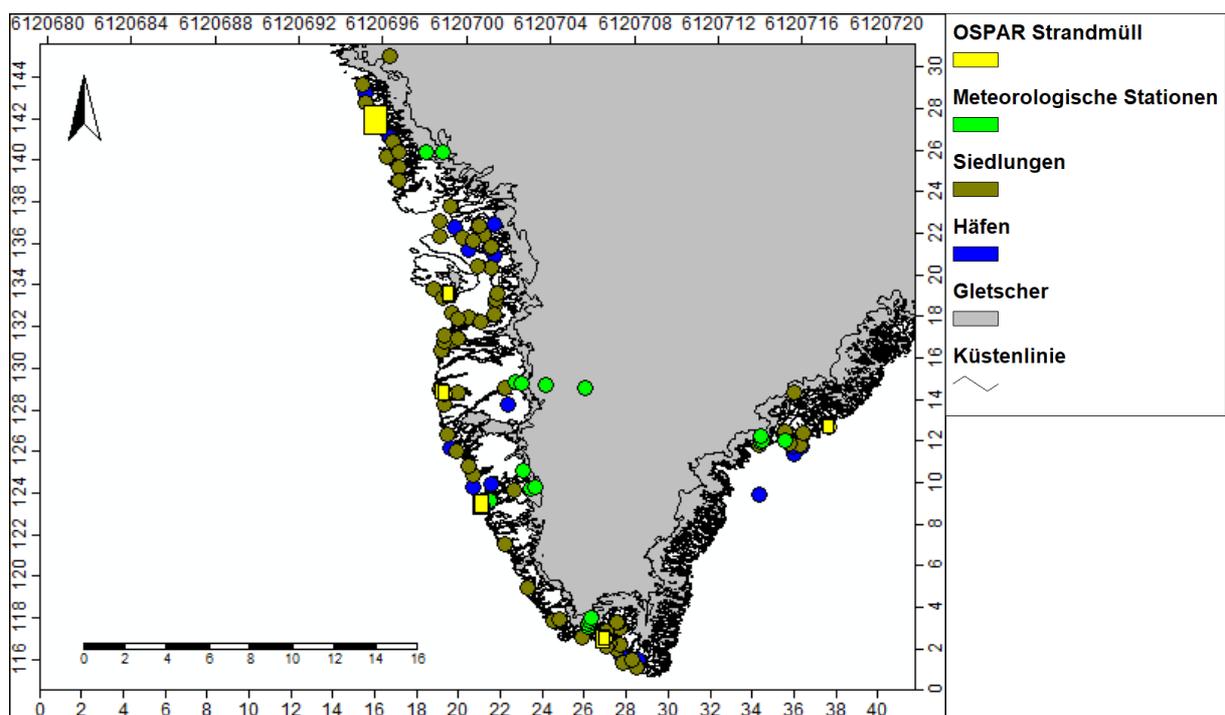
werden größere Mengen an Strandmüll auch an der Südküste von Spitzbergen erwartet. Dies konnte aufgrund fehlender Strandmülldaten jedoch nicht belegt werden.

Abbildung 1: Box-Whisker-Plots der Gesamtabundanz von Strandmüll auf Grönland, Island und Spitzbergen



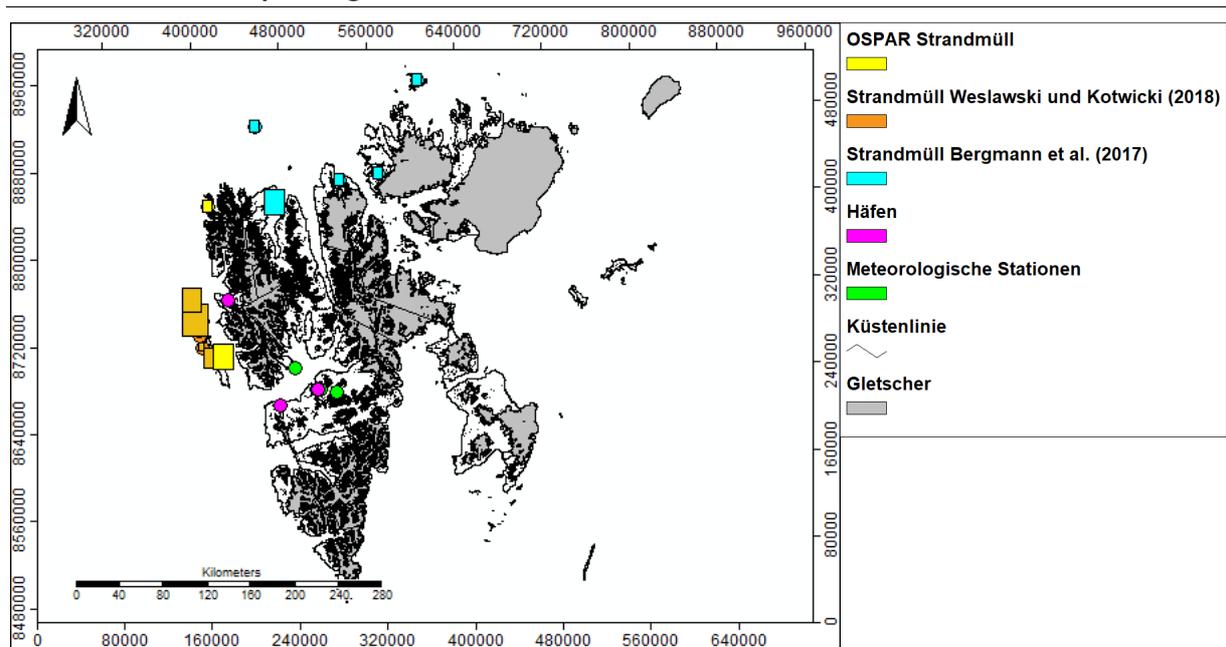
Akronyme auf der x-Achse sind OSPAR-Strand-IDs (GRL = Grönland, IS = Island, NO = Norwegen – hier Spitzbergen). In den Kästchen markieren horizontale Linien die drei Quartile, Fehlerbalken zeigen Standardabweichungen und leere Kreise zeigen Ausreißer. Das Diagramm wurde mit der Open-Source-Software R (<https://cran.r-project.org>) erstellt. Strände mit einer zu geringen Anzahl von Kartierungen (d.h. <4) wurden aus der Grafik weggelassen. Quelle: Eigene Darstellung, AE

Abbildung 2: Standorte von Strandmülluntersuchungen, Häfen, Siedlungen und meteorologischen Stationen auf Grönland



Rechtswert und Hochwert sind UTM-Koordinaten. Die Balkengröße an den Messstellen für Strandmüll entspricht der mittleren Gesamthäufigkeit des Strandmülls, normiert auf Werte von 10 bis 20. Quelle: Eigene Darstellung, AE

Abbildung 3: Standorte von Strandmülluntersuchungen, Häfen und meteorologischen Stationen auf Spitzbergen



Rechtswert und Hochwert sind UTM-Koordinaten. Die Balkengröße an den Messstellen für Strandmüll entspricht der mittleren Gesamtmenge an Strandmüll, normiert auf Werte von 10 bis 20. Quelle: Eigene Darstellung, AE

2.2 Fernerkundungsgestütztes Monitoring von Strandmüll

2.2.1 Methoden

BCSH hat eine Literaturstudie durchgeführt, um verschiedene Fernerkundungstechniken zur Erkennung von Plastikmüll an arktischen Stränden zusammenzufassen und zu vergleichen. Das Hauptziel war die Entwicklung einer großflächigen Anwendung für eine arktisweit einheitliche und vergleichbare Datenerfassung. Die entwickelte Methodik sollte im Hinblick auf Kosteneffizienz, örtliche Erreichbarkeit und Datenqualität bewertet werden. BCSH unterschied zwischen den drei Erfassungsplattformen: Satellit, Flugzeug und Drohne (UAVs). Der Stand der Technik in den einzelnen Anwendungsbereichen wurde zusammengefasst und die spektrale und räumliche Auflösung, die Flächenabdeckung, die örtliche Erreichbarkeit und die Kosten wurden verglichen (Tabelle 2). Studien zum Einsatz dieser Methoden für die Strandmüllerkennung wurden ebenfalls untersucht. Da die Anzahl der Studien, in denen Fernerkundungstechniken zur Erkennung von Strandmüll eingesetzt werden, noch begrenzt ist, wurden auch Studien einbezogen, die sich auf treibenden Plastikmüll im Meer konzentrieren.

2.2.2 Einführung in die Fernerkundung

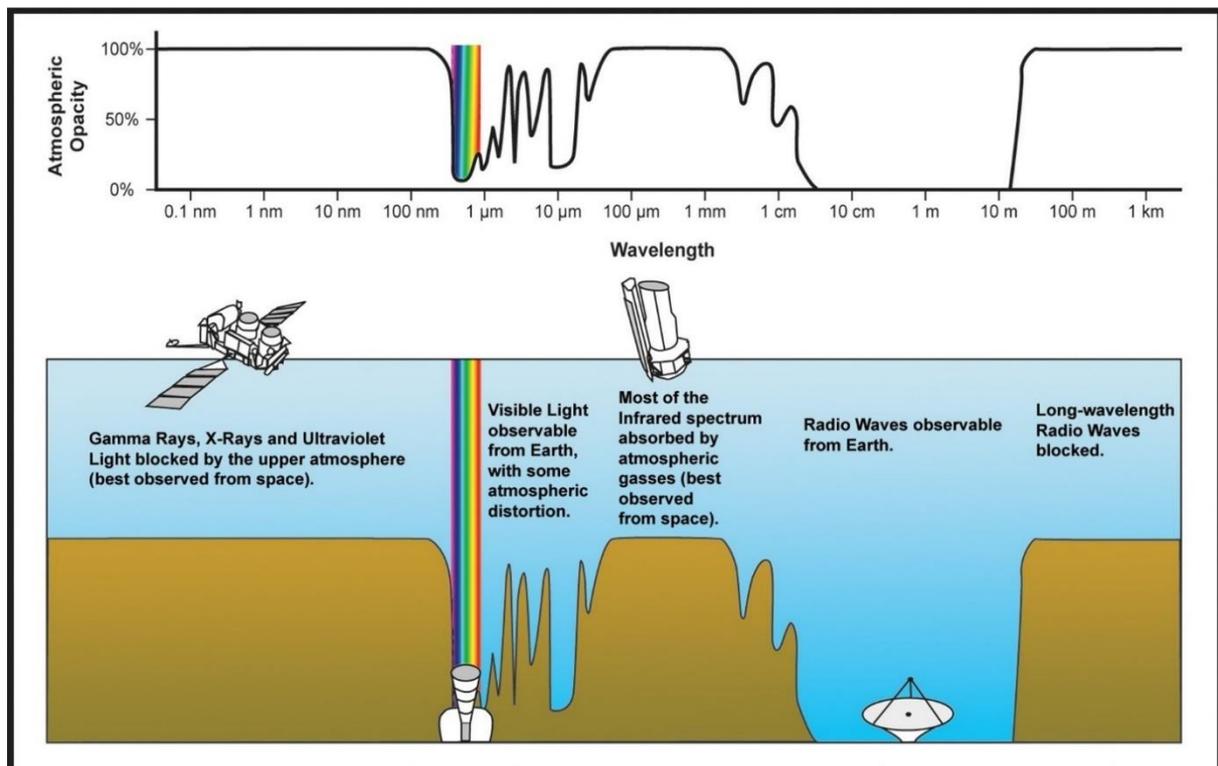
Zum besseren Verständnis der untersuchten Methoden wird im Folgenden eine kurze Einführung in das elektromagnetische Spektrum und die verwendete Terminologie der Fernerkundungsplattformen gegeben.

2.2.2.1 Elektromagnetisches Spektrum

Das elektromagnetische Spektrum (EMS) ist der Frequenzbereich aller Arten von elektromagnetischer Strahlung von Gammastrahlen (<0,01 nm) bis zu Radiowellen (>30 cm), die typischerweise durch ihre jeweiligen Wellenlängen gekennzeichnet sind (Campbell et al. 2011). In der Fernerkundung arbeiten die meisten Sensoren im sichtbaren Spektrum (VIS) (380 – 780 nm), im Infrarot (IR) (780 nm - 0,1 mm; einschließlich des nahen Infrarots (NIR): 780 nm

bis 1400 nm und des kurzwelligen Infrarots (SWIR): 1,4 bis 3 μm) und im Mikrowellenbereich (0,1 mm – 1 m). Gammastrahlen, Röntgenstrahlen, Ultraviolett, die meisten IR- und langwelligeren Radiowellen werden von der Atmosphäre geblockt oder absorbiert und können daher von passiven Fernerkundungssensoren nicht genutzt werden (Abbildung 4).

Abbildung 4: Elektromagnetisches Spektrum



Elektromagnetische Durchlässigkeit der Atmosphäre

Quelle: NASA

2.2.2.2 Aktive und passive Sensoren

Die Eigenschaften des EMS können von verschiedenen Arten von Sensoren genutzt werden, die in aktive und passive Sensoren unterteilt werden. Aktive Sensoren senden einen elektromagnetischen Puls aus und messen das reflektierte oder gestreute Signal. Passive Sensoren messen die natürlichen Emissionen der Erdoberfläche und der Atmosphäre in Abhängigkeit von ihrer spektralen Auflösung und Abdeckung (Erdle et al. 2011). Da alle Materialien der Erdoberfläche das einfallende Sonnenlicht je nach Wellenlänge unterschiedlich absorbieren, ist das erfasste Reflektionssignal für jedes Material charakteristisch und kann als Bestimmungsmerkmal für Klassifikationsansätze verwendet werden (Richards 1999).

2.2.2.3 Spektrale Auflösung und Abdeckung

Die spektrale Auflösung eines Sensors beschreibt die Breite der spektralen Bänder und zeigt somit seine Fähigkeit, Merkmale im EMS aufzulösen. So hat beispielsweise die MicaSense Altum eine spektrale Auflösung von 10 nm für das grüne, rote und redEdge-Band, 20 nm für das blaue Band und 40 nm für das NIR-Band (MicaSense Inc. 2020).

Die spektrale Abdeckung beschreibt den Bereich des EMS, der von den Spektralbändern eines Sensors abgedeckt wird. Die spektrale Abdeckung eines Sensors kann zwischen multispektralen (im Regelfall 2 - 10 Bänder: z.B. RGB mit den drei Bändern für Rot, Grün und Blau) und hyperspektralen Sensoren (100 - 1000 Spektralbänder) variieren (Pettorelli, 2019).

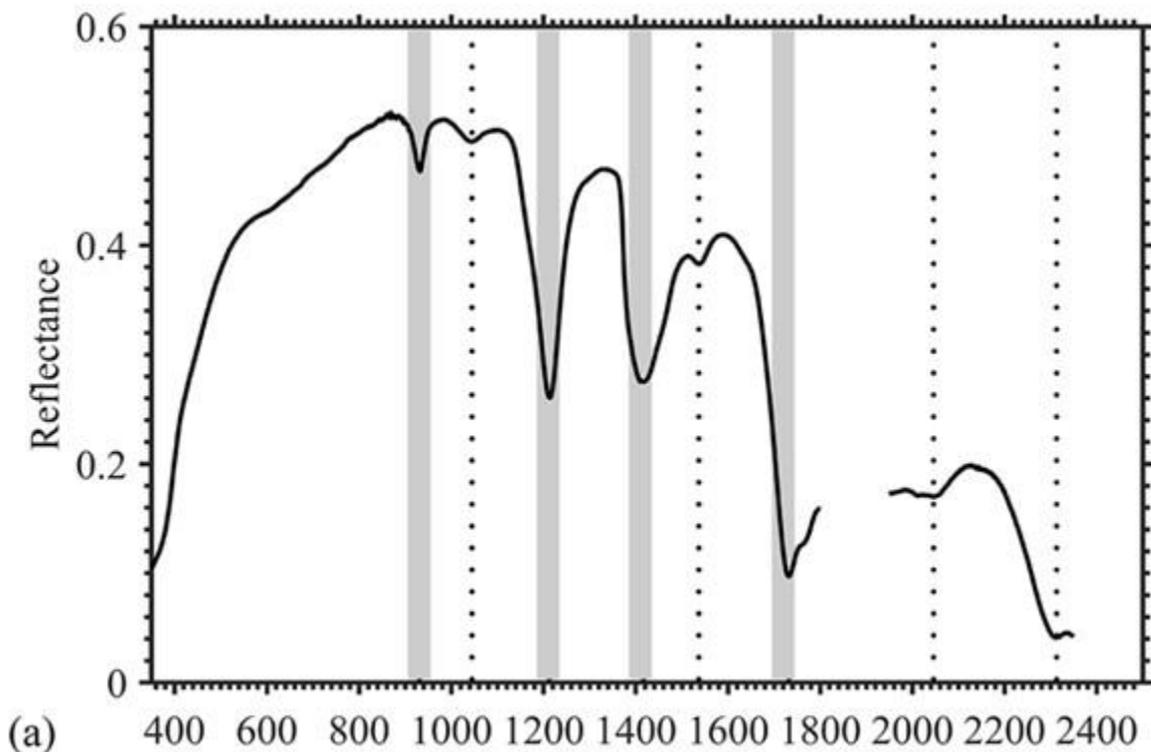
2.2.2.4 Räumliche Auflösung und Flächendeckung

Die räumliche Auflösung beschreibt die Pixelgröße des erfassten Bildmaterials. Die Pixelgröße von einzelnen Satellitenplattformen ist festgelegt, kann aber bei Flugzeug- oder Drohnenaufnahmen in Abhängigkeit von der Flughöhe variieren (Richards 1999). Einfache Werte der räumlichen Auflösung geben den gleichen Wert entlang und senkrecht zur Flugbahn an. Im Falle eines Unterschieds entlang und senkrecht zur Flugbahn werden zwei Werte angegeben. Die Flächendeckung bezieht sich auf die von einem Sensor abgedeckten Fläche und unterscheidet zwischen klein- und großräumigen Aufnahmen.

2.2.2.5 Spektrale Signatur

Die reflektierte Strahlung eines Materials ist eine Funktion der Wellenlänge und wird als spektrale Signatur bezeichnet. Die spektrale Signatur ist charakteristisch für verschiedene Materialien und kann für Klassifikationsansätze verwendet werden (Richards 1999). Abbildung 5 zeigt ein Beispiel für die spektrale Signatur von Plastik.

Abbildung 5: Elektromagnetisches Spektrum von Kunststoff



Beispiel eines Reflektionsspektrums von Plastikmüll, bei dem vier charakteristische Absorptionsbereiche in grau markiert sind Quelle: Garaba et al. 2020 lizenziert unter [CC BY 4.0](https://creativecommons.org/licenses/by/4.0/)

2.2.3 Ergebnisse und Diskussion

2.2.3.1 Überblick zur Anwendung von Satelliten zur Erfassung von Plastikmüll

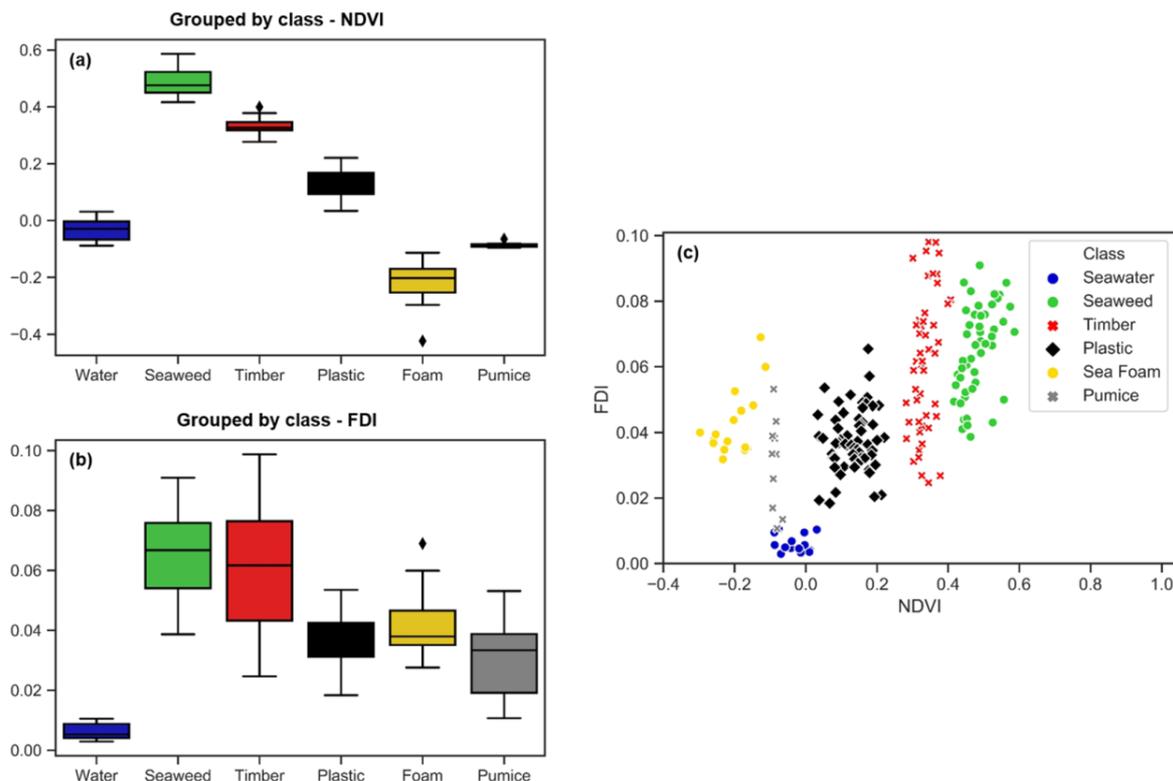
Satelliten ermöglichen die Erfassung großflächiger Gebiete mit einer räumlichen Auflösung von wenigen Dezimetern und mit einer breiten Palette an Sensoren. Maximenko et al. (2019) beschreiben mögliche Anwendungen für die Erkennung von Plastikmüll im Meer für aktive und passive Sensoren. Radarsensoren (aktive Sensoren) ermöglichen eine Beschreibung der Dynamik eines schwimmenden Objekts in Form der Driftgeschwindigkeit oder des erzeugten Nachstroms. Dies gilt insbesondere für treibende Plastikteile. Radarsensoren können bis zu

einer räumlichen Auflösung von unter einem Meter operieren. Passive Sensoren können für RGB-Komposite verwendet werden, um Kunststoffabfälle zu erfassen, und können möglicherweise den jeweiligen Abfalltyp identifizieren, indem sie Informationen über Farbe und Form des erfassten Mülls liefern. Eine wesentliche Voraussetzung ist eine hohe räumliche Auflösung (Maximenko et al. 2019). Satellitenplattformen mit passiven Sensoren decken ein breites Spektrum von räumlichen Auflösungen ab, das von Submetern für panchromatische Bänder (z. B. WorldView-3 (WV3), QuickBird) bis zu einigen Metern (WV3: 1,24 m; Skysat: 2 m; QuickBird: 2,4 m), mehreren 10 Metern (Landsat 7/8: 30 m); Sentinel-2A/2B: 10 - 20 m) und Hunderten von Metern (MODIS: 250 - 1000 m) in den multispektralen Bändern reichen kann. Neben der räumlichen Auflösung sind die spektrale Auflösung und die spektrale Abdeckung der Sensoren sowie die Revisionszeit der Plattformen wichtige Eigenschaften.

Bis dato wurde nur eine Handvoll Studien veröffentlicht, die Satellitenbilder für die Erkennung von Plastikmüll an Stränden oder im Meer nutzen. Topouzelis et al. (2019) und Biermann et al. (2020) untersuchten das Potenzial von Sentinel-2-Bildern zur Erkennung schwimmender Plastikteile. Topouzelis et al. (2019) verwendeten drei 100 m² große künstliche schwimmende Plastikobjekte, bestehend aus 1,5-Liter-PET-1-Wasserflaschen, LDPE-Plastiktüten und Geisternetzen aus Nylon, um die Möglichkeit der Unterscheidung von Plastik und Meerwasser zu untersuchen. Biermann et al. (2020) klassifizierten schwimmende Plastikteile erfolgreich auf Subpixel-Ebene mit einer Genauigkeit von bis zu 86%, indem sie den Normalized Difference Vegetation Index (NDVI) und einen Floating Debris Index (FDI) entwickelten. Die Autoren erkannten die spektralen Merkmale von Kunststoff in Pixeln, die zu mindestens 30% mit Flaschen oder Tüten oder zu 50% mit Fischernetzen bedeckt waren. Beide Studien nutzen die charakteristischen spektralen Eigenschaften des Meerwassers. Biermann et al. (2020) untersuchte zudem auch die Diskriminierung zwischen Kunststoffen und Seegras, Gischt und Holz (Abbildung 6). Die größte Einschränkung der Sentinel-2-Daten für die Erkennung von Strandabfällen bleibt die räumliche Auflösung von 10 bis 20 m. Selbst wenn man eine Erkennbarkeit auf einer Subpixel-Ebene von 30% annimmt, wäre eine Kunststoffabdeckung von 30 bis 120 m² erforderlich.

Die bisher einzige Studie, in der Satellitenbilder zur Erkennung von Strandmüll eingesetzt wurden, wurde von Acuña-Ruz et al. (2018) durchgeführt, die WV3-Bilder zur Erkennung von Plastikmüll an Stränden in Chiloé, Chile, verwendeten. Die Autoren wendeten einen halbautomatischen Ansatz zur Klassifikation der Landnutzung auf Pixelebene unter Verwendung der von WV3 erfassten Spektraldaten an. Müllobjekte bzw. Müllansammlungen mit einer Mindestgröße von 1 m² konnten mit einer Gesamtgenauigkeit von bis zu 88% erkannt werden.

Abbildung 6: Klassifikation von treibenden Objekten mittels NDVI und FDI



Klassifikation mit Hilfe von NDVI (a), FDI (b) und mit einer Kombination aus NDVI und FDI (c). Die Kombination von NDVI und FDI zeigt eine deutliche Clustering der einzelnen Materialien, aber auch NDVI allein zeigt ein großes Potenzial zur Erkennung von Plastik. Quelle: Biermann et al. 2020 lizenziert unter [CC BY 4.0](https://creativecommons.org/licenses/by/4.0/)

Am 1. April 2022 startete die hyperspektrale Satellitenmission EnMAP (Environmental Mapping and Analysis Program) des DLR (Deutsches Zentrum für Luft- und Raumfahrt e.V.). EnMAP bietet eine breite spektrale Abdeckung im sichtbaren Nahinfrarot (VNIR) 420 – 1000 nm und im SWIR 900 – 2450 nm. Die räumliche Auflösung beträgt 30 m. Einen Überblick über die bereits für die Erkennung von Plastikmüll verwendeten Sensoren geben Maximenko et al. (2019). Die Autoren fassen die verwendeten Plattformen und die jeweiligen räumlichen und spektralen Auflösungen zusammen (Abbildung 7).

Satellitenbilder haben aufgrund ihrer Flächendeckung und spektralen Auflösung ein großes Potenzial für die Erkennung von Plastikmüll an arktischen Stränden. Sie erleichtern die Datenerfassung in abgelegenen Gebieten und ermöglichen die Erfassung von spektralen Charakteristika von Plastik, wie in verschiedenen Studien gezeigt wurde (Topouzelis et al. 2019, Biermann et al. 2020, Acuña-Ruz et al. 2018 und Maximenko et al. 2019). Die Haupteinschränkungen der Satellitenerfassung sind nach wie vor die relativ grobe räumliche Auflösung von Multispektralbildern ab einer Größe von 1 m aufwärts sowie die potenziellen Kosten für eine großflächige Anwendungen. Auch wenn die meisten hochauflösenden Satellitendaten (>10 m) kostenfrei zugänglich sind (z. B. Sentinel-2, Landsat 7/8), ist die Erfassung von sehr hochauflösenden Daten nach wie vor mit Kosten verbunden (z. B. WV3: ca. 3.300€/100 km²). Eine weitere Herausforderung, insbesondere in der Arktis, ist die hohe Wolkenbedeckung, die einen langen Erfassungszeitraum und eine hohe Revisionszeit erfordert. Ähnliche Probleme mit der Wolkenbedeckung wurden von Acuña-Ruz et al. (2018) für Aufnahmen in Chiloé, Chile, beschrieben.

Wir erachteten die Satellitendaten von WV3 aufgrund ihrer räumlichen Auflösung und der spektralen Abdeckung als am besten geeignet für die Erhebung von Strandmüll. Die spektralen Eigenschaften der Sensoren von WV3 erscheinen dabei gut für die Erfassung der charakteristischen Absorptionsbereiche von Plastik geeignet (Abbildung 5, Abbildung 8).

Abbildung 7: Übersicht der Sensoren, die zur Erkennung von Plastikmüll eingesetzt wurden

Satellite/Sensor name	Spatial resolution (HR > 10 m; VHR < 10 m)	Spectral resolution	Wavelength range [nm]	Platform	Instrument
Sentinel-2/ MSI	HR	Multispectral	450–1,400	Satellite	
TanDEM-X	HR			Satellite	SAR
WorldView3	VHR	Multispectral	400–2,365	Satellite	
PlanetScope	VHR	Multispectral	455–860	Cubesat/Satellite	
SASI	VHR	Hyper	950–2,450	Airborne imager	
APEX	VHR	Hyper	372–2,540	Airborne imager	
AVIRIS-NG	VHR	Hyper	380–2,510	Airborne imager	
ASD FieldSpec Pro	VHR	Hyper	350–2,500	Handheld	
Spectra vista corporation	VHR	Hyper	350–2,500	Handheld	
Spectral evolution	VHR	Hyper	350–2,500	Handheld	

Quelle: Maximenko et al. (2019) lizenziert unter [CC BY 4.0](https://creativecommons.org/licenses/by/4.0/)

2.2.3.2 Überblick zur Anwendung von Flugzeug-gestützter Erfassung von Plastikmüll

In mehreren Studien (Garaba et al. 2018, Garaba et al. 2018b, Moy et al. 2018, Pichel et al. 2012 und Garcia-Garin et al. 2019) wurden flugzeuggestützte digitale Erhebungen zur Erkennung von Plastikmüll über Ozeanen und Küstengebieten durchgeführt. Für RGB-Bilder konnte eine räumliche Auflösung von einigen Zentimetern erreicht werden (Garcin-Garin et al. 2019, Moy et al. 2018). Typische Flughöhen für die luftgestützte Erfassung variieren zwischen 250 m und 650 m, was zu unterschiedlichen räumlichen Auflösungen führt (Garaba et al. 2018, Moy et al. 2018, Pichel et al. 2012, Garcia-Garin et al. 2019). Garaba et al. (2018b) kombinierten RGB-Aufnahmen mit NIR- und SWIR-Aufnahmen. In einer visuellen Sichtung konnten Objekte mit einer zehnfachen Größe der räumlichen Auflösung identifiziert werden (Garaba et al. 2018b, Moy et al. 2018, Garcia-Garin et al. 2019). Für eine halbautomatische Erkennungen wurde eine Spektralanalyse durchgeführt. Garaba et al. (2018b) beschreiben eine theoretische Erkennbarkeit auf Sub-Pixel-Ebene über dem Ozean unter Verwendung von Hyperspektralaufnahmen. Objekte, die 5% eines Pixels abdecken, sollten erkennbar sein. Garaba et al. 2018b verwendeten den hyperspektralen ITRES SASI-600 Imager mit 100 Wellenlängenbereichen zwischen 950 nm und 2.450 nm und einer räumlichen Auflösung von 0,5 m senkrecht und 1,2 m entlang der Strecke. Unter Annahme einer Detektierbarkeit von Plastikmüll auf bis zu 5% eines bestimmten Pixels ergibt sich eine mögliche Erkennung von Plastikgegenständen mit einer Größe von etwa 0,025 m x 0,06 m. In einer zweiten Studie erwarben Garaba et al. (2018) Hyperspektraldaten von AVIRIS (Airborne Visible/ Infrared Imaging Spectrometer) mit 224 zusammenhängenden Spektralbändern mit einer Abdeckung zwischen 400 - 2.500 nm. Es wurde eine räumliche Auflösung von 7,1 m erreicht, was zu einer potenziellen Erkennung von Objekten von etwa 2,5 m² führt, wenn man eine Erkennbarkeit auf der Subpixel-Ebene von 5% eines Pixels annimmt (Garaba et al. 2018).

Die oben zitierten Studien zeigen ein großes Potenzial luftgestützter Erfassungen für die Detektion von Plastikmüll. Die höhere räumliche Auflösung im Vergleich zu Satellitenplattformen ermöglicht die optische Detektion von Makroplastik auf RGB Bildern mit einer Größe von etwa zehnmal der räumlichen Auflösung (Garaba et al. 2018, Moy et al. 2018, Pichel et al. 2012, Garcia-Garin et al. 2019). Spektralanalysen ermöglichen darüber hinaus

halbautomatische Klassifikationsansätze, die sich die spektralen Eigenschaften von Plastik im NIR- und SWIR-Spektrum zunutze machen. Die Klassifikation von Plastikmüll, der bis zu 5% eines Pixels bedeckt, scheint über offenen Gewässern möglich zu sein (Garaba et al. 2018, Garaba et al. 2018b). Eine Sub-Pixel-Erkennung über Stränden wurde noch nicht getestet. Die räumliche Auflösung von Hyperspektralbildern aus luftgestützten Systemen kann bis in den Sub-Meter-Bereich gehen, während die geplante Hyperspektral-Satellitenmission EnMAP nur eine Auflösung von 30 m erreicht. Die größte Einschränkung der luftgestützten Erfassung sind die relativ hohen Kosten, insbesondere für eine arktisweite Erfassung. Eine vereinfachte und grundlegende Aufschlüsselung der Ausgaben umfasst die Betriebskosten der Geräte, Flugzeug- und Treibstoffkosten sowie Personal- und Lebenshaltungskosten. Coulter et al. (2007) beschreiben die Kosten für hyperspektrale Erhebungen aus der Luft bei mäßigem Relief, klarem Himmel und guter Infrastruktur in Gebieten Nordamerikas mit etwa \$100/Linienkilometer. Im Gegensatz dazu steigen die Kosten für Erhebungen bei starkem Relief, unvorhersehbaren Wetterbedingungen und schlechter Infrastruktur auf \$150/Linienkilometer. Coulter et al. (2007) beschreiben, dass ein Linienkilometer etwa 1 km² bei einer räumlichen Auflösung von 3 m abdeckt. Die angegebenen Kosten gehen von einem großen Erhebungsgebiet von mindestens 1.000 km² aus; kleinere Erhebungen führen zu einem deutlichen Anstieg der Linienkilometer-Kosten. Darüber hinaus sind hier die Kosten für die Mobilisierung und Demobilisierung noch nicht enthalten. Operative Einschränkungen aufgrund von Wolkenbedeckung unterhalb der Flughöhe können oft zu einer erheblichen Anzahl von Bereitschaftstagen führen. Die Mobilisierungs- und Demobilisierungskosten können je nach Erhebungsgebiet, Flugplanung, Genehmigungen, Versicherungen, Zollgebühren, Personaltransport und Logistik erheblich variieren. Außerdem wurde die betreffende Kostenschätzung für das Jahr 2007 durchgeführt und kann daher aufgrund schwankender Treibstoffkosten variieren (Coulter et al. 2007). BCSH hat mehrjährige Erfahrung im Bereich der digitalen Lufterfassung über Nord- und Ostsee und geht von einer möglichen Abdeckung von etwa 800 km Küstenlinie pro Tag bei einer Flughöhe von 550 m aus. Dieser Wert ist eine grobe Schätzung der möglichen Abdeckung und hängt stark von den vorherrschenden Küsteneigenschaften ab.

2.2.3.3 Überblick zur Anwendung von Drohnen-gestützter Erfassung von Plastikmüll

UAVs ermöglichen die geringste Flughöhe der drei Plattformen und damit die höchste räumliche Auflösung, auch wenn flugzeuggestützte Sensoren dem nahe kommen können. Die Integration verschiedener Sensoren in ein UAV wird durch die Sensorgröße sowie durch das maximale Startgewicht (MTOW) des UAVs bestimmt. Das MTOW hängt von der Größe und dem Motor des UAVs ab und beeinflusst das maximale abdeckbare Fluggebiet. RGB-Sensoren erreichen in der Regel eine räumliche Auflösung von mehreren Zentimetern, können aber auch bis in den Sub-Zentimeterbereich gehen (Martin et al. 2018). Multispektrale Sensoren liegen im Bereich weniger Zentimeter (z.B. MicaSense Altum, Parrot Sequia +). Sowohl multispektrale als auch RGB-Kameras können auf UAVs mit einem MTOW unter 5 kg montiert werden. Hyperspektralsensoren für UAVs können einen Spektralbereich von VNIR bis SWIR abdecken, sind aber sehr teuer (z. B. Micro-Hyperspec).

Martin et al. (2018) und Bao et al. (2018) haben erfolgreich eine halbautomatische Klassifikation von Plastikmüll mit Hilfe von UAV-RGB-Bildern durchgeführt. Bao et al. (2018) verwendeten Schwellenwerte zur Bildsegmentierung für eine erfolgreiche Klassifikation mit einer Gesamtgenauigkeit von 98,6%. Die Klassifikation wurde an einheitlichen Sandstränden durchgeführt. Die Autoren weisen jedoch auf eine potenzielle Überschätzung des Plastikmülls durch ihre Methode hin; es scheint, dass natürliche Gegenstände wie Muscheln, Äste und Blätter leicht als Plastikmüll fehlklassifiziert wurden. Martin et al. (2018) verwendeten sowohl eine manuelle Sichtung als auch einen Ansatz des maschinellen Lernens. Für den Ansatz des

maschinellen Lernens wurde ein Random-Forest-Klassifikator verwendet, der einen HoG-Deskriptor (Histogram of Orientated Gradients) einsetzte. Random Forest ist ein Ensemble-Lernverfahren, das häufig bei der Klassifikation von Landnutzung und -bedeckung eingesetzt wird. HoG ist eine weit verbreitete Methode zur Feature-Darstellung, die z. B. bei der Erkennung menschlicher Gesichter verwendet wird (Dalal & Triggs 2005). Martin et al. (2018) beschrieben eine signifikante positive Korrelation zwischen der Häufigkeit von Gegenständen, die mit der manuellen Sichtung und Random-Forest gefunden wurden (Spearman-Korrelation, $r=0,61$, $p=0,026$, $n=13$). Die Autoren beschrieben jedoch auch, dass die Algorithmen des maschinellen Lernens die Anzahl der Plastikteile um mehr als das Fünffache überschätzten und dass es auch zu nicht erkannten Objekten kam. Beide Studien zeigen deutlich, dass Drohnen für die automatische Erkennung von Kunststoffabfällen am Strand geeignet sind. Es ist zu beachten, dass es sich bei den Untersuchungsgebieten in beiden Fällen um homogene Sandstrände handelte, weshalb die Möglichkeit, diese Methoden auf Kiesstrände zu übertragen, noch nicht getestet wurde. Schließlich verglichen Martin et al. (2018) auch die Zeit für eine UAV-Untersuchung mit der Zeit, die für eine herkömmliche Stranderhebung benötigt wird. Die Autoren beschreiben den UAV-Ansatz als 39-mal schneller. UAVs ermöglichen hochauflösende Daten mit multi- und hyperspektraler Abdeckung. Sie können Strände mit hoher Zeiteffizienz überwachen und sind für eine (halb-)automatische Klassifikation geeignet. Vielversprechende Studien nutzten RGB-Bilder für eine erfolgreiche automatische Erkennung an Sandstränden, obwohl eine erfolgreiche Übertragung auf Kiesstrände noch untersucht werden muss. Außerdem muss die Anwendung von Multi- oder Hyperspektraldaten getestet werden. Einige der größten Einschränkungen dieser Methode sind die Erreichbarkeit von abgelegenen Gebieten sowie die Kosten, die durch den Einsatz von Hyperspektralsensoren entstehen würden. Die wichtigsten klimatischen Einschränkungen sind Regen oder starke Windgeschwindigkeiten (über 30 km/h); aufgrund ihrer geringen Flughöhe werden UAVs wahrscheinlich weniger durch Wolken beeinträchtigt.

2.2.3.4 Laufende Literaturrecherche

Die Literaturrecherche war ein fortlaufender Prozess während des Projekts, in dessen Verlauf eine hohe Anzahl von Studien veröffentlicht wurde. Die jüngsten Veröffentlichungen konzentrierten sich auf die Erkennung von Strandmüll mit Drohnen und unter Verwendung hochauflösender RGB-Kameras (z. B. Andriolo et al., 2020; Gonçalves et al., 2020a und 2020b; Escobar Sánchez et al., 2021; Martin et al., 2021; Merlino et al., 2020; Papakonstantinou et al., 2021). Die verwendete GSD variierte zwischen 0,18 cm (Merlino et al., 2020) und 1,2 cm (Andriolo et al., 2020) und umfasste Flächen zwischen <1 ha und 5 ha (Papakonstantinou et al., 2021). Nur Martin et al. (2021) führten eine großflächige Erfassung durch, indem sie insgesamt 44 Strände entlang der saudi-arabischen Küste mit einer Länge von 1400 km erfassten. Um eine sehr niedrige GSD zu erreichen, waren geringe Flughöhen (bis zu 6 m) erforderlich, und die Erfassung von Transekten von 100 m Strandlänge konnte bis zu einer halben Stunde Flugzeit in Anspruch nehmen.

Es wurden verschiedene Klassifikationsansätze getestet und mit in situ OSPAR-Erfassungen verglichen. Bei den Klassifikationsansätzen handelte es sich um ein manuelles Screening von Drohnenaufnahmen und pixel- und objektbasierte (halb-)automatische Klassifikationen mit Algorithmen des maschinellen Lernens (z. B. Random Forest, Support Vector Maschine, Maximum Likelihood Classifier) und Convolutional Neural Networks.

Meeresmüll wurde durch manuelles Screening mit Erkennungsraten zwischen 20% (Merlino et al., 2020 (GSD = 0,18 cm)) und bis zu fast 100% (Andriolo et al., 2020 (GSD = 1,2 cm); Escobar Sánchez et al., 2021 (GSD = 0,27 cm); Gonçalves et al., 2020b (GSD = 0,55 cm)) identifiziert.

Der Detektionserfolg bei der Anwendung von (halb-)automatischen Klassifikationsansätzen zur Erkennung von Strandmüll bewegte sich in verschiedenen Studien zwischen 25% - 74% (Escobar Sánchez et al., 2021), 64% - 73% (Gonçalves et al., 2020), 62% - 82% (Martin et al. 2021) und 77,26% (Papakonstantinou et al., 2021).

Für weitere Untersuchungen wurde der Einsatz von multispektralen Sensoren in mehreren Studien diskutiert und empfohlen (Gonçalves et al., 2020a und 2020c; Escobar Sánchez et al., 2021; Wolf et al., 2020).

2.2.3.5 Klassifikationsmethoden

Neben der Literaturrecherche zu den drei Fernerkundungsplattformen wurde auch ein Schwerpunkt auf die Eignung von (halb-)automatischen Klassifikationsmethoden gelegt. Daher wurden Klassifikationsmethoden, die auf den oben beschriebenen Plattformen eingesetzt werden, im Hinblick auf eine arktisweite Anwendung bewertet. Die häufigsten Ansätze waren Bilderkennungsverfahren und bildgebende Spektroskopie (z.B. Acuña-Ruz et al. (2018), Biermann et al. 2020, Garaba et al. 2018, Martin et al. 2018). Martin et al. (2018) wendeten Bilderkennungsverfahren auf sehr hochauflösende Drohnendaten an. Bildgebende Spektroskopie zur Erkennung von Strandabfällen wurde von Acuña-Ruz et al. (2018) angewendet. Die bildgebende Spektroskopie beschreibt die Messung, Analyse und Interpretation von elektro-optischen Spektren, die über große Flächen aufgenommen werden. Sie ermöglicht die Klassifikation von Fernerkundungsbildern auf Pixelebene anhand der spektralen Eigenschaften der vorkommenden Landbedeckung (Shaw und Burke 2003). Für eine großflächige Anwendung wie in der Arktis ist eine pixelbasierte Klassifikation von Satellitendaten von großem Interesse. Daher wurden Veröffentlichungen über das Reflektionsspektrum von Plastikmüll weiter untersucht. Garaba et al. (2020) präsentieren ein kontinuierliches Spektrum von Plastikmüll im RGB-, NIR- und SWIR-Bereich. Es wurden verschiedene Wellenlängenbereiche identifiziert, die für das Vorhandensein von Kunststoffen charakteristisch sind. Diese liegen um 931 nm, 1215 nm, 1417 nm und 1732 nm und damit im Bereich zwischen NIR und SWIR (Abbildung 8). Sensoren, die diese Wellenbereiche abdecken, eignen sich besonders gut für die (halb-)automatische Erkennung von Plastikmüll, da sie eine mögliche Unterscheidung von den umgebenden Materialien versprechen.

2.2.4 Fazit

Tabelle 2 gibt einen Überblick über die spektrale und räumliche Auflösung, die spektrale und räumliche Abdeckung, die Erfassungsgrenzen und die Kosten der drei Plattformen. Da die einzelnen Merkmale nicht auf die gleiche Art und Weise bewertet werden sollten und jede Methode ihre eigenen Vorteile und Beschränkungen hat, wäre die Erstellung einer Rangliste subjektiv und wurde daher nicht angewandt. Die Literaturstudie unterstreicht, dass keine der drei Plattformen für sich genommen eine zufriedenstellende Lösung liefern kann. Maximenko et al. (2019) schlagen daher eine Integration mehrerer Beobachtungssysteme für die Erkennung von Meeresmüll vor.

Tabelle 2: Vergleich von Fernerkundungsplattformen für eine arktisweite Strandabfallüberwachung

	Satellit (WorldView 3)	Flugzeug	UAV
Spektrale Abdeckung	RGB, NIR, SWIR	RGB, NIR, SWIR	RGB, NIR, (SWIR)
Räumliche Auflösung	0,31 m/ 1,24 m/ 3,7 m	Zentimeter bis Meter	Sub-Zentimeter
Flächen Abdeckung	Großflächig	Mittelgroß	Kleinräumig

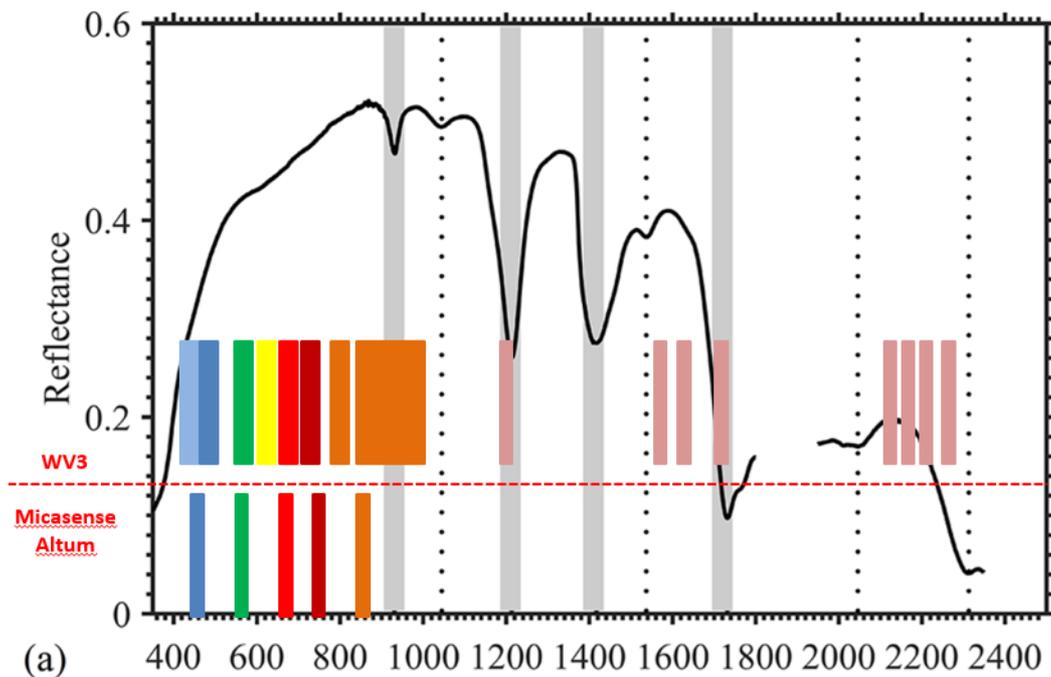
	Satellit (WorldView 3)	Flugzeug	UAV
Flughöhe	617 km	250 m bis 650 m	10 m bis 100 m
Erkennbare Müllgröße	Optisch: >3 m Spektral: 1,24 m (Pixel-Ebene)	Optisch: >10/ 20 cm Spektral: >5% eines Pixels über Wasser	Optisch: >10 cm Spektral: Pixel-Ebene
Kosten für ein Arktisweites Monitoring	Mittel	Hoch	Sehr hoch
Einschränkungen	Relative grobe Auflösung, Wolkenbedeckung	Hohe Kosten im Allgemeinen und sehr hohe Kosten für kleine Gebiete, Wolkenabdeckung	Kleinräumig, Erreichbarkeit von abgelegenen Gebieten, Wind, hohe Kosten für SWIR-Sensoren

Vergleich der spektralen und räumlichen Auflösung, der Flächenabdeckung, der Erfassungsgrenzen und der Kosten. WorldView 3 wurde als Beispiel für eine potenzielle Satellitenplattform ausgewählt, da es im Vergleich zu anderen Satellitensystemen eine hohe räumliche Auflösung aufweist.

Der BCSH unterstützt die Idee eines integrierten Ansatzes und schlägt eine Kombination aus zwei Plattformen, nämlich Satellit und UAV, für die arktisweite Erfassung von Strandmüll vor. Da die Haupteinschränkung von Satellitenplattformen die relativ grobe räumliche Auflösung ist, schlägt BCSH eine Kombination mit sehr hochauflösenden UAV-Bildern vor. Die Vorteile beider Plattformen können kombiniert werden, um vielversprechende Erfassungsmöglichkeiten zu schaffen. Multispektrale Satellitenbilder ermöglichen die Untersuchung von pixelbasierten Klassifikationsansätzen, wie sie von Acuña-Ruz et al. (2018) durchgeführt wurden, wobei das charakteristische Reflektionsspektrum von Plastik genutzt wird (Abbildung 8)

Derzeit schränkt die relativ grobe räumliche Auflösung von Satelliten die Erkennung einzelner Müllteile am Strand ein, es besteht jedoch ein großes Potenzial für eine arktisweite Erfassung von Anhäufungen von Strandmüll. Identifizierte Hotspots können mit Hilfe von UAV-Bildern weiter untersucht werden. UAVs ermöglichen eine zeiteffiziente Erfassung im Zentimeterbereich zu geringen Kosten und können die traditionellen Erhebungen von Strandmüll ergänzen. Dennoch ist ein arktisweiter Einsatz von Drohnenbildern aufgrund der Kosten und der schwierigen Erreichbarkeit nicht praktikabel. Drohnenbilder erlauben außerdem die Auswertung verschiedener räumlicher Auflösungen für die Erkennung von Plastikmüll, die durch unterschiedliche Flughöhen oder down-sampling gewonnen werden können. Daher können UAVs einen Ausblick auf künftige Satellitenmissionen bieten, indem sie die Einschränkungen der räumlichen Auflösung überwinden. Die Hauptbeschränkung von UAVs ist die geringe spektrale Abdeckung im niedrigen bis mittleren Preissegment und die geringe Flächenabdeckung, was beides durch Satellitenbilder ausgeglichen werden kann.

Abbildung 8: Elektromagnetisches Spektrum von Kunststoff mit spektraler Abdeckung von WV3 und MicaSense Altum



Beispiel eines Reflektionsspektrums von Plastikmüll aus Garaba et al. (2020), wobei die vier charakteristischen Absorptionsbereiche grau markiert sind. WV3- und MicaSense Altum-Spektralbänder sind beigefügt, um ihre Überlappung mit den charakteristischen Kunststoffmerkmalen zu zeigen. Die WV3-Bänder liegen oberhalb der roten Linie, die MicaSense Altum-Bänder unterhalb. Quelle: Angepasst von Garaba et al. 2020 lizenziert unter CC BY 4.0

Für diese Studie empfiehlt BCSH die Verwendung von WorldView3 (WV3) Satellitenbildern. WV3 kombiniert eine sehr hohe räumliche Auflösung (1,24 m für VIR und 3,7 m für SWIR) mit einer multispektralen Abdeckung und wurde bereits erfolgreich zur Erkennung von Strandmüll eingesetzt (Acuña-Ruz et al. 2018). Das panchromatische Band (0,31 m) kann für die Schärfung der RGB-Bänder verwendet werden, was zu einem Farbbild mit einer Auflösung von 0,31 m führt, das wiederum eine visuelle Identifizierung von großen Kunststoffabfällen ermöglicht. Die multispektralen Bänder können darüber hinaus für (halb-)automatische Klassifikationsansätze verwendet werden. Als UAV-Sensor empfiehlt BCSH den MicaSense Altum. Der MicaSense Altum Sensor besteht aus fünf Einzelsensoren im VIR (RGB, redEdge und NIR) mit einer räumlichen Auflösung von 3,4 cm bei einer Flughöhe von 80 m. Trotz vielversprechender Studien zu luftgestützten Systemen mit hoher räumlicher und spektraler Auflösung machen die hohen Kosten eine flugzeuggestützte Erfassung für eine arktisweite Anwendung weniger geeignet.

3 Arbeitspaket 2

3.1 Statistische Analysen zur Identifizierung von Anreicherungen von Strandmüll

3.1.1 Methoden

Quellen für Strandmüll können in landbasierte und meeresbasierte unterteilt werden. Letztere umfassen Fischerei, Schifffahrt, Offshore-Bergbau und Windkraftanlagen, während erstere Tourismus, unkontrollierte Emissionen aus Deponien, Häfen und Eintrag über Zuflüsse (d.h. Flüsse und Ästuar) umfassen. Tudor und Williams (2004) haben versucht, die Arten von Strandabfällen den Quellen zuzuordnen, indem sie die Matrix-Score-Technik entwickelt haben. Abgesehen von fischereibezogenen Müllteilen ist die Quellenzuordnung jedoch sehr unsicher, teilweise weil viele Mülltypen aus mehreren Quellen stammen können.

Es wird angenommen, dass Flüsse in erheblichem Umfang Müll in Meeresgewässer emittieren (Gasperi et al., 2014; Rech et al., 2014), aber die Quantifizierung der Quellterme ist bis heute unsicher (Morritt et al., 2014), da empirische Studien die hohe zeitliche Variabilität des Abflusses an den Flussmündungen vernachlässigen, und Modellstudien hauptsächlich generische Parametrisierungen verwenden und unter einem Mangel an Daten für die Randbedingungen leiden.

Informationen über Flusseinträge von Müll in die Arktis sind Gegenstand von Spekulationen. Bergmann et al. (2017), Kirkfeldt (2016) und Nashoug (2016) weisen Strandmüll auf Spitzbergen bzw. Grönland hauptsächlich meeresbasierten Quellen zu, darunter hauptsächlich der Fischerei. Kirkfeldt (2016) diskutiert Deponien als potenzielle Quellen für Strandmüll auf Grönland. Auch wissenschaftliche Feldstudien stehen im Verdacht, zur Verschmutzung durch Müll beizutragen (Nashoug, 2016). Der Mangel an Informationen über das Abfallaufkommen in der Arktis macht es erforderlich, Daten über die potenziellen Verursacher von Strandabfällen in der Arktis zu sammeln.

Daher listete AE Datenanforderungen auf, die für die Identifizierung der Anreicherung von Strandmüll auf Grönland und Spitzbergen erforderlich sind. Diese Anforderungen umfassen georeferenzierte Daten zu Siedlungen, Häfen, Deponien, Strömungen und Wind, von denen die beiden letzteren das Anlanden von Müll aus meeresbasierten Quellen erklären können. Informationen zu Deponien und Verbrennungsanlagen auf Grönland wurden der Publikation von Eisted und Christensen (2011) entnommen. Daten zu Siedlungen, Häfen, Deponien und Bergbauaktivitäten auf Grönland wurden von OA bereitgestellt und sind in B.1 und B.2 dargestellt.

Die folgenden Daten wurden von AE aus dem Internet erfasst:

- ▶ Winddaten von Spitzbergen (<https://www.unis.no/resources/weather-stations/>),
- ▶ Winddaten von Grönland (<https://www.promice.org/PromiceDataPortal/>),
- ▶ Daten zu Strömungen und Lagrange-Transport aus einem Modell der Computational Fluid Dynamics (CFD) der Gewässer um Spitzbergen (Hattermann et al., 2016; <https://data.npolar.no/home/>),
- ▶ Topografische Daten (Shapefiles) von Grönland in 1:1.000.000 (<https://eurogeographics.org/>),

- ▶ Topografische Daten (Shapefiles) von Spitzbergen in 1:100.000 (<https://data.npolar.no/home/>),
- ▶ Koordinaten der Häfen auf Grönland (<http://capetotrade.com/getportlist.php?ref1=GL>),
- ▶ Koordinaten der Häfen auf Spitzbergen (<http://ports.com/browse/europe/svalbard-and-ian-mayen/>).

AE georeferenzierte die Daten und erstellte Shapefiles aus Positionen meteorologischer Stationen, Häfen und Siedlungen (Abbildung 2, Abbildung 3). Letztere Daten wurden von BCSH bereitgestellt. Außerdem wurden Winddaten mit der R-Routine CLIFRO (<https://cran.r-project.org/web/packages/clifro/index.html>) analysiert und dargestellt.

ASTD-Daten zu Schifffahrts- und Fischereitätigkeiten in der Arktis wurden vom PAME International Secretariat bereitgestellt. Diese Daten wurden zu Gesamtvorkommen (= Abundanzen) von Fischereifahrzeugen, Passagierschiffen und anderen Schiffen in den Gewässern von Westgrönland (d.h. westlich von $-44,0^\circ$ Länge) bzw. Ostgrönland (d.h. östlich von $-44,0^\circ$ Länge) aggregiert.

Schließlich wurden statistische Analysen durchgeführt, um die Ursachen für die Strandverschmutzung auf Grönland zu identifizieren. Es wurde eine Permutationsanalyse der Kovarianz (PERMANCOVA) mit der mittleren Häufigkeit von Fischereifahrzeugen [Anzahl] als Faktor und der Einwohnerzahl [Anzahl], der Entfernung zur nächsten Siedlung [km], der Entfernung zum nächsten Hafen [km] und Übernachtungen im jeweiligen Bezirk Grönlands [Anzahl] als Kovariaten gerechnet. Als abhängige Variable wurde die mittlere Gesamthäufigkeit von Strandmüll auf Grönland aus der OSPAR-Strandmüll-Datenbank verwendet. Häufigkeiten von Passagierschiffen und anderen Schiffen wurden als Faktoren ausgeschlossen, um eine Überparametrisierung und Redundanz der Informationen des statistischen Modells zu vermeiden. Windinformationen konnten nicht direkt mit erhobenen Strandstandorten verknüpft werden, da die Entfernungen zwischen den OSPAR-Stränden und den nächstgelegenen meteorologischen Stationen teilweise mehrere hundert Kilometer betragen. Daher wurden Winddaten aus dem statistischen Modell ausgeschlossen, und die Interpretationen von Winddaten erfolgten eher qualitativ als quantitativ. Zusätzliche Tests für Autokorrelation, Normalverteilung und Varianzhomogenität wurden gerechnet, um sicherzustellen, dass die Ergebnisse der PERMANCOVA nicht verzerrt sind. Für alle statistischen Analysen wurde die Statistiksoftware Systat 12.0 (Systat Inc.) verwendet.

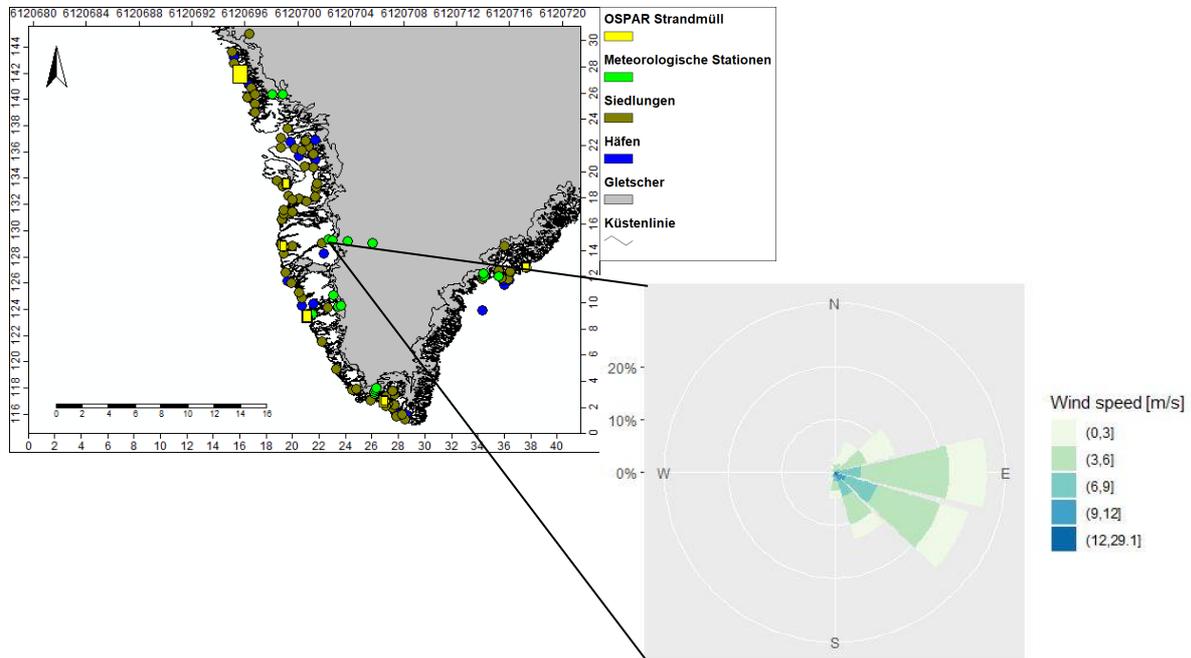
3.1.2 Ergebnisse und Diskussion

Gemäß Eisted und Christensen (2011) gibt es auf Grönland sechs kleine bis mittlere Verbrennungsanlagen und 30 Strohverbrennungsanlagen. Fast jede Siedlung hat eine eigene Mülldeponie, teilweise wird Hausmüll direkt an den Stränden deponiert. Informationen über die Menge und Zusammensetzung des Mülls auf Grönland sind rudimentär oder fehlen ganz. Eine Übersicht über die Lage der Deponien und deren jeweilige Größe ist in B.2 dargestellt. Abgesehen von Einträgen aus Schifffahrt und Fischerei tragen Auswehungen aus Deponien und Wegwerfen von Müll am Strand wesentlich zu den gefundenen Strandmüllmengen auf Grönland bei (Kirkfeldt, 2016).

Arktis-weit dominieren jedoch meeresbasierte Quellen von Strandmüll (Bergmann et al., 2017; PAME, 2019; Tekmann et al., 2017). Dementsprechend führt der windinduzierte Transport zu einer Akkumulation von Strandmüll an Orten, die dem Wind stark ausgesetzt sind (Schulz et al., 2015a). Die Menge an Strandmüll ist gering, wenn der Westwindanteil vernachlässigbar ist

(Abbildung 9). Gemäß Abbildung 9, Abbildung 10 und Abbildung 11 können an der Westküste Grönlands hohe West- und Südwestwindanteile zu Akkumulationen von Strandmüll führen. Dies stimmt gut mit Analysen von Strandmülldaten in der Nordsee überein, wo Winddrift als Hauptantriebskraft für das Anlanden von Müll diskutiert wurde (Neumann et al., 2014; Schulz et al., 2015a). Außerdem kann die Nähe zu Städten wie Nuuk als zusätzlicher Faktor angesehen werden, der zu einer Anreicherung von Strandmüll führt (Kirkfeldt, 2016).

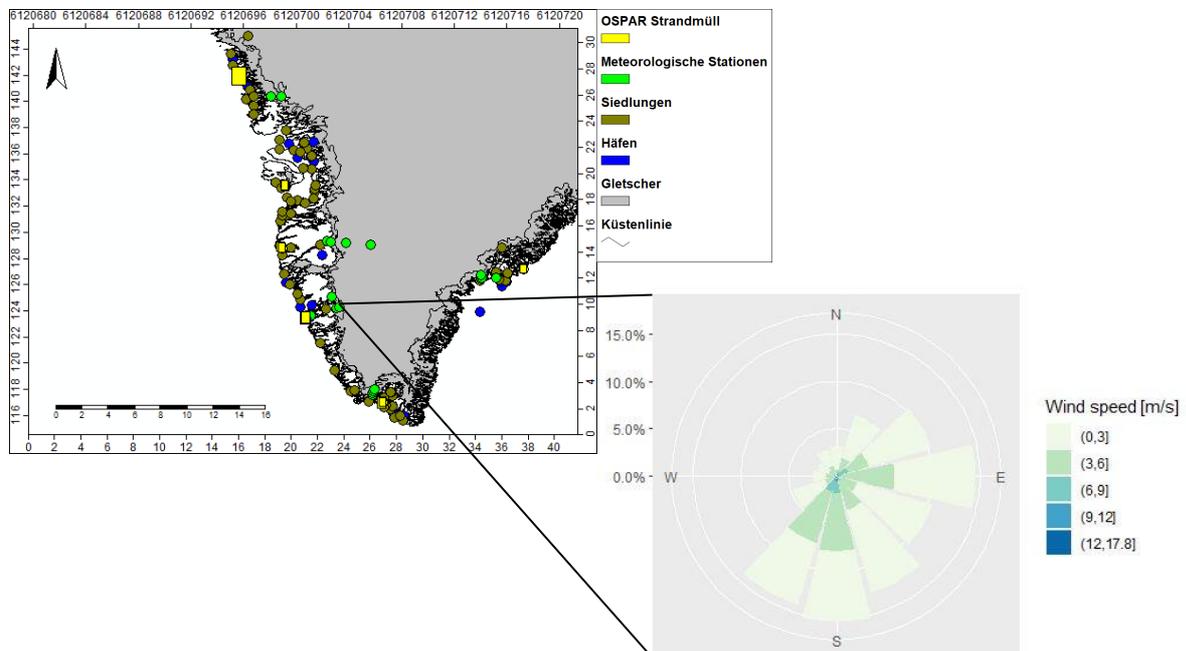
Abbildung 9: Karte von Grönland mit einer Windrose



Schwarze Linien deuten die Position der zugehörigen meteorologischen Station nördlich von Nuuk an.

Quelle: Eigene Darstellung, AE

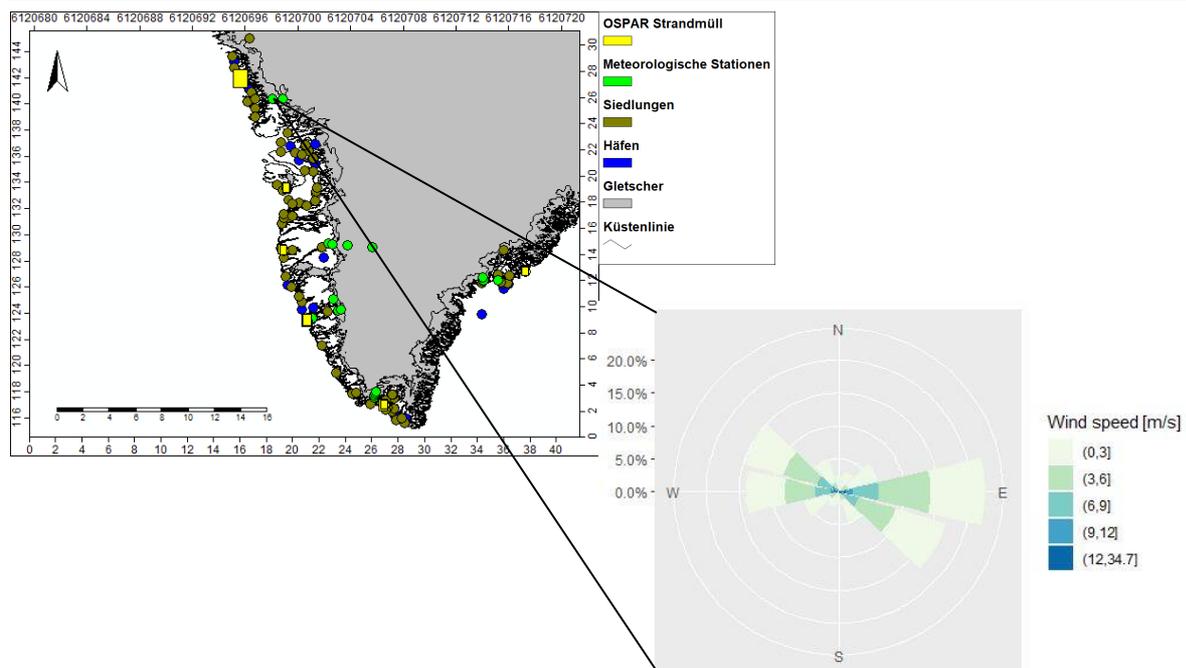
Abbildung 10: Karte von Grönland mit einer Windrose



Schwarze Linien deuten die Position der zugehörigen meteorologischen Station in der Nähe Nuuks an.

Quelle: Eigene Darstellung, AE

Abbildung 11: Karte von Grönland mit einer Windrose

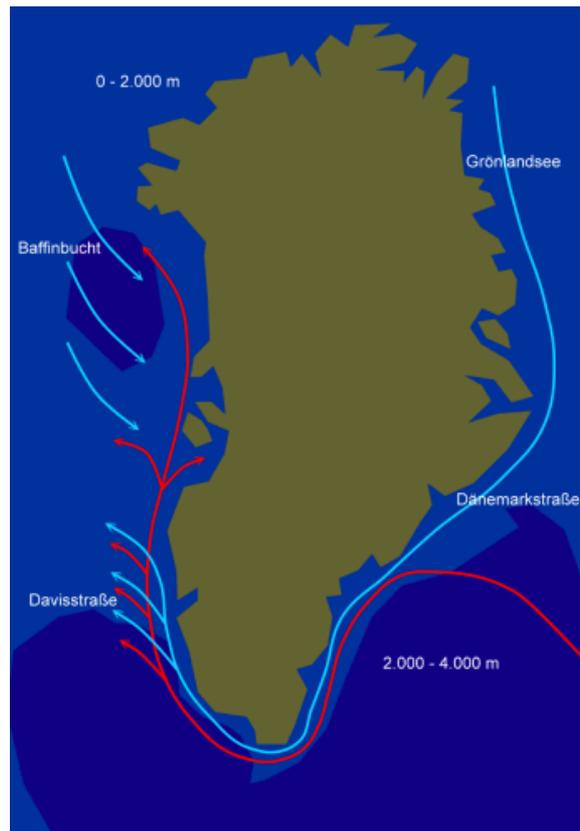


Schwarze Linien deuten die Position der jeweiligen meteorologischen Station bei Upernavik an.

Quelle: Eigene Darstellung, AE

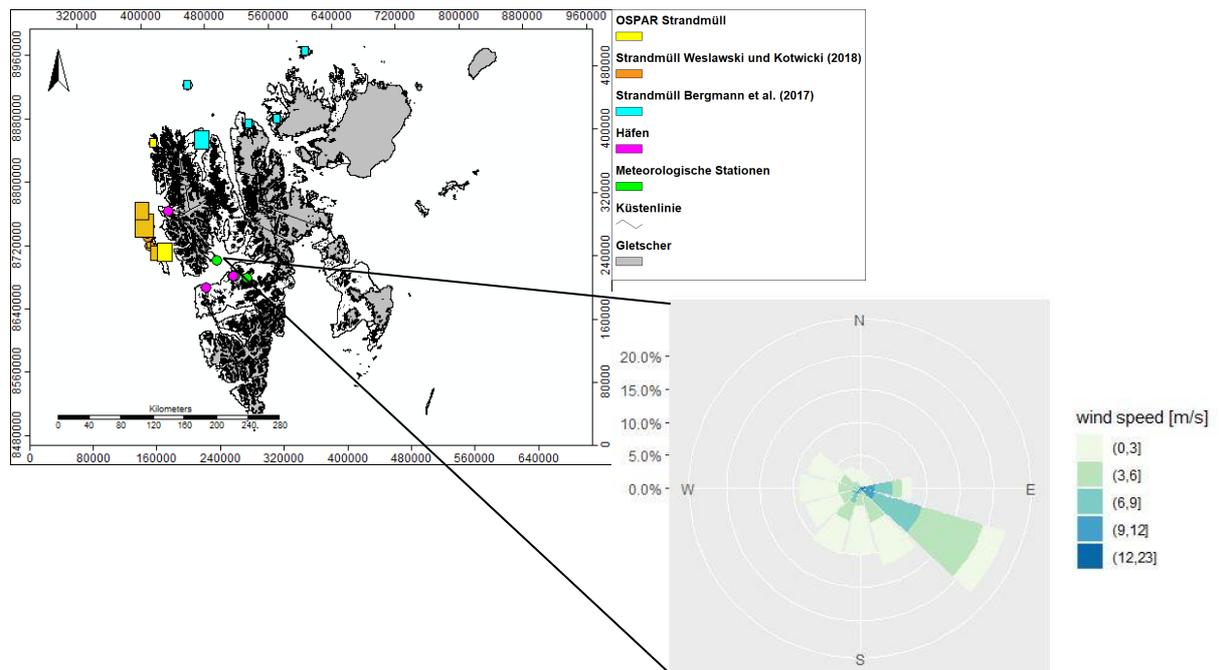
Darüber hinaus erklären die vorherrschenden residualen Strömungen zum Teil das vermehrte Auftreten von Strandmüll an der Westküste Grönlands (Abbildung 12). Daher wurde erwartet, dass in Nuuk, Ilulissat und Upernavik (B.1) Hotspots von Strandmüll vorhanden sind, was diese Küstenabschnitte zu geeigneten Stränden für die Untersuchung in diesem Projekt macht. Die beobachteten geringen Mengen an Strandmüll an der Westküste von Spitzbergen (Weslawski und Kotwicki, 2018) sind auf die vor den vorherrschenden Ostwinden geschützten Lage zurückzuführen (Abbildung 13). Im Norden Spitzbergens wurden an wind- und strömungsexponierten Strandabschnitten große Mengen an Strandmüll gefunden (Bergmann et al., 2017). Die für Spitzbergen in der obigen Abbildung angegebene Windrose ist beispielhaft für eine Reihe von Windrosen (d.h. für fünf Standorte auf Spitzbergen), die ähnliche Muster vorherrschender Ostwinde aufweisen. Im Gegensatz zu Grönland waren auf Spitzbergen nur wenige Informationen über mögliche Strandmüll beeinflussende Faktoren vorhanden. Daher ist für Spitzbergen die Interpretation der Strandmüll Daten sehr eingeschränkt.

Abbildung 12: Darstellung der vorherrschenden residualen Strömungen in den Gewässern um Grönland



Rote Pfeile zeigen warme Strömungen, blaue Pfeile zeigen kalte Strömungen. Quelle: arktis-reise.de

Abbildung 13: Karte von Spitzbergen mit einer Windrose



Schwarze Linien deuten die Position der jeweiligen meteorologischen Station bei Barentsburg an.
Quelle: Eigene Darstellung, AE

Tabelle 3 zeigt aggregierte Daten zum Schiffsverkehr in den Gewässern um Grönland. Die Schifffahrtsdichte unterschied sich zwischen West- und Ostgrönland um eine Größenordnung.

Tabelle 3: Aggregierte Daten zur Schifffahrt in den Gewässern um Grönland, beispielhaft angegeben für das Jahr 2016

Unterkategorie	Region	Arithmetisches Mittel [Häufigkeit]	Standardabweichung [Häufigkeit]
Alle Schiffe	Grönland	19.515	4.237
	Ostgrönland	744	958
	Westgrönland	18.771	3.579
Fischereifahrzeuge	Grönland	7.839	2.097
	Ostgrönland	256	149
	Westgrönland	7.583	2.125
Passagierschiffe	Grönland	941	268
	Ostgrönland	62	138
	Westgrönland	878	184
Andere Schiffe	Grönland	10.735	2.566
	Ostgrönland	425	785
	Westgrönland	10.310	1.977

Tabelle 4 fasst die Ergebnisse der PERMANCOVA zusammen, die gerechnet wurde, um die Quellen von Strandmüll auf Grönland zu identifizieren. Während eine Autokorrelation nicht definitiv ausgeschlossen werden konnte, waren Normalität (Kolmogorov-Smirnov-Test) und Varianzhomogenität (Levene-Test) gegeben. Daher wird angenommen, dass das Modell nicht oder kaum verzerrt ist. Die Modellgüte war mit einem Bestimmtheitsmaß von 0,83 gut. Fischerei und Übernachtungen wurden als signifikante Faktoren bzw. Kovariaten identifiziert, die die Häufigkeit von Strandmüll bestimmen. Dies steht im Einklang mit früheren Studien zu Strandmüll in der Arktis, welche die Dominanz von meerbasierten Quellen betonten (Bergmann et al., 2017; Kirkfeldt, 2016; Tekmann et al., 2017). Übernachtungen spiegeln nicht immer unbedingt den Einfluss des Tourismus wider. Sie sind hoch in Gebieten mit ausreichender Infrastruktur, wo auch die Emissionen von Hausmüll über Deponien und Wegwerfen hoch sind. Strietmann et al. (2021) identifizierten an mehreren Orten an der Westküste Grönlands Hausmüll als dominierenden Teil des Strandmülls, während die Fischerei einen weiteren großen Beitrag zum Strandmüll lieferte. Dies steht auch im Einklang mit den Ergebnissen von Mallory et al. (2021), die feststellten, dass die Entfernung zu Siedlungen die Strandmüllsdichte an der Westküste Grönlands signifikant erklärt, während angenommen wurde, dass der Transport über große Entfernungen aus seebasierten Quellen selbst an abgelegenen Stränden in hohen Breiten zu einer hohen Strandmüllsdichte beiträgt. Strand et al. (2021) verwendeten ein Lagrange-Transportmodell. Die Autoren nahmen an, dass fischereibedingte Abfälle an Strandstandorten auf Spitzbergen aus lokalen Quellen (der Barentssee und der norwegischen See) stammen. In Übereinstimmung damit führten Vesman et al. (2020) Meeresquellen als Hauptverursacher von Strandmüll auf der Nordinsel des Nowaja-Zemlya-Archipels an.

Tabelle 4: Ergebnisse einer Permutationsanalyse der Kovarianz (PERMANCOVA)

Faktor/ Kovariate	t [-]	p [-]	d [-]
Fischereifahrzeuge	15,196	0,002	
Bewohner	1,551	0,239	
Entfernung zu Siedlungen	0,573	0,465	
Entfernung zum Hafen	0,274	0,611	
Übernachtungen	36,823	<0,001	
Tests			
Levene-Test		0,217	
Kolmogorov-Smirnov-Test		0,438	
Dublin-Watson-Test			1,634

Ergebnisse einer Permutationsanalyse der Kovarianz (PERMANCOVA) zu den treibenden Kräften von Strandmüll auf Grönland ($r^2 = 0,827$, $p < 0,05$, $n = 17$).

3.2 Modellierungsansatz zur Identifizierung von Anreicherungen von Strandmüll

3.2.1 Methoden

Das Hauptziel dieser Analyse war die Vorhersage von Orten rund um Spitzbergen mit einer hohen Wahrscheinlichkeit für die Anlandung von Makroplastik. BCSH verwendete zwei Strömungsdatensätze mit unterschiedlichen räumlichen Auflösungen und bewertete die Ergebnisse beider Modelle. Für Grönland stand kein hochauflösender Datensatz über Meeresströmungen zur Verfügung, weshalb der Modellierungsansatz nicht angewandt wurde.

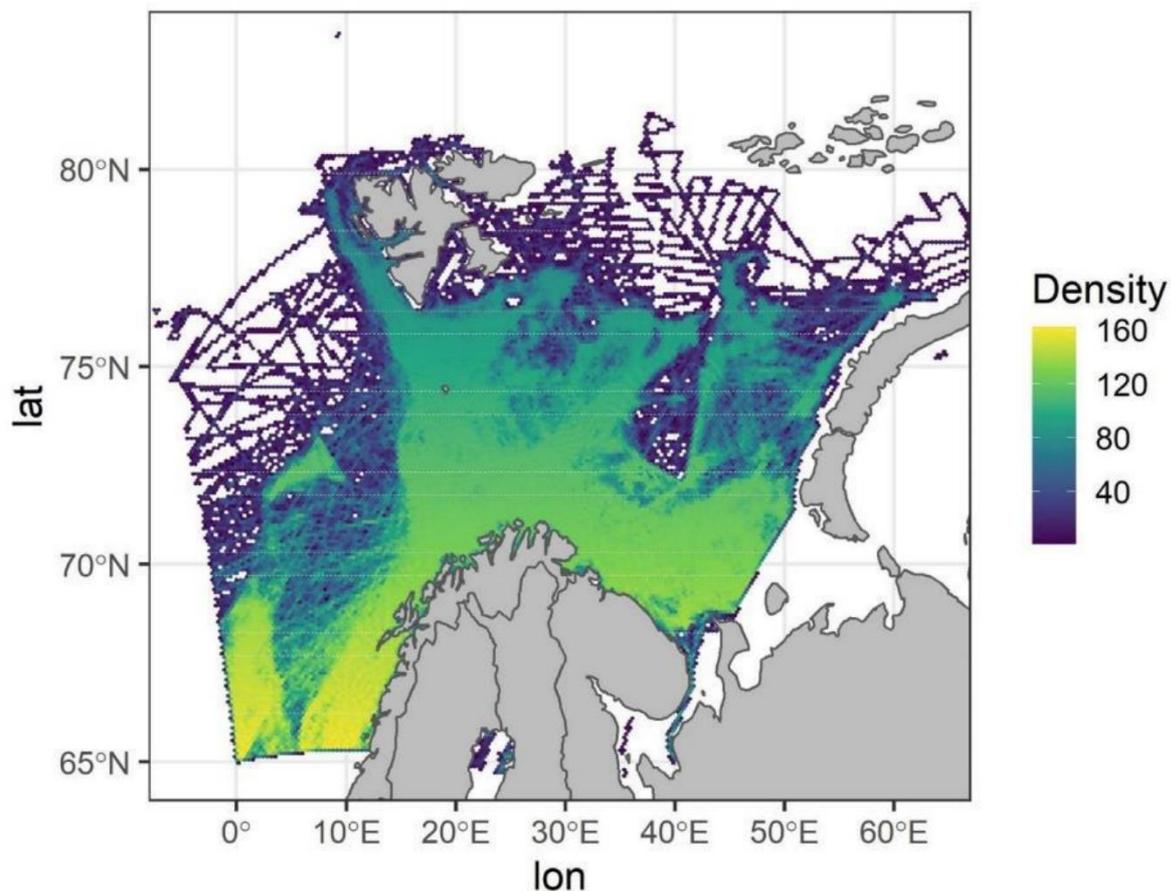
3.2.1.1 Datenquellen

3.2.1.1.1 Fischereidaten

In weiten Teilen der Arktis dominieren meeresbasierte Quellen von Müll, wobei die Fischerei die Hauptquelle darstellt (Bergmann et al., 2017; PAME, 2019; Tekmann et al., 2017). Bergmann et al. (2017) beschreiben, dass 44 bis 100% der Masse des bei Stranduntersuchungen in Spitzbergen gesammelten Mülls aus fischereibezogenen Objekten besteht. Daher wurden Fischereidaten für eine erste Schätzung der monatlichen Abfallquellen verwendet, die aus der Fischerei in der Region um Spitzbergen stammen. Die Fischereitätigkeit in dem Gebiet nördlich des 65. Breitengrades und zwischen 5° westlicher und 65° östlicher Länge wurde als Quelle berücksichtigt (Abbildung 14).

Zunächst wurde die Fischereitätigkeit aus den monatlichen AIS-Daten für 2019 ermittelt, die auf der EMODNET-Website (<https://www.emodnet-humanactivities.eu/view-data.php>) verfügbar sind, und im Rasterformat heruntergeladen. Jedes Monatsraster stellt die Anzahl der Routen von Fischerbooten pro Quadratkilometer dar (Abbildung 14). Anschließend haben wir auf der Grundlage der monatlichen Rasterdichte alle 100 km der Route (0,1% der Gesamtpunkte) zufällig Plastikpartikel auf dem Meer platziert. Schließlich wurde jeder monatliche Partikeldatensatz als unabhängige Textdatei gespeichert, um ihn später in die vorliegenden Modelle zu laden.

Abbildung 14: Kumulierte Verkehrsdichte



Kumulierte Verkehrsdichte (Anzahl der Routen pro Quadratkilometer) für das Jahr 2019 mit Eingangsdaten der EMODNET-Website. Quelle: Eigene Darstellung, BCSH

3.2.1.1.2 Daten zu Meeresströmungen

Es wurden zwei Datensätze mit täglichen Strömungen ausgewertet, von denen sich beide in der räumlichen Auflösung und der Ausdehnung des Gebiets unterschieden:

Ein Datensatz mit geringerer Auflösung und größerer räumlicher Ausdehnung wurde von der Marine Copernicus Website (<https://marine.copernicus.eu>) heruntergeladen, mit einer Auflösung von $0,025 \times 0,025$ Grad und einer räumlichen Ausdehnung von -10°W bis 60°E und von 55°N bis 90°N sowie einer zeitlichen Ausdehnung von zwei Jahren, vom 15. August 2008 bis zum 15. August 2010 (C.1). Ziel dieser Ebene war es, die Wege der freigesetzten Kunststoffpartikel in Abhängigkeit von der monatlichen Fischereiintensität zu simulieren. Sie wurde auch verwendet, um die Partikel in das höher aufgelöste Modell einfließen zu lassen.

Zusätzlich sind auf der Website des norwegischen Wetterdienstes (<https://api.npolar.no>) tägliche Strömungsdaten in höherer Auflösung und in einem engeren räumlichen Bereich um Spitzbergen verfügbar. Dieser Datensatz ist von 2005 bis 2010 mit einer räumlichen Auflösung von 800 m verfügbar und deckt ein engeres Gebiet um Spitzbergen ab. Daher konnte er nicht das gesamte für diese Studie betrachtete Fischereigebiet abdecken (C.2), und die Kunststoffpartikel mussten aus dem Modell mit geringerer Auflösung eingespeist werden. Die Strömungsdaten wurden für einen Zeitraum von einem Jahr, vom 16. August 2009 bis zum 16. August 2010, heruntergeladen.

3.2.1.1.3 Wind- und Wellendaten

Auch wenn Wind- und Wellenschlagdaten wichtige Komponenten für die Vorhersage der Routen von treibenden Objekten auf dem Meer sind, wurden für das betrachtete Gebiet und den betrachteten Zeitraum keine zuverlässigen Daten gefunden. Die meisten satellitengestützten Wind- und Wellendaten waren entweder für die Jahre 2008 bis 2010 nicht verfügbar oder deckten die Breitengrade oberhalb von 80°N nicht ab. Darüber hinaus war die Auflösung nie höher als 0,25°. Daher konnten Wind- und Wellendaten für die vorliegende Studie nicht berücksichtigt werden.

3.2.1.2 Modelle für Partikelbewegungen

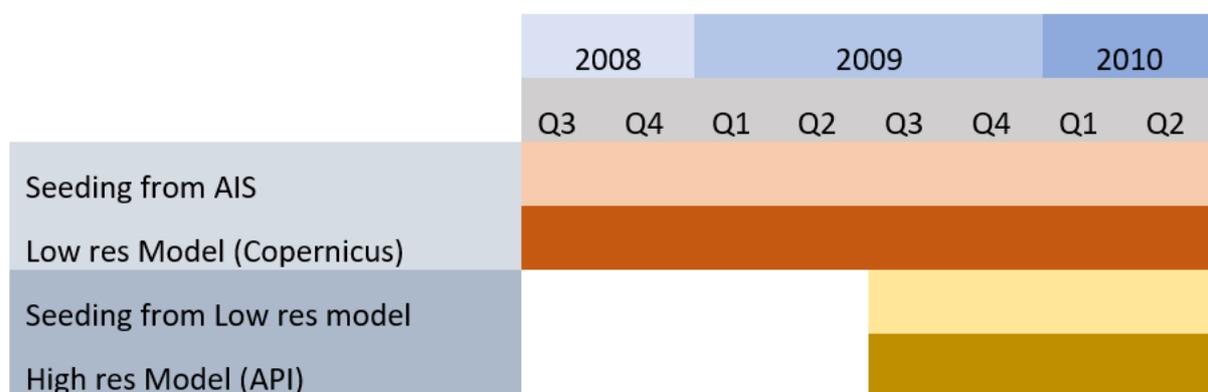
Die Modellierung wurde mit OpenDrift v1.0 durchgeführt, einem Open-Source-Framework auf Python-Basis für die Lagrangesche Partikelmodellierung (Dagestad et al. 2018).

Lagrangesche Trajektorienmodelle werden häufig verwendet, um die Bahnen von treibenden Objekten im Ozean vorherzusagen. Die Daten zu den Strömungen wurden als NetCDF-Dateien (Copernicus) oder NetCDF-ROMS-Dateien (API) eingespeist, während die Partikel nach dem Zufallsprinzip aus den Textdateien des entsprechenden Monats entnommen wurden.

Wie bereits erwähnt, wurde die Modellierung in zwei Phasen durchgeführt. In der ersten Phase (LR-Modell) wurde das Partikeltrajektorienmodell auf die simulierten Meeresabfälle angewandt, die zwischen August 2008 und August 2010 jeden Monat im Gebiet freigesetzt wurden, wobei die niedrig aufgelösten Strömungsdaten von Copernicus verwendet wurden. In der zweiten Phase (HR-Modell) wurden die Partikel aus dem LR-Modell, die in das von den hochauflösenden Strömungsdaten (API) abgedeckte Gebiet gelangen, in die hochauflösenden Strömungsdaten von API von August 2009 bis August 2010 eingespeist (Abbildung 15).

Für beide Modelle wurde die Standardkonfiguration des PlasticDrift-Moduls verwendet. Aufgrund des Mangels an Daten zu Wind und Wellengang wurde ein Unsicherheitsfaktor von 10% in die Strömungen einbezogen, um den Partikeln mehr Raum für die Ausbreitung über eine größere Oberfläche zu geben und realistischere Bedingungen zu simulieren als die, die allein durch die Meeresströmung entstehen.

Abbildung 15: Schematische Darstellung der Einspeisung- und Modellierungszeiträume



Schematische Darstellung der Einspeisungs- und Modellierungszeiträume für das niedrig auflösende und das hochauflösende Modell der Kunststofftrajektorien. Die Einspeisung der Partikel aus den AIS-Daten erfolgte während des gesamten Zeitraums für das niedrig auflösende Modell, wohingegen die Einspeisung der Partikel in das hochauflösende Modell unter Verwendung der Ergebnisse des niedrig auflösenden Modells als Partikelquelle zwischen August 2009 erfolgte. Quelle: Eigene Darstellung, BCSH

Die kumulative Strandung der Müllpartikel zum Ende des Untersuchungszeitraums (August 2010) wurde für das LR-Modell und das HR-Modell ermittelt und für die weitere Analyse als NetCDF-Dateien gespeichert.

3.2.1.3 Strandungsdichte und Vergleich der Modelle

Die gestrandeten Partikel im Gebiet um Spitzbergen wurden sowohl aus dem LR-Modell als auch aus dem HR-Modell in die Software R (RCore, 2019) importiert und mit der ggplot2-Bibliothek (REF) visualisiert. Die statistische Korrelation zwischen beiden Punktverteilungen wurde mit Hilfe eines linearen Modells bewertet. Darüber hinaus wurden statistische Unterschiede zwischen den räumlichen Dichtemustern gestrandeter Partikel entlang der Küste bewertet, indem die Signifikanz der paarweisen Unterschiede relativ zum Mittelwert und zur Varianz aller Unterschiede zwischen den beiden Eingabedatensätzen berechnet wurde. Auf diese Weise konnten Regionen mit signifikanten Unterschieden zwischen den beiden Datensätzen identifiziert werden (z. B. Bateman et al. 2010; Januchowski et al. 2010). Signifikante räumliche Unterschiede wurden mithilfe der SDMTools-Bibliothek (REF) in der Software R analysiert.

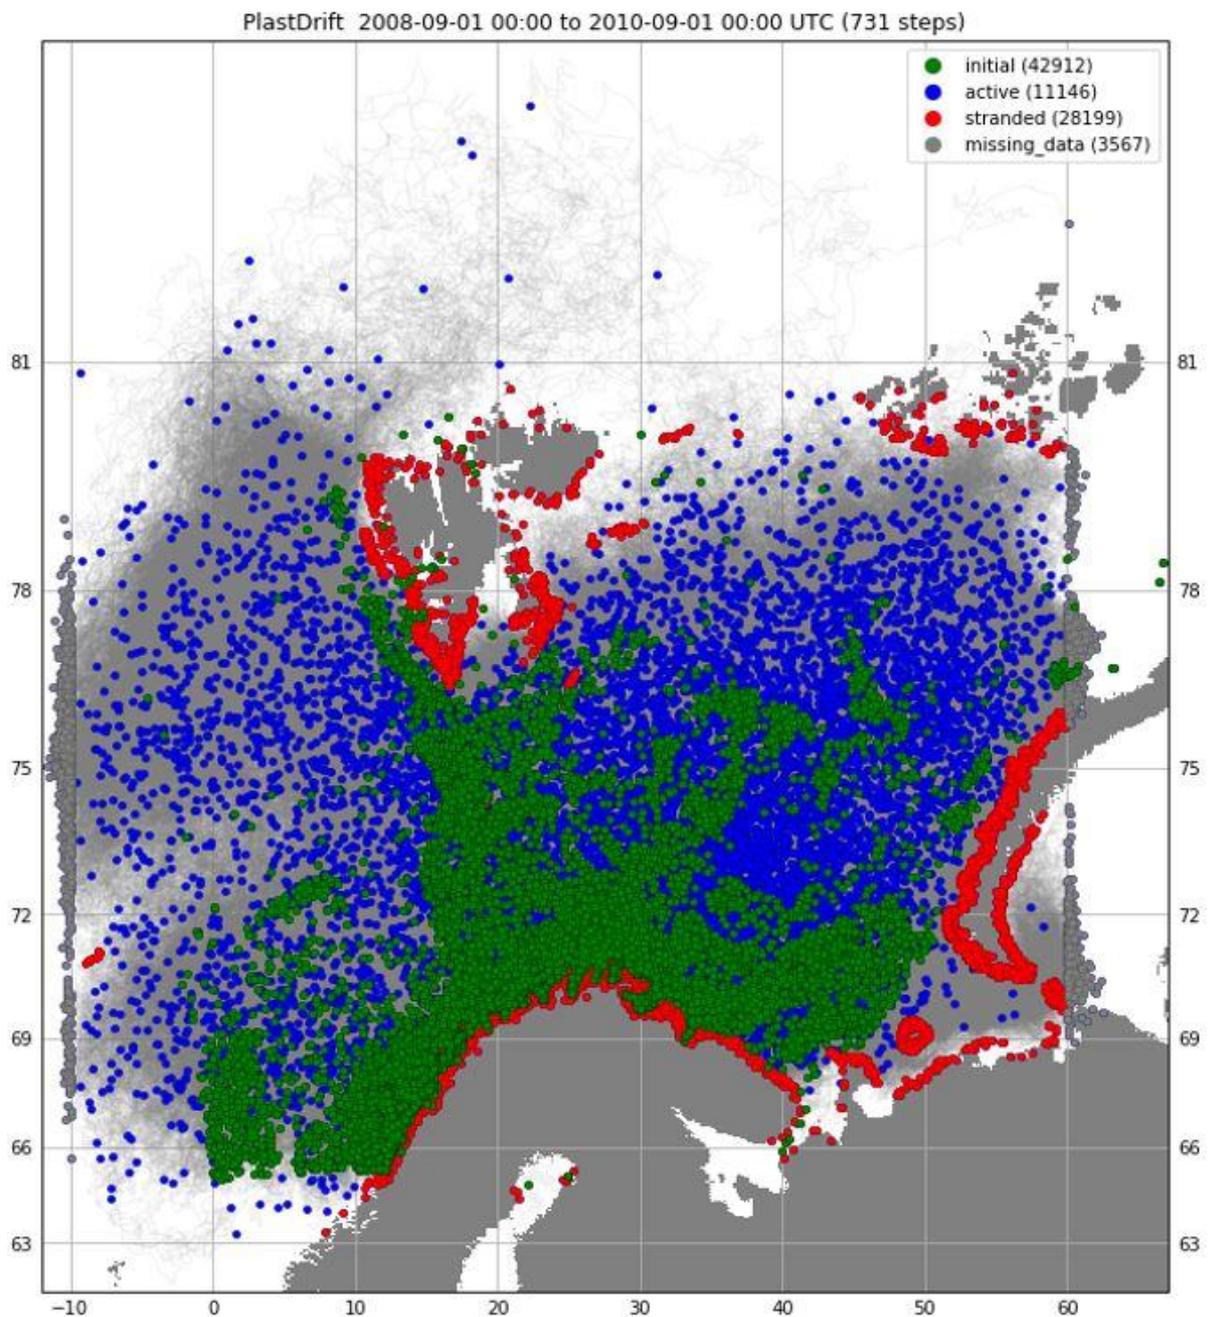
3.2.2 Ergebnisse

3.2.2.1 Ergebnisse der Müllanlandung für unterschiedliche Modellauflösungen

Die Ergebnisse zum Ende des Untersuchungszeitraums (August 2010) sind für das LR-Modell (Abbildung 16) und das HR-Modell (Abbildung 17) dargestellt. In beiden Fällen stellen die grünen Punkte die anfänglich freigesetzten Plastikpartikel dar (42.912 Partikel für das LR-Modell und 13.948 Partikel für das HR-Modell).

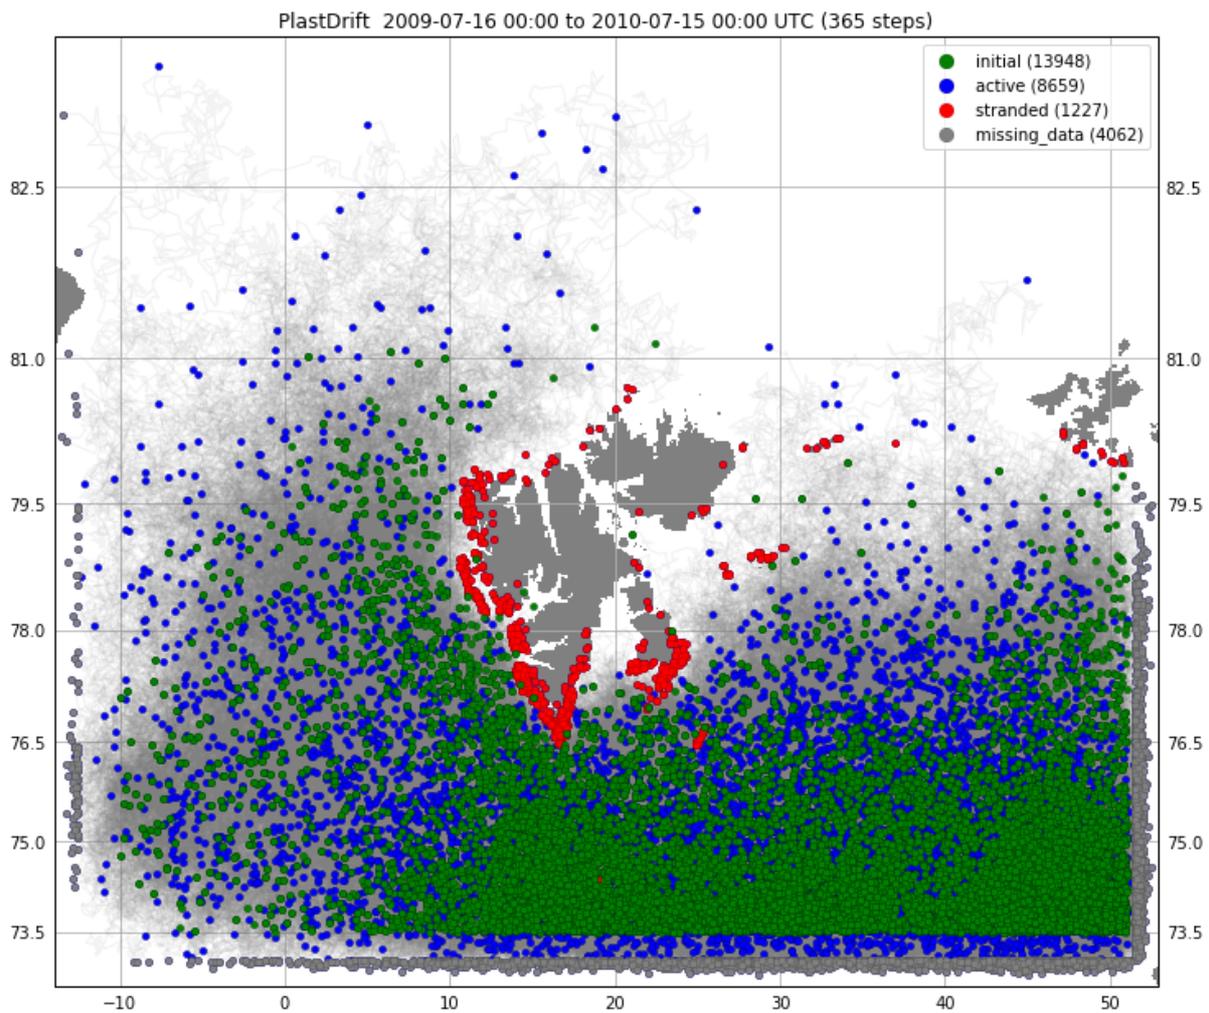
Die detaillierten Strandungspunkte und die Dichte der Punkte sind in Abbildung 18 für das LR-Modell bzw. in Abbildung 19 für das HR-Modell dargestellt. Beide Partikeltrajektorienmodelle zeigen ähnliche Strandungsmuster, unabhängig von ihrer räumlichen Auflösung. Die höchste Strandungswahrscheinlichkeit trat an der Süd- und Westküste Spitzbergens auf.

Abbildung 16: Anfangs- und Endsituation des LR-Modells



Grüne Punkte stellen die aus den AIS-Daten ermittelten Ausgangspositionen der Partikel dar, blaue Punkte die endgültigen (aktiven) Partikelpositionen, rote Punkte die gestrandeten Partikel und graue Punkte fehlende Partikel (die das Untersuchungsgebiet verlassen haben). Die grauen Linien zeigen die Routen der Partikel. Quelle: Eigene Darstellung, BCSH

Abbildung 17: Ausgangs- und Endsituation des HR-Modells

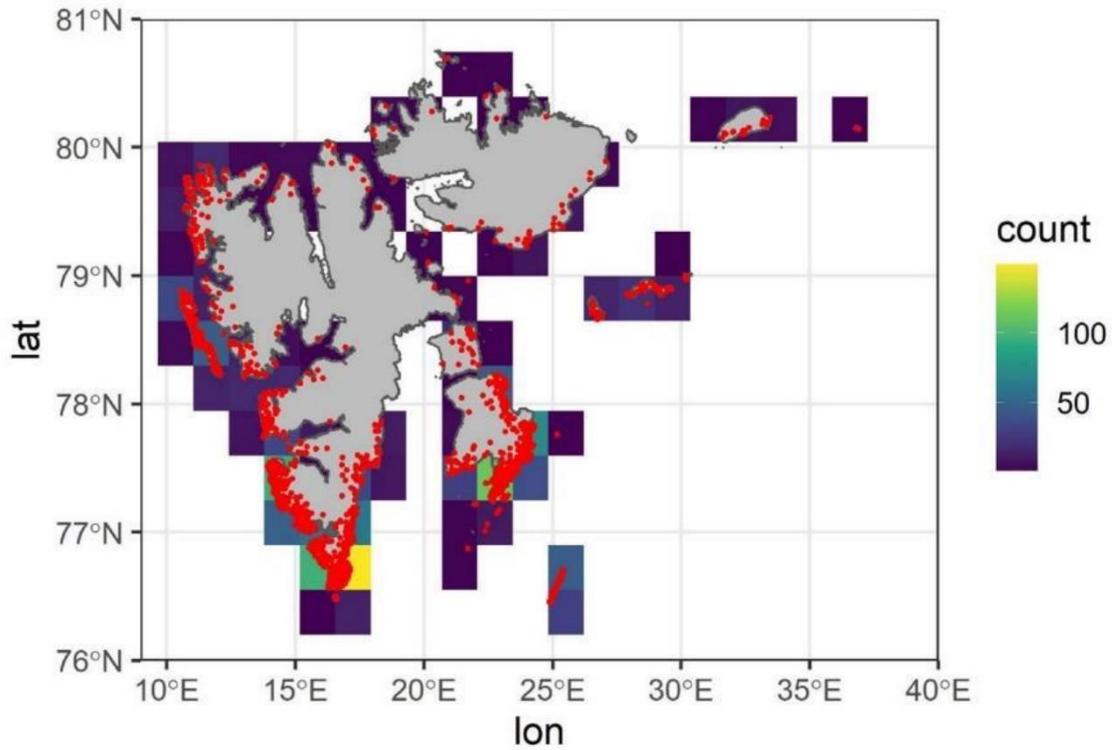


Die grünen Punkte stellen die Ausgangspositionen der Partikel aus dem LR-Modell dar, blaue Punkte die endgültigen (aktiven) Partikelpositionen, rote Punkte die gestrandeten Partikel und graue Punkte fehlende Partikel (die das Untersuchungsgebiet verlassen haben). Die grauen Linien zeigen die Routen der Partikel. Quelle: Eigene Darstellung, BCSH

3.2.2.2 Vergleich der Ergebnisse zur Müllstrandung

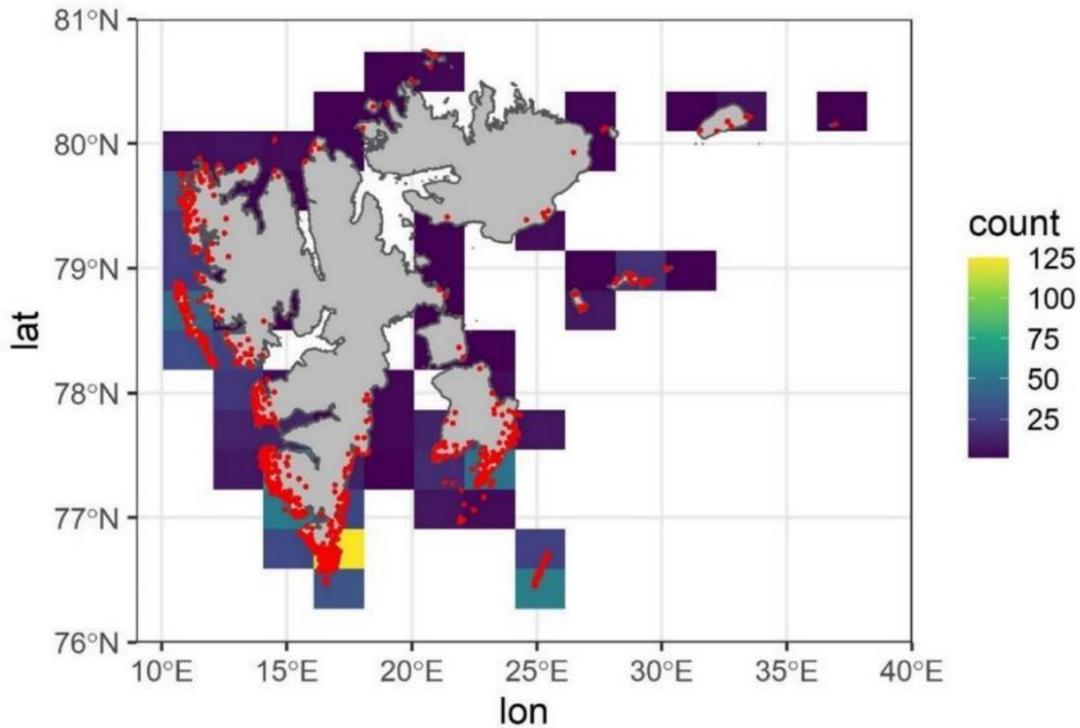
Um zwei vergleichbare Datensätze zu erhalten, wurden die Punkte in Zellen von 5 km x 5 km, die die Küstenlinie schneiden, zusammengefasst (Abbildung 20). Ein lineares Regressionsmodell zeigte einen signifikanten Zusammenhang zwischen den beiden Dichteverteilungen entlang der Küste von Spitzbergen mit einem Bestimmtheitsmaß (R^2) von 0,758. Die Residuen des linearen Regressionsmodells zeigten größere Abweichungen zwischen den vorhergesagten Beständen an der Südküste (Abbildung 21). Eine Analyse der räumlich signifikanten Unterschiede bestätigte die Ergebnisse der linearen Regression und zeigte signifikante Unterschiede im südlichen und westlichen Bereich (Abbildung 22). Das HR-Trajektorienmodell zeigte eine höhere Wahrscheinlichkeit für gestrandete Partikel an der Westküste und auf der Insel Hopen (gekennzeichnet durch orangefarbene Quadrate), während das LR-Trajektorienmodell eine höhere Wahrscheinlichkeit für gestrandete Partikel im Storfjord und auf Edgeøya zeigte (gekennzeichnet durch grüne Quadrate).

Abbildung 18: Gestrandete Partikel und Partikeldichte des LR-Modells



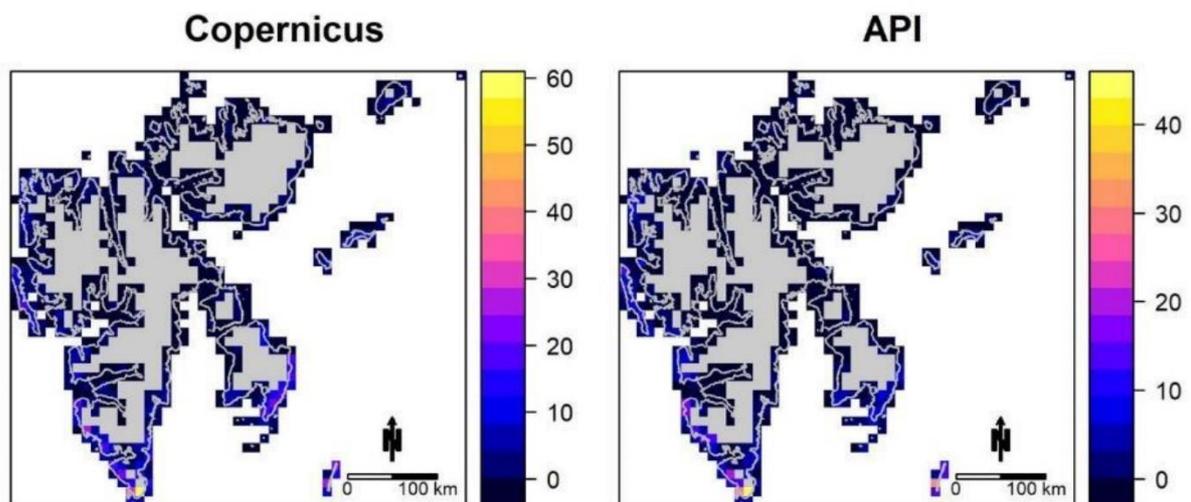
Gestrandete Partikel (rote Punkte) und Geschätzte Partikeldichte entlang der Küste von Spitzbergen, abgeleitet aus dem Low-Resolution-Modell zum letzten Zeitschritt. Quelle: Eigene Darstellung, BCSH

Abbildung 19: Gestrandete Partikel und Partikeldichte des LR-Modells



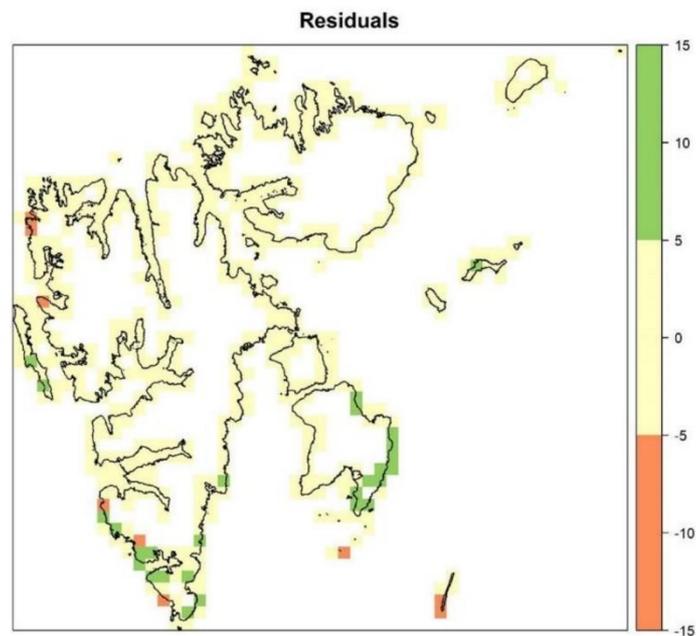
Gestrandete Partikel (rote Punkte) und Geschätzte Partikeldichte entlang der Küste von Spitzbergen, abgeleitet aus dem High-Resolution-Modell zum letzten Zeitschritt. Quelle: Eigene Darstellung, BCSH

Abbildung 20: Vergleich der Strandungsdichte der beiden Modelle



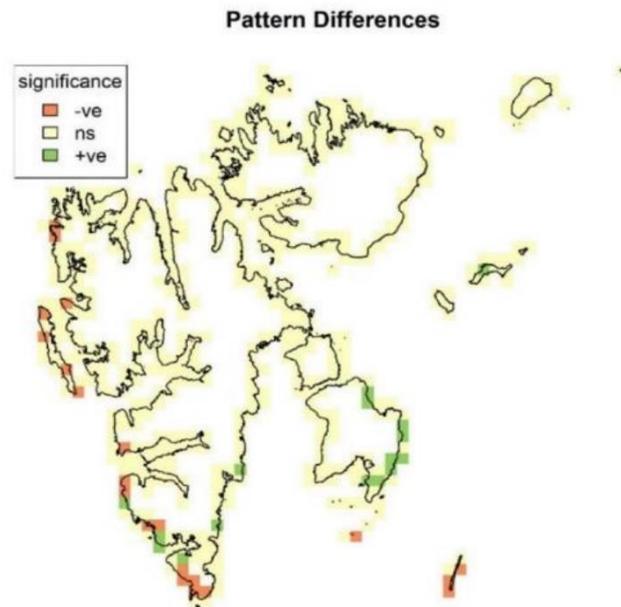
Dichte der gestrandeten Partikel in 5 km x 5 km großen Rasterzellen, die für den Vergleich zwischen den Ergebnissen des LR-Modells und des HR-Modells verwendet wurden. Quelle: Eigene Darstellung, BCSH

Abbildung 21: Residuen des linearen Modells zum Vergleich der Strandungsdichte, die mit dem HR- und dem LR-Modell ermittelt wurde



Obwohl die Ergebnisse gut miteinander korrelieren ($R^2 = 0,795$), wurden an der Süd- und Westküste hohe Residualwerte beobachtet. Rote Quadrate zeigen Gebiete mit einer deutlich höheren Strandungswahrscheinlichkeit nach dem HR-Modell. Grüne Quadrate zeigen Gebiete mit deutlich höherer Strandungswahrscheinlichkeit nach dem LR-Modell. Die Rasterzellen haben eine Auflösung von 5 km x 5 km. Quelle: Eigene Darstellung, BCSH

Abbildung 22: Unterschiede zwischen LR und HR



Signifikante räumliche Unterschiede zwischen den Strandungsdichten, die sich aus den HR- und LR-Modellen ergeben. Rote Quadrate zeigen Gebiete mit einer höheren signifikanten Strandungswahrscheinlichkeit im HR-Modell. Grüne Quadrate zeigen Gebiete mit einer höheren signifikanten Strandungswahrscheinlichkeit im LR-Modell. Die Rasterzellen haben eine Auflösung von 5 km x 5 km. Quelle: Eigene Darstellung, BCSH

3.2.3 Diskussion

Die Ergebnisse der beiden Modellansätze deuten darauf hin, dass Anhäufungen von Strandmüll hauptsächlich an der Westküste Spitzbergens stattfinden (Abbildung 18, Abbildung 19). Studien zur Strandmüllerrfassung auf Spitzbergen wiesen jedoch auf relativ geringe Ablagerungen an der Westküste hin, verglichen mit höheren Ablagerungen im Norden. Eine Erklärung dafür könnten die vorherrschenden Ostwinde sein. Da für das Untersuchungsgebiet keine Wind- und Wellendaten verfügbar waren, könnten sich die Ergebnisse ändern, sobald diese mit einbezogen werden. Wind- und Wellendaten sind auch eine Voraussetzung für die Leeway-Konfiguration, die im Vergleich zu PlasticDrift, eine genauere Modellkonfiguration für große Kunststoffteile darstellt. Bei der Interpretation der Strandmüll Daten auf Spitzbergen ist allgemein Vorsicht geboten, da Referenzdaten vor allem für die Nord- und Westküste zur Verfügung stehen und Informationen über die potenziellen Einflussfaktoren begrenzt sind. Unter der Annahme, dass die Ergebnisse beider Modelle (Copernicus und API) genügend Ähnlichkeiten aufweisen, könnte ein neues Modell mit niedriger Auflösung für 2019 mit Wind- und Wellendaten durchgeführt werden. Darüber hinaus sollten Daten über die Häufigkeit von Strandmüll, die bei der Feldarbeit dieser Studie erhoben wurden, in künftige Ansätze einbezogen werden. Die Ergebnisse der Modelle dieser Studie zeigen die Anzahl der an der Küste ankommenden Partikel. Die Partikel werden deaktiviert, sobald sie die Küstenlinie berühren. Sie könnten jedoch auch sofort wieder ins Wasser zurückkehren, wenn es sich nicht um eine Sedimentationsumgebung handelt (z. B. Klippen), oder wenn sie während der Flut oder eines Sturms an den Strand gelangen. Dies hängt von verschiedenen Faktoren wie der Art der Küste (Strand oder Klippe), der Neigung des Strandes oder dem Welleneinfall ab. Eine Folgestudie könnte auf dem bestehenden Modell aufbauen und Wind- und Wellendaten sowie Informationen über den Küstentyp einbeziehen. Informationen über einzelne Küstentypen könnten während der Feldarbeit für diese Studie gewonnen werden. Aufgrund der geringen Auflösung der Ozeanzirkulationsmodelle und der

Wind- und Wellendaten können die Modellierungsansätze bisher nur einen ersten Hinweis auf die Lage der Akkumulationsorte von Meeresmüll in der Arktis geben. Um einzelne Strände zu identifizieren, sind arktisweit höher aufgelöste Daten notwendig.

4 Arbeitspaket 3

4.1 Zusammenfassung der Feldarbeit

Am 30. April 2021 führten M. Schulz (AE), A. Trobisch (AE) und M. Schnurawa (BCSH) am Hundestrand von Rantum auf Sylt eine Strandmüllerhebung nach der OSPAR-Methode (2010) und eine Drohnenvermessung durch. Zwischen dem Dünengürtel und der Wasserlinie wurden zwei 50 m lange Strandabschnitte mit der OSPAR-Methode kartiert (OSPAR, 2010). Die Koordinaten großer Müllteile wurden mit einem hochauflösenden Global Positioning System (GPS) eingemessen. Anschließend erfolgte die Drohnenvermessung von M. Schnurawa an einem 600 m langen Strandabschnitt, der die beiden konventionell kartierten 50 m langen Strandabschnitte umfasste.

In den ersten sechs Monaten des Jahres 2021 organisierten A. Trobisch (AE) und M. Schnurawa (BCSH) die Expeditionen nach Spitzbergen und Grönland, um die verschiedenen logistischen Optionen zu prüfen. Erfolgversprechende Ansätze waren landgestützte Operationen mit lokalen Partnern mit Zodiacs oder kleinen Booten, das Chartern eines privaten Schiffes und die Zusammenarbeit mit Kreuzfahrtunternehmen.

Hinsichtlich der Kreuzfahrtveranstalter stand BCSH im Austausch mit der Association of Arctic Expedition Cruise Operators (AECO). Die Umweltspezialistin von AECO stellte das Projekt den AECO-Mitgliedern und mehreren Kreuzfahrtunternehmen (z. B. Arctic Sailing Escape, Hurtigruten, Marine Incognita, OceanWide und Secret Atlas) vor und kontaktierte BCSH, um eine mögliche Zusammenarbeit zu besprechen. Aufgrund der Unsicherheiten der Covid-19-Pandemie haben sich BCSH und AE jedoch gegen eine kreuzfahrtbasierte Feldarbeit entschieden. Dennoch ist eine Kooperation mit einem Kreuzfahrtanbieter eine attraktive Option, die für zukünftige Kampagnen in Betracht gezogen werden sollte, da sie wissenschaftliche Forschung, Öffentlichkeitsarbeit und Bildung kombinieren kann. Darüber hinaus erlaubt es die Anwendung von Citizen-Science-Ansätzen sowie eine Implementierung innerhalb einer bestehenden Infrastruktur.

Das Chartern eines privaten Schiffes wurde nur kurz in Betracht gezogen, da die Preise zu teuer waren und es nur sinnvoll finanzierbar wäre, wenn das Schiff mit anderen Interessengruppen oder Wissenschaftler:innen geteilt würde, was aufgrund der Covid-19-Pandemie nicht möglich war.

Letztendlich beschlossen BCSH und AE, den landgestützten Ansatz für alle Untersuchungsgebiete auf Spitzbergen und Grönland anzuwenden und dabei mit lokalen Partnern zusammenzuarbeiten. Von der Basisstation an Land aus wurden die Vermessungen geplant und die Ausrüstung vorbereitet. Ein Bootsführer brachte alle Teilnehmer:innen mit einem Zodiac oder einem kleinen Boot zum Untersuchungsgebiet. Da die Ergebnisse des Arbeitspakets 2 nur grobe Hinweise auf Strände mit hohem Müllvorkommen geben konnten, war lokale Expertise unerlässlich. Auf Spitzbergen lieferte Geir Gabrielsen vom NP detailliertes Wissen über potenzielle Strände. Für Grönland fand ein Informationsaustausch zwischen BCSH und AE mit WSP und dem WWF für Nuuk und dem Bootsführer Jan Banemann und der Gemeinde Qeqqata für Sisimiut statt. Der landgestützte Einsatz ermöglichte eine flexible Planung der Kartierungen und kurzfristige Entscheidungen, die auf Grund der Wetterbedingungen erforderlich waren.

Die Expedition nach Spitzbergen dauerte vom 25. Juni 2021 bis zum 17. Juli 2021. In Oslo war eine zehntägige Quarantäne notwendig, bevor am 5. Juli 2021 die Reise über Longyearbyen nach Ny-Ålesund fortgesetzt werden konnte. In Ny-Ålesund nahmen A. Trobisch und M. Schnurawa an wissenschaftlichen Treffen und Austausch innerhalb des Forschungscamps teil. Aufgrund

ungünstiger Wetterbedingungen war außer einem Test der Ausrüstung außerhalb der Radio Silent Zone am 7. Juli 2021 nur eine eintägige Exkursion für eine Strandmüllerhebung am Kapp Mitra möglich (Abbildung 24). Am Tag vor der Exkursion herrschte starker Wind, der wahrscheinlich das Anlanden von Treibgut beeinflusste. Neben A. Trobisch und M. Schnurawa nahmen ein Bootsführer, zwei Studierende und zwei Eisbärenbeobachter an der Exkursion teil. Insgesamt wurden zwei 50 m lange Strandabschnitte mit der OSPAR-Methode kartiert. Die Koordinaten wurden mittels eines hochauflösenden GPS bestimmt. Die Koordinaten einzelner Müllteile konnten mangels Zugangs zu Internet und Funk nicht gemessen werden. Ein zusätzlicher Strandabschnitt konnte nur zu 20% kartiert werden, da sich ein Eisbär näherte und die Exkursion daher abgebrochen werden musste. Tabelle 5 zeigt die Eigenschaften und Koordinaten der untersuchten Strandabschnitte.

Vor Beginn der OSPAR-Kartierung wurden Drohnen-Befliegungen durchgeführt (zwei RBG- und zwei VIR-Erhebungen; Abbildung 23). Die Befliegungen umfassten die beiden nach OSPAR überwachten Abschnitte und insgesamt ca. 2,75 km Küstenlinie und eine Fläche von rund 25 ha.

Ein WV3-Satellitenbild von Kapp Mitra wurden bereits am 25. Juli, 2021 aufgenommen. Die Aufnahme umfasst eine Fläche von ca. 7500 ha mit einer Küstenlinie von 23 km Länge und beinhaltet 17 Spektralbänder (1x panchromatisch, 8x RGB/NIR, 8x SWIR). Aufgrund der möglichen Bewölkung wurde eine Erfassungszeitspanne von bis zu drei Wochen vor der Feldarbeit gewählt. Der endgültige Versatz zwischen Satellitenerfassung und Feldarbeit betrug acht Tage.

Abbildung 23: Kapp Mitra, Landung von WingtraOne - Foto: Geir Wing Gabrielsen



Tabelle 5 **Koordinaten und Eigenschaften der beiden Strandabschnitte von Kapp Mitra, aufgenommen am 11. Juli 2021. Die Koordinaten sind als Universal Transverse Mercator (UTM) – Koordinaten angegeben mit dem Datum WGS84.**

Parameter	Kapp Mitra 1	Kapp Mitra 2
Position Start	550671,3N, 8783090,3E	550621,2N, 8783078,4E
Position Ende	550621,2N, 8783078,4E	550571,6N, 8783066,1E
Merkblatt Strand	nein	nein
Strandsubstrat	80% Felsen, 20% Sand	80% Felsen, 20% Sand
Strandneigung	10%	10%
Mittlere Breite bei Hochwasserniptide	15 m	15 m
Gesamtlänge des Strandes	175 m	175 m
Strandumgebung	Steine, Treibholz, Tundra	Steine, Treibholz, Tundra
Exposition zum Meer	SSE	SSE
Vorherrschende Windrichtung	E – SE	E – SE
Vorherrschende Strömung	Keine Information	Keine Information
Objekte, die Strömungen beeinflussen	Nein	Nein
Entfernung zur nächsten Siedlung/Hafen	23 km (Ny-Ålesund)	23 km (Ny-Ålesund)
Position der nächsten Siedlung/Hafen	SE	SE
Einwohnerzahl der nächsten Siedlung	50 (Winter) – 150 (Sommer)	50 (Winter) – 150 (Sommer)
Art des nächsten Hafens	Hauptsächlich Zodiacs und kleine Polarkreisboote, einige Robbenjagdboote und Versorgungsschiffe	Hauptsächlich Zodiacs und kleine Polarkreisboote, einige Robbenjagdboote und Versorgungsschiffe
Größe des nächsten Hafens	klein (10 – 15 Boote)	klein (10 – 15 Boote)
Nächste Flussmündung	Keine Information	Keine Information
Abwassereinleitung	nein	nein
Tourismus	nein	nein
Infrastruktur hinter dem Strand	nein	nein
Verpflegungsmöglichkeiten am Strand	nein	nein
Aktivitäten zur Strandreinigung	nein	nein

Parameter	Kapp Mitra 1	Kapp Mitra 2
Müllsammlung	nein	nein
Erreichbarkeit	Per Boot mit Eisbärenbeobachtern	Per Boot mit Eisbärenbeobachtern
Strandnutzung	Erstmalig für wissenschaftliche Zwecke, bisher keine Nutzung	Erstmalig für wissenschaftliche Zwecke, bisher keine Nutzung

Die Expedition nach Grönland fand vom 13.09.2021 bis zum 28.09.2021 statt. Aufgrund technischer Probleme der Fluggesellschaft musste der Rückflug auf den 29.09.2021 verschoben werden. Während des Aufenthaltes auf Grönland wurden Strandmüllerhebungen bei Nuuk und Sisimiut mit bis zu vier nachgebildeten Strandabschnitten durchgeführt (Tabelle 6). Die Anreise zu den ausgewählten Stränden erfolgte per Boot mit einem Bootsführer. Konventionelle Kartierungen wurden nach der OSPAR-Methode (OSPAR, 2010) durchgeführt, wobei die aktuelle Kategorisierung von 2021 verwendet wurde. Die Kategorisierung wurde um Strandmülltypen ergänzt, die für die Westküste Grönlands charakteristisch sind. Diese neuen Mülltypen wurden aus dem SUMAG-Projekt abgeleitet und basieren auf einer Aufteilung der OSPAR-Strandmülltypen, wie dies in ähnlicher Weise durch die Joint Category-Liste der MSRL erfolgt ist. Darüber hinaus wurden GNSS-Messungen durchgeführt, um die genaue Position des gefundenen Mülls als Referenz für die Drohnenkartierungen zu bestimmen. Aufgrund technischer Probleme mit dem GNSS-Empfänger stand dieser Ansatz nur für die beiden Kartierungsgebiete um Sisimiut zur Verfügung.

Vor Beginn des OSPAR-Monitorings wurden für jedes der sechs Untersuchungsgebiete Drohnenbefliegungen durchgeführt (zwei RBG- und zwei VIR-Untersuchungen; Tabelle 7). WV3-Satellitenbilder von Nuuk und Sisimiut wurden am 13. September bzw. 15. September 2021 aufgenommen. Alle Standorte waren wolkenfrei. Eine Übersicht über die Satellitenabdeckung ist in Abbildung 25 und Abbildung 26 dargestellt. Bei Nuuk betrug der Zeitunterschied zwischen Satellitenaufnahme und Feldarbeit nur zwei bis vier Tage, bei Sisimiut sechs bis sieben Tage.

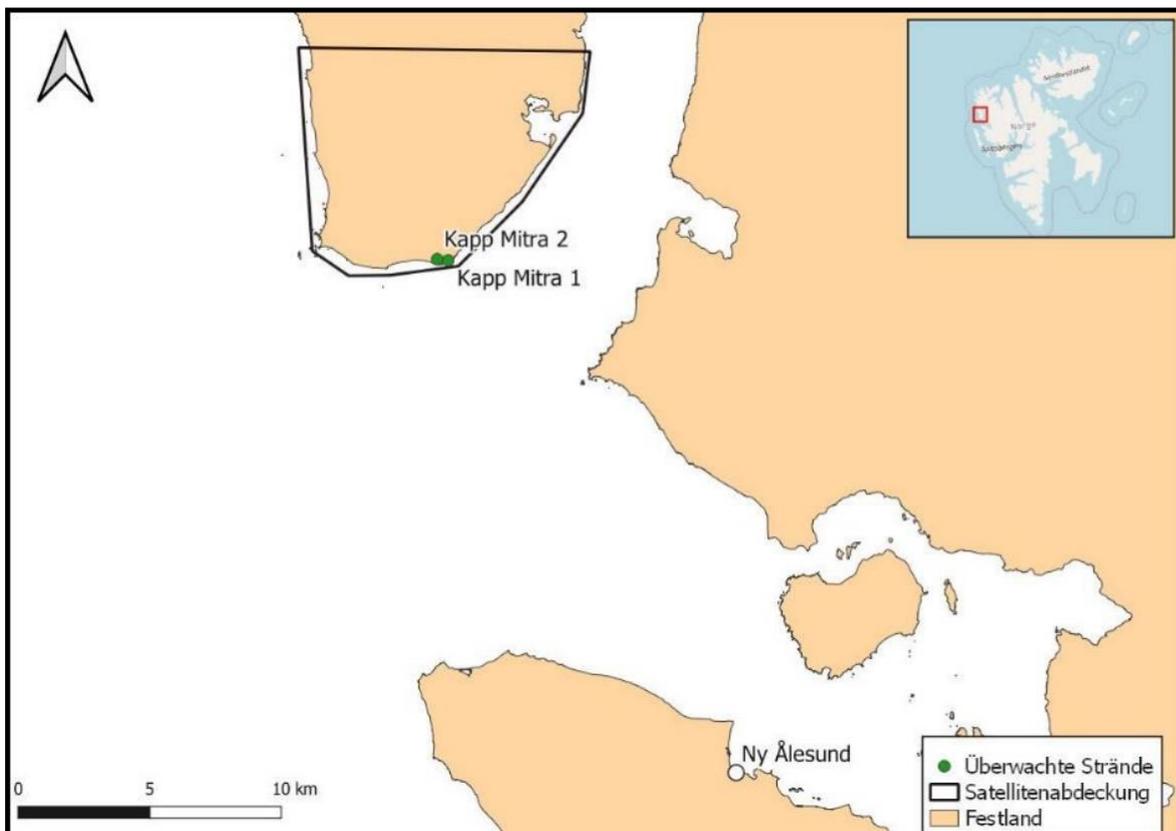
Tabelle 6: Koordinaten und Eigenschaften kartierter Strandabschnitte bei Nuuk und Sisimiut. Koordinaten werden als Universal Transverse Mercator (UTM) – Koordinaten angegeben mit dem Datum WGS84.

Parameter	Nuuk Tag 1	Nuuk Tag 2-1	Nuuk Tag 2-2	Nuuk Tag 2-3	Nuuk Tag 3	Sisimiut Tag 4-1	Sisimiut Tag 4-2	Sisimiut Tag 4-3	Sisimiut Tag 4-4	Sisimiut Tag 5-1	Sisimiut Tag 5-2
Daten	September 15, 21	September 16, 21	September 16, 21	September 16, 21	September 17, 21	September 23, 21	September 23, 21	September 23, 21	September 23, 21	September 24, 21	September 24, 21
Position Start	461901N, 7109578E	462106N, 7109376E	462850N, 7105287E	462855N, 7105248E	462037N, 7094362E	404196N, 7424987E	404180N, 7425034E	404138N, 7425123E	404114N, 7425167E	409475N, 7424354E	409590N, 7424297E
Position Ende	461862N, 7109570E	462093N, 7109345E	462879N, 7105285E	462840N, 7105163E	462022N, 7094386E	404180N, 7425034E	404138N, 7425123E	404114N, 7425167E	404086N, 7425208E	409505N, 7424323E	409578N, 7424332E
Strandsubstrat	90% Kies	50% Kies, 50% Steine	50% Kies, 50% Sand	100% Kies	90% Kies	100% Sand	100% Sand	100% Sand	100% Sand	85% Sand, 12,5% Kies, 2,5% Steine	85% Sand, 15% Kies
Strandreinigung	Nein	Nein	Nein	Saisonal im Mai/Juni und September /Oktober	Nein	Nein	Nein	Nein	Nein	Nein	Nein
Mittlere Breite bei Hochwasser- nippide	15 m	17 m	8 m	5 m	11 m	9 m	9 m	9 m	9 m	8 m	14 m
Gesamtlänge des Strandes	40 m	30 m	30 m	90 m	30 m	250 m	250 m	250 m	250 m	50 m	50 m
Strandumgebung	Tundra	Tundra	Tundra und Grasland	Tundra	Tundra	Tundra	Tundra	Tundra	Tundra	Tundra	Tundra
Exposition zum Meer	Keine Angabe	N	S/ SE	E.	S/ SE	WSW	WSW	WSW	WSW	Keine Angabe	Keine Angabe

Parameter	Nuuk Tag 1	Nuuk Tag 2-1	Nuuk Tag 2-2	Nuuk Tag 2-3	Nuuk Tag 3	Sisimiut Tag 4-1	Sisimiut Tag 4-2	Sisimiut Tag 4-3	Sisimiut Tag 4-4	Sisimiut Tag 5-1	Sisimiut Tag 5-2
Vorherrschende Windrichtung	NE	E/ NO	S/ SE	S/ SE	S/ SE	Keine Angabe	Keine Angabe	Keine Angabe	Keine Angabe	Keine Angabe	W
Vorherrschende Richtung der Strömungen	NE	E/NE	S/ SE	S/ SE	S/ SE	W	W	W	W	W	W
Objekte, die küstennahe Strömungen beeinflussen	Nein	Nein	Nein	Nein	Nein	Nein	Nein	Nein	Nein	Nein	Nein
Entfernung zur nächsten Siedlung/Hafen	6,5 km	6,5 km	11 km	11 km	21 km	20 km	20 km	20 km	20 km	27 km	27 km
Lage der nächsten Siedlung/ Hafen	NE	NE	N	N	N	WNW	WNW	WNW	WNW	NW	NW
Einwohnerzahl der nächsten Siedlung	17.500	17.500	17.500	17.500	17.500	5.500	5.500	5.500	5.500	5.500	5.500
Art des nächsten Hafens	Kleine und große Schiffe, Fähren und Container- schiffe	Kleine und große Schiffe, Fähren und Container- schiffe	Kleine und große Schiffe, Fähren und Container- schiffe	Kleine und große Schiffe, Fähren und Container- schiffe	Kleine und große Schiffe, Fähren und Container- schiffe	Seehafen	Seehafen	Seehafen	Seehafen	Seehafen	Seehafen
Größe des nächsten Hafens	groß	groß	groß	groß	groß	klein	klein	klein	klein	klein	klein
Tourismus	nein	nein	nein	nein	nein	nein	nein	nein	nein	nein	nein

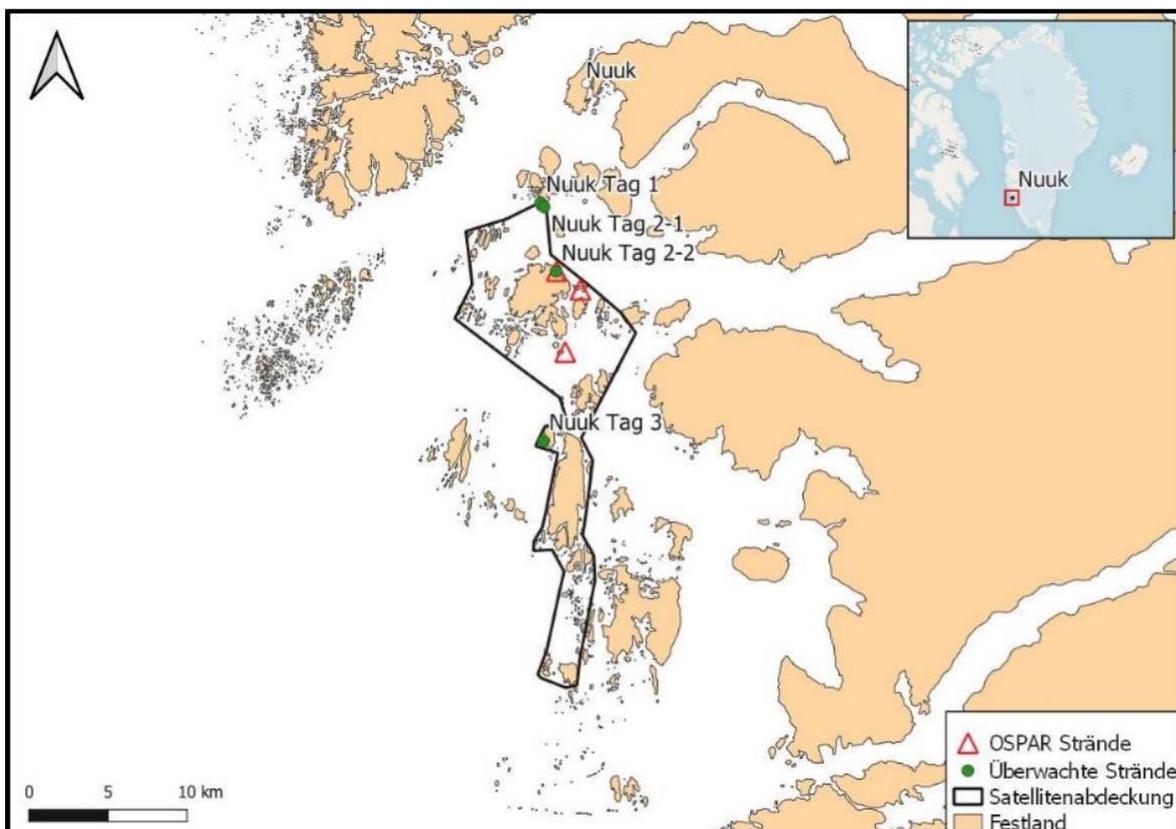
Parameter	Nuuk Tag 1	Nuuk Tag 2-1	Nuuk Tag 2-2	Nuuk Tag 2-3	Nuuk Tag 3	Sisimiut Tag 4-1	Sisimiut Tag 4-2	Sisimiut Tag 4-3	Sisimiut Tag 4-4	Sisimiut Tag 5-1	Sisimiut Tag 5-2
Infrastruktur hinter dem Strand	keine	keine	keine	keine	keine	keine	keine	keine	keine	keine	keine
Verpflegungs- möglichkeiten am Strand	keine	keine	keine	keine	keine	keine	keine	keiner	keine	keine	keine
Strandreinigungs- aktivitäten	nein	nein	nein	Ja	nein	nein	nein	nein	nein	2019	2019
Müllsammlung	nein	nein	nein	Ja	nein	nein	nein	nein	nein	2019	2019
Erreichbarkeit	Mit Schiff	Mit Schiff	Mit Schiff	Mit Schiff	Mit Schiff	Mit Schiff	Mit Schiff				
Strandnutzung	Fischerei in der Nähe	Keine Infor- mation									

Abbildung 24: Untersuchungsgebiet Spitzbergen: Kapp Mitra



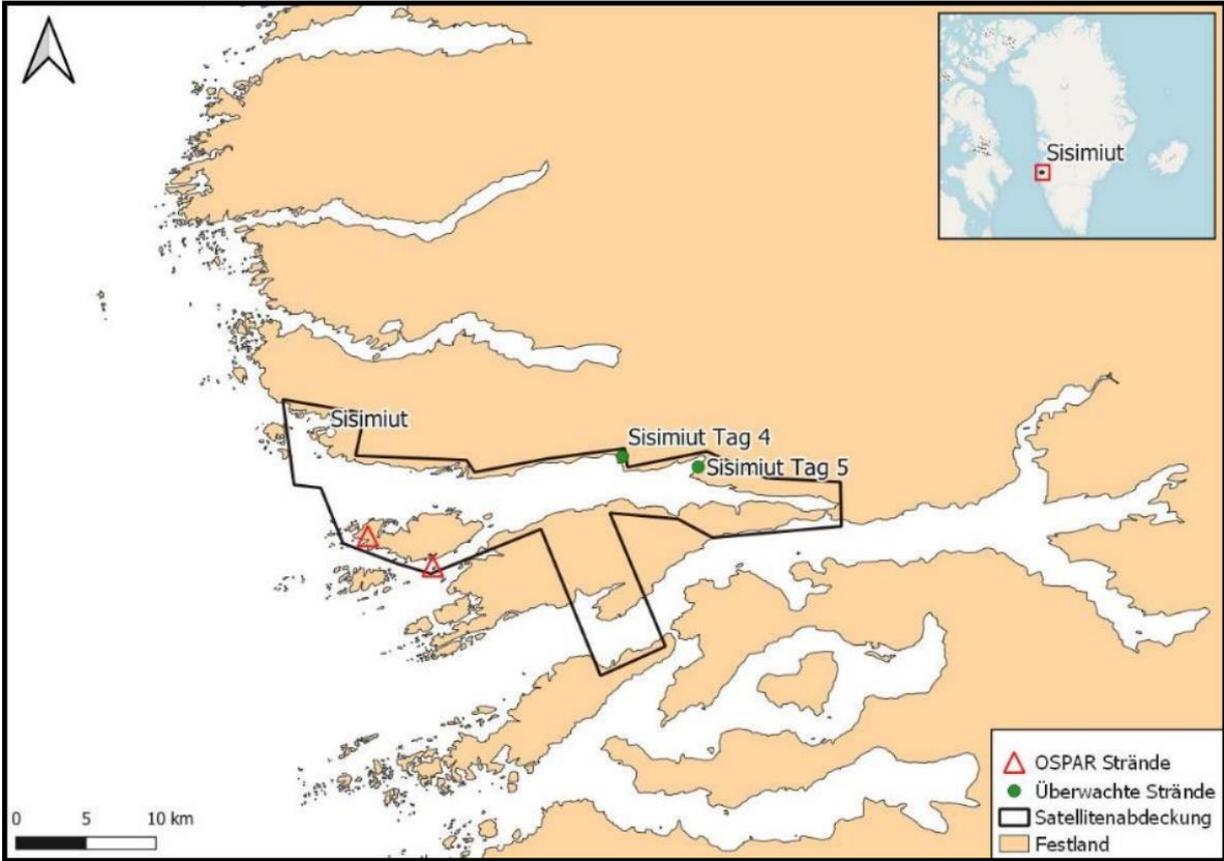
Quelle: Eigene Darstellung, BCSH

Abbildung 25: Untersuchungsgebiet Grönland: Nuuk



Quelle: Eigene Darstellung, BCSH

Abbildung 26: Untersuchungsgebiet Grönland: Sisimiut



Quelle: Eigene Darstellung, BCSH

4.2 Methoden

4.2.1 OSPAR

Für das in situ Monitoring von Strandmüll wurde die OSPAR-Methode angewendet, wie auf Seite 36, Abschnitt 2.1.2.1 beschrieben.

Basierend auf den Kartierungsdaten der Strandabschnitte auf Spitzbergen und Grönland wurden mittlere Abundanzen berechnet. Aus diesen mittleren Abundanzen wurden mittlere Materialzusammensetzungen berechnet und die häufigsten Müllkategorien identifiziert (Tabelle 2). Power-Analysen an einseitigen Wilcoxon-Rangsummentests mit einer Stichprobe wurden gerechnet, um abzuschätzen, wie lang Strandabschnitte sein müssen, um eine signifikante Verringerung der Strandverschmutzung um bis zu 10%, 20%, 30%, 40% und 50% zu erkennen. Hierfür wurde ein Signifikanzniveau von 0,05 verwendet. Poweranalysen wurden mit der Statistiksoftware Gpower (@Universität Kiel, Deutschland) durchgeführt.

4.2.2 Drohnen Erfassung

Um hochauflösende Luftbilder des Untersuchungsgebiets zu erhalten, wurden Drohnenbefliegungen durchgeführt. Dazu wurde eine WingtraOne-Drohne mit zwei Sensoren, einer Sony QX1 20MP-Kamera und einem MicaSense Altum Multispektralsensor, verwendet. Es konnte jeweils nur ein Sensor angebracht werden, was zu mindestens zwei Erhebungen pro Untersuchungsgebiet führte. Die WingtraOne funktioniert wie eine Starrflüglerdrohne und ist daher für großflächige Anwendungen, wie sie in der Arktis erforderlich sind, besonders geeignet. Die GSD für alle Erhebungen betrug 1,4 cm für die Sony QX1 und 3,4 cm für die MicaSense Altum, was zu einer Flughöhe von 68 m und 80 m führte. Die frontale und seitliche Überlappung wurde für die Sony QX1 auf 56% und 80-90% und für den MicaSense Altum auf 70% und 80-90% eingestellt. Die frontale Überlappung war durch die Mindestfluggeschwindigkeit der Drohnen, die GSD und die Auslösezeit des Sensors begrenzt und wurde für beide Konfigurationen maximiert. Die Flugzeit der einzelnen Erhebungen lag zwischen 06:56 und 49:26 Minuten und es wurden Gebiete zwischen 1,31 ha und 33,85 ha erfasst. Pro Erhebung wurden zwischen 108 und 1877 Einzelbilder aufgenommen und mit Geotags versehen (Tabelle 7). Das PPK-Modul der WingtraOne und ein Stonex S900T GNSS-Empfänger wurden zur Korrektur der absoluten Geolokation mit einer Genauigkeit von etwa 2 cm für die RGB-Bilder verwendet.

Die mit Geo-Tags versehenen Bilder wurden in Pix4D mapper Version 4.6.4 verarbeitet, um Punktwolken zu erstellen und um Höhenmodelle (DSM), Orthomosaik und Indexkarten zu berechnen. Da die PPK-Korrektur nur für die Sony QX1 verfügbar war, wurden für die Angleichung zwischen Multispektral- und RGB-Bildern Bodenkontrollpunkte (GCPs) verwendet.

Tabelle 7: Übersicht über die Drohnenerhebungen auf Spitzbergen und Grönland

Untersuchungsgebiet	Datum	Ortszeit der VIR- Flüge	Anzahl Bilder [RGB/ VIR]	Flugzeit [Min] [RGB/ VIR]	Flächenabdeckung [ha][RGB/VIR]
Kapp Mitra 1	Juni 11, 21	10:38 – 11:28	1223/ 1877	45:11/ 50:26	32,1/ 33,85
Kapp Mitra 2	Juni 11, 21	12:50 – 13:36	1165/ 1790	37:03/ 46:42	33,97
Nuuk Tag 1	September 15, 21	10:07 – 10:24	163/ 240	09:00/ 17:19	2,93
Nuuk Tag 2-1	September 16, 21	09:31 – 09:46	186/ 285	10:56/ 15:47	2,13
Nuuk Tag 2-2	September 16, 21	13:09 – 13:23	142/ 205	09:55/ 14:08	1,31

Untersuchungs- gebiet	Datum	Ortszeit der VIR- Flüge	Anzahl Bilder [RGB/ VIR]	Flugzeit [Min] [RGB/ VIR]	Flächen- abdeckung [ha][RGB/VIR]
Nuuk Tag 3	September 17, 21	13:53 – 14:12	988/ 454	33:45/ 19:34	21,09/ 5,45
Sisimiut Tag 1	September 23, 21	11:22 – 11:25	108/ 168	08:08/ 03:56	1,98
Sisimiut Tag 2	September 24, 21	12:35 – 12:51	226/ 345	10:55/ 16:49	4,24

4.2.2.1 Manuelle Sichtung

Für die manuelle Sichtung wurden die Orthomosaik (RGB, GSD: 1,4 cm) in QGIS 3.16.6 geladen. Ein Raster von 5 x 5 m und ein Maßstab von 1:20 wurden verwendet, um das Untersuchungsgebiet visuell nach Müllobjekten abzusuchen. Alle Bilder wurden von derselben Person gesichtet, was den Vergleich zwischen den Erhebungen sicherstellt. Zur Erleichterung der Kategorisierung wurde Wissen über die wichtigsten Abfallkategorien vor Ort genutzt.

Die Grenzen der Müllobjekte wurden markiert und in einem Shapefile-Format gespeichert. Wenn möglich, wurden Informationen über das Material hinzugefügt. Ein Sicherheitsindikator beschrieb das Maß an Sicherheit, mit dem ein Objekt als Müll identifiziert werden konnte, mit Werten zwischen 1 und 3 (unsicher, möglich, sicher). Objekte, die keiner Kategorie zugeordnet werden konnten, wurden als sonstige eingestuft. Nach Abschluss der manuellen Sichtung wurde die Fläche der Objekte berechnet und Höheninformationen aus dem DSM extrahiert. Das DSM wurde außerdem verwendet, um eine Höhenlinie von 0 m (ü. NN) zu erstellen, von der aus die kürzeste Entfernung zu jedem Müllobjekt berechnet wurde.

Mit einer Digitalkamera aufgenommene Fotos wurden verwendet, um die markierten Objekte zusammen mit in situ GNSS-Messungen zu überprüfen. Aufgrund technischer Probleme waren GNSS-Messungen nur für die beiden Erhebungen in der Nähe von Sisimiut (Grönland) verfügbar und wurden an einer Teilmenge der Objekte durchgeführt, die mit der OSPAR-Methode gefunden und erfasst wurden. Es war nicht möglich, alle Objekte zu vermessen, da die Zugänglichkeit und die Zeit begrenzt waren. Für die beiden Erhebungen in der Nähe von Sisimiut wurden die Ergebnisse der manuellen Sichtung mit den per GNSS gemessenen Objekten verglichen und eine Erkennungsrate berechnet.

Zur Veranschaulichung der räumlichen Verteilung wurde eine Dichtekarte von 1,2 x 1,2 m, 3,7 x 3,7 m und 10 x 10 m berechnet, die sowohl die Anzahl der Objekte als auch die Flächenabdeckung pro Einheit enthält. Die Rastergröße von 1,2 x 1,2 m und 3,7 x 3,7 m wurde so gewählt, dass sie der Zellengröße der WorldView3-Bilder entspricht. Die Dichtekarten wurden an den Rasterzellen der WorldView3-Satellitenbilder ausgerichtet und zur Bestimmung der von Kunststoffen bedeckten Satellitenpixel verwendet.

4.2.2.2 Statistische Analyse

Um die Häufigkeit der Müllfunde im Zuge der OSPAR-Erhebungen und der Drohnenerhebungen zu vergleichen, wurden für jedes untersuchte Gebiet die gefundenen Müllobjekte ausgezählt. Der Erfolg der Drohnenerhebungen wurde durch Berechnung des prozentualen Anteils der auf den Drohnenaufnahmen gefundenen Objekte bewertet, wobei die OSPAR-Ergebnisse als Gesamtmenge der Müllmenge betrachtet wurden.

Für eine statistische Analyse der Eigenschaften der entdeckten Müllobjekte wurden die Daten der Drohnenflüge auf Grönland und Spitzbergen kombiniert. Alle auf den Luftbildern gefundenen Müllobjekte wurden berücksichtigt, unabhängig von ihrer Position innerhalb oder außerhalb der OSPAR-Referenzgebiete. Objekte, deren Material nicht als Plastik klassifiziert

wurde, wurden von der weiteren Analyse ausgeschlossen. Eine Übersichtstabelle mit der Anzahl der gefundenen Müllobjekte für jede Materialkategorie befindet sich im Anhang (E.1). Die Größenverteilung der Plastikobjekte ist stark rechtsseitig, wobei nur wenige Objekte von großer Größe sind. Nur fünf Objekte waren größer als 1 m^2 (bis zu $4,7 \text{ m}^2$), so dass diese von den weiteren Analysen ausgeschlossen wurden. Außerdem wurden alle Objekte mit Farben, die weniger als 20-mal gefunden wurden, ausgeschlossen.

Jedes Objekt wurde zusätzlich einer Müllkategorie zugewiesen. Konnte keine bestimmte Kategorie erkannt werden, wurde die Kategorie "Sonstige" gewählt. Auf der Grundlage dieser Klassifizierung wurde eine neue Variable "type_ident" eingeführt. Diese Variable ist ein binärer Code, der angibt, ob ein Objekt einer bestimmten Müllkategorie zugeordnet werden konnte (1) oder nicht (0). In ähnlicher Weise wurde die binäre Variable "certain" eingeführt, die auf den Angaben basiert, wie sicher ein Objekt als Abfall eingestuft wurde (mit 1 = möglicherweise Abfall, 2 = wahrscheinlich Abfall, 3 = sicher Abfall). Nur Müllobjekte, die mit Sicherheit (3) eingestuft wurden, wurden mit 1 kodiert, andere (1-2) wurden mit 0 kodiert.

Die Eigenschaften der entdeckten Müllobjekte wurden untersucht, um herauszufinden, warum einige Müllobjekte auf Drohnenaufnahmen zu finden sind und andere nicht. Dafür wurde die Verteilung von Größe und Farbe der Plastikabfälle untersucht. Um deren Auswirkungen auf die Bestimmung einer Müllkategorie zu untersuchen, wurde ein binomiales generalisiertes lineares Modell (glm) verwendet. Das gesättigte Modell enthielt "type_ident" als Response-Variable und die erklärenden Variablen Farbe und Fläche (cm^2) sowie deren Interaktions-Term ($\text{type_ident} \sim \text{Farbe} * \text{Fläche}$). Wir haben dieselbe Modellstruktur angewandt, um die Auswirkungen von Größe und Farbe auf die Wahrscheinlichkeit zu untersuchen, mit der ein Objekt auf den Drohnenaufnahmen als Müll erkannt werden konnte (" $\text{certain} \sim \text{colour} * \text{area}$ ").

Alle Modelle wurden schrittweise reduziert und mit den gesättigten Modellen verglichen, indem ihre AIC-Werte (Akaike-Informationskriterium) bewertet wurden. Siehe E.3 und 0 im Anhang für eine Übersicht über alle vollständigen und reduzierten Modelle, einschließlich ihrer AIC-Einstufung. Modelle mit einem $\Delta\text{AIC} < 2$ wurden als gleichermaßen zutreffend angesehen. Die Homogenität der Varianz wurde durch die Darstellung der Residuen der am besten passenden Modelle bewertet (Anhang). Ausreißer, die nach dem Standard der Cook'schen Distanz einflussreich waren, wurden ausgeschlossen. Um Multikollinearität zu vermeiden, berechneten wir den Varianzinflationsfaktor (VIF) für alle Modelle (Zuur et al., 2010). Das visreg-Paket wurde verwendet, um die endgültigen Modelle darzustellen. Die gesamte Datenverarbeitung und statistische Analyse wurde in R Version 3.6.3 (RCore Team, Wien) durchgeführt.

4.2.2.3 (Halb-)Automatische Klassifikation

Für die (halb-)automatische Klassifikation von Plastik wurden Ansätze des maschinellen Lernens (Random Forest (RF), Support Vector Machine (SVM)) und des Deep Learning (neuronales Netz) angewandt und hinsichtlich ihrer Leistung verglichen. Aufgrund der gewählten GSD von 1,4 cm bzw. 3,4 cm für RGB und VIR wurde ein pixelbasierter Ansatz verwendet, da Objekte bis hinunter zur Größe einzelner Pixel erwartet wurden.

Um den Nutzen von multispektralen Drohnenaufnahmen zu bewerten, wurden die Klassifikationsergebnisse von RGB- und VIR-Datensätzen miteinander verglichen. Dazu wurde der RGB-Datensatz durch die Berechnung der Farbräume LAB, HSV und YcBcR erweitert. Der VIR-Datensatz wurde um die gleichen Farbräume sowie um fünf Indizes erweitert: NDVI, BNDVI, GNDVI, NDRE und $\text{rendvi}2$.

4.2.2.3.1 Indizes und Farbräume.

Um die Eingangsparameter für eine halbautomatische Klassifikation zu erweitern, wurden Indizes und Farbräume berechnet.

Die verwendeten Indizes wurden aus den Spektralbändern des MicaSense Altum Sensors abgeleitet und durch die spektrale Abdeckung des Sensors limitiert. Es handelt sich um normalisierte Kombinationen von zwei Einzelbändern, die in Drohnenanwendungen weit verbreitet sind, vor allem bei Vegetationsanalysen (Beyer & Grenzdörfer, 2018; Pourazar et al., 2019). Die verwendeten Indizes sind: *Normalized Difference Vegetation Index (NDVI)*, *Blue NDVI (BNDVI)*, *Green NDVI (GNDVI)*, *Normalized Difference Red Edge (NDRE)* und *redEdge NDVI (Rendvi2)* (Tabelle 8).

Die Verwendung von Farbräumen zur Erkennung von Strandabfällen wurde bereits in mehreren Studien erfolgreich eingesetzt (Gonçalves et al., 2020a, 2020b, 2020c und Pinto et al., 2021). Die verwendeten Farbräume waren HSV, CIE-LAB und YCbCr (Tabelle 9). Sie wurden auf der Grundlage der RGB-Bilder berechnet.

Tabelle 8: Indizes abgeleitet vom MicaSense Altum-Sensor

NDVI	BNDVI	GNDVI	NDRE	Rendvi2
$\frac{NIR - red}{NIR + red}$	$\frac{NIR - blue}{NIR + blue}$	$\frac{NIR - green}{NIR + green}$	$\frac{NIR - redEdge}{NIR + redEdge}$	$\frac{redEdge - red}{redEdge + red}$

Tabelle 9: Farbräume abgeleitet aus den RGB Bändern

HSV	CIE-LAB	YCbCr
H: Farbwert	L: Helligkeitswert	Y: Grundhelligkeit
S: Farbsättigung	A: Grün-Rot Achse	Cb: Blau-Gelb Farbigkeit
V: Hellwert	B: Blau-Gelb Achse	Cr: Rot-Grün Farbigkeit

4.2.2.3.2 Extraktion von Trainings- und Validierungsdaten

Um verschiedene Klassifikationsansätze zu trainieren und zu validieren, wurden zwei Referenzdatensätze erstellt. Dazu wurden Landbedeckungsklassen definiert: Für Spitzbergen wurden fünf Klassen definiert, darunter *Plastik*, *Steine*, *Vegetation*, *Wasser* und *Holz*, und für Grönland neun Klassen, darunter *Algen*, *Plastik*, *Steine*, *Sand*, *Schnee*, *Vegetation*, *Wasser*, *Holz* und *Schatten*. Die Klasse *Schatten* wurde in einem späteren Schritt nach der Auswertung der ersten Klassifikationsergebnisse hinzugefügt und wurde nur in Szenario (3) verwendet. Der Unterschied in der Anzahl der Klassen zwischen Spitzbergen und Grönland ist das Ergebnis der unterschiedlichen Umgebungsbedingungen.

Für alle Untersuchungsgebiete wurden Polygone erstellt, die die vorkommenden Bodenbedeckungsklassen abdecken, einschließlich der gesichteten Plastikobjekte. Aus diesen Polygonen wurden für jede Klasse zufällig Referenzpunkte mit einem Mindestabstand von der dreifachen GSD ausgewählt. Die Referenzpunkte aus den Erhebungen auf Spitzbergen und Grönland wurden in zwei Datensätze aufgeteilt, da sich die Landbedeckungsklassen unterschieden.

Für Spitzbergen wurden insgesamt 26091 Punkte ausgewählt, wobei die kleinste Klasse *Plastik* mit 660 Proben und die größte Klasse *Steine* mit 10881 Proben erfasst wurde. Eine Unterteilung

in 496 Punkte pro Klasse für das Training und 150 Punkte für die Validierung wurde vorgenommen, um ein Gleichgewicht zwischen den Klassen zu gewährleisten.

Für Grönland wurden insgesamt 39015 Punkte beprobt, wobei die kleinste Klasse *Schatten* mit 2000 Stichproben und die größte Klasse *Vegetation* mit 7482 Stichproben war. Eine Unterteilung in 1500 Punkte pro Klasse für das Training und 500 Punkte für die Validierung wurde durchgeführt, um ein Gleichgewicht zwischen den Klassen zu gewährleisten.

Die erzeugten Punkte wurden in R Version 3.6.3 verwendet, um die Pixelwerte der verschiedenen Feature Räume zu extrahieren und die einzelnen Klassifikatoren zu trainieren. Für Grönland wurden drei Szenarien von Feature Räumen getestet:

1. 1,4 cm RGB Daten kombiniert mit LAB, HSV und YcBcR, insgesamt 12 Features
2. 3,4 cm VIR Daten kombiniert mit fünf Indizes, insgesamt 10 Features
3. 3,4 cm VIR Daten kombiniert mit LAB, HSC, YcBcR und fünf Indizes, insgesamt 19 Features

4.2.2.3.3 Klassifikatoren

Für die (halb-)automatische Klassifikation von Strandmüll wurden drei Klassifikatoren eingesetzt und in ihrer Leistung verglichen. Der Vergleich wurde nur für die Aufnahmen aus Grönland durchgeführt, da hier mehr Referenzdaten vorhanden waren. Da die Klassifikationsgenauigkeit von Random Forest, Support Vector Machine und Deep Learning vergleichbar war, wurde nur Random Forest für die Aufnahmen von Spitzbergen verwendet, da dieser am wenigsten rechenintensiv ist.

4.2.2.3.3.1 Random Forest

Random Forest (RF) ist ein in der Fernerkundung weit verbreiteter Ensemble-Klassifikator (z. B. Gonçalves et al., 2020a, 2020b, 2020c; Martin et al., 2018). RF wurde von Breiman im Jahr 2001 eingeführt und kombiniert unabhängige Entscheidungsbäume zu einem Ensemble-Lernalgorithmus. Die Annahme ist, dass individuelle Fehler von einzelnen Bäumen produziert werden, die von der Mehrheit der anderen Bäume nicht produziert werden. Die Kombination von individuellen Klassifikatoren reduziert zudem die Varianz und den Bias des Algorithmus (Breiman, 2001; Waske, B., Braun, M., 2009). Durch zufällige Teilmengen von Trainingsdaten werden Eingabedaten generiert, die dann zum Training des Klassifikators verwendet werden. Jede Teilmenge verwendet in der Regel zwei Drittel des Datensatzes für das Training. Das letzte Drittel wird für die Bewertung der Klassifikation als das sogenannte Out-of-Bag (oob) verwendet. Entscheidungsbäume treffen an jedem Knotenpunkt auf der Grundlage einer zufälligen Teilungsregel eine Entscheidung über die Aufteilung der Eingabedaten. Die Aufteilungsregeln werden durch eine zufällig ausgewählte Featureauswahl (hier Spektralbänder, Indizes und Farbräume) definiert, die die Korrelation zwischen den Bäumen und damit auch den Generalisierungsfehler reduziert (Breiman 2001). Die Größe der Featuremenge wird in der Regel durch die Quadratwurzel der Anzahl der Input-Features definiert. Um die beste Entscheidung an jedem Knoten zu bestimmen, können verschiedene Techniken wie Gain-Ratio (Quinlan, 1993), Gini-Index (Breiman et al., 2017) und Chi-Quadrat (Mingers, 1989) verwendet werden. Der am häufigsten verwendete Ansatz für Random Forest ist der Gini-Index, der die Unreinheit vor und nach einem Splitting berechnet, um die beste Entscheidung zu ermitteln. Der höchste Rückgang der Unreinheit spiegelt die beste Entscheidung wider. Der Gini-Index führt zu einer einfachen und kompakten Baumstruktur. Jeder Entscheidungsbaum gibt die am häufigsten vorkommende Klasse an die Dateneingabe zurück. In der Regel wird das endgültige Klassifikationsergebnis durch eine einfache Mehrheitsentscheidung erzielt. Die Anzahl der Bäume und die Größe der Feature-Untermenge wird vom Benutzer festgelegt.

Random Forest wurde mit der Open-Source-Software R Version 3.6.3 angewendet. Die randomForest-Bibliothek wurde von Liaw und Wiener unter Verwendung des Fortran-Originals von Breiman et al. (2011) implementiert. Um die beste Klassifikationsgenauigkeit zu erzielen, wurden die Anzahl der Bäume und der Input Features für jedes Szenario optimiert.

4.2.2.3.3.2 *Support Vector Machine*

Support Vector Machines (SVM) sind ein weiterer Klassifikator des maschinellen Lernens, der in der Fernerkundung weit verbreitet ist und bereits bei der Erkennung von Strandmüll eingesetzt wurde (Escobar Sánchez et al., 2021; Gonçalves et al., 2020c).

SVM verwendet Trainingsdaten, um eine Entscheidungsfläche (Hyperebene) zu erstellen, die die Eingabedaten in benutzerdefinierte Klassen trennt. Wenn die Klassen nicht linear trennbar sind, transformiert SVM sie mithilfe von Kernel-Verfahren in einen hochdimensionalen Raum. Eine häufig verwendete Kernel-Funktion ist die radiale Basisfunktion (Waske et al, 2007), die auch in dieser Studie verwendet wurde. Bei der Anwendung von SVM mit der radialen Basisfunktion können zwei Parameter angepasst werden. Der Kostenparameter C, der die Menge der Trainingsdaten definiert, die falsch klassifiziert werden können, und der Parameter γ , der die Form der Entscheidungsgrenze verändert (Gonçalves et al., 2020c). Zur Ermittlung der optimalen Werte für C und γ wurde für jedes Szenario die Methode der Rastersuche angewandt. Die Rastersuchmethode wendet einen definierten Wertebereich verschiedener Kombinationen der Parameter C und γ an, um die Kombination mit der höchsten Klassifikationsgenauigkeit zu ermitteln (Gonçalves et al., 2020c; Mather & Tso, 2016).

4.2.2.3.3.3 *Deep Learning*

Zum Vergleich mit den Algorithmen des maschinellen Lernens wurde ein einfaches dreischichtiges vollverknüpftes neuronales Netz zur Müllklassifikation mit demselben Referenzdatensatz getestet. Das neuronale Netz bestand aus einer Eingabe-, einer verdeckten und einer Ausgabeschicht. Es wurden drei Szenarien der Klassengewichtung für den Cross-Entropie-Verlust getestet, um die Klassifikation von Plastik zu verbessern. Im ersten Szenario wurde keine Gewichtung verwendet, im zweiten Szenario eine mittlere Gewichtung für Plastik (Faktor 4 für Plastik und 1 für andere Klassen) und im dritten Szenario eine starke Gewichtung mit einem Faktor von 4 für Plastik und 0,1 für andere Klassen. Das neuronale Netz wurde in Python v.3.9.7 (im PyTorch Framework) trainiert und berechnet.

4.2.2.3.3.4 *FasterRCNN*

Eine Objekterkennung mithilfe von Bounding Boxes wurde unter Verwendung des FasterRCNN getestet. Aufgrund der begrenzten Anzahl an Objekten, die für das Training zur Verfügung standen, passte sich das Modell zu sehr an die Eingabedaten an (was zu einer geringen Testgenauigkeit führte), was ein Hinweis auf die Möglichkeit eines akzeptablen Modells in der Zukunft mit deutlich mehr Daten sein könnte. Neben dieser ersten Bewertung wurde das FasterRCNN nicht weiter getestet.

4.2.2.4 **Bewertung der Genauigkeit**

Um die Qualität der Klassifikationsergebnisse zu überprüfen, wurde eine Validierung vorgenommen. Die Validierung wurde mit Hilfe einer Konfusionsmatrix durchgeführt. Die Konfusions- oder Fehlermatrix liefert eine Kreuztabelle mit den von der Klassifikation vorhergesagten Klassen und den Validierungsdaten. Die Validierungsdaten machten etwa 25% der Referenzdaten aus. Die Konfusionsmatrix gibt Aufschluss über die Gesamtgenauigkeit und die Genauigkeit pro Klasse sowie über die Benutzer- und Produzentengenauigkeit. Außerdem können flächenbezogene Schätzungen vorgenommen werden. Die Verwendung einer Konfusionsmatrix impliziert die Annahme, dass jeder Pixel einer einzelnen Klasse zugeordnet

werden kann. Die durch die Konfusionsmatrix erhaltene Genauigkeit kann als thematische Genauigkeit verstanden werden. Die Diagonale der Matrix stellt die richtig klassifizierten Daten dar, während die Nebendiagonale eine falsche Klassifikation darstellt. Die Benutzergenauigkeit (User's Accuracy, UA) wird anhand der Anzahl der korrekt klassifizierten Validierungsdaten im Verhältnis zur Gesamtmenge der einer bestimmten Klasse zugeordneten Validierungsdaten berechnet. Pixel, die fälschlicherweise einer bestimmten Klasse zugeordnet wurden, stellen den Kommissionsfehler dar. Die Produzentengenauigkeit (Producer's Accuracy, PA) spiegelt die Anzahl der Validierungsdaten einer bestimmten Klasse wider, die korrekt der entsprechenden Klasse zugeordnet wurden. Validierungsdaten, die nicht der entsprechenden Klasse zugeordnet sind, stellen einen Versäumnisfehler dieser bestimmten Klasse dar. Daher stellt ein Versäumnisfehler in der einen Klasse einen Kommissionsfehler in der anderen dar (Strahler, 2006).

4.2.3 Satellitenbilder

Für eine großflächige Anwendung von Fernerkundungsmethoden zur Erkennung von Strandmüll in der Arktis wurde die Verwendung von Satellitenbildern getestet. Dazu wurden WV3-Satellitenbilder kurz vor den Terminen der Feldarbeit aufgenommen, wobei VIR- und SWIR-Bilder mit einer Auflösung von 1,2 m bzw. 3,7 m aufgezeichnet wurden. Die WV3-Bilder wurden von Maxar Technologies als Level-3-Orthoprodukt mit atmosphärischem Ausgleich (nur für Grönland) und radiometrischer Korrektur bestellt. Die Spektralsignale der WV3-Bilder wurden mit einem Dynamikbereich von 16 Bit geliefert und in spektrale Oberflächenreflektion umgewandelt. Da die für Spitzbergen erworbenen WV3-Bilder keine atmosphärische Kompensation enthielten, wurde ein Verfahren zur atmosphärischen Korrektur angewendet, wie in de Grandpré et al. (2022) beschrieben.

Da die zu erwartenden Müllobjekte eine Größe von weniger als einem Pixel haben, ist eine manuelle Sichtung nicht möglich. Auch wurde kein Vergleich mit der OSPAR-Überwachung vorgenommen, da die Erkennung und Klassifizierung von Makromüll eine viel höhere Auflösung erfordern würde (siehe Drohnenbilder). Stattdessen konzentrierten wir uns auf die Frage, ob Satellitenbilder dabei helfen können, Gebiete mit hohen Müllansammlungen an Stränden ausfindig zu machen. Studien über treibenden Meeressmüll haben gezeigt, dass selbst Abfälle in Subpixelgröße von Satelliten erfasst werden können (Biermann et al., 2020).

Um das Potenzial von WV3-Bildern für die Erkennung von Müll am Strand zu bewerten, wurden die Dichtekarten der manuellen Drohnensichtung verwendet, um einen Referenzdatensatz zu erstellen. Anhand der Informationen über die Müllabdeckung pro Pixel wurden die Referenzdaten zu Pixeln zusammengefasst, die Müll in zwei 5%-Klassen zwischen 0 und 10% und in neun 10%-Klassen von 10 bis 100% abdecken. Zusätzlich wurden Pixel, die die wichtigsten Hintergrundgruppen abdeckten, in die folgenden Klassen zusammengefasst: *Vegetation*, *Steine*, *Holz* und *Sand*. Die Referenzdaten wurden dann verwendet, um das Spektralsignal der Satellitenbilder zu extrahieren und zu vergleichen.

Außerdem wurde ein Ansatz der spektralen Entmischung angewandt, um zu prüfen, ob Pixel, die teilweise von Plastik bedeckt sind, mit Hilfe eines linearen Entmischungsmodells identifiziert werden können. Dazu wurden die spektralen Endglieder (reine Spektren jeder Klasse) aller vorkommenden Klassen durch Mittelung des Spektralsignals der Pixel berechnet, die zu 100% von der entsprechenden Klasse bedeckt waren. Für Plastik wurde das Spektralsignal des Pixels mit der höchsten Plastikabdeckung (96,7%) verwendet. Mit Hilfe der Endglieder berechnet das lineare Entmischungsmodell den Anteil der verschiedenen Klassen innerhalb eines Pixels.

4.3 Ergebnisse und Diskussion

4.3.1 Ergebnisse der konventionellen Kartierungen

Auf Spitzbergen lag die durchschnittliche Gesamtabundanz bei 28,5 Müllteilen pro 50 m Strandlänge. Strandmüll bestand zu 57,9% aus Plastik, zu 40,4% aus Holz und zu 1,7% aus Gummi. Der hohe Plastikanteil stimmt gut mit den Ergebnissen früherer Strandmüllstudien auf Spitzbergen überein (Bergmann et al., 2017). Von den Top-14-Müllkategorien sind sechs Fischerei und Schifffahrt zuzuordnen (Tabelle 10), was mit den Ergebnissen früherer Studien übereinstimmt (Bergmann et al., 2017; Weslawski und Kotwicki, 2018).

Tabelle 10: Die häufigsten Müllkategorien an den beiden Strandabschnitten bei Kapp Mitra, kartiert nach dem OSPAR-Protokoll (OSPAR, 2010). Zahlen in eckigen Klammern geben die OSPAR-Strandmüll-IDs an.

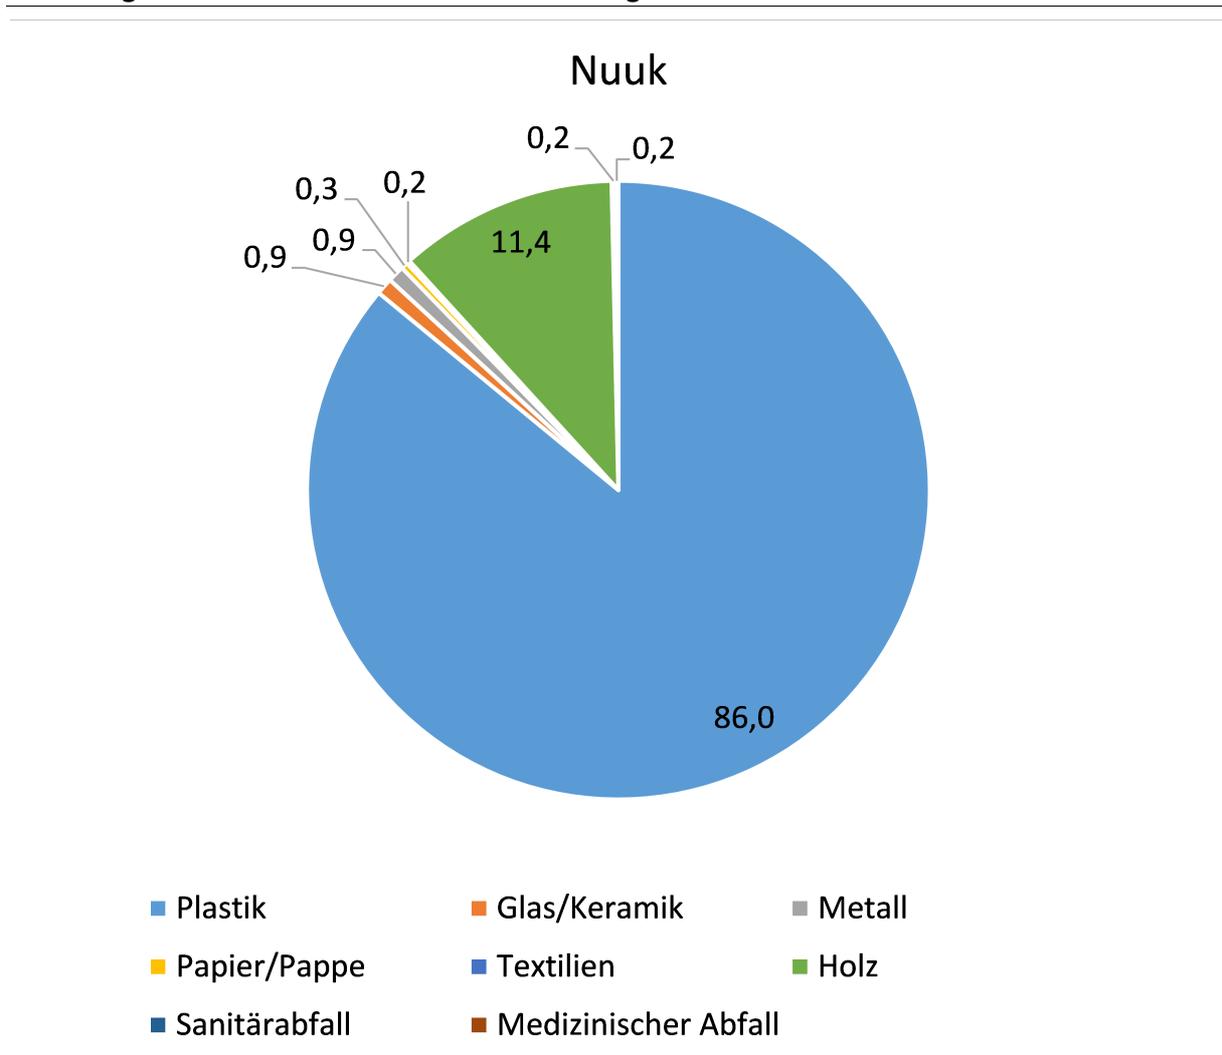
Rang	Strandmüllkategorie nach OSPAR	Mittlere Abundanz [Anzahl]
1	Holz: Sonstige <50 cm [74]	8
2	Plastik: Netze und Netzfragmente <50 cm [115]	4,5
3	Plastik: Plastikfragmente 2,5 cm >> 50 cm [461 a]	3,5
4	Holz: Sonstige >50 cm [75]	3
5	Plastik: Styropor [45]	2
6	Plastik: Kappen und Deckel [15]	1,5
6	Plastik: Umschnürbänder [39]	1,5
8	Plastik: Verhedderte Netze [331 a]	1
8	Plastik: Fischkisten [341 a]	1
10	Plastik: Seile [31]	0,5
10	Plastik: Schnüre [321 a]	0,5
10	Plastik: Sonstiges [48]	0,5
10	Gummi: Luftballons [49]	0,5
10	Holz: Kork [68]	0,5

In der Nähe von Nuuk und Sisimiut betrug die mittlere Gesamtmenge an Strandmüll $116,4 \pm 111,9$ Teile bzw. $87,3 \pm 33,5$ Teile pro 50 m Strandabschnitt. Dies lag in der gleichen Größenordnung wie von Strietmann et al. (2021) an der Westküste Grönlands gefunden. Die Materialzusammensetzung wurde von Plastik und verarbeitetem Holz dominiert (Abbildung 27 und Abbildung 28), was wiederum mit den Ergebnissen von Strietmann et al. (2021) übereinstimmt. Unter den Top-Ten-Mülltypen waren solche Müllteile am häufigsten, die eindeutig meeresbasierten Quellen zugeordnet werden können (Tabelle 11 und Tabelle 12). Dieser Befund steht teilweise im Widerspruch zu den Ergebnissen von Strietmann et al. (2021), die feststellten, dass Hausmüll an der Westküste von Grönland überwiegt. Diese Unterschiede sind wahrscheinlich darauf zurückzuführen, dass die letztgenannten Autoren teilweise Strände

in größerer Nähe zu Siedlungen untersucht haben als in der vorliegenden Studie. Die genauen Entfernungen zu Siedlungen sind in der Studie von Strietmann et al. (2021) jedoch nicht angegeben.

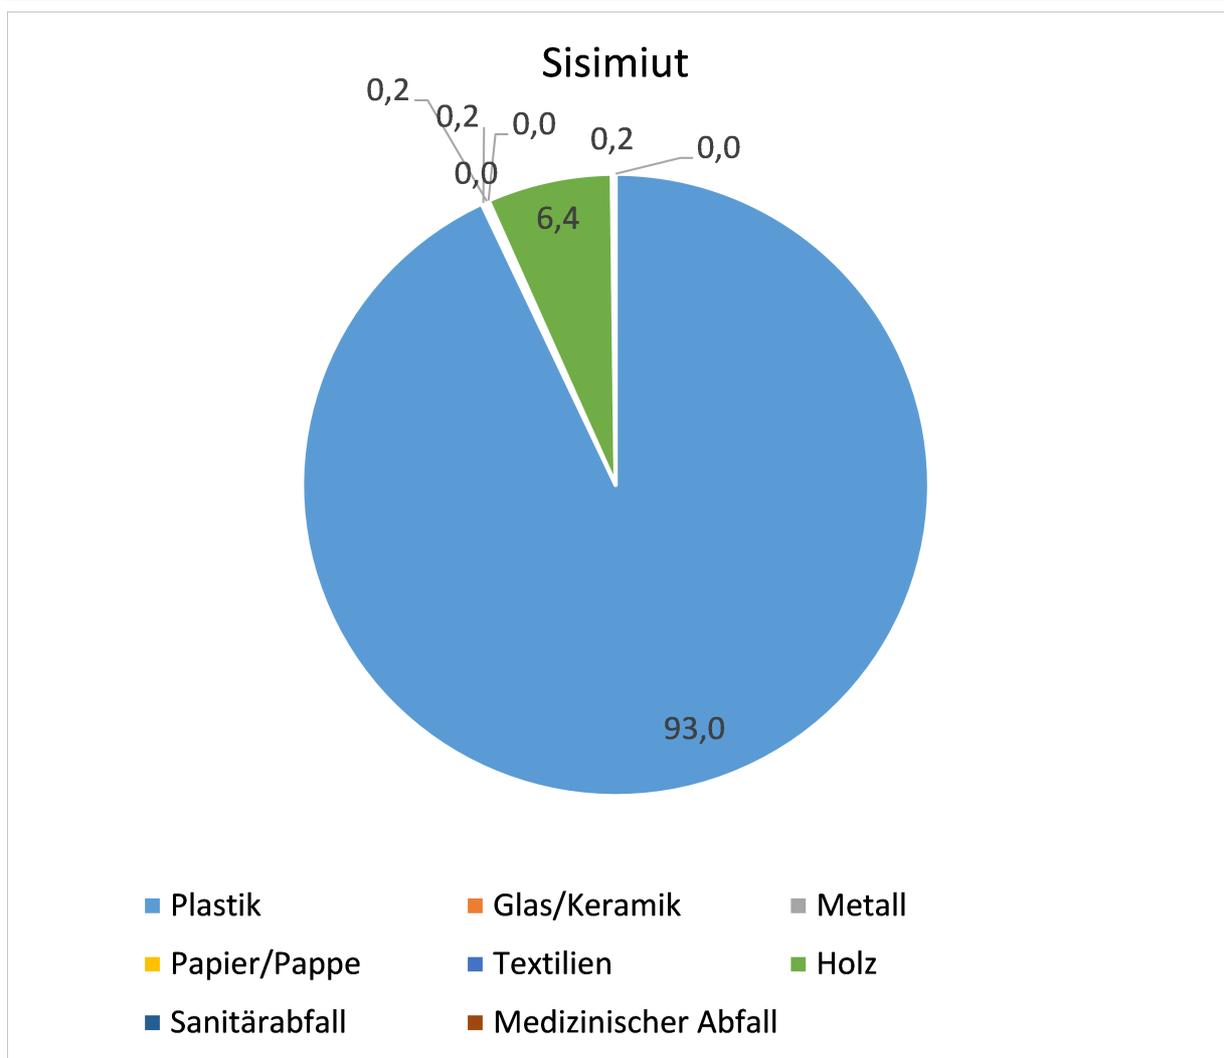
Power-Analysen ergaben statistische Teststärken $< 50\%$ und $> 80\%$ für Strände in der Nähe von Nuuk bzw. Sisimiut bei einer Verringerung der Strandabfälle um 50% (Abbildung 29). Bei niedrigeren Reduktionsraten war die statistische Aussagekraft noch geringer und damit nicht ausreichend. Daher sollten kartierte Strandabschnitte eine Mindestlänge von 200 m haben, da in der Nähe von Sisimiut Daten von vier Strandabschnitten von 50 m Länge für Poweranalysen verwendet wurden. Aus logistischer Sicht unterstützt dies wiederum den Einsatz von Drohnen für Strandmüllerhebungen auf Grönland.

Abbildung 27: Mittlere Materialzusammensetzung des Strandmülls an den Stränden bei Nuuk.



Quelle: Eigene Darstellung, AE

Abbildung 28: Mittlere Materialzusammensetzung des Strandmülls an den Stränden bei Sisimiut.



Quelle: Eigene Darstellung, AE

Tabelle 11: Die häufigsten Mülltypen an konventionell kartierten Strandabschnitten bei Nuuk auf Grönland. Zahlen in eckigen Klammern geben OSPAR-Strandmülltyp-IDs an.

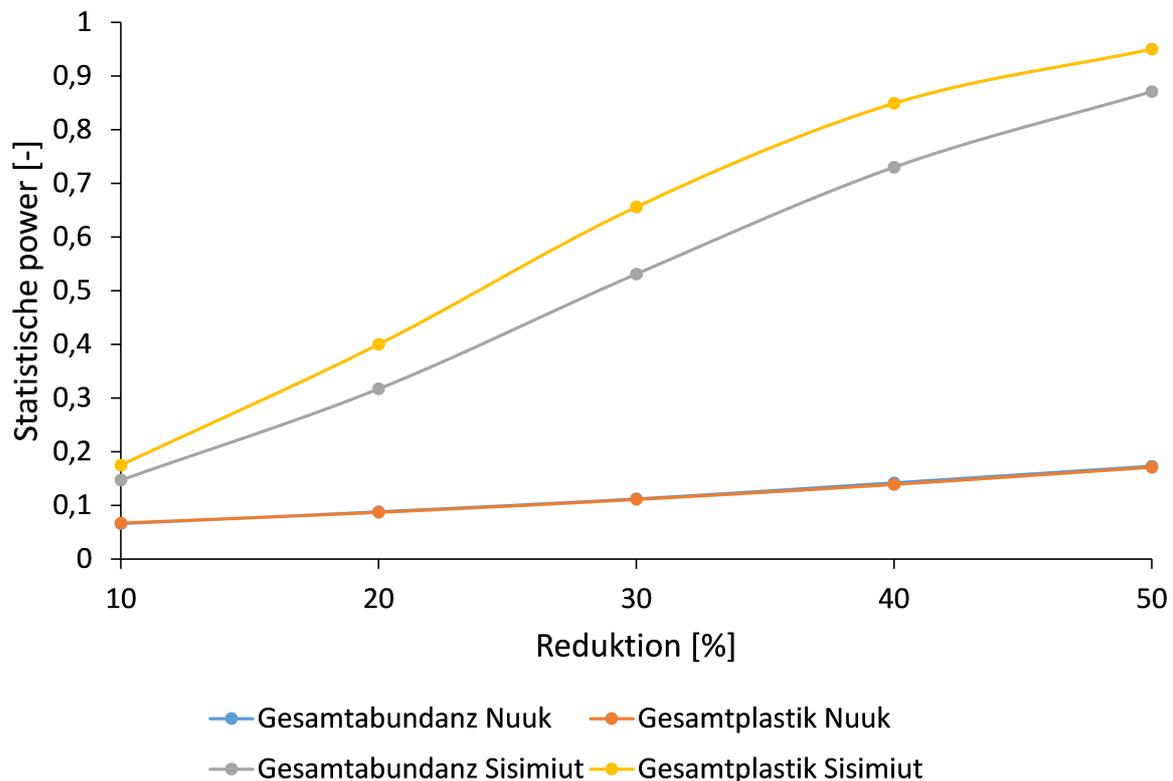
OSPAR-Strandmülltyp	Arithmetisches Mittel	Standardabweichung [Anzahl]	Anteil an der Gesamtabundanz [%]	Variationskoeffizient [%]	
[Anzahl]					
Plastikfragmente 2,5 cm – 50 cm [461]	27,4	23,5	23,5	85,8	
Styropor [sonstige Artikel]	11,6	20,5	10,0	176,8	
Schrot patronen [43]	11,4	10,2	9,8	89,6	
Seil >1 cm [31]	11,4	11,5	9,8	100,7	
Sonstiges Holz <50 cm [74]	7,8	8,5	6,7	108,6	

OSPAR-Strandmülltyp	Arithmetisches Mittel			
Sonstiges Holz 50 cm [75]	5,2	6,2	4,5	119,6
Umschnürungsbänder [39]	4,0	3,8	3,4	95,2
Sonstige Plastikartikel [48]	3,4	7,6	2,9	223,6
Plastikflaschen [4]	2,8	4,8	2,4	170,2

Tabelle 12: Die häufigsten Mülltypen an konventionell kartierten Strandabschnitten bei Sisimiut auf Grönland. Zahlen in eckigen Klammern geben OSPAR-Strandmülltyp-IDs an.

OSPAR-Strandmülltyp	Arithmetisches Mittel [Anzahl]	Standardabweichung [Anzahl]	Anteil an der Gesamtabundanz [%]	Variationskoeffizient [%]
Plastikfragmente 2,5 cm – 50 cm [461]	23,3	22,1	26,7	94,5
Schrot Patronen [43]	10,4	5,1	11,9	48,6
Schnüre und Filamente [322]	5,9	6,9	6,8	117,1
Schnur und Kordel <1 cm; nicht von Scheuerschutz oder nicht identifiziert [321]	4,8	3,6	5,4	76,4
Umschnürungsbänder [39]	4,8	2,8	5,4	59,5
Seil >1 cm [31]	4,0	2,0	4,6	50,0
Styropor [sonstige Teile]	3,9	4,5	4,5	114,3
Sonstiges Holz <50 cm [74]	3,4	3,6	3,9	104,9
Verheddeter Scheuerschutz [332]	3,2	1,9	3,6	61,3
Netze und Netzteile <50 cm [115]	2,8	2,5	3,2	87,6

Abbildung 29: Statistische Teststärke für verschiedene Verringerungen der Gesamtabundanz von Strandmüll. Die Ergebnisse wurden mittels einseitiger Wilcoxon-Rangsummentests für eine Stichprobe mit einem Signifikanzniveau von 0,05 berechnet.



Quelle: Eigene Darstellung, AE

4.3.2 Ergebnisse und Diskussion der Drohnenerhebung

4.3.2.1 Manuelles Sichten

Das manuelle Sichten der Drohnenaufnahmen, welches in QGIS 3.16.6 durchgeführt wurde, ergab für die untersuchten Strandbereiche Müllhäufigkeiten zwischen 0 und 63 Stück (Tabelle 13). Das manuelle Sichten des Drohnenmaterials dauerte zwischen 05:00 Minuten und 30:00 Minuten.

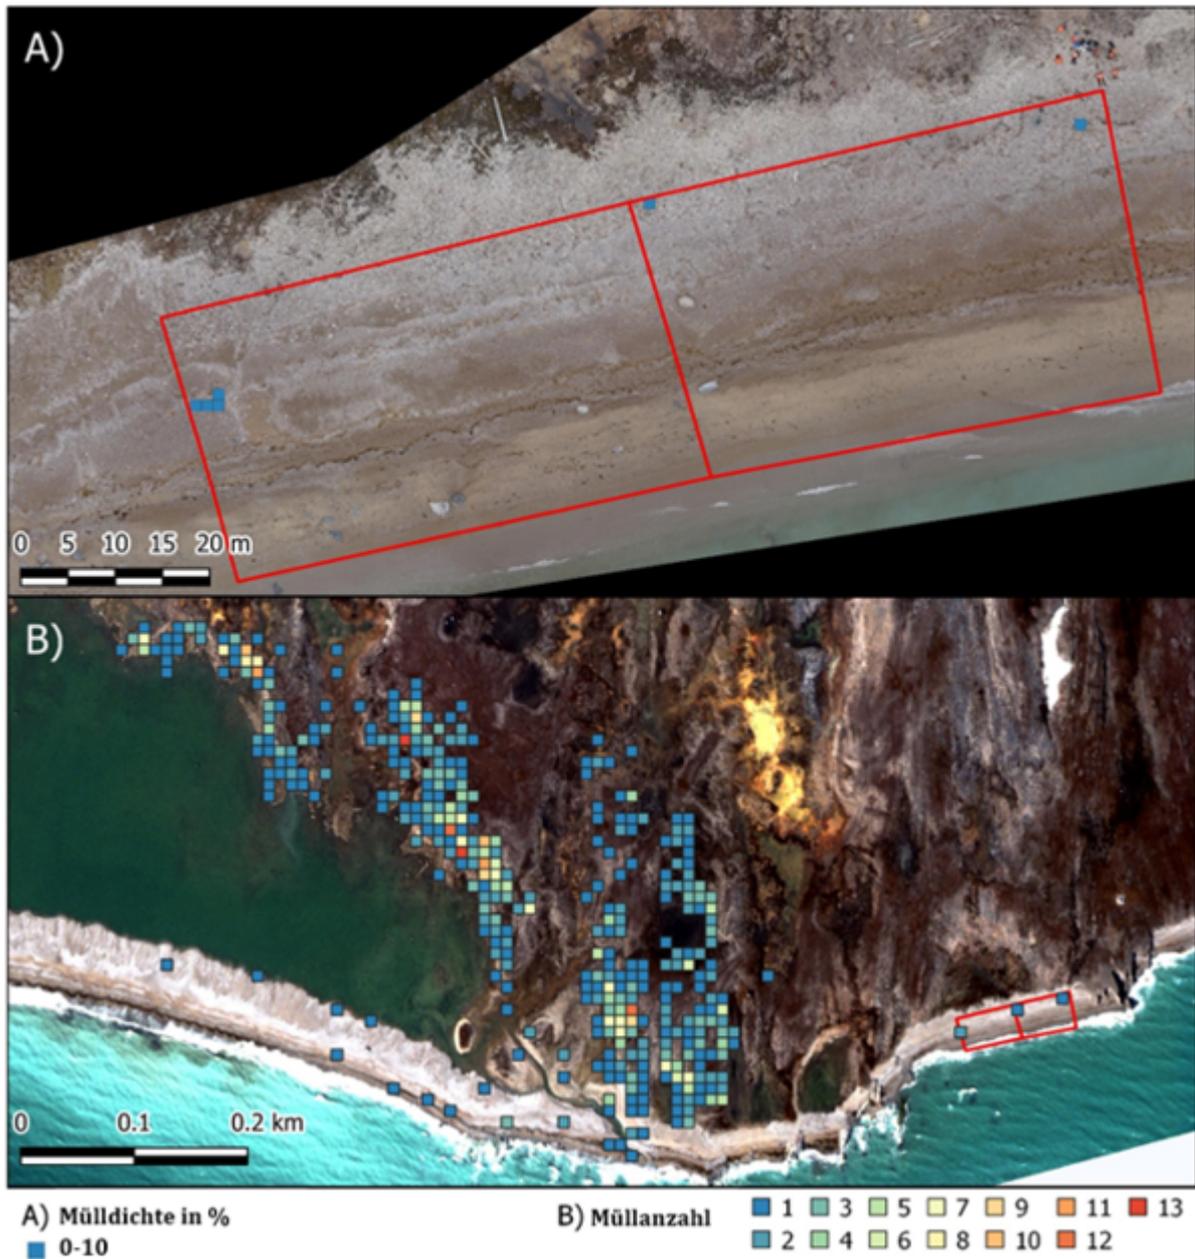
Die Bilder von Kapp Mitra 2 wurden nicht mit den Ergebnissen der OSPAR-Methode verglichen, da das Monitoring und die Drohnenerhebungen aufgrund einer Eisbärensichtung unterbrochen werden mussten und die genauen Grenzen der für den Vergleich erforderlichen Untersuchungsfläche nicht vorlagen. Das Gebiet wurde dennoch für die automatische Erkennung und als Referenz für die Satellitenbilder gesichtet.

Es wurden Dichtekarten berechnet, die die räumliche Verteilung der Abfälle an den überwachten Stränden und in der Umgebung zeigen. Die Dichtekarten mit einer Rastergröße von 1,2 x 1,2 m sind in Abbildung 30, Abbildung 31, Abbildung 32 und Abbildung 33 dargestellt. Eine weitere Analyse der manuellen Sichtung wurde in 4.3.2.2 durchgeführt. In Abbildung 30 ist die Anzahl der in Kapp Mitra gefundenen Abfälle in einem Raster von 10 x 10 m dargestellt.

Tabelle 13: Anzahl der bei der manuellen Überprüfung und der OSPAR-Überwachung vor Ort gefundenen Müllgegenstände

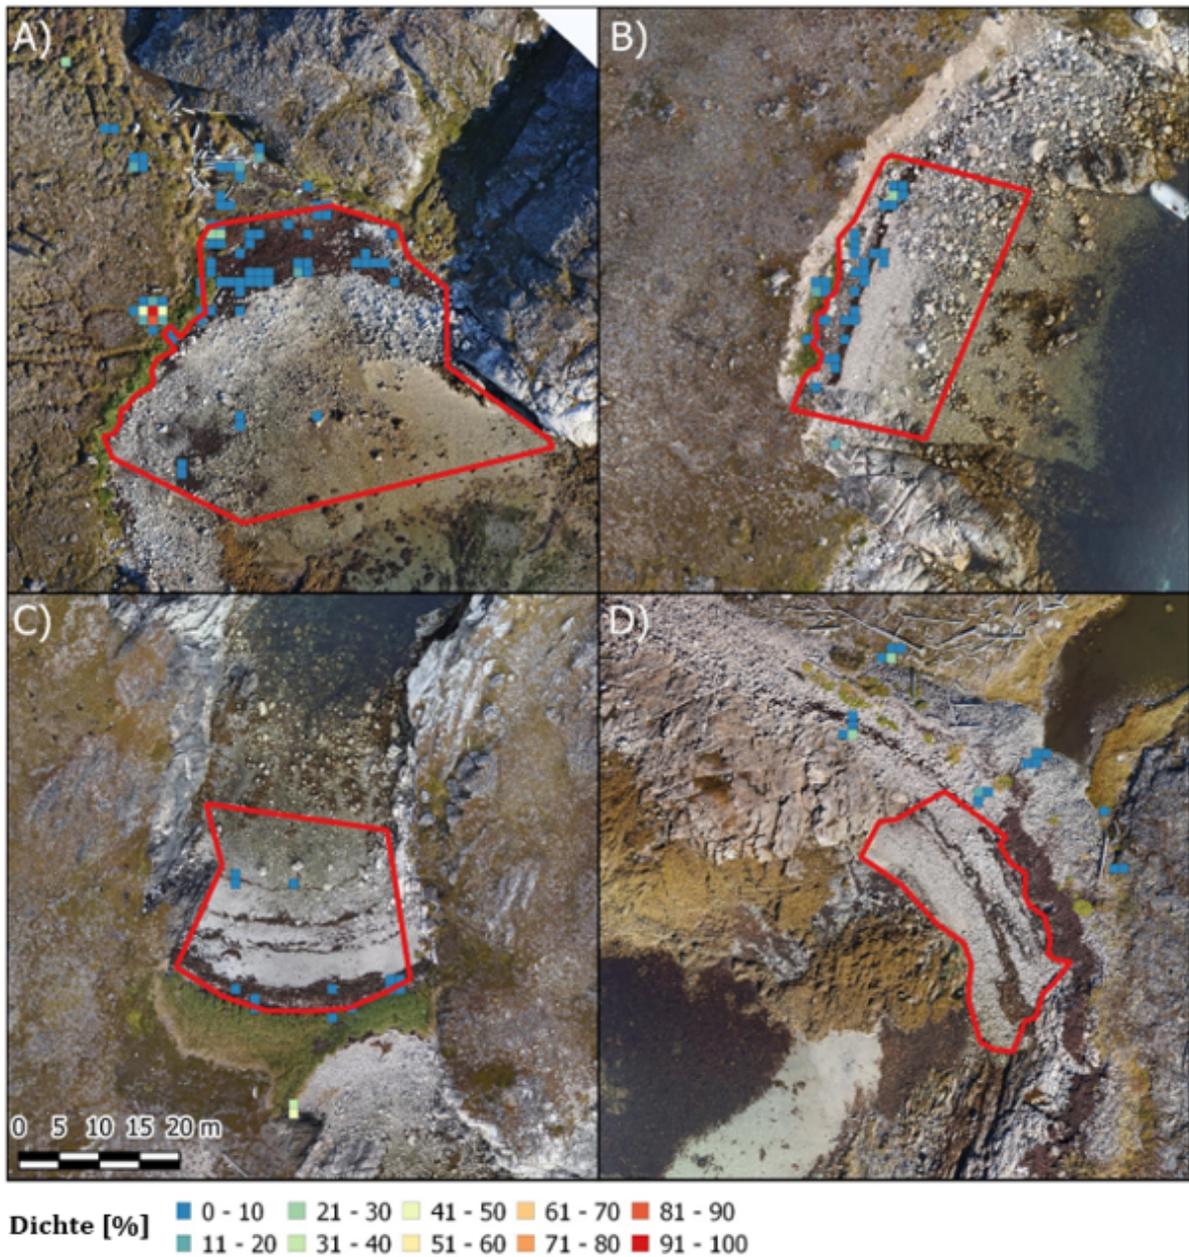
Name des Strandes	Benötigte Zeit für Sichtung	Anzahl an Müll-objekten	Anzahl an Plastik-objekten	Anzahl an Müll-objekten OSPAR	Anzahl an Plastikobjekten OSPAR
Kapp Mitra 1	15 Min	15	11	57	33
Kapp Mitra 2					
Nuuk Tag 1	20 Min	43	35	273	232
Nuuk Tag 2-1	10 Min	32	24	162	107
Nuuk Tag 2-2	5 Min	10	9	130	113
Nuuk Tag 3	5 Min	0	0	11	10
Sisimiut Tag 4	30 Min	63	55	325	316
Sisimiut Tag 5	20 Min	10	38	251	251

Abbildung 30: Dichtekarte der Flächendeckung und der Anzahl der Plastikmüllobjekte in Kapp Mitra



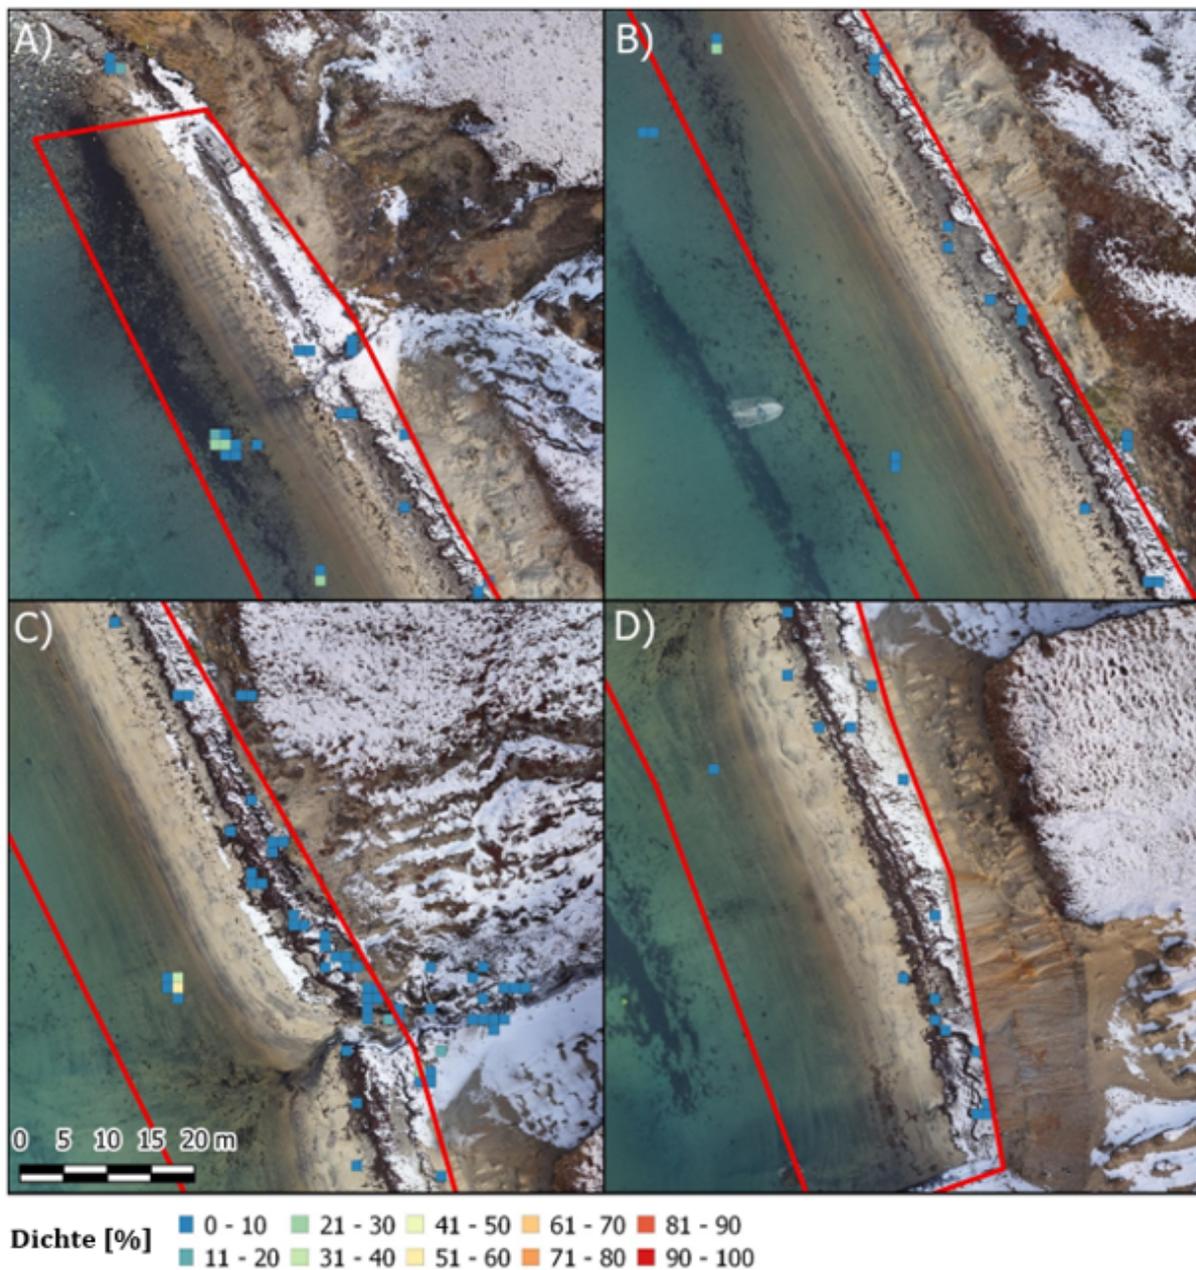
A) Dichtekarte des Untersuchungsgebiets Kapp Mitra (1 und 2) mit der von Plastikgegenständen bedeckten Fläche in einem Raster von 1,2 x 1,2 m. B) Dichtekarte der Anzahl der im Gebiet Kapp Mitra gefundenen Plastikteile in einem Raster von 10 x 10 m. Rot markiert ist das Gebiet, das nach der OSPAR-Methode untersucht wurde. Quelle: Eigene Darstellung, BCSH

Abbildung 31: Dichtekarte des Plastikmülls in den Untersuchungsgebieten rund um Nuuk



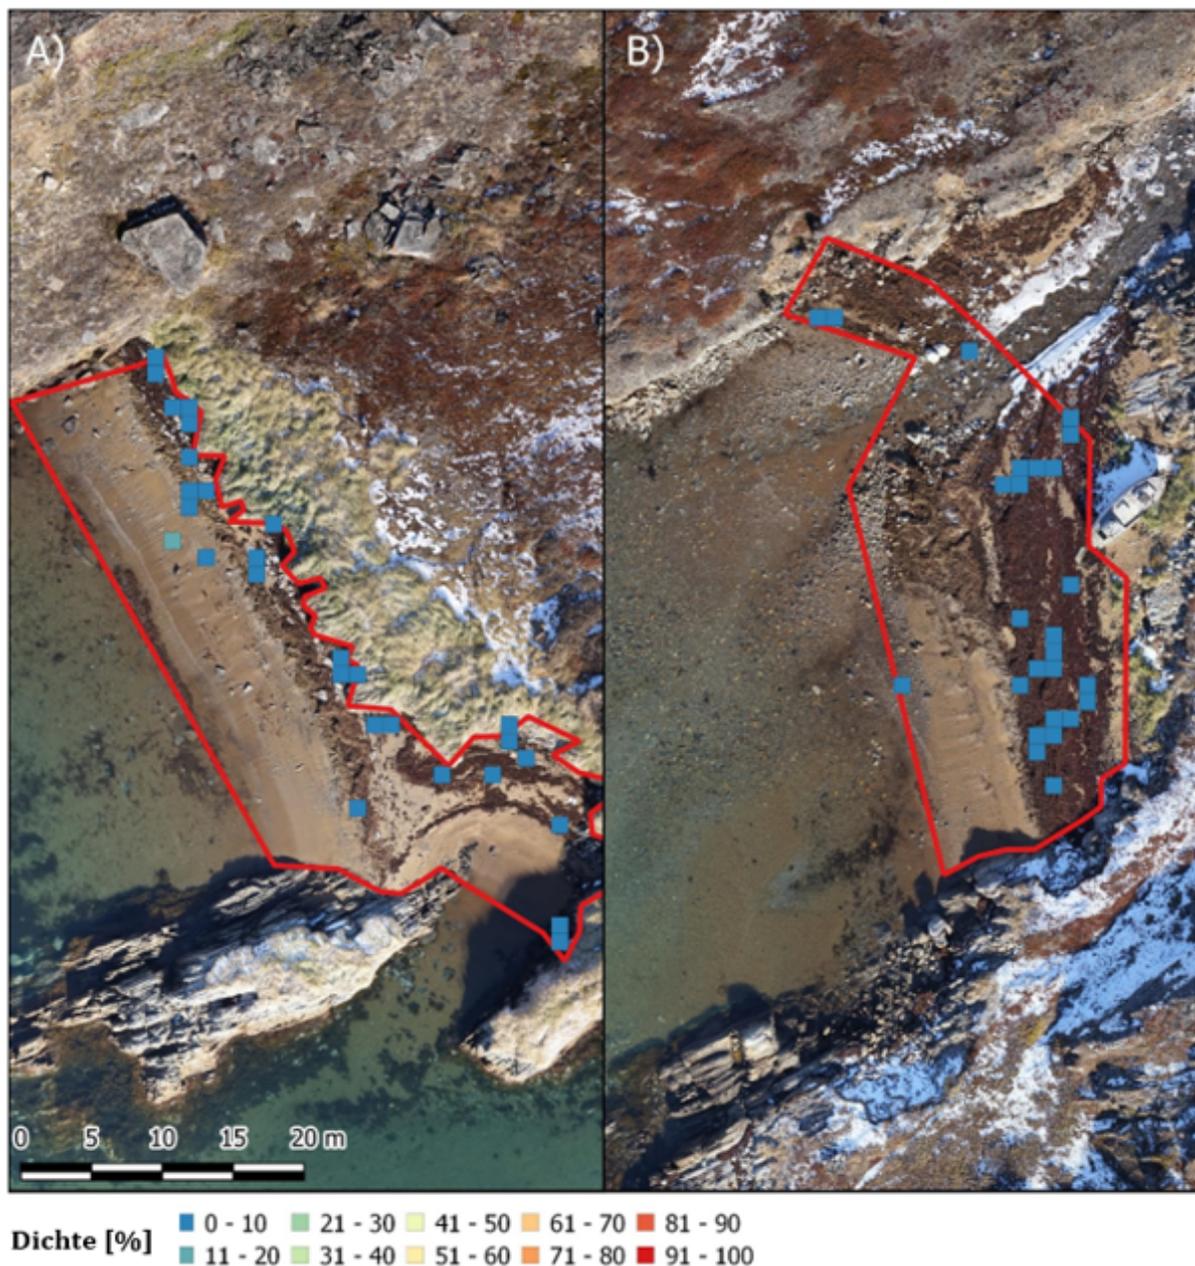
A), B), C) und D) zeigen die Strandabschnitte der Untersuchungsgebiete Nuuk Tag 1, Nuuk Tag 2-1, Nuuk Tag 2-2 bzw. Nuuk Tag 3. Rot markiert ist das Gebiet, das nach der OSPAR-Methode untersucht wurde. Die Dichtekarten zeigen die von Plastikteilen bedeckte Fläche in einem Raster von 1,2 x 1,2 m. Quelle: Eigene Darstellung, BCSH

Abbildung 32: Dichtekarte des Plastikmülls im Untersuchungsgebiet Sisimiut Tag 4



A), B), C) und D) sind einzelne Strandabschnitte desselben Untersuchungsgebiets. Rot markiert ist das Gebiet, das nach der OSPAR-Methode untersucht wurde. Die Dichtekarten zeigen die von Plastikteilen bedeckte Fläche in einem Raster von 1,2 x 1,2 m. Quelle: Eigene Darstellung, BCSH

Abbildung 33: Dichtekarte des Plastikmülls im Untersuchungsgebiet Sisimiut Tag 5



A) und B) sind einzelne Strandabschnitte desselben Untersuchungsgebiets. Rot markiert ist das Gebiet, das nach der OSPAR-Methode untersucht wurde. Die Dichtekarten zeigen die von Plastikteilen bedeckte Fläche in einem Raster von 1,2 x 1,2 m. Quelle: Eigene Darstellung, BCSH

Für Sisimiut wurde ein Vergleich zwischen den bei der manuellen Sichtung gefundenen Objekten und den per GNSS-Empfänger im Feld gemessenen Objekten durchgeführt. Es wurden 112 bzw. 55 Objekte bei Sisimiut Tag 4 bzw. Sisimiut Tag 5 vermessen. Bei der manuellen Sichtung konnten 44,64% (Sisimiut Tag 4) und 54,55% (Sisimiut Tag 5) dieser Objekte erfasst werden Tabelle 14. Abbildung 34 und Abbildung 35 zeigen die räumliche Verteilung der mit beiden Methoden gefundenen Objekte und der beim manuellen Screening übersehenen Müllobjekte. Fotos aller per GNSS-Empfänger gemessenen Objekte sind im Anhang D.1 und D.2 zu finden, mit der Angabe, ob sie auch bei der manuellen Sichtung der Drohnenbilder gefunden wurden.

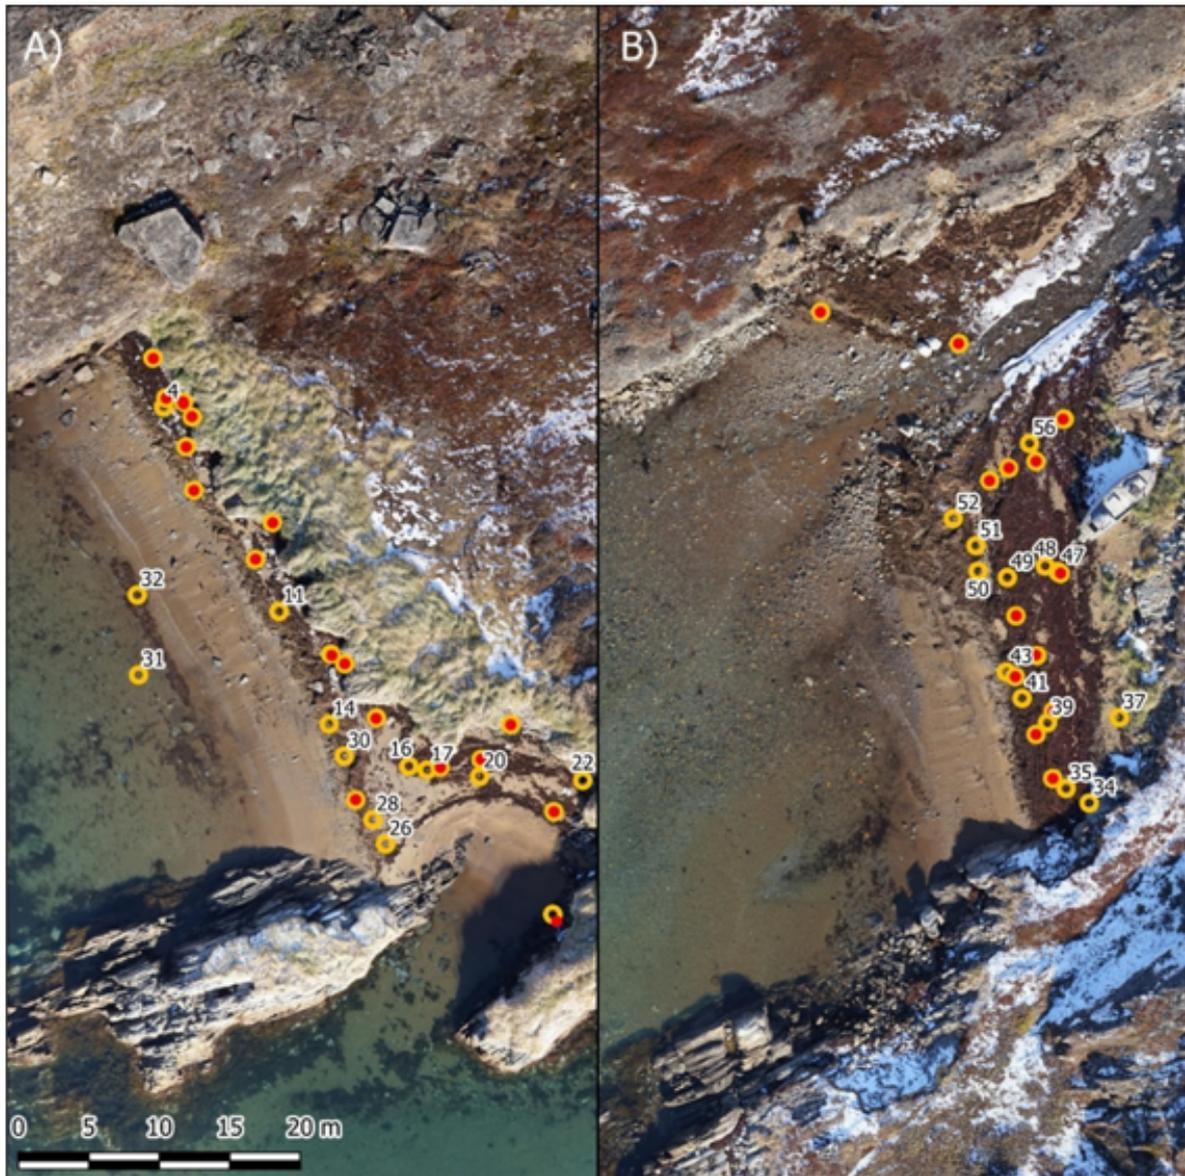
Abbildung 34: Räumliche Verteilung der per GNSS-Empfänger markierten Objekte und der bei der manuellen Überprüfung gefundenen Objekte im Untersuchungsgebiet Sisimiut Tag 4



● Mittels GNSS vermessene Müllobjekte ● Bei manueller Sichtung erfasste Müllobjekte

Tüte: 104; Boje: 30; Flasche: 83, 105, 112, 120; Bürste: 76; Behälter: 20, 44, 80, 84, 88, 103; Becher: 98, Schaumstoff: 62, 102; Folie: 41, 71, 75, 110; Lebensmittelbehälter: 4, 58, 85, 121; Deckel: 31; Netz: 25; Plastikfragmente: 6, 21, 26, 28, 50, 82, 93; Plastik sonstige: 42, 101; Seil: 12, 16, 36, 43, 49; Schrotflinte Hülse: 5, 11, 14, 22, 24, 57, 68, 70, 81, 89, 107; Umschnürungsband: 32, 118; Schnüre und Fäden: 18, 37, 69, 90, 119; ; Styropor: 23; Holz: 7, 8, 79
 Quelle: Eigene Darstellung, BCSH

Abbildung 35: Räumliche Verteilung der per GNSS-Empfänger markierten Objekte und der bei der manuellen Überprüfung gefundenen Objekte im Untersuchungsgebiet Sisimiut Tag 5



● Mittels GNSS vermessene Müllobjekte ● Bei manueller Sichtung erfasste Müllobjekte

Folie: 11, 14, 22, 30; Lebensmittelbehälter: 39; Deckel: 31; Seil: 4, 32, 37; Schrotflinte Hülse: 16, 28, 34, 35, 41, 43, 48, 49, 52, 56; Umschnürungsband: 20; Schnüre und Fäden: 26, 50; Schlauch: 17, 47

Quelle: Eigene Darstellung, BCSH

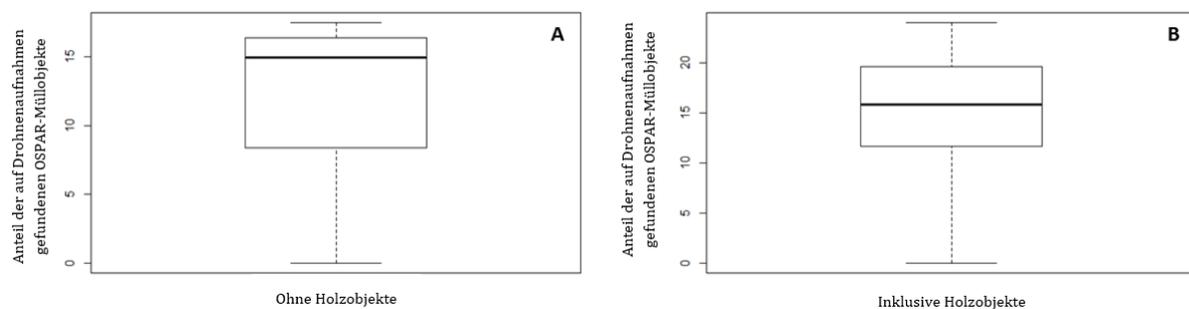
Tabelle 14: Vergleich zwischen der GNSS-Messung von Objekten und dem manuellen Screening

Untersuchungsgebiet	Objekte, die mit exakter Geolokalisierung über GNSS-Empfänger markiert wurden	Objekte, die bei der manuellen Sichtung der Drohnenaufnahmen markiert wurden	Prozentualer Anteil der bei der manuellen Sichtung gefundenen Objekte im Vergleich zu den per GNSS-Empfänger markierten Müllobjekten
Sisimiut Tag 4	112	50	44,64%
Sisimiut Tag 5	55	30	55,55%

4.3.2.2 Statistische Analyse

Wir haben die Anzahl der gefundenen Müllobjekte, die innerhalb derselben Gebiete während der OSPAR- und Drohnenuntersuchungen gefunden wurden, verglichen und den Prozentsatz der auf den Drohnenaufnahmen gefundenen Objekte pro Gebiet berechnet. Einschließlich aller gefundenen Objekte, auch solche aus Holz, wurde ein Maximum von 24%, ein Mittelwert von 14,8%, ein Median von 15,8% und ein Minimum von 0% an Objekten auf den Luftaufnahmen gefunden (Abbildung 36 A, n = 8 verschiedene Standorte). Wenn Holzobjekte ausgeschlossen wurden, wurden maximal 17,5% gefunden (Abbildung 36 B).

Abbildung 36: Prozentualer Anteil der Müllobjekte, die während der Drohnenerfassung in bestimmten Gebieten gefunden wurden (n = 8 unterschiedliche, unabhängige Standorte). A: alle Objekte, einschließlich Holz. B: nur Müllobjekte, die nicht als Holz klassifiziert wurden.



Quelle: Eigene Darstellung, BCSH

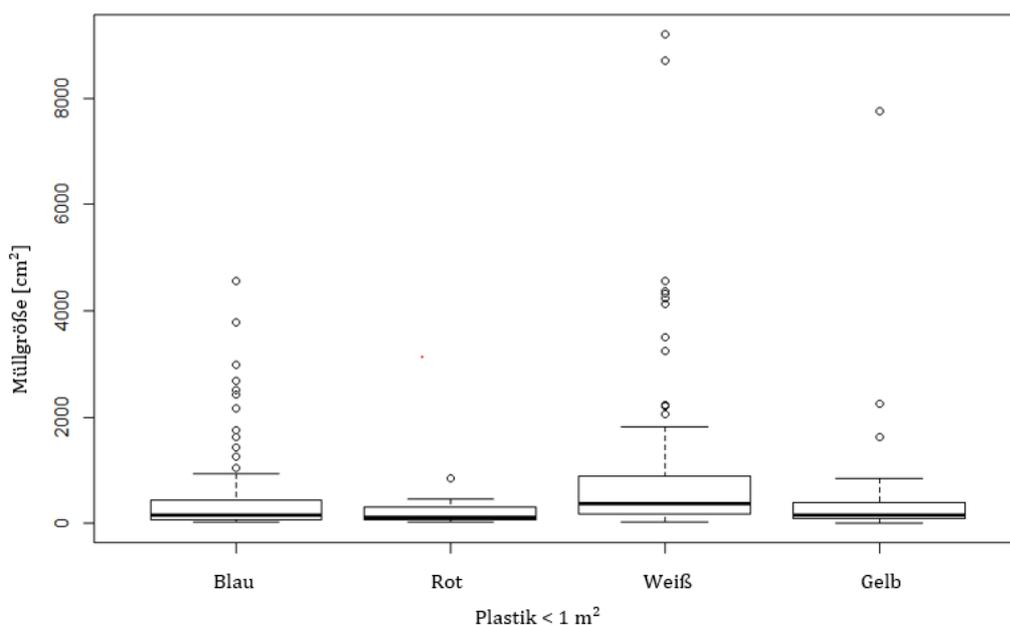
Die Größenverteilung der Müllobjekte war stark rechtsschief mit wenigen großen Objekten (>1 m²), was sich in der Abweichung der Median- und Mittelwerte widerspiegelt (Tabelle 15). Durch den Ausschluss von Objekten, die nicht als Plastik eingestuft wurden, sowie von Objekten mit einer Größe von >1 m² wurde diese Abweichung verringert.

Tabelle 15: Größenverteilung der auf den Drohnenaufnahmen gefundenen Müllobjekte. In der Tabelle sind die Minimal-, Median-, Mittel- und Maximalgröße in cm² aller Objekte, nur von Plastikobjekten und von Plastikobjekten kleiner als 1 m² aufgeführt.

Data	Minimum [cm ²]	Median [cm ²]	Mittelwert [cm ²]	Maximum [cm ²]
Alle Abfälle	19,9	392,3	4563,3	1.733.736,8
Nur Plastik Objekte	19,9	262,7	924,7	47.541,6
Plastik Objekte <1 m ²	19,9	223,6	616,2	9.192

Die Darstellung der Größenverteilung für jede Farbe des Plastikmülls, der mindestens 20-mal gefunden wurde, zeigte eine sehr ähnliche Rechtsschiefe für alle vier Farben (Abbildung 37). Nur weiße Plastikobjekte zeigten eine andere Größenverteilung mit einem höheren Median als die anderen Farben (blau = 161,10 cm²; rot = 127,29 cm²; weiß = 372,74 cm²; gelb = 161,57 cm²).

Abbildung 37: Boxplots, die die Verteilung der Objektgröße (als Fläche [cm²]) für jede Farbkategorie der auf Drohnenaufnahmen gefundenen Plastikabfallobjekte zeigen.



Quelle: Eigene Darstellung, BCSH

Bei der Prüfung der Auswirkungen von Größe und Farbe der Objekte auf die Wahrscheinlichkeit, den Objekttyp zu identifizieren, zeigte das initiale gesättigte Modell sehr hohe VIFs (Fläche = 21,72, Farbe = 77,59, =Fläche*Farbe = 602,79). In Anlehnung an Zuur et al. (2010) haben wir daher den Parameter mit dem höchsten VIF-Wert entfernt. Reduzierte Modelle mit Fläche und Farbe sowie Fläche allein als erklärende Variablen hatten sehr ähnliche AICs mit $\Delta AIC < 2$, so

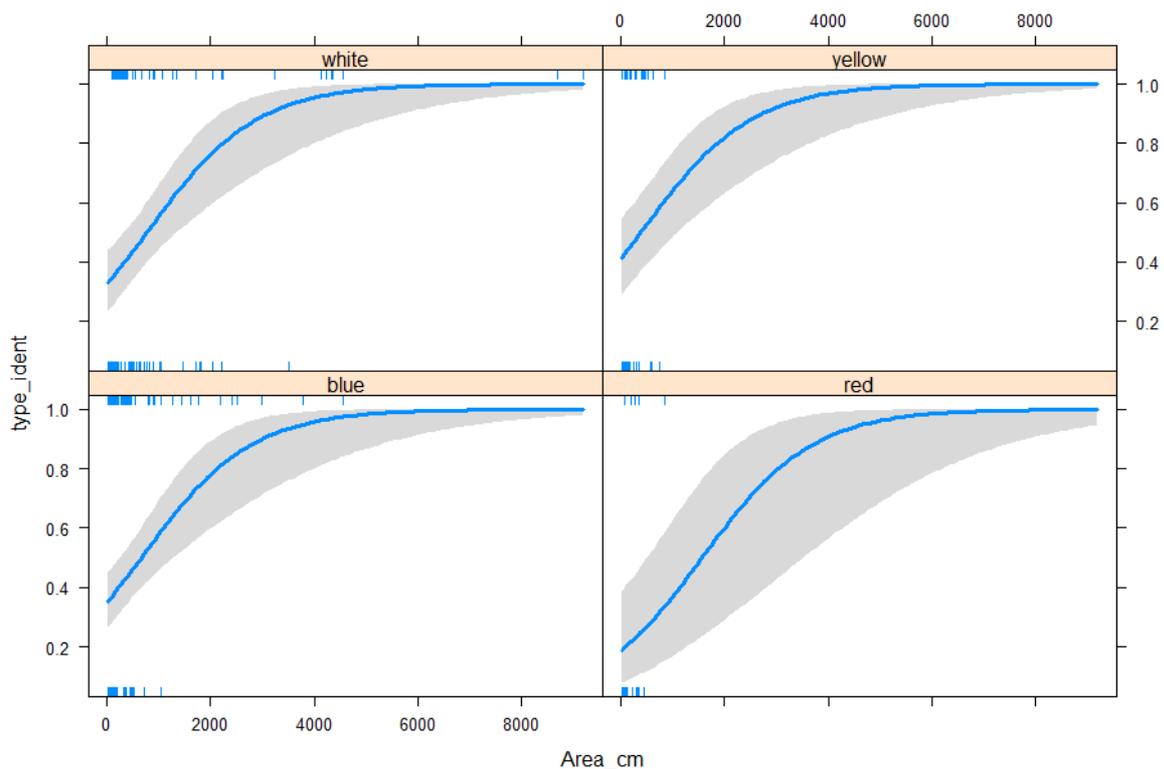
dass sie als gleichermaßen passend angesehen wurden (siehe E.3 und 0). Das Modell mit Fläche (hochsignifikant) und Farbe (nicht signifikant) wurde für die Darstellung gewählt, wobei der Effekt der Objektgröße [cm²] darauf, ob der Mülltyp für jede gefundene Farbe identifiziert werden konnte, dargestellt wurde (Abbildung 38). Eine große Objektgröße begünstigt die Identifizierung des Typs erheblich, aber dieser Effekt ist für die einzelnen Farben ähnlich.

Tabelle 16: Modellergebnisse zur Abschätzung der Wahrscheinlichkeit, dass der Typ eines Plastikmüllobjekts anhand von Drohnenaufnahmen identifiziert werden kann.

Parameter	Chi-quadrat	df	p	VIF
Fläche [cm ²]	28,10	1	1,15e-07***	1,34
Farbe	4,31	3	0,23	1,34

Es werden die Ergebnisse einer Varianzanalyse (ANOVA) einer binomialen generalisierten linearen Regression mit einer Logit-Link-Funktion gezeigt. Der Varianzinflationsfaktor (VIF) wurde berechnet, um Multikollinearität zu vermeiden. Sternchen zeigen Signifikanzen an (* p<0,5; ** p<0,01; *** p<0,001).

Abbildung 38: Der Einfluss von Größe (Fläche [cm²]) und Farbe auf die Wahrscheinlichkeit, dass die Art eines Plastikmüllobjekts anhand von Drohnenaufnahmen identifiziert werden kann.



Die blaue Linie stellt die Regressionslinie des Binomialmodells dar. Die Konfidenzbänder sind als grau schattierte Fläche dargestellt. Quelle: Eigene Darstellung, BCSH

Hinsichtlich der Auswirkungen von Größe und Farbe der Objekte auf die Wahrscheinlichkeit, dass ein Plastikobjekt mit Sicherheit als Müll identifiziert wird, wies das ursprüngliche Vollmodell sehr hohe VIFs auf (VIF Fläche = 8,81; VIF Farbe = 4,66, VIF Fläche*Farbe = 24,55). Daher wurde das Modell um den Term mit dem höchsten VIF-Wert reduziert. Reduzierte Modelle mit Fläche und Farbe sowie Fläche allein als erklärende Variablen wiesen sehr ähnliche AICs mit $\Delta AIC < 2$ auf, so dass sie als gleichermaßen passend angesehen wurden (siehe E.3). Das

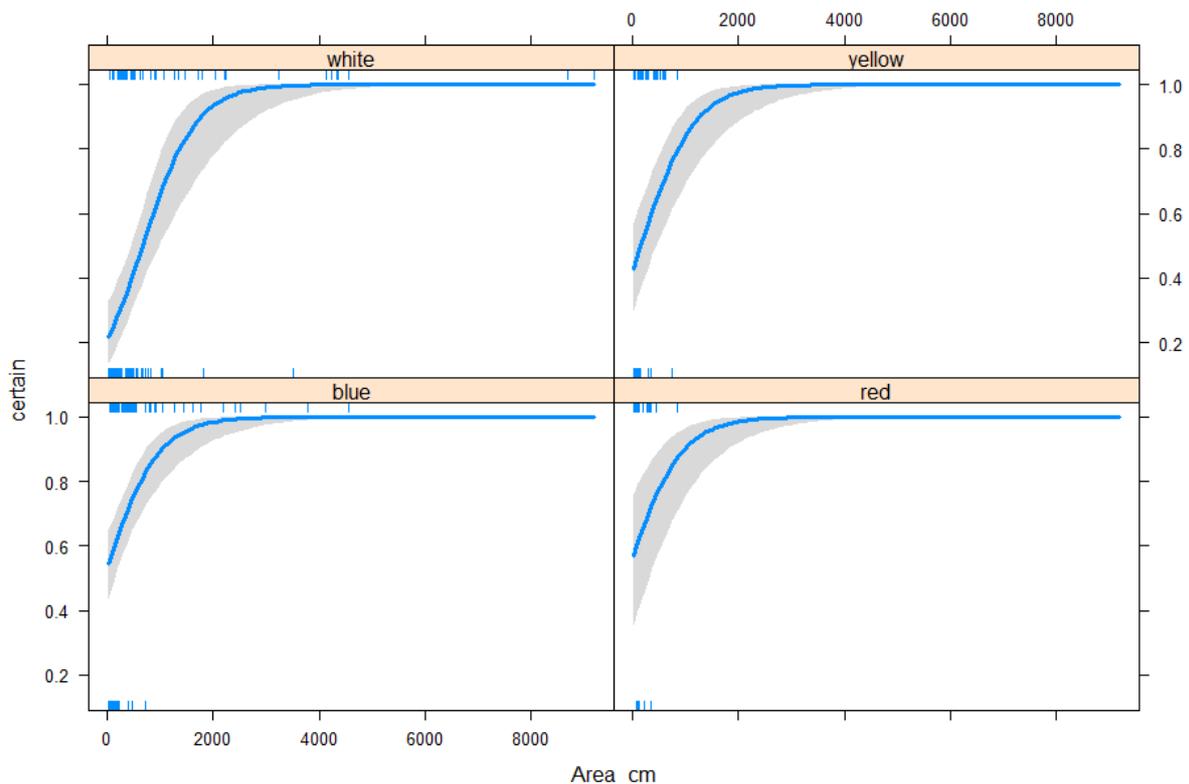
Modell, das beide Parameter, Fläche und Farbe, aber keinen Interaktionsterm enthält, erwies sich nach AIC als das am besten passende Modell (siehe 0). Daher wird es hier in Abbildung 39 dargestellt. Ähnlich wie bei der Typenidentifikation erhöhen große Objektgrößen die Wahrscheinlichkeit einer bestimmten Klassifizierung erheblich. Allerdings hat auch die Farbe des Objekts eine signifikante Auswirkung, wobei weiße Objekte im Allgemeinen seltener mit Sicherheit als Müll klassifiziert werden, während blaue und rote Objekte die höchsten Wahrscheinlichkeiten aufweisen.

Tabelle 17: Modellergebnisse zur Abschätzung der Wahrscheinlichkeit, mit der ein Plastikmüllobjekt mit Sicherheit als ein solches identifiziert werden kann.

Parameter	Chi-quadrat	df	p	VIF
Fläche [cm ²]	48,98	1	2,58e-12***	1,34
Farbe	24,69	3	1,793e-05***	1,34

Es werden die ANOVA-Ergebnisse einer binomialen generalisierten linearen Regression mit einer Logit-Link-Funktion gezeigt. Der Varianzinflationsfaktor (VIF) wurde berechnet, um Multikollinearität zu vermeiden. Sternchen zeigen Signifikanzen an (* p<0,5; ** p<0,01; *** p<0,001).

Abbildung 39: Der Einfluss von Größe (Fläche [cm²]) und Farbe auf die Wahrscheinlichkeit, dass ein Plastikmüllobjekt mit Sicherheit als ein solches identifiziert werden kann.



Die blaue Linie stellt die Regressionslinie des Binomialmodells dar. Die Konfidenzbänder sind als grau schattierte Fläche dargestellt. Quelle: Eigene Darstellung, BCSH

4.3.2.3 (Halb-)Automatische Klassifikation

Die (halb-)automatische Klassifikation wurde für die Drohnenerfassung auf Grönland und Spitzbergen angewandt, und die Ergebnisse wurden im Hinblick auf ihre jeweilige Gesamt-, Nutzer- und Produzentengenauigkeit verglichen. Für Grönland lag die beste OA bei 90,6% und

für Spitzbergen bei 85,8%, jeweils unter Verwendung von RF v3. Die höchste Nutzer- und Produzentengenauigkeit wurde mit 95,2% und 82,9% für Grönland bzw. 76,2% und 65,3% für Spitzbergen erreicht (Tabelle 18, Tabelle 19). Um die besten Klassifikationsergebnisse zu erzielen, wurden für Grönland verschiedene Klassifikatoren und Feature Räume getestet.

Die Ergebnisse schwanken zwischen 62,5% und 90,6% für die Gesamtgenauigkeit, 52,6% und 95,2% für die Produzentengenauigkeit und 25,4% und 82,9% für die Benutzergenauigkeit (Tabelle 18) Die PA von 95,2% wurde mit dem stark gewichteten NN erreicht, was auf eine mögliches Overfitting der Plastikklasse hinweist, was durch den entsprechenden UA von nur 40,6% bestätigt wird. Im Allgemeinen zeigten die verschiedenen Klassifikatoren vergleichbare Ergebnisse für die einzelnen Szenarien. Im Vergleich der verschiedenen Szenarien erzielte v3 die höchsten OAs für alle Klassifikatoren. Die Klassifikationsergebnisse wurden außerdem mit dem manuellen Screening des Drohnenmaterials in Bezug auf die mit Müll bedeckte Fläche verglichen, was zu einer bis zu 10- bis 2000-mal höheren Flächeneinschätzung von Plastik für den RGB-Input und bis zu 40- bis 425-mal höher für den VIR-Input führte (Tabelle 18). Die höchste Überschätzung von Plastik trat für NN mit einer starken Gewichtung der Plastikklasse auf, was ein starkes Overfitting dieses Szenario bestätigt.

Tabelle 18: Klassifikationsgenauigkeit Grönland

		Klassifikationsgenauigkeit			Anteil der von Plastik bedeckten Fläche [%]					
		OA [%]	PA Plastik [%]	UA Plastik [%]	Nuuk Tag 1	Nuuk Tag 2-1	Nuuk Tag 2-2	Nuuk Tag 3	Sisimiut Tag 4	Sisimiut Tag 5
Manuelle Sichtung der Drohnenbilder					0,1	0,1	0,1	0,06	0,04	0,04
RF RGB	v1	75,6	54,0	63,0	6,3	2,7	7,1	2,5	18,3	6,4
SVM RGB	v1	77,3	52,6	70,3	5,1	1,0	5,5	1,6	20,3	5,6
NN RGB	v1a	78,0	52,8	67,2	3,0	2,9	1,8	2,5	46,1	4,7
	v1b	77,3	52,8	67,7	8,3	10,7	10,1	10,0	62,3	10,7
	v1c	62,5	92,6	25,4	33,3	46,0	50,9	45,6	86,6	32,8
RF VIR	v2	89,6	67,8	82,9	8,6	7,0	5,6	7,5	4,2	10,1
	v3	90,6	72,4	81,5	4,3	5,4	5,4	6,7	4,3	7,5
SVM VIR	v2	89,5	64,0	81,6	9,7	8,2	5,5	9,5	5,6	11,2
	v3	90,4	72,0	79,8	5,5	6,8	6,0	5,8	7,7	8,3
NN VIR	v2a	90,1	72,0	79,5	9,0	7,9	8,1	11,4	4,2	10,9

		Klassifikationsgenauigkeit			Anteil der von Plastik bedeckten Fläche [%]					
	v2b	88,1	83,6	62,5	17,6	22,6	17,4	19,4	9,6	19,2
	v2c	79,8	95,2	40,6	27,5	42,5	33,5	32,7	15,4	27,0
	v3a	89,9	71,6	76,3	7,6	8,0	6,8	6,6	4,4	9,0
	v3b	84,5	89,6	48,6	10,5	19,5	16,1	18,4	8,6	15,7
	v3c	87,9	84,0	62,4	17,2	29,4	20,1	17,6	9,6	17,5

OA: Gesamtgenauigkeit, UA: Benutzergenauigkeit und PA: Produzentengenauigkeit; v1: RGB mit Farbräumen, v2: VIR mit spektralen Indizes, v3: VIR mit spektralen Indizes und Farbräumen; NN: a: keine Gewichtung der einzelnen Klassen, b: mittlere Gewichtung der Plastikklasse, c: hohe Gewichtung der Plastikklasse. In Rot: höchste Werte für OA, UA und PA

Tabelle 19: Klassifikationsgenauigkeit Spitzbergen

		Klassifikationsgenauigkeit		
		OA [%]	PA Plastik [%]	UA Plastik [%]
RF RGB	v1	78,6	64,0	76,2
RF VIR	v2	83,8	63,3	69,3
	v3	85,8	65,3	74,8

OA: Gesamtgenauigkeit, UA: Benutzergenauigkeit und PA: Produzentengenauigkeit.; v1: RGB mit Farbräumen, v2: VIR mit spektralen Indizes, v3: VIR mit spektralen Indizes und Farbräumen; In Rot: höchste Werte für OA, UA und PA

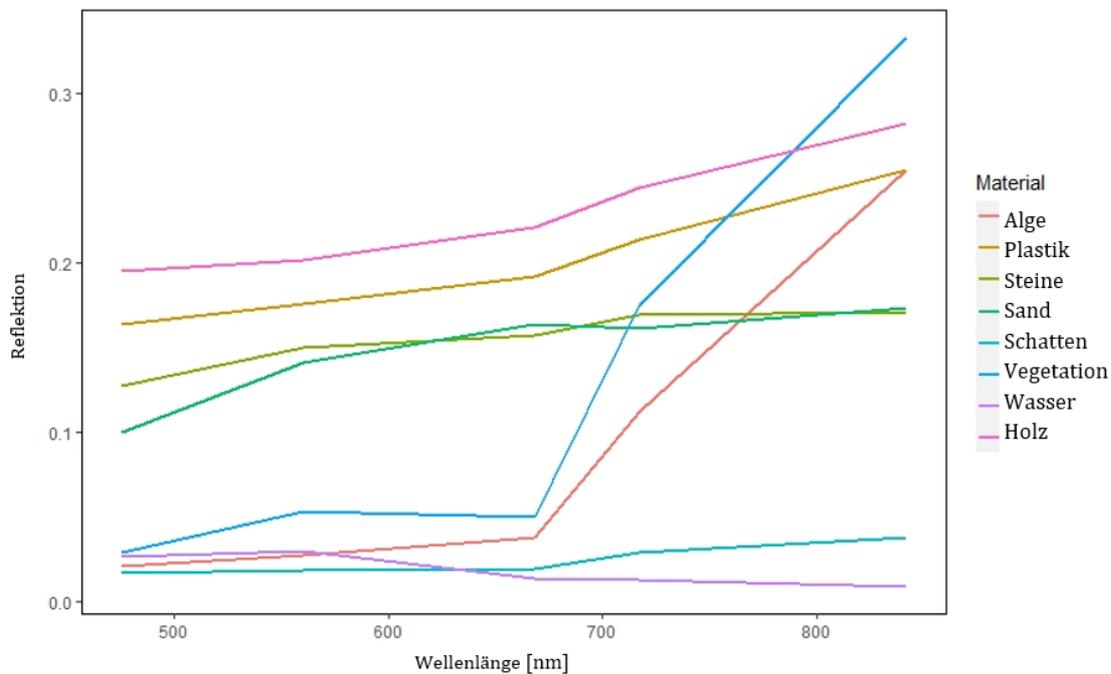
Zum besseren Verständnis möglicher Fehlklassifikationen wurden Konfusionsmatrizen erstellt. Die Ergebnisse zeigten, dass die höchste Fehlklassifikation von *Plastik* mit *Steinen* und *Holz* auftrat (F.1-F.18). Fehlklassifikationen traten in beiden Richtungen auf, nämlich bei Plastikobjekten, die fälschlicherweise der Klasse *Steine* oder *Holz* zugeordnet wurden, und bei *Steinen* oder *Holz*, die fälschlicherweise der Klasse *Plastik* zugeordnet wurden. Je nach Strandumgebung hatten die falschen Zuordnungen dieser Klassen einen größeren Einfluss auf die Gesamtergebnisse.

Um mögliche Ursachen von Fehlzusordnungen der drei kritischen Klassen zu verstehen, haben wir die Referenzdatensätze ausgewertet und Reflektionswerte, Indizes und Farbräume extrahiert. In Abbildung 40 ist der durchschnittliche Reflektionswert der verschiedenen Klassen für Grönland dargestellt. Der Durchschnittswert von Plastik überschneidet sich mit keiner anderen Klasse. Um die Verteilung der Referenzdaten genauer zu sehen, wird eine Dichtefunktion der Reflektionswerte von *Plastik*, *Steine* und *Holz* dargestellt, da die meisten Fehlklassifikationen in diesen Klassen auftraten (Abbildung 41, Abbildung 42). Im Gegensatz zu Abbildung 40 ist eine starke Überlappung aller Spektralbänder zu beobachten. Abbildung 43 bis Abbildung 45 zeigen ein ähnliches Muster für die verwendeten Indizes und Farbräume mit starken Überschneidungen zwischen den Klassen. Diese Überschneidungen könnten dazu geführt haben, dass die Algorithmen für das Maschinelle Lernens Schwierigkeiten hatten,

zwischen diesen drei Klassen zu unterscheiden. Ein ähnliches Muster von Überschneidungen zwischen *Plastik*, *Steinen* und *Holz* wurde bei den Referenzdaten aus Spitzbergen (G.1bis G.6) beobachtet.

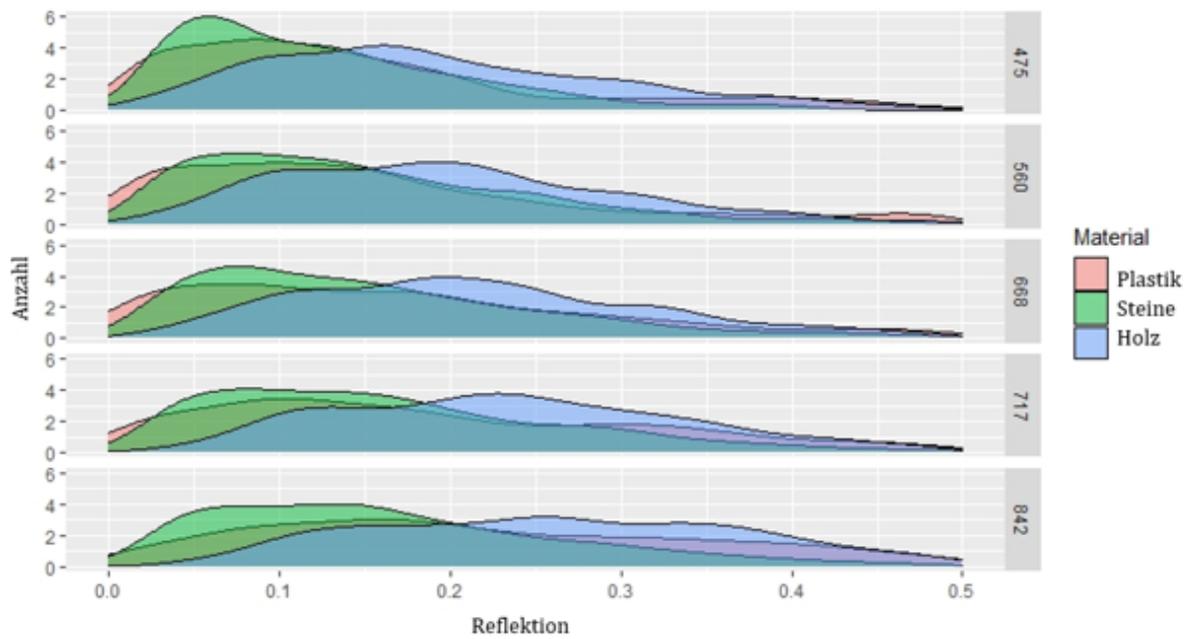
Ein Vergleich zwischen den durchschnittlichen Reflektionswerten aus den Referenzdaten und den Reflektionswerten der in situ georeferenzierten Plastikobjekte wurde in Abbildung 46 und Abbildung 47 vorgenommen. Der Reflektionswert der in situ Messpunkte bestätigte die beobachtete große Spannweite der Reflektionswerte von Plastikobjekten.

Abbildung 40: Durchschnittliche Reflektion der Eingangsklassen aus den Referenzdaten von Grönland



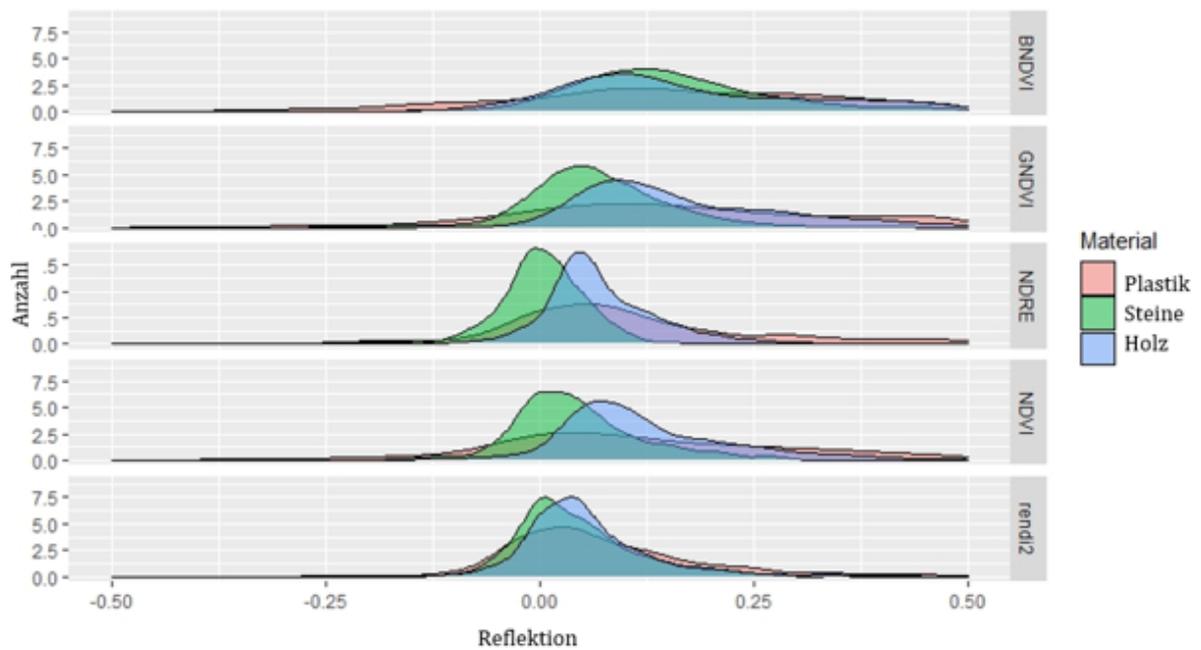
Die Klasse Schnee wurde für die Visualisierung nicht berücksichtigt, da ihr Reflektionswert für alle Wellenlängen außerhalb des in dieser Visualisierung verwendeten y-Achsenbereichs liegt. Quelle: Eigene Darstellung, BCSH

Abbildung 41: Dichtefunktionen der aus den Referenzdaten auf Grönland extrahierten Reflektionswerte für die Wellenlängen von 475, 560, 668, 717 und 842 nm.



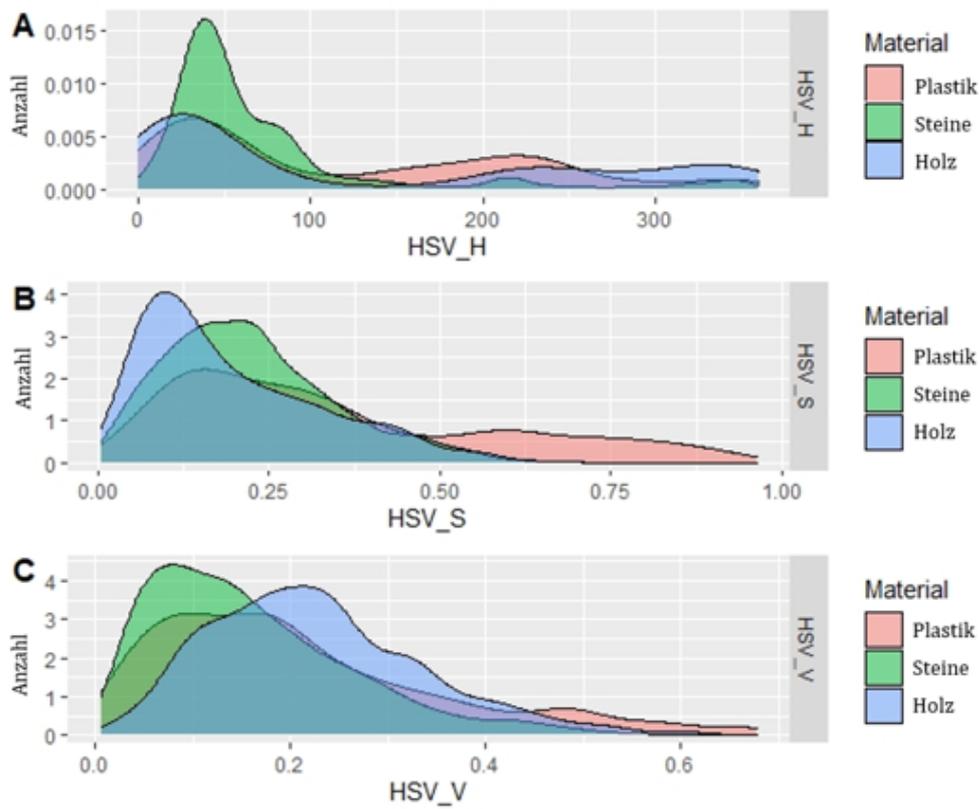
Quelle: Eigene Darstellung, BCSH

Abbildung 42: Dichtefunktionen der angewandten Indizes, extrahiert aus den Referenzdaten für Grönland



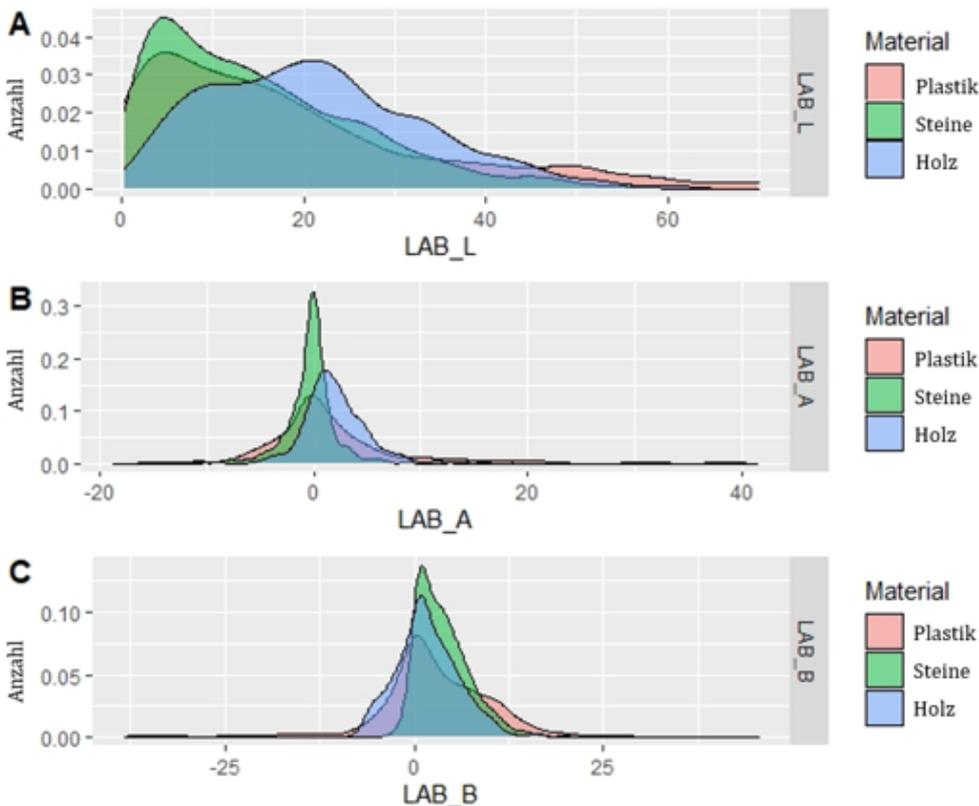
Quelle: Eigene Darstellung, BCSH

Abbildung 43: Dichtefunktionen des HSV-Farbraums für die Referenzdaten aus Grönland



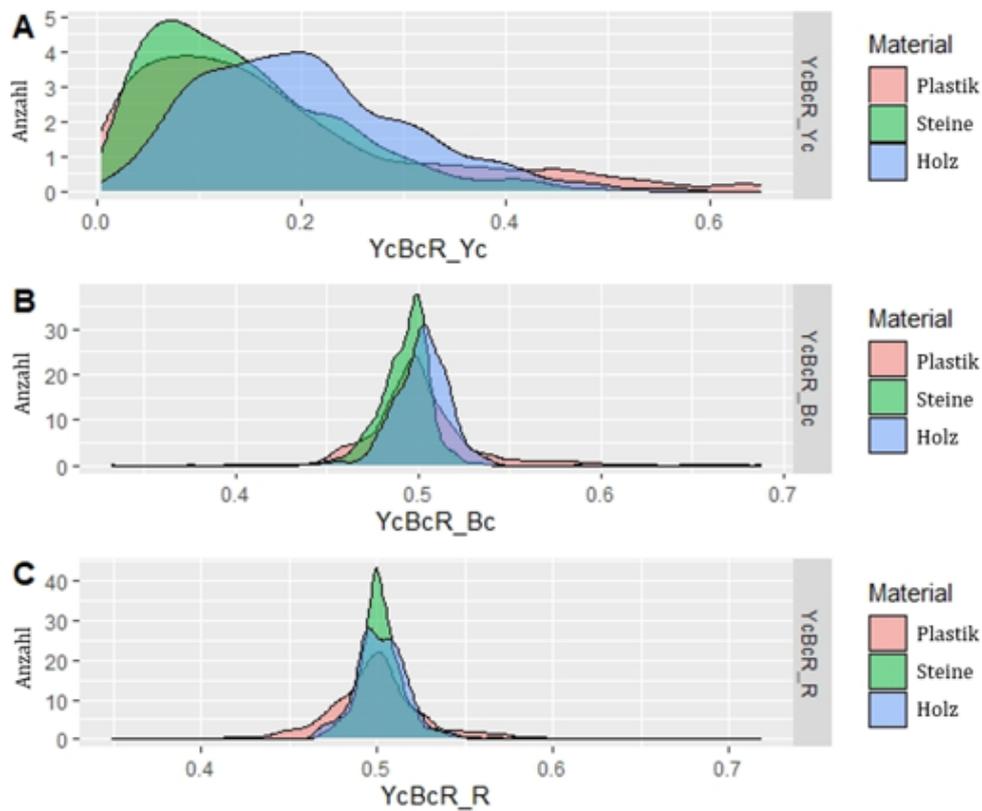
Quelle: Eigene Darstellung, BCSH

Abbildung 44: Dichtefunktionen des LAB-Farbraums für die Referenzdaten aus Grönland



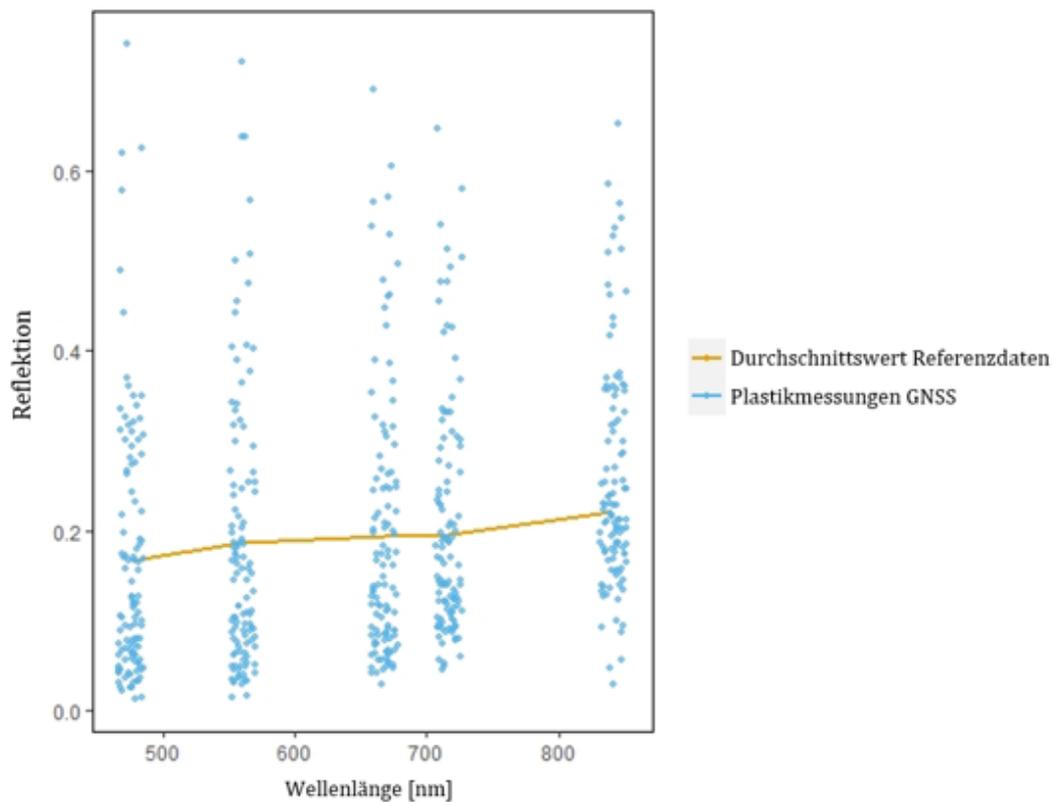
Quelle: Eigene Darstellung, BCSH

Abbildung 45: Dichtefunktionen des YcBcR-Farbraums für die Referenzdaten aus Grönland



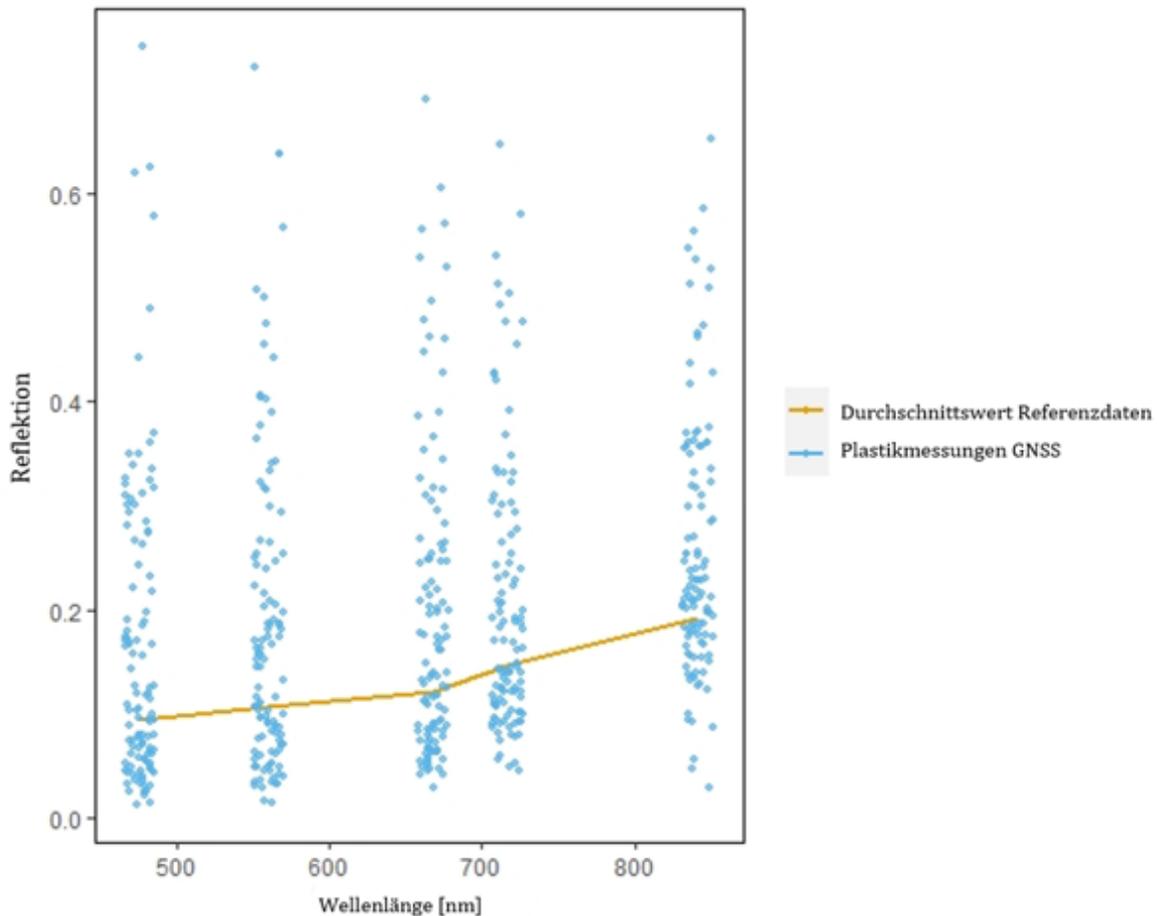
Quelle: Eigene Darstellung, BCSH

Abbildung 46: Vergleich des Referenzdatensatzes mit in situ georeferenzierten Plastikobjekten



Vergleich der Reflektionswerte von Plastikobjekten für Sisimiut Tag 4. Quelle: Eigene Darstellung, BCSH

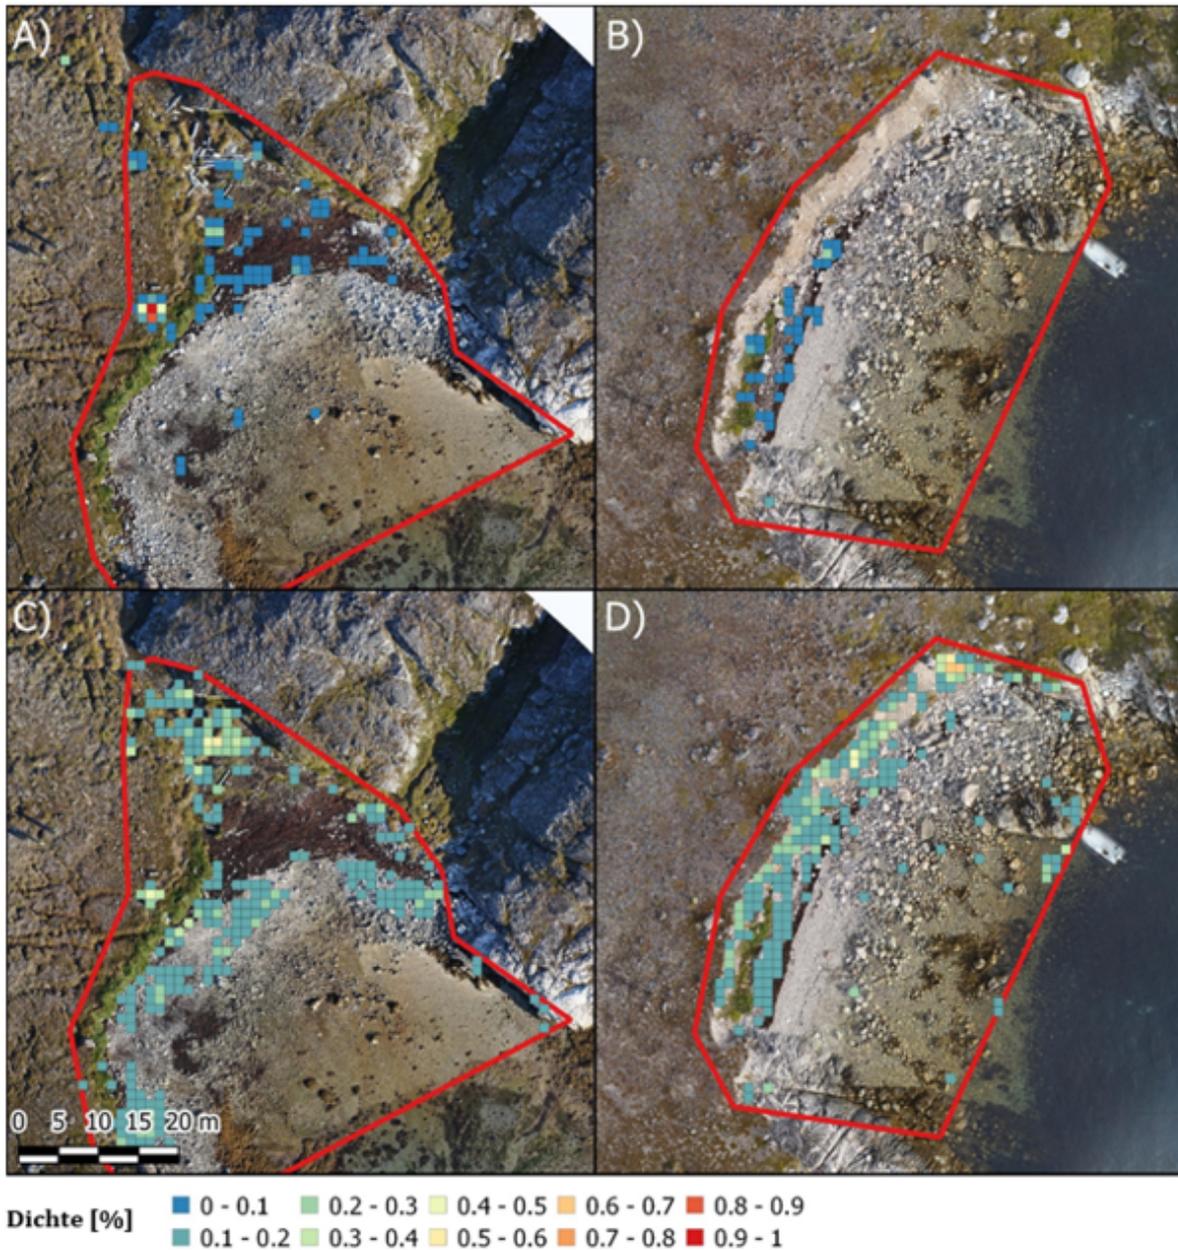
Abbildung 47: Vergleich des Referenzdatensatzes mit in situ georeferenzierten Plastikobjekten



Vergleich der Reflektionswerte von Plastikobjekten für Sisimiut Tag 5. Quelle: Eigene Darstellung, BCSH

Um die Verteilung von Plastik zwischen der (halb-)automatischen Klassifikation und dem manuellen Screening visuell zu vergleichen, wurden Dichtekarten für alle Erhebungen auf Grönland erstellt (Abbildung 48 bis Abbildung 51). Für die (halb-)automatische Klassifikation wurden die Ergebnisse von RF v3 verwendet, da sie die höchste OA erreichten. Die erstellten Dichtekarten bestätigen die in Tabelle 18 festgestellte starke Überschätzung der Plastikklassifikationen. Insbesondere mit Steinen und Holz bedeckte Flächen weisen bei der RF-Klassifikation hohe Plastikdichten auf, während Flächen mit Vegetation, Wasser und Sand genauere Ergebnisse zeigen.

Abbildung 48: Dichtekarte der Flächenabdeckung von Plastikmüll aus manueller Sichtung und aus RF v3



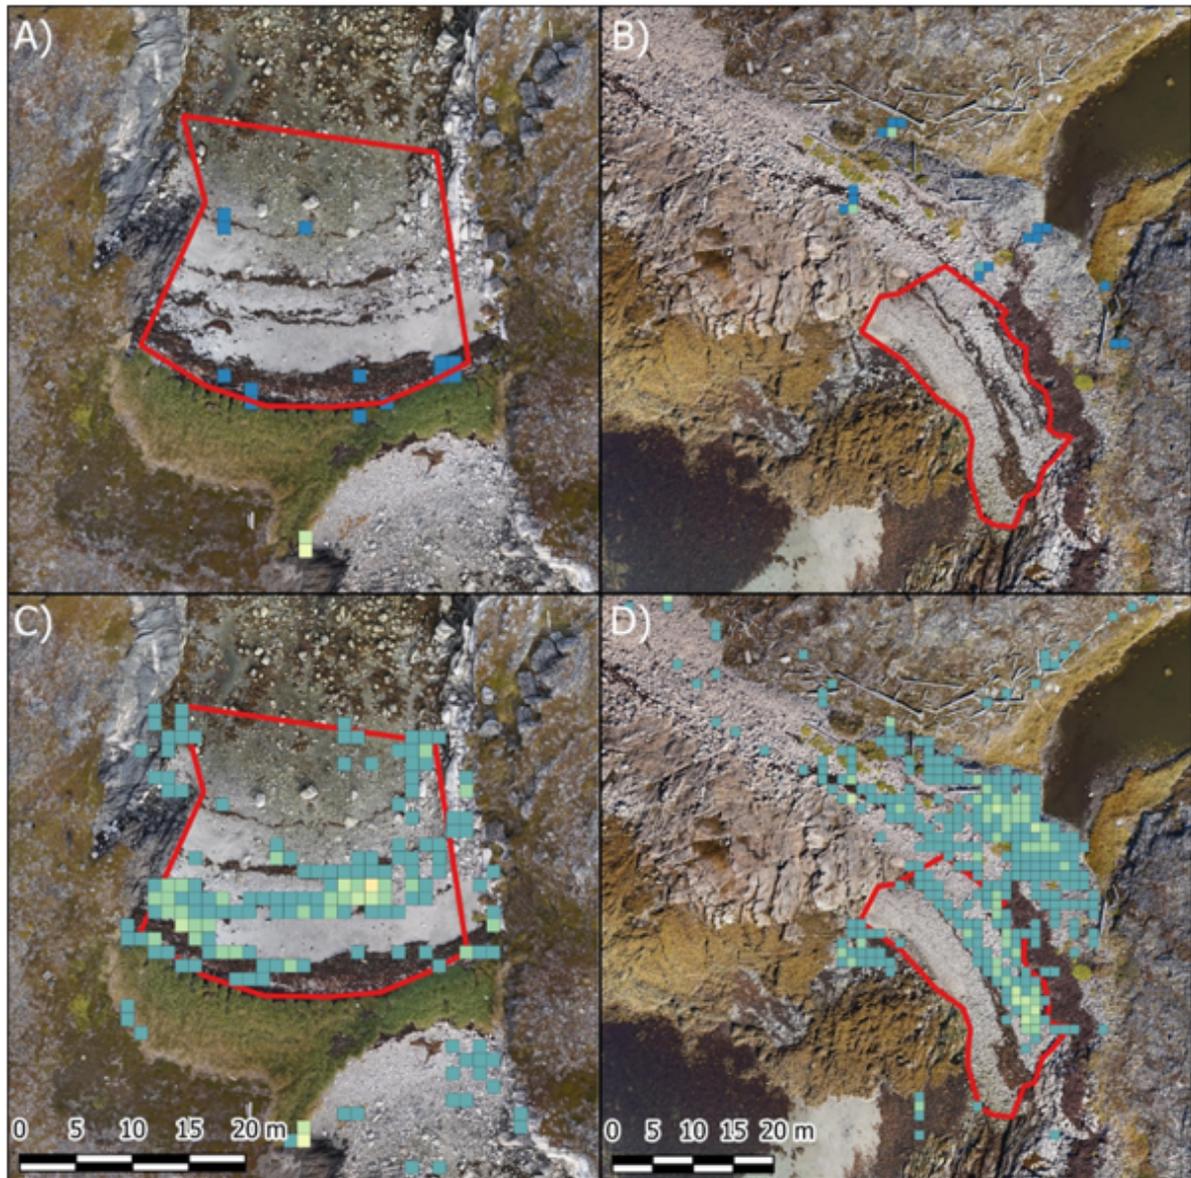
A) und C) Nuuk Tag 1 manuelle Sichtung der Drohnenbilder bzw. RF v3

B) und D) Nuuk Tag 2_1 manuelle Sichtung von Drohnenbildern bzw. RF v3.

Rasterzellen mit einer Dichte von 0 - 0,1 wurden für C) und D) zum besseren visuellen Vergleich ausgeschlossen.

Quelle: Eigene Darstellung, BCSH

Abbildung 49: Dichtekarte der Flächenabdeckung von Plastikmüll aus manueller Sichtung und aus RF v3



Dichte [%]

■ 0 - 0.1	■ 0.2 - 0.3	■ 0.4 - 0.5	■ 0.6 - 0.7	■ 0.8 - 0.9
■ 0.1 - 0.2	■ 0.3 - 0.4	■ 0.5 - 0.6	■ 0.7 - 0.8	■ 0.9 - 1

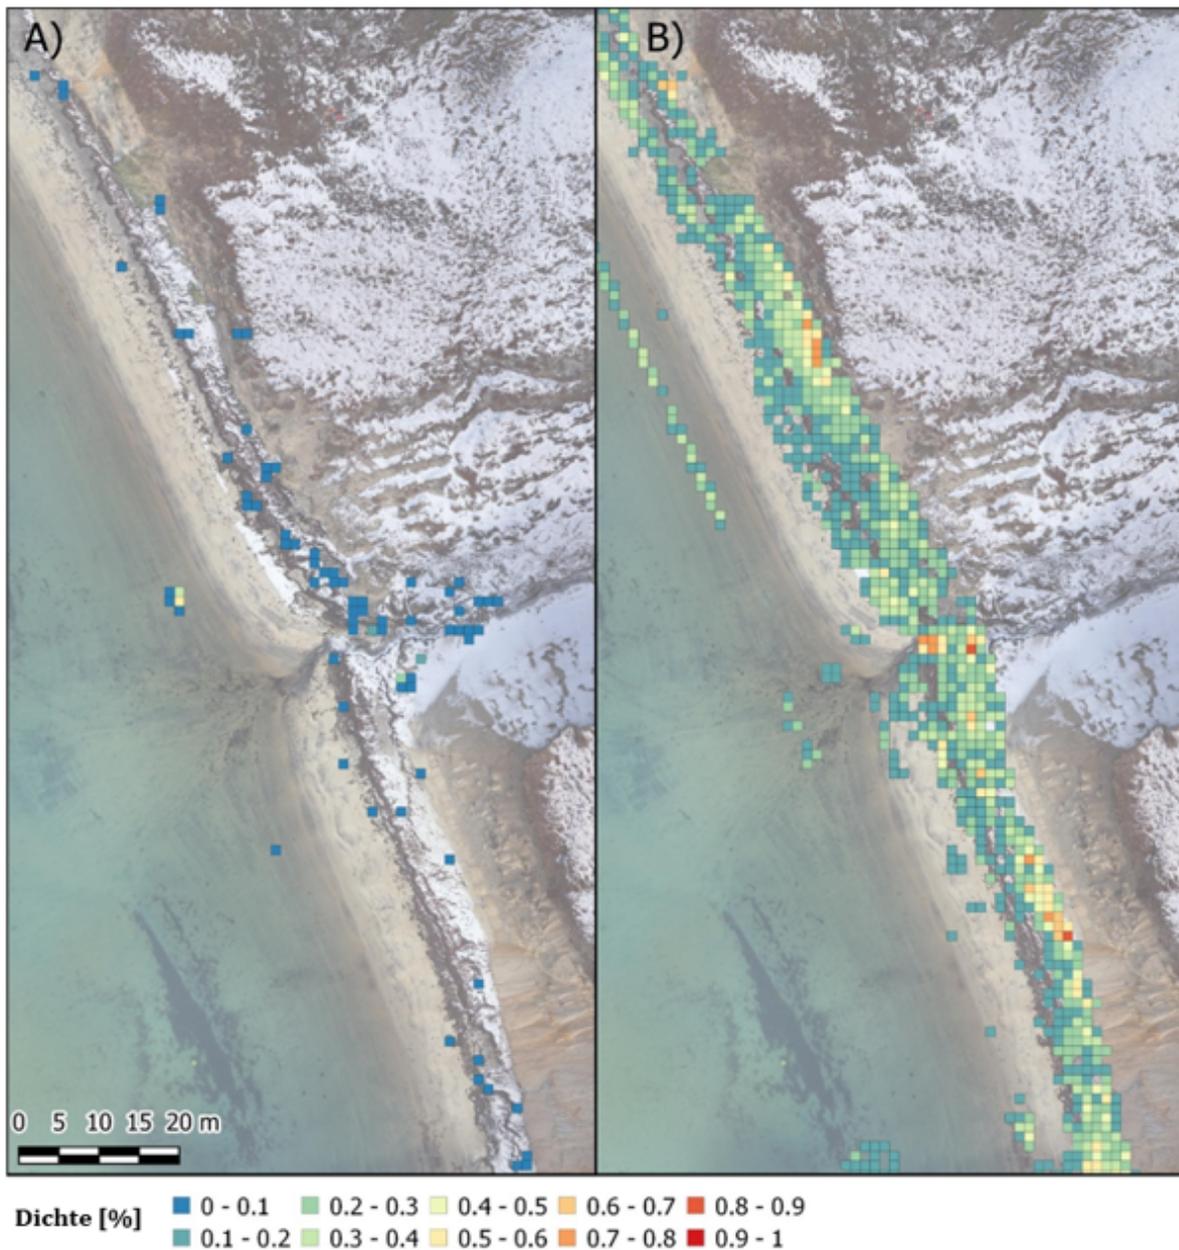
A) und C) Manuelle Sichtung der Drohnenbilder bzw. RF v3 von Nuuk Tag 2_2

B) und D) Manuelle Sichtung von Drohnenbildern bzw. RF v3 von Nuuk Tag 3

Rasterzellen mit einer Dichte von 0 - 0,1 wurden für C) und D) zum besseren visuellen Vergleich ausgeschlossen.

Quelle: Eigene Darstellung, BCSH

Abbildung 50: Dichtekarte der Flächenabdeckung von Plastikmüll aus manueller Sichtung und aus RF v3

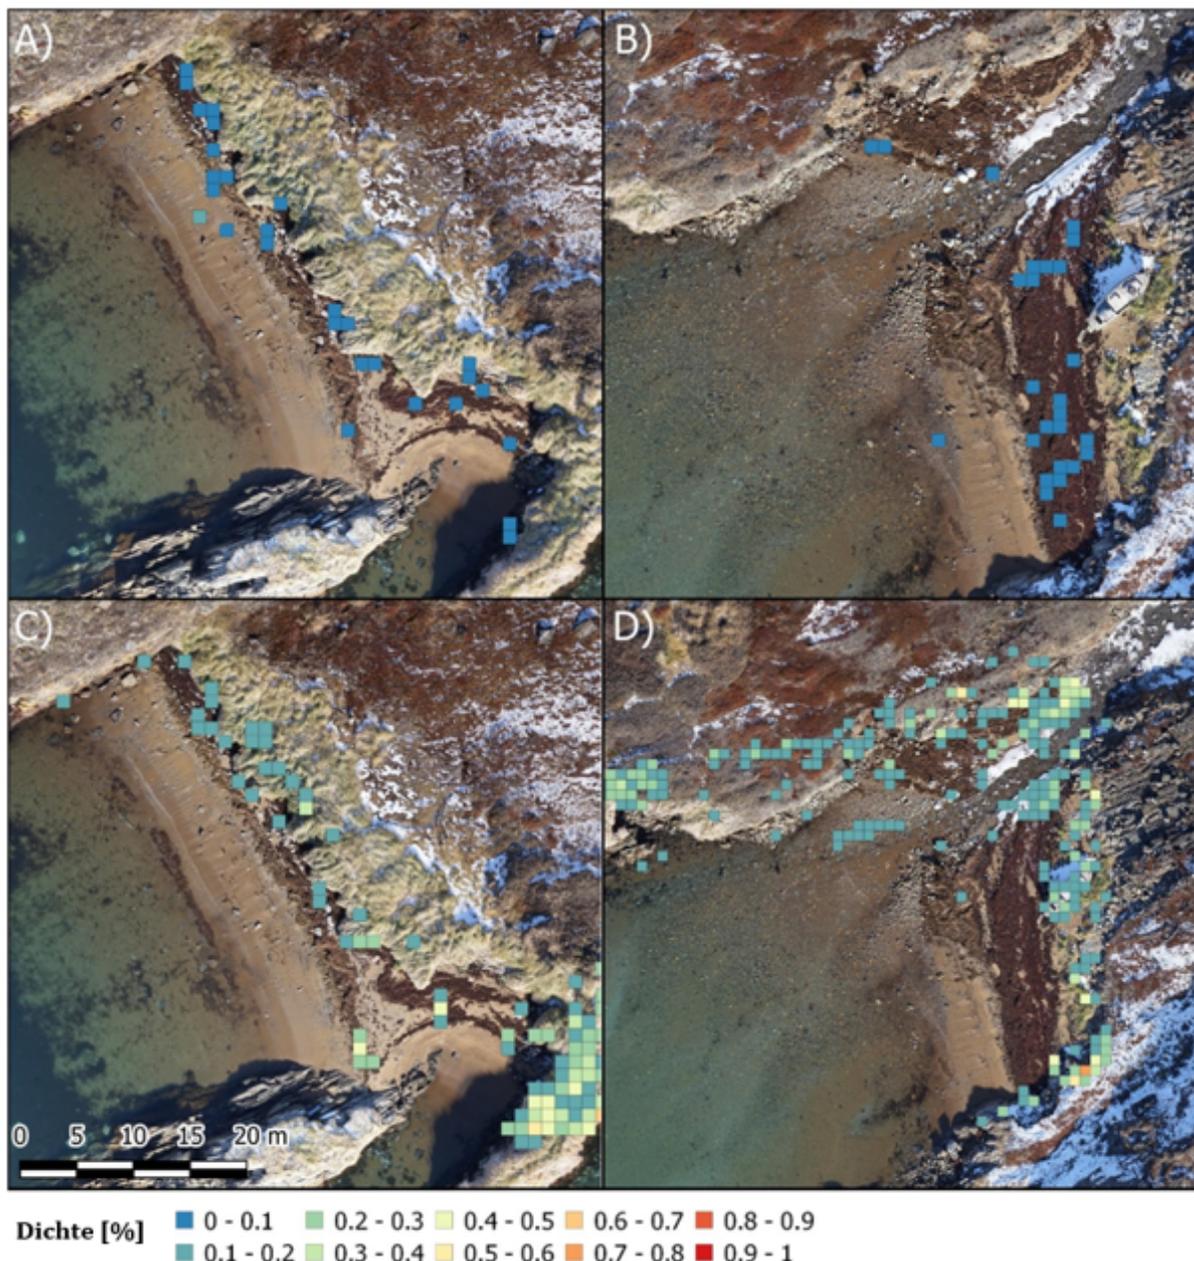


A) und B) Manuelle Sichtung von Drohnenbildern bzw. RF v3 für Sisimiut Tag 4

Für B) wurden zum besseren visuellen Vergleich Rasterzellen mit einer Dichte von 0 - 0,1 ausgeschlossen.

Quelle: Eigene Darstellung, BCSH

Abbildung 51: Dichtekarte der Flächenabdeckung von Plastikmüll aus manueller Sichtung und aus RF v3



A) und C) Manuelle Sichtung der Drohnenbilder bzw. RF v3 für Sisimiut Tag 5-1

B) und D) Manuelle Sichtung der Drohnenbilder bzw. RF v3 für Sisimiut Tag 5-2.

Rasterzellen mit einer Dichte von 0 - 0,1 wurden für C) und D) zum besseren visuellen Vergleich ausgeschlossen.

Quelle: Eigene Darstellung, BCSH

4.3.2.4 Diskussion Drohnenerhebung

Ziel dieser Studie war die Bewertung von Fernerkundungstechniken für die Erfassung von Strandmüll in der Arktis, wobei der Schwerpunkt auf Makromüll lag.

Es wurden Drohnenbefliegungen durchgeführt, um hochauflösende RGB- und VIR-Bilder zu erheben, eine manuelle Sichtung durchzuführen und Ansätze des maschinellen Lernens für (halb-)automatische Klassifikationen zu testen. Die Ergebnisse der manuellen Sichtung wurden darüber hinaus als Referenzdaten für die Satellitenbilder verwendet. Zur Überprüfung des

Müllaufkommens wurden OSPAR-Strandmüllmonitorings an allen Untersuchungsgebieten durchgeführt.

Manuelle Sichtung der Drohnenaufnahmen

Bei der manuellen Sichtung konnten zwischen 0 und 17,5% der Plastikteile gefunden werden, verglichen mit denen, die bei der OSPAR-Erfassung gefunden wurden. Dieser Wert ist niedriger im Vergleich zu den meisten früheren Studien, in denen Drohnenaufnahmen zur Erkennung von Strandmüll verwendet wurden, die eine Erkennbarkeit zwischen 18% (Merlino et al., 2020) und bis zu fast 100% (Andriolo et al., 2020; Escobar Sánchez et al., 2021; Gonçalves et al., 2020b) erreichten (Tabelle 20). Nur Lo et al. (2020) beschrieben mit 3,7% eine niedrigere Erkennungsrate, allerdings unterteilten diese Autoren die Müllobjekte in verschiedene Größenklassen. Die Erkennungsrate von 3,7% wurde für Objekte zwischen 2,5 und 5 cm erreicht.

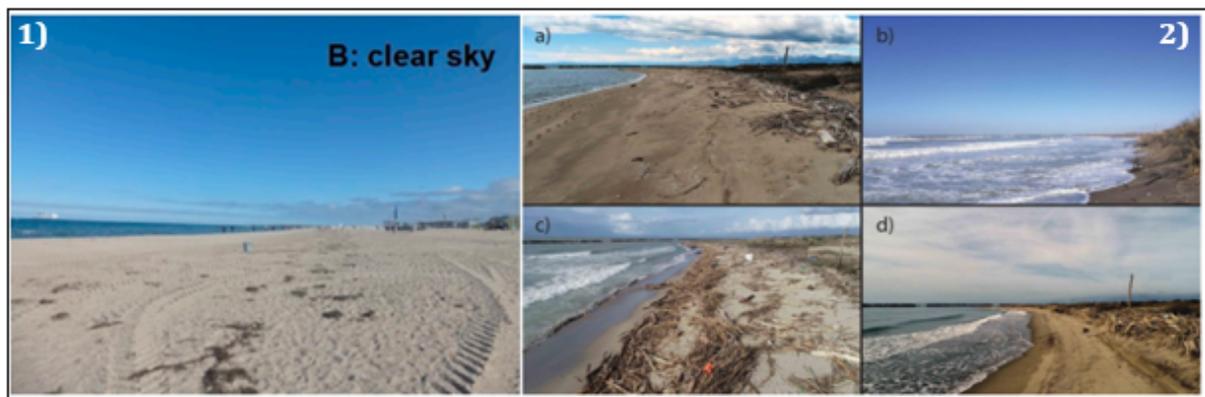
Für die niedrigen Erfassungsraten in dieser Studie wurden drei mögliche Gründe ermittelt, die im Folgenden erörtert werden: Die Größenverteilung der Müllobjekte, die Strandverhältnisse und die räumliche Auflösung (GSD) der Drohnenaufnahmen.

Die Größenverteilung der Müllobjekte hat einen großen Einfluss auf die Erkennbarkeit von Strandmüll, wobei größere Objekte leichter zu erkennen sind. Martin et al. (2018) und Merlino et al. (2020) beschrieben, dass "kleinere Objekte" (<4 cm) in den jeweiligen Studien eine höhere Wahrscheinlichkeit hatten, nicht gefunden zu werden. Dies wurde von Lo et al. (2020) bestätigt, die steigende Erkennungsrate bei einer Zunahme der Objektgröße beschrieben. Daher kann der Gesamtanteil der entdeckten Müllobjekte je nach der Größenverteilung am Untersuchungsort zwischen verschiedenen Standorten erheblich variieren. Dies könnte ein Grund dafür sein, dass Andriolo et al. (2020) fast 100% der Müllobjekte fanden, während Merlino et al. (2020) nur etwa 18-20% entdeckten, obwohl die von Andriolo et al. (2020) verwendete GSD gröber und die Strandverhältnisse komplexer waren. Betrachtet man die von Andriolo et al. (2020) gefundenen Objekte, so wurden über 50% Kategorien zugeordnet, die typischerweise eine Größe von mehr als 10 cm haben und daher leichter zu erkennen sind. Für diese Studie kann nur eine ungefähre Schätzung der Größenverteilung der Müllobjekte gegeben werden, da das OSPAR-Monitoring keine Größenmessung der Objekte beinhaltet, sondern nur Größenbereiche für einige Kategorien angibt. An den Untersuchungsstandorten Kapp Mitra (Spitzbergen), Nuuk (Grönland) und Sisimiut (Grönland) waren Plastikfragmente (2,5 cm – 50 cm) die häufigste oder zweithäufigste Kategorie von Kunststoffabfällen, wobei die meisten Objekte von den Erfasser:innen vor Ort als <10 cm eingestuft wurden. Weitere häufig vorkommende Mülltypen waren Styropor, Umschnürungsbänder, Schnüre und Kordeln, Fäden und Fasern, Netze und Netzreste <50 cm, Kappen und Deckel sowie Schrotpatronen (Tabelle 10, Tabelle 11 und Tabelle 12), die ebenfalls überwiegend eine Größe von <10 cm aufwiesen. Die Dominanz kleiner Objekte könnte zu der relativ geringen Gesamterkennbarkeit im Vergleich zu anderen Studien geführt haben. Dies kann durch einen Blick auf die Größenverteilung der manuellen Sichtung bestätigt werden, wo kleine Objekte unterrepräsentiert zu sein scheinen. Große Objekte (>10 cm) machen zwischen 70 und 80% der bei der manuellen Sichtung gefundenen Plastikobjekte aus.

Ein zweiter Parameter, der sich auf die Erkennbarkeit von Strandmüll auswirkt, sind die Strandverhältnisse. Dazu gehören die Art des Strandes (Substrat: Sand oder Kies), seine Homogenität (z. B. Vorhandensein von Vegetation, Holz oder Steinen) und die daraus resultierende Möglichkeit, dass Abfälle vergraben oder versteckt werden. Je heterogener ein Strand ist, desto schwieriger ist es, Müllobjekte vom Hintergrund zu unterscheiden. Die bunten Farben, die es leicht machen, Müllobjekte zu erkennen, dominieren möglicherweise nicht gegenüber der Vegetation oder farbigen Steinen. Weiße, schwarze und transparente Objekte

können mit Felsen, Kieseln oder Holz verwechselt werden. Darüber hinaus können Vegetation, Steine oder Holz Müllobjekte auf Drohnenbildern verdecken (Merlino et al., 2020). Zusätzlich kann Schnee Objekte begraben und eine Identifizierung von weißen oder transparenten Objekten erschweren (Abbildung 53). Die Mehrzahl der bisherigen Studien wurde an Sandstränden durchgeführt (Escobar Sánchez et al., 2021; Falatti et al., 2019; Gonçalves et al., 2020b; Martin et al., 2018 und Merlino et al., 2020) (Tabelle 20). Eine Ausnahme bilden Lo et al. (2020), die sowohl Sand- als auch Kiesstrände untersuchten. Informationen über die Homogenität des Strandes und die Möglichkeit, ob Objekte verdeckt oder vergraben wurden, sind in früheren Studien oft nur schwer zu ermitteln, wenn sie nicht explizit erwähnt wurden. Sofern verfügbar, geben die Orthomosaik und Bilder der Untersuchungsgebiete jedoch einen ersten Eindruck der Homogenität der Strände (Abbildung 52, Andriolo et al., 2020; Falatti et al., 2019, Gonçalves et al., 2020b; Martin et al., 2018).

Abbildung 52: Übersicht über die Strandverhältnisse aus früheren Studien zur manuellen Auswertung von Strandmüll auf Drohnenbildern



Quelle: 1) Escobar Sánchez et al., 2021; 2) Merlino et al., 2020, beide lizenziert unter [CC BY 4.0](https://creativecommons.org/licenses/by/4.0/)

Die in den Studien von Escobar Sánchez et al. (2021), Falatti et al. (2019) und Gonçalves et al. (2020b) untersuchten Strände scheinen größtenteils homogen zu sein und nur wenige Vegetationsflächen aufzuweisen. Die von Martin et al. (2018) untersuchten Strände weisen einen höheren Anteil an Vegetation auf, während Andriolo et al. (2020) und Merlino et al. (2020) die heterogenste Umgebung mit einem hohen Anteil an Vegetation und Treibholz untersuchten (Abbildung 52). Lo et al. (2020) gab keine Übersicht über die Strandverhältnisse, beschrieb jedoch einen als Kiesstrand und einen zweiten Strand als homogenen Sandstrand. Beim Vergleich der Erkennbarkeit von Müllobjekten zeigten die Studien mit Kiesstränden und heterogeneren Strandverhältnissen niedrigere Erkennungsraten (Martin et al., 2018; Merlino et al., 2020 und Lo et al., 2020). Lo et al. (2020), die sowohl Sand- als auch Kiesstrände untersuchten, zeigten, dass Sandstrände eine höhere Entdeckungsrate aufwiesen als Kiesstrände. Eine Ausnahme bildeten Andriolo et al. (2020), die fast alle Objekte erkennen konnten, obwohl die Strandumgebung komplex war. Ein möglicher Grund für die hohe Erkennungsrate bei Andriolo et al. (2020) ist der Einfluss der Größenverteilung der Müllobjekte und der hohen Anzahl großer Gegenstände. In dieser Studie wurden insgesamt sieben arktische Strände (einschließlich verschiedener Strandabschnitte) überwacht, darunter fünf Kies- und zwei Sandstrände. Die Strandverhältnisse aller Untersuchungsstandorte wurde als heterogen eingestuft, mit einem hohen Anteil an Treibholz, Steinen und Vegetation und mit einer leichten Schneebedeckung an den beiden Sandstränden in der Nähe von Sisimiut (Abbildung 53). Im Vergleich der Strandtypen gehörten die beiden Sandstrände zu den Stränden mit den höchsten Erkennungsraten (15% und 17,4%). Die geringe Detektionsrate an den beiden Sandstränden im Vergleich zu Studien mit ähnlichen Strandsubstraten könnte durch die Schneebedeckung, die

Größenverteilung der Abfälle und die GSD beeinflusst sein. Abbildung 37 zeigt, dass von den auf den Drohnenbildern gefundenen Plastikobjekten weiße Objekte eine andere Größenverteilung aufwiesen als farbige, wobei der Median der Objektgröße zwei- bis dreimal so groß war wie bei weißen Objekten. Geht man davon aus, dass kein farblicher Unterschied in der tatsächlichen Größenverteilung besteht, so waren weiße oder transparente Objekte schwerer zu erkennen, insbesondere vor hellen Hintergründen wie Felsen und Schnee. Dies konnte am Untersuchungsort Sisimiut Tag 4 bestätigt werden, wo 50% der per GNSS gemessenen Objekte, die beim manuellen Screening nicht gefunden werden konnten, weiß oder transparent waren. Der komplexe Hintergrund mit Vegetation und farbigen Steinen könnte außerdem die Erkennbarkeit von farbigen Objekten verringert und die Gesamterkennungsrate beeinflusst haben.

Abbildung 53: Beispiele für die Strandumgebung auf Spitzbergen und Grönland



1) Gebiet am Strand von Kapp Mitra, Spitzbergen 2) Strand im Untersuchungsgebiet von Nuuk Tag 1, Grönland
3) Vergrabene oder verdeckte Müllgegenstände bei Sisimiut Tag 4 und Sisimiut Tag 5, Grönland

Quelle: Eigene Darstellung, BCSH

Neben der Größenverteilung der Abfälle und der Strandverhältnisse hat die GSD der Drohnenaufnahmen den größten Einfluss auf die Erkennbarkeit von Strandmüll, da sie die Anzahl der Pixel pro Objekt bestimmt. Eine höhere GSD (niedriger GSD-Wert) verringert die Mindestgröße eines Objekts, die ausreicht, um erkannt zu werden. Objekte mit etwa dem Zehnfachen der GSD können auf RGB-Bildern visuell erkannt werden (Moy et al. 2018, Pichel et al. 2012, Garcia-Garin et al. 2019). Die GSD ist der einzige der oben genannten Parameter, der direkt vom Anwender definiert werden kann, da er vom gewählten Sensor und der Flughöhe abhängt. In früheren Studien wurde eine GSD zwischen 0,18 cm (Merlino et al., 2020) und 1,2 cm

(Andriolo et al., 2020) verwendet (Abbildung 52). Ein Vergleich der Erkennbarkeit der oben genannten Studien ergab, dass die Erkennungsrate nicht immer mit einer Verringerung der GSD-Werte zunahm. Dies bestätigt den Einfluss zusätzlicher Parameter wie der Größenverteilung der Müllobjekte und der Strandverhältnisse. Um die Auswirkungen des GSD zu bewerten, verglichen Lo et al. (2020) verschiedene GSD-Einstellungen für dieselben Strände und bestätigten, dass niedrigere GSD-Werte zu einer Erhöhung der Nachweisbarkeit führen. Dennoch ist der niedrigste GSD-Wert möglicherweise nicht immer die beste Wahl, da eine Verringerung des GSD-Werts eine geringere Flughöhe erfordert und zu einer geringeren Flächenabdeckung führt. Darüber hinaus sind Starrflüglerdrohnen, die in der Regel für die Überwachung großer Gebiete eingesetzt werden, in ihrer Mindestflughöhe begrenzt. Da Starrflüglerdrohnen eine Mindestfluggeschwindigkeit benötigen, um stabil zu sein, und die Verschlusszeit der Sensoren begrenzt ist, kann nur die Flughöhe angepasst werden, um sicherzustellen, dass die Abdeckung der Bilder ausreichend ist und zu keinen Datenlücken führt. Multikopter können die Fluggeschwindigkeit anpassen und daher auch in sehr geringen Höhen betrieben werden, haben aber in der Regel eine geringere Flächenabdeckung. Daher eignen sie sich für experimentelle Zwecke, nicht aber für großflächige Anwendungen. Die bisherigen Studien zur manuellen Sichtung von Strandmüll setzten alle Multikopter ein und konzentrierten sich auf kleine Testflächen. Nur Martin et al. (2018) beschreibt eine großflächige Anwendung entlang der saudi-arabischen Küstenlinie. Da für die Mülldetektion in der Arktis die zeitliche und räumliche Abdeckung entscheidend ist, wurde für diese Studie eine WingtraOne Starrflügler-Drohne verwendet. Die minimale GSD der verwendeten Drohnen-Sensor-Konfiguration betrug 1,4 cm für den RGB-Sensor. Unter der Annahme einer möglichen Erkennbarkeit von Objekten mit einer Mindestgröße des Zehnfachen der GSD wurde angenommen, dass hauptsächlich Müllobjekte >14 cm erkannt werden. Aufgrund der Form und Farbe von Plastikgegenständen wurde jedoch erwartet, dass auch kleinere Gegenstände gefunden werden. Ein Ziel dieser Studie war es daher, zu prüfen, ob eine GSD von 1,4 cm ausreichend ist, um die Verteilung von Müll an arktischen Stränden abzubilden. Die Ergebnisse der manuellen Sichtung haben gezeigt, dass dies nicht der Fall ist und für künftige Anwendungen eine geringere GSD erforderlich sein wird. Wie oben beschrieben, erschwerte der Umgebungshintergrund eine farbbasierte Erkennung von kleinen Gegenständen. Darüber hinaus zeigt ein Vergleich der Erkennungsrate dieser Studie mit den Ergebnissen von Andriolo et al. (2020), die eine ähnliche GSD verwendeten, große Unterschiede, die auf Unterschiede in der Größenverteilung der Müllobjekte zurückzuführen sind.

Tabelle 20: Übersicht über die bei der manuellen Überprüfung von Drohnenaufnahmen gefundenen Müllobjekte und die entsprechende Größenverteilung der Objekte, der Strandverhältnisse und der GSD

	Plastikmüll, der durch manuelle Sichtung gefunden wurde, im Vergleich zur Gesamtzahl der Bodenuntersuchung	Größenverteilung	Strandverhältnisse	GSD [cm]
Diese Studie	0 – 17,5%	Mehrheit der Objekte <10 cm	Kiesstrand und Sandstrand	1,4
Andriolo et al., 2020	“nicht nennenswerte Anzahl übersehen”	~ 50% der Plastikgegenstände war Flaschen, Säcke und Oktopus-Pots	Dünengebiet an der Küste	1,2
Escobar Sánchez et al., 2021	87,5 - 99%	NA	Sandstrand	0,27
Falatti et al., 2019	87,8 – 95,9%	Zwischen 2 – 35% der Gegenstände waren <5 cm	Sandstrand	0,44
Gonçalves et al., 2020b	98%	NA	Sandstrand und teilweise Düne	0,55
Lo et al. 2020	3,7 - 100%	Für Größenklassen zwischen 2,5 – 5 cm und 30 – 50 cm	Kiesstrand und Sandstrand	0,2 – 0,6
Martin et al., 2018	61,8%	NA	Sandstrand	0,5 – 0,7
Merlino et al., 2020	18 - 20%	NA	Sandstrand	0,18

NA: Keine Information zu der Größenverteilung

Weitere kleinere Faktoren, die sich auf die Erkennbarkeit auswirken können, sind die Tageszeit der Erfassung, die Wetterbedingungen und der Anwender, der die manuelle Sichtung durchführt. Lo et al. (2020) und Martin et al. (2018) schlagen vor, Erhebungen um die Mittagszeit durchzuführen, um Schatteneffekte zu minimieren, die sich negativ auf die Detektierbarkeit auswirken können. In der Arktis ist die Vermeidung von Schatteneffekten eine große Herausforderung, da der Sonnenwinkel den ganzen Tag über niedrig bleibt. Außerdem können sich die Wetterbedingungen auf die Lichtempfindlichkeit (ISO) und damit auf die Bildqualität auswirken. In abgelegenen Gebieten wie der Arktis kann man keine perfekten

Bedingungen in Bezug auf Tageszeit und Wetter erwarten, da die Zeit für die Erfassung in der Regel begrenzt ist. Für die manuelle Sichtung sind Anwender, die mit dem Untersuchungsgebiet und den zu erwartenden Müllgegenständen vertraut sind, von Vorteil, da sie eher in der Lage sein werden, die Müllgegenstände auf den Drohnenbildern zu identifizieren.

Neben der Detektierbarkeit wurde auch der Zeitaufwand für die Drohnenerhebungen und die manuelle Sichtung ausgewertet. Die Dauer der Drohnenerhebungen lag zwischen 20 und 60 Minuten, einschließlich etwa 15 Minuten für den Aufbau der Drohne. Die Datenverarbeitung und -aufbereitung erfolgte größtenteils automatisch und erforderte etwa 01:30 Stunden manuelle Arbeitszeit pro Erhebung. Bei großen Erfassungen, wie sie in Kapp Mitra durchgeführt wurden, konnten bis zu fünfzig 50-m-Transekte pro Stunde erfasst werden, was zu einer Arbeitszeit (Drohnenerhebung und Datenverarbeitung) von etwa 3 Minuten pro 50-m-Transekt führt, wenn alle Transekte ausgewertet werden. Kleinere Gebiete, die nur ein einziges 50-m-Transekt umfassen, benötigen immer noch mindestens 20 Minuten für die Drohnenerfassung und etwa 1,5 Stunden für die Datenverarbeitung. Die manuelle Sichtung der 50 m langen Transekte dauerte zwischen 5 und 20 Minuten, je nach Strandhintergrund und der Anzahl der Müllgegenstände. Einschließlich der Drohnenerfassung, der Datenverarbeitung und der manuellen Sichtung kann die Gesamtzeit für ein drohnengestütztes Monitoring eines 50-Meter-Transekts zwischen 8 und 130 Minuten liegen (Tabelle 21).

Tabelle 21: Zeitaufwand für die drohnengestützte Erfassung von Strandmüll

Erfasster Strand	Drohnen Erfassung	Datenverarbeitung	Manuelle Sichtung	Gesamt	OSPAR
50 m Transekt	01:10 – 20:00 Min	01:50 – 90:00 Min	05:00 – 20:00 Min	08:00 – 130:00 Min	90:00 – 180:00 Min

Das OSPAR-Monitoring in der Arktis wurde von zwei bis drei Erfasser:innen durchgeführt, die zwischen 30 Minuten und einer Stunde pro 50-Meter-Transekt benötigten, was eine Gesamtarbeitszeit zwischen 90 und 180 Minuten ergab. Verglichen mit der berechneten Zeit für ein drohnengestütztes Monitoring benötigt die OSPAR-Methode für große Gebiete bis zu 22-mal länger, könnte aber für kleine Gebiete schneller sein. Die Gesamtzeit für ein drohnengestütztes Müllmonitoring kann durch eine erfolgreiche Integration von (halb-)automatischen Klassifikationsansätzen reduziert werden, wodurch die Zeit für die manuelle Sichtung verringert werden kann. Martin et al. (2018) beschrieben, dass ihre Drohnenerhebungen im Vergleich zu einem standardmäßigen in situ Ansatz um das 39-fache schneller waren, allerdings ohne die für die manuelle Sichtung erforderliche Zeit einzurechnen. Da die Strände in der Arktis oft abgelegene sind, kann die Zeit am Strand begrenzt sein. Daher kann eine schnellere Erfassung der Strände vor Ort bereits von großem Vorteil sein.

Die manuelle Auswertung von Drohnenbildern ist eine vielversprechende Methode zur Erkennung von Strandmüll, wie bereits in mehreren Studien gezeigt wurde (z. B. Escobar Sánchez et al., 2021; Falatti et al., 2019; Gonçalves et al., 2020b und Lo et al. 2020). Drohnenerhebungen ermöglichen eine schnelle, nicht-invasive Erfassung von großen und abgelegenen Gebieten. Außerdem können sie Informationen über die räumliche Verteilung und die Auswirkungen der Strandmorphologie sowie über die Größenverteilung des Mülls liefern. Die Umweltbedingungen und die Anforderungen an eine große Flächenabdeckung und die kurze zur Verfügung stehende Erfassungszeit machen eine Umsetzung in der Arktis jedoch zu einer Herausforderung. Die Ergebnisse dieser Studie zeigen, dass eine GSD von 1,4 cm für die

Erkennung kleiner Objekte nicht ausreichend ist. Um den komplexen Umweltbedingungen und der Größenverteilung der Müllobjekte gerecht zu werden, wird eine GSD von weniger als einem Zentimeter empfohlen. Doch selbst bei Anwendung einer GSD von 0,18 cm bis 0,4 cm (Merlino et al., 2020 bzw. Lo et al., 2020) beschrieben die Autoren Schwierigkeiten bei der Erfassung von Strandmüll für Objekte <10 cm. Außerdem müssen weitere Einschränkungen berücksichtigt werden. Um eine Drohnenuntersuchung in der Arktis durchzuführen, ist in abgelegenen Gebieten ein Drohnenpilot erforderlich, und wenn die Abfälle nicht nur überwacht, sondern auch eingesammelt werden sollen, müssen die Strände persönlich betreten werden, wodurch einer der Hauptvorteile von Drohnenuntersuchungen wegfällt. Zudem ist die Erkennbarkeit von Müll bei vergrabenen oder verdeckten Müllobjekten stets eingeschränkt und eine Aussage über das Gewicht des Mülls kann nicht ohne weiteres getroffen werden. Um den Anforderungen einer schnellen Erfassung großer Flächen gerecht zu werden, bieten sich Starrflüglerdrohnen an. Professionelle Starrflüglerdrohnen wie der WingtraOne und die senseFly eBee erreichen mit ihren Sensoren bisher nur GSDs von 0,7 – 1 cm, was für die Erfassung von kleinen Müllobjekten nicht ausreichend sein dürfte. Dies kann sich in Zukunft durch die Integration neuer Sensortechnologie ändern, die bereits im Hochpreissegment verfügbar ist (z.B. PhaseOne-Sensoren). Alternativ könnte die Implementierung von Citizen Science mit dem Einsatz von kostengünstigen Multikoptern eine Option für eine kleinräumige Integration in das arktische Strandmüllmonitoring sein. Insbesondere eine Einbindung in bestehende Kreuzfahrt- oder Forschungsprogramme könnte von Interesse sein. Das Gebiet um Nuuk hat gezeigt, dass trotz der langen Küstenlinie nur ein kleiner Teil davon für die Erfassung von Strandabfällen geeignet ist und daher auch mit einem kostengünstigen Multikopter abgedeckt werden könnte. Es könnte ein genau festgelegter operationeller Ablauf entwickelt und mit den verschiedenen Beteiligten geteilt werden. Drohnenerhebungen könnten während bestehender Kreuzfahrten, Universitätsexkursionen oder Forschungsprogrammen durchgeführt und anschließend von Expert:innen gesammelt und interpretiert werden. Um den Anforderungen der Arktis gerecht zu werden, muss ein solcher Erfassungssablauf noch entwickelt werden.

Neben der Bewertung der Einsetzbarkeit von Starrflüglerdrohnen für eine manuelle Mülldetektion in der Arktis wurden die Ergebnisse der manuellen Sichtung als Referenz für die (halb)automatischen Klassifikationsansätze des multispektralen UAV-Sensors sowie für die Satellitenbilder verwendet.

(Halb-)automatische Klassifikation

Die Vorteile von Drohnenanwendungen für die Überwachung von Strandmüll wurden bereits für eine manuelle Sichtung genannt und diskutiert. Einer der größten Vorteile von Drohnenerhebungen im Vergleich zu traditionellen in situ Methoden, nämlich die große Flächenabdeckung, bringt auch die Herausforderung mit sich, große Mengen an Daten und Bildern zu sichten. Auf Grönland und Spitzbergen wurden insgesamt 4201 RGB- und 5364 VIR-Bilder gesammelt, die eine Gesamtfläche von etwa 100 ha pro Sensor abdecken. Mit Multikoptern, die in geringerer Höhe fliegen, um eine höhere GSD zu erreichen, könnten sogar noch mehr Bilder für dieselbe Fläche aufgenommen werden, da der Bildausschnitt kleiner ist. Eine manuelle Sichtung großer Flächen kann daher sehr zeitaufwändig sein, so dass sie weder zeit- noch kosteneffizient ist. Deshalb ist für eine großflächige Erfassung die Anwendung (halb-)automatischer Klassifikationsverfahren erforderlich. Mehrere Ansätze wurden bereits für die Erkennung von Strandmüll getestet, wie Grenzwertverfahren (Bao et al., 2018), Maximum-Likelihood-Klassifikator (ML) (Bao et al., 2018; Escobar Sánchez et al., 2021), Random Forest (RF) (Escobar Sánchez et al., 2021; Gonçalves et al., 2020a; Gonçalves et al., 2020b; Gonçalves et al., 2020c; Martin et al., 2018; Wolf et al. 2020), Support Vector Machine (SVM) (Escobar Sánchez et al., 2021; Wolf et al. 2020), K-nearest neighbors (KNN) (Gonçalves et al., 2020c), und Convolutional Neural Networks (Bak et al., 2019; Falatti et al., 2019; Gonçalves et al., 2020b;

Papakonstantinou et al., 2021; Wolf et al. 2020). Die oben genannten Studien verwendeten hochauflösende RGB-Drohnenbilder mit einer GSD zwischen 0,2 cm (Wolf et al., 2020) und 3 cm (Bao et al., 2018). Die Klassifikationsansätze variierten zudem zwischen pixelbasierten, objektbasierten und Kachel-basierten Klassifikationen. Die Ergebnisse der Klassifikationsansätze sind in Tabelle 22 zusammengefasst. Wie in Goncalves et al. (2020a) erwähnt, ist ein Vergleich zwischen verschiedenen Klassifikatoren in verschiedenen Studien immer mit Vorsicht zu genießen, da Faktoren wie die Strandverhältnisse, die Anzahl der Testgebiete und die Größenverteilung der Müllobjekte einen größeren Einfluss haben können als die Klassifikationsmethode selbst. Bao et al. (2018) war unter den Studien mit der höchsten Gesamtgenauigkeit (OA), obwohl sie die niedrigste GSD aller genannten Studien und einen relativ einfachen Klassifikationsansatz verwendeten. Hier dürfte die sehr homogenen Strandverhältnisse einen größeren Einfluss gehabt haben als die GSD oder der Klassifikator. Neben der OA, die nur in einigen der genannten Studien verfügbar war, werden die UA (in einigen Studien auch als Sensitivität oder Recall bezeichnet) und die PA (auch als Präzision oder positiv vorhergesagter Wert (PPV) bezeichnet) sowie der F-Score zur Genauigkeitsbewertung verwendet.

Der F-Score ist ein Maß für die Gesamtqualität eines Klassifikators und kombiniert UA und PA:

$$F_{score} = 2 * \frac{UA * PA}{UA + PA}$$

Er wurde in der Mehrzahl der Studien zur automatischen Erkennung von Strandmüll verwendet (Falatti et al., 2019; Gonçalves et al., 2020a, b, c; Martin et al., 2018; Papakonstantinou et al., 2021; Wolf et al. 2020).

In dieser Studie wurden drei Klassifikatoren (RF, SVM und NN) unter Verwendung von RGB- und VIR-Bildern angewandt. Die multispektralen Bilder wurden getestet, um festzustellen, ob die zusätzlichen spektralen Informationen die niedrigen GSD-Werte ausgleichen können. Die GSD der beiden Sensoren betrug 1,4 cm für RGB und 3,4 cm für VIR. Die mit den RGB-Aufnahmen erzielte OA lag zwischen 62,5% und 78,6%, wobei die besten Ergebnisse für RF erzielt wurden. Die erreichte OA ist vergleichbar mit den Ergebnissen von Escobar Sánchez et al. (2021) und Papakonstantinou et al. (2021), obwohl in diesen Studien eine GSD von 0,27 cm bzw. 0,5 cm verwendet wurde. Die ähnliche OA im Vergleich zu Escobar Sánchez et al. (2021), die nur den RGB-Farbraum verwendeten, könnten das Ergebnis einer Erweiterung des Feature-Raums um die HSV-, CIE-LAB- und YcbCr-Farbräume sein, wie sie zuvor in Gonçalves et al. (2020a, b, c) angewendet wurde. Bao et al. (2020) und Wolf et al. (2020), die eine GSD von 1 – 3 cm bzw. 0,5 cm verwendeten, erreichten höhere OA mit bis zu 98% bzw. 83%. Der in dieser Studie erzielte F-Score schwankte zwischen 40% und 70% für die RGB-Bilder und ist auch mit den in Tabelle 22 zusammengefassten Studien vergleichbar und liegt nur geringfügig unter den Ergebnissen der Studien von Falatti et al. (2019), Gonçalves et al. (2020a, c), Papakonstantinou et al. (2021) und Wolf et al. (2020), die F-Scores zwischen 73% und 81% erreichten.

Vergleicht man die Leistung für RGB- und VIR-Bilder, so zeigt sich in dieser Studie, dass die Klassifikatoren, die VIR-Bilder verwenden, die Klassifikatoren für RGB-Bilder mit dem höchsten OA von 90,6% gegenüber 78,6% und einem F-Score von 77% gegenüber 70% übertreffen. In beiden Fällen wurden die besten Ergebnisse bei OA und F-Score mit RF erzielt, aber SVM zeigte ähnliche Ergebnisse. Bei Verwendung des Neuronalen Netzes (NN) mit Gewichtung konnte ein Overfitting des Modells mit sehr hohen PA- und niedrigen UA-Werten beobachtet werden. Die Ergebnisse für RGB- und VIR-Bilder deuten darauf hin, dass der für die Klassifikation verwendete Feature-Raum einen größeren Einfluss auf die Klassifikationsleistung hatte als die GSD, was die Anwendung von VIR-Sensoren für die Zukunft vielversprechend macht. Betrachtet man jedoch die tatsächlichen Klassifikationskarten, so konnte in dieser Studie für beide Sensoren eine enorme Überschätzung von Plastik festgestellt werden. Trotz der guten

statistischen Ergebnisse war es nicht möglich, die verschiedenen Klassen anhand ihrer spektralen Information richtig zu trennen (Abbildung 40 bis Abbildung 45). Insbesondere die Klassen *Holz* und *Steine* wurden häufig fälschlicherweise als *Plastik* klassifiziert. Da diese Klassen an den untersuchten Standorten viel häufiger vorkamen als Plastik, konnte bereits ein kleiner Prozentsatz falsch klassifizierter Steine oder Holz die Anzahl der als Plastik klassifizierten Pixel erheblich erhöhen. Dies unterstreicht erneut den starken Einfluss der Strandverhältnisse auf die Klassifikationsleistung. Bei VIR-Aufnahmen haben auch die Wetterbedingungen einen großen Einfluss. Vor und nach jeder Messung wird ein Bild einer Referenzreflektionsfläche aufgenommen, um die aufgezeichneten digitalen Werte in Reflektionswerte umzuwandeln. Daher sollten sich die Wetterbedingungen (insbesondere die Wolkenbedeckung) innerhalb einer einzigen Messung nicht ändern, da dies zu verfälschten Reflektionswerten führen und die Klassifikationsergebnisse beeinträchtigen könnte. Wenn dies jedoch sichergestellt werden kann, ermöglichen die Reflektionswerte von VIR-Aufnahmen eine Übertragbarkeit der Referenzdaten und der Modelle für spektralbasierte Klassifikationsansätze. Im Gegensatz dazu sind RGB-Bilder für farbbasierte Klassifikationen stark wetter- und lichtabhängig und schwer übertragbar.

Diese Studie bestätigt das große Potenzial (halb-)automatischer Klassifikationsansätze, die eine Methode zur zeit- und kosteneffizienten großflächigen Erfassung von Strandmüll anhand von Drohnenbildern bieten. Statistische Verfahren ermöglichen eine Bewertung der Klassifikationsergebnisse, und da die Klassifikation benutzerunabhängig ist, ist kein vorheriges Expertenwissen über die Mülltypen erforderlich. Allerdings müssen die vielversprechenden statistischen Ergebnisse immer durch die tatsächlichen Klassifikationskarten bestätigt werden. Hier zeigen die Ergebnisse, dass bei Klassifikationsansätzen, die sich allein auf die spektralen Merkmale konzentrieren, eine starke Überschätzung von Plastik auftritt. Die Feature Räume der verwendeten Sensoren waren nicht in der Lage, zwischen den vorkommenden Landbedeckungsklassen zu unterscheiden. Daher muss die spektrale Abdeckung der Sensoren erweitert werden, oder es müssen andere Strukturparameter einbezogen werden. Die Anwendung einer objektbasierten Klassifikation könnte die Fehlklassifikation von Holz reduzieren, würde aber eine bessere GSD erfordern. Auch Methoden der Bilderkennung sind vielversprechend, erfordern aber eine bessere GSD und eine große Menge an Trainingsdaten. Darüber hinaus konzentrierten sich die meisten Studien bisher nur auf die Erkennung von Müll und nicht auf deren Typisierung, wie sie bei den OSPAR-Erhebungen durchgeführt wurde. Von den oben erwähnten Studien haben nur Wolf et al. (2020) einen Ansatz zur Kunststofftyperkennung mit Hilfe von Bilderkennungstechniken vorgestellt. Für eine künftige Implementierung in laufende Überwachungsprogramme ist dies ein wesentlicher Schritt, der weiter untersucht und entwickelt werden muss, wobei die erforderliche Flächenabdeckung (Begrenzung der GSD), die Strandverhältnisse und die Größenverteilung der Müllobjekte berücksichtigt werden müssen.

Die in dieser Studie angewandten Methoden reichten nicht aus, um Mülltypen zu erkennen oder zu identifizieren, was vor allem an den Einschränkungen der GSD und der komplexen Strandverhältnisse lag. Nichtsdestotrotz geben die Ergebnisse einen ersten Eindruck über VIR-Sensoren für die Erkennung von Strandmüll und Empfehlungen für zukünftige drohnengestützte Müllüberwachung in der Arktis. Aufgrund der komplexen Strandverhältnisse und der Größenverteilung der Müllobjekte in der Arktis wird eine GSD von weniger als einem Zentimeter oder eine Erweiterung der spektralen Abdeckung empfohlen. Die Methode mit der höchsten OA in dieser Studie war RF mit vergleichbaren Ergebnissen wie SVM.

Tabelle 22: Übersicht über die Ergebnisse verschiedener Ansätze des maschinellen Lernens für die Erfassung von Strandmüll mithilfe von Drohnenbildern.

	Durch (halb-) automatische Erkennung gefundene Müllobjekte	Verwendeter Klassifikator	Strandverhältnisse	Sensor	GSD [cm]
Diese Studie RGB	OA: 62,5% - 78,6% PA: 52,6% - 92,6% UA: 25,4% - 70,3% F-score: 40% - 70%	RF, SVM, NN	Kies- und Sandstrand	RGB	1,4
Diese Studie VIR	OA: 79,8% - 90,6% PA: 63,3% - 95,2% UA: 40,6% - 82,9% F-score: 57% - 77%	RF, SVM, NN	Kies- und Sandstrand	VIR	3,4
Bak et al., 2019	OA: 98%	CNN	Kies- und Sandstrand	RGB	0,4
Bao et al., 2018	OA: 98,6% - 98,9%	ML und Grenzwert	Sandstrand	RGB	1-3
Escobar Sánchez et al., 2021	OA: 25% - 74% PA: 0 - 100% UA: 0 - 11%	Objektbasiert: ML, RF, SVM	Sandstrand	RGB	0,27
Falatti et al., 2019	PA: 12% - 69% UA: 25% - 100% F-score: 19% - 81%	CNN	Sandstrand	RGB	0,44
Gonçalves et al., 2020a	PA: 53% - 77% UA: 62% - 74% F-score: 57% - 76%	RF	Sandstrand und Düne	RGB	0,55
Gonçalves et al., 2020b	PA: 65% - 71% UA: 55% - 70% F-score: 60% - 70%	RF, CNN	Sandstrand und Düne	RGB	0,55

	Durch (halb-) automatische Erkennung gefundene Müllobjekte	Verwendeter Klassifikator	Strandverhältnisse	Sensor	GSD [cm]
Gonçalves et al., 2020c	PA: 61% - 70% UA: 67% - 78% F-score: 64% - 73%	Objektbasiert RF, SVM, KNN	Sandstrand	RGB	0,55
Martin et al., 2018	PA: 40% UA: 8% F-score: 13%	RF	Sandstrand	RGB	0,3 - 0,5
Papakonstantinou et al., 2021	OA: 61% - 78% PA: 63% - 98% UA: 15% - 84% F-score: 28% - 77%	Fünf verschiedene CNNs	Sandstrand	RGB	0,5
Wolf et al. 2020	OA: 83%** PA: 77%** UA: 77%** F-score: 77%**	CNN, SVM, RF	Strand- und Flusssystem	RGB	0,2

OA: Anzahl der korrekt identifizierten Referenzobjekte geteilt durch die Gesamtzahl der Referenzobjekte

PA von Plastik: Anzahl der korrekt identifizierten Plastikobjekte geteilt durch die Gesamtzahl der Referenzobjekte aus Plastik

UA von Plastik: Anzahl der korrekt identifizierten Plastikobjekte geteilt durch die Anzahl der als Plastik klassifizierten Referenzobjekte

F-Score: Zwei mal das Produkt aus UA und PA geteilt durch die Summe aus UA und PA

** Ergebnisse für CNN-Klassifikator.

4.3.3 Ergebnisse und Diskussion der WV3-Satellitenbilder

Die spektralen Informationen der WV3-Bilder wurden aus Pixeln extrahiert, die Plastik und die häufigsten Landbedeckungsklassen (*Steine, Sand, Schnee, Vegetation, Wasser* und *Holz*) abdecken. Die Plastik-Pixel wurden weiter unterteilt nach der Fläche, mit der die Pixel mit Plastik bedeckt waren. Für alle anderen Klassen wurden Pixel mit einer Klassenabdeckung von 100% verwendet. Eine Übersicht über die Anzahl der Pixel pro Klasse ist in Tabelle 23 und

Tabelle 24 für die multispektralen WV3-Bilder bzw. die WV3-SWIR-Bilder dargestellt. Bei den höher aufgelösten Multispektralbildern (1,2 x 1,2 m) waren 95% bzw. 74% aller identifizierten Plastikpixel auf Spitzbergen und Grönland mit weniger als 5% Plastik bedeckt. Für Spitzbergen und Grönland waren null bzw. fünf Pixel mit mehr als 50% Plastik bedeckt (Tabelle 23). Bei den SWIR-Bildern waren nur drei Pixel mit mehr als 10% Plastik bedeckt, die alle auf Grönland identifiziert wurden.

Tabelle 23: Anzahl der Pixel, die zur Extraktion der Spektralinformationen der multispektralen WV3-Bilder verwendet wurden

Material	Pixel Abdeckung	Spitzbergen (n Pixel)	Grönland (n Pixel)
Plastik	0 – 1%	604	120
	1 – 5%	336	127
	5– 10%	33	47
	10 – 20%	10	18
	20 – 30%	0	11
	30 – 40%	1	3
	40 – 50%	0	4
	50 – 60%	0	2
	60 – 70%	0	1
	70 – 80%	0	0
	80 – 90%	0	1
	90 – 100%	0	1
Steine	100%	>2000	>250
Sand	100%	-	>1000
Schnee	100%	>250	0
Vegetation	100%	>1000	>750
Wasser	100%	>8000	>8000
Holz	100%	>100	<50

Tabelle 24: Anzahl der Pixel, die zur Extraktion der Spektralinformationen der WV3 SWIR-Bilder verwendet wurden

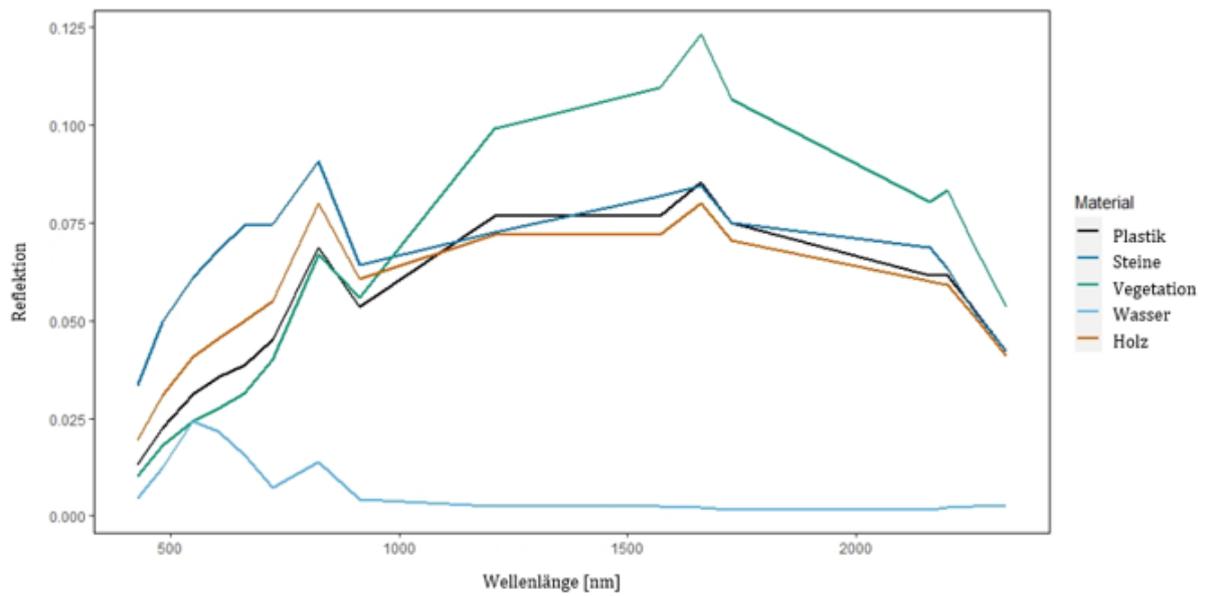
Material	Pixel Abdeckung	Spitzbergen (n Pixel)	Grönland (n Pixel)
Plastik	0 – 1%	642	122
	1 – 5%	5	32
	5– 10%	0	4
	10 – 20%	0	2
	20 – 30%	0	1
	30 – 100%	0	0
Steine	100%	250	100
Sand	100%	0	150
Schnee	100%	50	0
Vegetation	100%	150	100
Wasser	100%	1000	1000
Holz	Nicht verfügbar	30	15

Die extrahierten Spektralinformationen für Spitzbergen und Grönland werden als Durchschnittswerte pro extrahierter Klasse in Abbildung 54 bzw. Abbildung 55 dargestellt. Da es sich bei den Plastikpixeln um gemischte Pixel handelte, wurde das spektrale Signal auch in Abhängigkeit von der Plastikbedeckung dargestellt (Abbildung 56 und Abbildung 57). Die Reflektionswerte und die Form unterschieden sich zwischen den beiden Untersuchungsstandorten, da unterschiedliche Methoden zur atmosphärischen Korrektur angewandt wurden. Vergleicht man das durchschnittliche spektrale Signal aller Plastikpixel mit den anderen Klassen, so lässt sich eine starke Ähnlichkeit der Plastikpixel mit Holz- und Vegetationspixeln feststellen. Da die Plastikpixel eine relativ geringe Plastikbedeckung aufwiesen, dominierten die anderen Klassen, hauptsächlich Vegetation und Holz, das Signal der Plastikpixel. Dies wird durch Abbildung 56 und Abbildung 57 bestätigt, die die unterschiedliche Plastikbedeckung pro Pixel zeigen. Je geringer die Plastikbedeckung war, desto ähnlicher war das Signal den anderen Klassen, aber selbst bei der höchsten Plastikbedeckung schien das Signal einen starken Einfluss der Vegetation zu haben. Bei der Betrachtung der hohen Plastikbedeckung sind die SWIR-Werte jedoch nicht immer verfügbar, da die SWIR-Bilder schlechter aufgelöst waren als das multispektrale WV3-Produkt und der Plastikanteil daher zu gering war. Darüber hinaus ist es wichtig, die Schwankungen innerhalb der Klassen zu berücksichtigen, um festzustellen, ob verschiedene Klassen spektral getrennt werden können. Eine Übersicht findet sich im Anhang in H.1 und H.2. Beide Abbildungen zeigen eine große Varianz der Reflektionswerte für die Klassen *Sand*, *Steine* und *Plastik* für Grönland bzw. *Plastik*, *Steine* und *Holz* für Spitzbergen. Da die Abdeckung der Pixel mit Plastik sehr gering war, war ein Vergleich mit dem Spektralmuster von Plastik mit seinen typischen spektralen Merkmalen, wie in Garaba et al. (2020) beschrieben und in Abbildung 8 dargestellt, nicht möglich. Eine Erkennung von Strandmüll auf einer Sub-Pixel-Skala wurde durch spektrale Entmischung von

WV3-Bildern getestet. Das durchschnittliche Spektralsignal für jede Klasse wurde berechnet, um ein spektrales Unmixing mit Hilfe der Rstoolbox-Bibliothek in R Version 3.6.3 durchzuführen. Frühere Studien haben gezeigt, dass unter Verwendung von Sentinel-2-Satellitenbildern treibender Plastikmüll auf dem Meer auf einer Subpixel-Skala mit einer Plastikabdeckung von 30-55% erkannt werden können (Biermann et al., 2020; Topouzelis et al., 2019). Sentinel 2 hat eine ähnliche spektrale Abdeckung wie die WV3-Bilder mit 12 Bändern vom Sichtbaren bis zum SWIR, aber eine Auflösung von 10 – 60 m. Eine Sub-Pixel-Detektion von Kunststoffen über offenen Gewässern für noch kleinere Objekte, die bis zu 5% eines Pixels abdecken, wurde von Garaba et al. (2018b) unter Verwendung von Hyperspektralbildern beschrieben. In dieser Studie war das ein spektrales Entmischen der Referenzdaten nicht in der Lage, die Plastikbedeckung dieser zu erkennen. Im Gegensatz zu treibendem Meeresmüll ist der Hintergrund von Strandumgebungen komplexer (z. B. Vegetation, Sand, Felsen, Holz) und die Größenverteilung des Mülls im Untersuchungsgebiet war sehr gering. Bei der Einbeziehung von SWIR-Bildern wurde die in Biermann et al. (2020) und Topouzelis et al. (2019) beschriebene Subpixelgröße von 30 - 55% für kein Pixel erreicht. Im Vergleich zu Garaba et al. (2018b) schien die spektrale Abdeckung für eine Subpixel-Detektion von bis zu 5% unzureichend zu sein, was teilweise auch durch die komplexen Hintergrundsignale beeinflusst wurde.

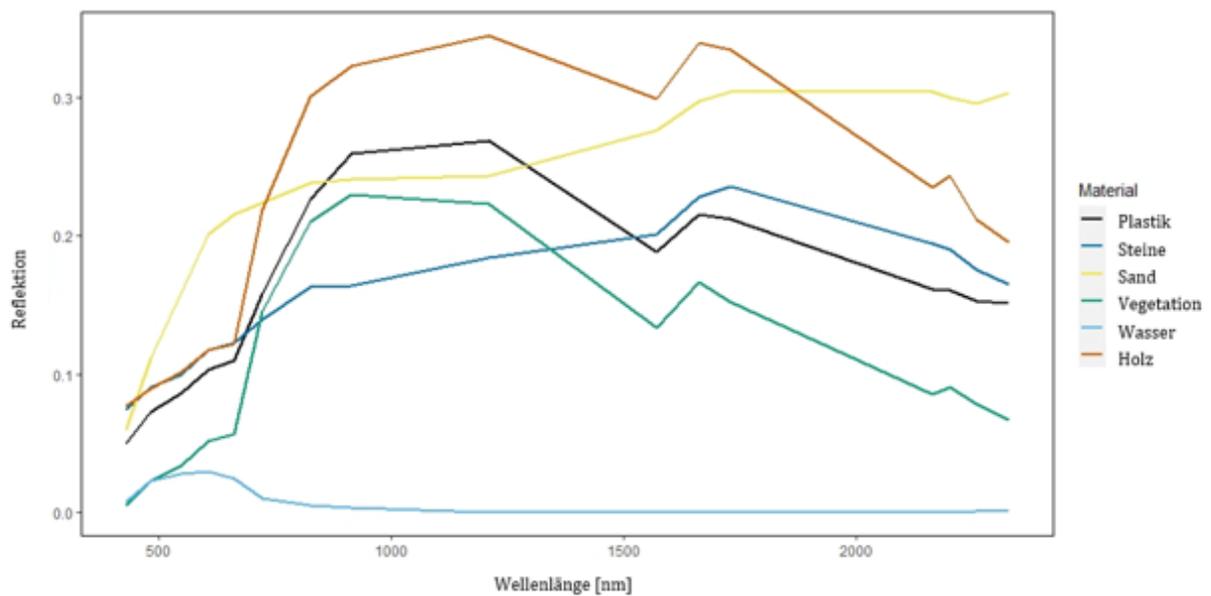
Die Ergebnisse der WV3-Bilder zeigten, dass die Erkennung von Strandmüll mit Satellitenbildern immer noch durch ihre räumliche Auflösung begrenzt ist. Nur große Müllansammlungen scheinen erkennbar zu sein (Acuña-Ruz et al., 2018). Die Größe der Abfälle und die räumliche Verteilung der Abfälle an arktischen Stränden waren zu gering, um auf WV3-Bildern erkannt zu werden. Eine höhere räumliche Auflösung oder eine größere spektrale Abdeckung wäre erforderlich, um auch geringere Müllansammlungen an Stränden mit Hilfe von Satelliten zu erkennen. In zukünftigen Studien sollten spektrale Entmischungsansätze für die Erkennung von Strandabfällen in Untersuchungsgebieten mit sehr hohem Abfallaufkommen weiter getestet werden, um die für eine erfolgreiche Erkennung erforderliche Abdeckung von Kunststoffen zu bestimmen. Die Ergebnisse einer solchen Untersuchung können dann genutzt werden, um die Auflösung von Satellitenbildern zu bestimmen, die erforderlich ist, um Müllansammlungen wie auf Grönland und Spitzbergen zu erkennen. Ein weiterer vielversprechender Ansatz wäre die Auswertung von Treibholzansammlungen als Indikator für große Mengen an Meeresmüll, da Treibholz auf WV3-Bildern nachweisbar war. Neben der räumlichen Auflösung sind die Kosten kommerzieller Satelliten noch immer ein Hindernis für eine großflächige Anwendung (WV3: rund \$3500 für 100 km²). Um von der großflächigen Abdeckung durch Satellitenbilder zu profitieren, muss die Erkennbarkeit kleinerer Müllansammlungen am Strand noch ermöglicht werden, und die Kosten für die Datenerfassung müssen gesenkt werden.

Abbildung 54: Durchschnittliches Spektralsignal von WV3-Bildern auf Spitzbergen



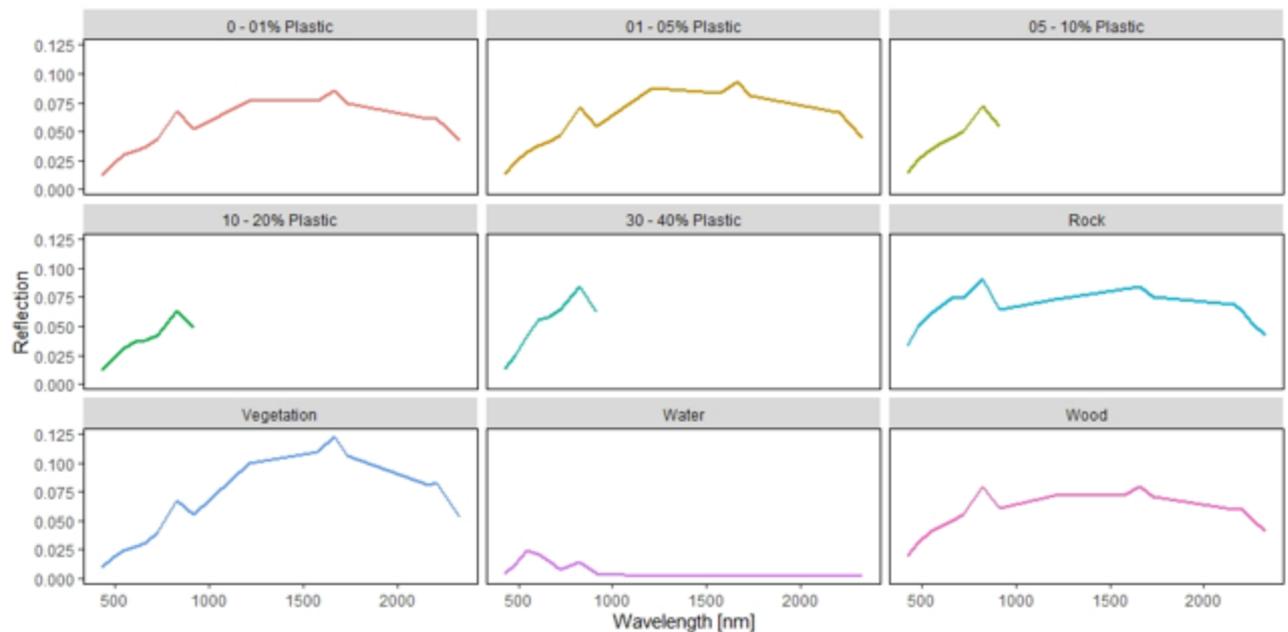
Quelle: Eigene Darstellung, BCSH

Abbildung 55: Durchschnittliches Spektralsignal von WV3-Bildern auf Spitzbergen



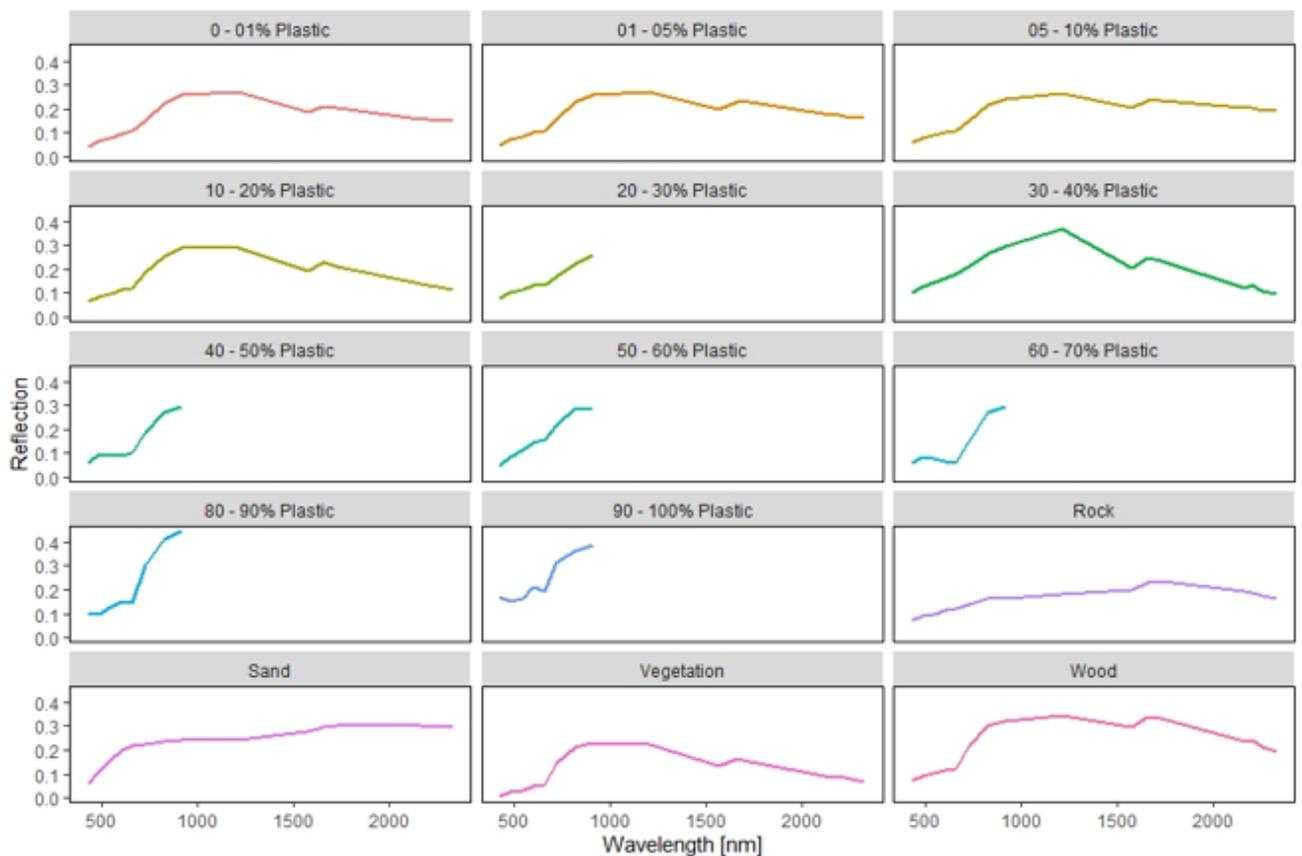
Quelle: Eigene Darstellung, BCSH

Abbildung 56: Durchschnittliches Spektralsignal, das aus WV3-Bildern von Spitzbergen für verschiedene Kunststoffbedeckungen extrahiert wurde



SWIR-Reflektionswerte waren aufgrund der größeren Auflösung nicht immer verfügbar.
Quelle: Eigene Darstellung, BCSH

Abbildung 57: Durchschnittliches Spektralsignal, das aus WV3-Bildern von Grönland für verschiedene Kunststoffbedeckungen extrahiert wurde



SWIR-Reflektionswerte waren aufgrund der größeren Auflösung nicht immer verfügbar.
Quelle: Eigene Darstellung, BCSH

5 Arbeitspaket 4

M. Schnurawa hat am Arctic Plastic Symposium in Reykjavik, Island teilgenommen (02. bis 04. März 2021) und einen wissenschaftlichen Vortrag gehalten.

M. Schulz (AE) hat am Arctic Plastic Symposium in Reykjavik, Island (02. bis 04. März 2021) mit einer Posterpräsentation teilgenommen.

M. Schnurawa (BCSH) hat am Nationalen Forum für Fernerkundung und Copernicus 2022, Berlin (21. bis 23. Juni 2022) teilgenommen. Er hat einen wissenschaftlichen Vortrag über die Ergebnisse von AP3.

6 Literaturverzeichnis

- Acuña-Ruz, T., Uribe, D., Taylor, R., Amézquita, L., Guzmán, M. C., Merrill, J., Martínez, P., Voisin, L., Mattar, C. (2018): Anthropogenic marine debris over beaches: Spectral characterization for remote sensing applications. *Remote Sensing of Environment*, 217, 309-322.
- Alkalay R., Pasternak G., Zask A., (2007): Clean-coast index—A new approach for beach cleanliness assessment. *Ocean & Coastal Management* 50, 352–362.
- Andriolo, U., Gonçalves, G., Bessa, F., & Sobral, P. (2020). Mapping marine litter on coastal dunes with unmanned aerial systems: A showcase on the Atlantic Coast. *Science of the Total Environment*, 736, 139632.
- Bao, Z., Sha, J., Li, X., Hanchiso, T., & Shifaw, E. (2018): Monitoring of beach litter by automatic interpretation of unmanned aerial vehicle images using the segmentation threshold method. *Marine pollution bulletin*, 137, 388-398.
- Barnes, D. K. A., Fraser, K. P. P., (2003): Rafting by five phyla on man-made flotsam in the Southern Ocean. *Marine Ecology Progress Series* 262, 289–291.
- Barnes, D. K. A., Milner, P., (2005): Drifting plastic and its consequences for sessile organism dispersal in the Atlantic Ocean. *Marine Biology* 146, 815–825.
- Bateman, B.L., VanDerWal, J., Williams, S.E. & Johnson, C.N. (2010): Inclusion of biotic interactions in species distribution models improves predictions under climate change: the northern bettong *Bettongia tropica*, its food resources and a competitor. *Journal of Biogeography*, In Review.
- Bergmann M., Lutz B., Tekman M. B., Gutow L. (2017): Citizen scientists reveal: Marine litter pollutes Arctic beaches and affects wild life. *Marine Pollution Bulletin* 125, 535–540.
- Beyer, F., & Grenzdörfer, G. (2018): Klassifikation von Vegetationstypen auf Moorstandorten unter Verwendung von multisensoralen Drohnen Daten.
- Biermann, L., Clewley, D., Martinez-Vicente, V., & Topouzelis, K. (2020). finding plastic patches in coastal Waters using optical Satellite Data. *Scientific reports*, 10(1), 1-10.
- Bravo M., de los Ángeles Gallardo M., Luna-Jorquera G., Núñez P., Vásquez N., Thiel M., (2009): Anthropogenic debris on beaches in the SE Pacific (Chile): Results from a national survey supported by volunteers. *Marine Pollution Bulletin* 58, 1718–1726.
- Breiman, L. (2001). Random forests. *Machine learning*, 45(1), 5-32.
- Breiman, Leo, et al. *Classification and regression trees*. Routledge, 2017.
- Browne, M. A., Ayake, A., Galloway, T. S., Lowe, D. M., Thompson, R. C., (2008): Ingested Microscopic Plastic Translocates to the Circulatory System of the Mussel, *Mytilus edulis* (L.). *Environmental Science & Technology* 42, 5026–5031.
- Browne, M. A., Galloway, T. S., Thompson, R. C., (2010): Spatial Patterns of Plastic Debris along Estuarine Shorelines. *Environmental Science & Technology* 44, 3404–3409.
- Bullimore, B. A., Newman, P. B., Kaiser, M. J., Gilbert, S. E., Lock, K. M., (2001): A study of catches in a fleet of “ghost-fishing” pots. *Fishery Bulletin* 99, 247–253.
- Buhl-Mortensen L., Buhl-Mortensen P., (2017): Marine litter in the Nordic Seas: Distribution composition and abundance. *Marine Pollution Bulletin* 125, 260–270.
- Campbell, J. B., & Wynne, R. H. (2011): *Introduction to remote sensing*. Guilford Press, 31-37.
- Cheshire A., Adler E., Barbière J., Cohen Y., Evans S., Jarayabhand S., Jeftic L., Jung R.-T., Kinsey S., Kusui, E. T., Lavine I., Manyara P., Oosterbaan L., Pereira M. A., Sheavly S., Tkalin A., Varadarajan S., Wenneker B.,

- Westphalen G., (2009): UNEP/IOC Guidelines on Survey and Monitoring of Marine Litter. Regional Seas Reports and Studies No. 186. IOC Technical Series No. 83: 96 pp.
- Coulter, D., Hauff, P. L., & Kerby, W. L. (2007): Airborne hyperspectral remote sensing. In Proceedings of the 5th Decennial International Conference on Mineral Exploration (pp. 375-378). Toronto, Ontario, Canada.
- Dagestad, K. F., Röhrs, J., Breivik, Ø., & Ådlandsvik, B. (2018): OpenDrift v1. 0: a generic framework for trajectory modelling.
- Dalal, N., & Triggs, B. (2005): Histograms of oriented gradients for human detection. In 2005 IEEE computer society conference on computer vision and pattern recognition (CVPR'05) (Vol. 1, pp. 886-893). IEEE.
- de Grandpré, A., Kinnard, C., & Bertolo, A. (2022): Open-Source Analysis of Submerged Aquatic Vegetation Cover in Complex Waters Using High-Resolution Satellite Remote Sensing: An Adaptable Framework. *Remote Sensing*, 14(2), 267.
- Erdle, K., Mistele, B., & Schmidhalter, U. (2011): Comparison of active and passive spectral sensors in discriminating biomass parameters and nitrogen status in wheat cultivars. *Field Crops Research*, 124(1), 74-84.
- Eisted R., Christensen T. H. (2011): Waste management in Greenland: current situation and challenges. *Waste Management & Research*, 29(10), 1064–1070.
- Escobar-Sánchez, G., Haseler, M., Oppelt, N., & Schernewski, G. (2021). Efficiency of aerial drones for macrolitter monitoring on Baltic Sea beaches. *Frontiers in Environmental Science* 8, 283.
- Fallati, L., Polidori, A., Salvatore, C., Saponari, L., Savini, A., & Galli, P. 5.1 Anthropogenic Marine Debris assessment with Unmanned Aerial Vehicle imagery and Deep Learning: a case study along the beaches of the Republic of Maldives. *New insights into coral reef threats and restoration perception: a case study in the Republic of Maldives*, 124.
- Fowler, C. W., (1987): Marine Debris and Northern Fur Seals: a Case Study. *Marine Pollution Bulletin* 18, 326-335.
- Galgani, F., Leaute, J. P., Moguedet, P., Souplet, A., Verin, Y., Carpentier, A., Goragner, H., Latrouite, D., Andral, B., Cadiou, Y., Mahe, J. C., Poulard, J. C., Nerisson, P., (2000): Litter on the Sea Floor along European Coasts. *Marine Pollution Bulletin* 40, 516-527.
- Garaba, S. P., & Dierssen, H. M. (2018): An airborne remote sensing case study of synthetic hydrocarbon detection using short wave infrared absorption features identified from marine-harvested macro-and microplastics. *Remote Sensing of Environment*, 205, 224-235.
- Garaba, S. P., Aitken, J., Slat, B., Dierssen, H. M., Lebreton, L., Zielinski, O., & Reisser, J. (2018): Sensing ocean plastics with an airborne hyperspectral shortwave infrared imager. *Environmental science & technology*, 52(20), 11699-11707.
- Garaba, S. P., & Dierssen, H. M. (2020): Hyperspectral ultraviolet to shortwave infrared characteristics of marine-harvested, washed-ashore and virgin plastics. *Earth System Science Data*, 12(1), 77-86.
- Garcia-Garin, O., Aguilar, A., Borrell, A., Gozalbes, P., Lobo, A., Penadés-Suay, J., Rage, J. A., Revuelta, O., Serrano, M., Vighi, M. (2020): Who's better at spotting? A comparison between aerial photography and observer-based methods to monitor floating marine litter and marine mega-fauna. *Environmental Pollution*, 258, 113680.
- Gaspero J., Dris R., Bonin T., Rocher V., Tassin B. (2014): Assessment of floating plastic debris in surface water along the Seine River. *Environmental Pollution* 195, 163-166.
- Gonçalves, G., Andriolo, U., Pinto, L., & Bessa, F. (2020a). Mapping marine litter using UAS on a beach-dune system: a multidisciplinary approach. *Science of The Total Environment* 706, 135742.

- Gonçalves, G., Andriolo, U., Pinto, L., & Duarte, D. (2020b). Mapping marine litter with Unmanned Aerial Systems: A showcase comparison among manual image screening and machine learning techniques. *Marine pollution bulletin* 155, 111158.
- Gonçalves, G., Andriolo, U., Gonçalves, L., Sobral, P., & Bessa, F. (2020c). Quantifying marine macro litter abundance on a sandy beach using unmanned aerial systems and object-oriented machine learning methods. *Remote Sensing*, 12(16), 2599
- Gregory, M. R., (2009): Environmental implications of plastic debris in marine settings—entanglement, ingestion, smothering, hangers-on, hitch-hiking and alien invasions. *Philosophical Transactions of the Royal Society B* 364, 2013–2025.
- Howell, E. A., Bograd, S. J., Morishige, C., Seki, M. P., Polovina, J. J., (2012): On North Pacific circulation and associated marine debris concentration. *Marine Pollution Bulletin* 65, 16–22.
- Januchowski, S. R., Pressey, R. L., VanDerWal, J., & Edwards, A. (2010): Characterizing errors in digital elevation models and estimating the financial costs of accuracy. *International Journal of Geographical Information Science*, 24(9), 1327-1347.
- Kirkfeldt T. S., (2016): *Marine Litter in Greenland*. Aalborg University, Denmark, 60 pp.
- Majer, A.P., Vedolin, M.C., Turra, A., (2012) Plastic pellets as oviposition site and means of dispersal for the ocean-skater insect *Halobates*. *Marine Pollution Bulletin* 64, 1143–1147.
- Mallory M. L., Baak J., Gjerdrum K., Mallory O. E., Manley B., Swan C., Provencher J. F. (2021): Anthropogenic litter in marine waters and coastlines of Arctic Canada and West Greenland. *Science of the Total Environment* 783, 146971.
- Martin, C., Parkes, S., Zhang, Q., Zhang, X., McCabe, M. F., & Duarte, C. M. (2018): Use of unmanned aerial vehicles for efficient beach litter monitoring. *Marine pollution bulletin*, 131, 662-673.
- Martin, C., Zhang, Q., Zhai, D., Zhang, X., & Duarte, C. M. (2021). Enabling a large-scale assessment of litter along Saudi Arabian red sea shores by combining drones and machine learning. *Environmental Pollution*, 277, 116730.
- Mather, P., & Tso, B. (2016). *Classification methods for remotely sensed data*. CRC press.
- Matsuoka, T., Nakashima, T., Nagasawa, N., (2005): A review of ghost fishing: scientific approaches to evaluation and solutions. *Fisheries Science* 71, 691–702.
- Maximenko, N., et al., (2019): Towards the integrated marine debris observing system. *Frontiers in marine science*, 6, 447.
- Merlino, S., Paterni, M., Berton, A., & Massetti, L. (2020). Unmanned aerial vehicles for debris survey in coastal areas: Long-term monitoring programme to study spatial and temporal accumulation of the dynamics of beached marine litter. *Remote Sensing* 12(8), 1260.
- Micasense, Inc (2020): Altum Specifications. <https://micasense.com/wp-content/uploads/2019/11/Altum-Specifications-1.pdf>
- Mingers and J. An empirical comparison of pruning methods for decision tree induction. *Machine learning*, 4:227–243, 1989
- Morridd D., Stefanoudis P. V., Pearce D., Crimmen O. A., Clark P. F. (2014): Plastic in the Thames: A river runs through it. *Marine Pollution Bulletin* 78, 196–200.
- Moy, K., Neilson, B., Chung, A., Meadows, A., Castrence, M., Ambagis, S., Davidson, K. (2018): Mapping coastal marine debris using aerial imagery and spatial analysis. *Marine pollution bulletin*, 132, 52-59.
- Nashoug B. F. (2016): *Sources of Marine Litter” –Workshop Report, Svalbard 4th -6th September 2016: 23 pp.*

- Neumann D., Callies U., Matthies M., (2014): Marine litter ensemble transport simulations in the southern North Sea. *Marine Pollution Bulletin* 86 (1-2), 219-228.
- Opfer S., Arthur C., Lippiatt S., (2012): NOAA Marine Debris Shoreline Survey Field Guide, 14 pp.
- OSPAR, (2010): Guideline for Monitoring Marine Litter on the Beaches in the OSPAR Maritime Area. OSPAR Commission, ISBN 90-3631-973.
- PAME, (2019): Desktop Study on Marine Litter including Micro-plastics in the Arctic https://www.pame.is/images/03_Projects/Arctic_Marine_Pollution/Litter/Desktop_study/Desktop_Study_on_marine_litter.pdf
- Papakonstantinou, A., Batsaris, M., Spondylidis, S., & Topouzelis, K. (2021). A citizen science unmanned aerial system data acquisition protocol and deep learning techniques for the automatic detection and mapping of marine litter concentrations in the coastal zone. *Drones*, 5(1), 6.
- Pettorelli, N. (2019). *Satellite remote sensing and the management of natural resources*. Oxford University Press, 4-9.
- Pichel, W. G., Veenstra, T. S., Churnside, J. H., Arabini, E., Friedman, K. S., Foley, D. G., Brainard, R. E., Kiefer, D., Ogle, S., Clemente-Colón, P., Li, X. (2012): GhostNet marine debris survey in the Gulf of Alaska—Satellite guidance and aircraft observations. *Marine pollution bulletin*, 65(1-3), 28-41.
- Pinto, L., Andriolo, U., & Gonçalves, G. (2021). Detecting stranded macro-litter categories on drone orthophoto by a multi-class Neural Network. *Marine Pollution Bulletin*, 169, 112594.
- Pourazar, H., Samadzadegan, F., & Dadrass Javan, F. (2019). Aerial multispectral imagery for plant disease detection: Radiometric c Rech S., Macaya-Caquilpán V., Pantoja J. F., Rivadeneira M. M., Jofre Madariaga D., Thiel M. (2014): Rivers as a source of marine litter – A study from the SE Pacific. *Marine Pollution Bulletin* 82, 66–75.
- Quinlan, R. C. (1993). 4.5: Programs for machine learning morgan kaufmann publishers inc. San Francisco, USA.
- Ribic, C. A., Sheavly, S. B., Rugg, D. J., Erdmann, E. S., (2010): Trends and drivers of marine debris on the Atlantic coast of the United States 1997–2007. *Marine Pollution Bulletin* 60, 1231–1242.
- Richards, J. A., & Richards, J. A. (1999). *Remote sensing digital image analysis* (Vol. 3, pp. 10-38). Berlin et al.: Springer., 1-20.
- Schulz M., Clemens T., Förster H., Harder T., Fleet D. M., Gaus S., Grave C., Flegel I., Schrey E., Hartwig E., (2015): Statistical analyses of the results of 25 years of beach litter surveys on the south-eastern North Sea coast. *Marine Environmental Research* 109: 21-27.
- Schulz M., Krone R., Dederer G., Wätjen K., Matthies M., (2015): Comparative analysis of time series of marine litter surveyed on beaches and the seafloor in the southeastern North Sea. *Marine Environmental Research* 106, 61-67.
- Schulz M., Neumann D., Fleet D. M., Matthies M., (2013): A multi-criteria evaluation system for marine litter pollution based on statistical analyses of OSPAR beach litter monitoring time series. *Marine Environmental Research*, doi.10.1016/j.marenvres.2013.08.013.
- Schulz M., van Loon W., Fleet D., Baggelaar P., van der Meulen E., (2017): OSPAR standard method and software for statistical analysis of beach litter data. *Marine Pollution Bulletin* 122, 166-175.
- Schulz M., Walvoort D. J. J., Barry J., Fleet D. M., van Loon W. M. G. M., (2019): Baseline and power analyses for the assessment of beach litter reductions in the European OSPAR region. *Environmental Pollution* 248, 555-564.
- Shaw, G. A., & Burke, H. K. (2003): Spectral imaging for remote sensing. *Lincoln laboratory journal*, 14(1), 3-28.

- Strahler, A. H., Boschetti, L., Foody, G. M., Friedl, M. A., Hansen, M. C., Herold, M., ... & Woodcock, C. E. (2006). Global land cover validation: Recommendations for evaluation and accuracy assessment of global land cover maps. *European Communities, Luxembourg*, 51(4), 1-60.
- Strand K. O., Huserbråten M., Dagestad K.-F., Mauritzen C., Grøsvik B. E., Nogueira L. A., Melsom A., Röhrs J. (2021): Potential sources of marine plastic from survey beaches in the Arctic and Northeast Atlantic. *Science of the Total Environment* 790, 148009.
- Strietman W.J., van den Heuvel-Greve M.J., van den Brink A.M., Leemans E., Strand J., Bach L. (2021): Beach litter in West Greenland: a source analysis. Report, 64 pp.
- Tekman M. B., Krumpfen T., Bergmann M. (2017): Marine litter on deep Arctic seafloor continues to increase and spreads to the North at the HAUSGARTEN observatory. *Deep-Sea Research Part I* 120, 88–99.
- Tekman, M.B., Gutow, L., Macario, A., Haas, A., Walter, A., Bergmann, M.: Alfred Wegener Institute Helmholtz Centre for Polar and Marine Research. <https://litterbase.awi.de/litter>
- Topouzelis, K., Papakonstantinou, A., & Garaba, S. P. (2019): Detection of floating plastics from satellite and unmanned aerial systems (Plastic Litter Project 2018). *International Journal of Applied Earth Observation and Geoinformation*, 79, 175-183.
- Tudor D. T., Williams A. T. (2004): Development of a 'Matrix Scoring Technique' to determine litter sources at a Bristol Channel beach. *Journal of Coastal Conservation* 9, 119-127.
- van Franeker, J. A., Blaize, C., Danielsen, J., Fairclough, K., Gollan, J., Guse, N., Hansen, P.-L., Heubeck, M., Jensen, J.-K., Le Guillou, G., Olsen, B., Olsen, K.-O., Pedersen, J., Stienen, E. W. M., Turner, D. M., (2011): Monitoring plastic ingestion by the northern fulmar *Fulmarus glacialis* in the North Sea. *Environmental Pollution* 159, 2609-2615.
- Vesman A., Moulin E., Egorova A., Zaikov K. (2020): Marine litter pollution on the Northern Island of the Novaya Zemlya archipelago. *Marine Pollution Bulletin* 150, 110671.
- Votier, S. C., Archibald, K., Morgan, G., Morgan, L., (2011): The use of plastic debris as nesting material by a colonial seabird and associated entanglement mortality. *Marine Pollution Bulletin* 62, 168–172.
- Waske, B., & Benediktsson, J. A. (2007). Fusion of support vector machines for classification of multisensor data. *IEEE Transactions on geoscience and remote sensing*, 45(12), 3858-3866.
- Waske, B., & Braun, M. (2009). Classifier ensembles for land cover mapping using multitemporal SAR imagery. *ISPRS journal of photogrammetry and remote sensing*, 64(5), 450-457.
- Weslawski J. M., Kotwicki L., (2018): Macro-plastic, a new vector for boreal species dispersal on Svalbard. *Polish Polar Research* 39, 165–174.
- Wolf, M., van den Berg, K., Garaba, S. P., Gnann, N., Sattler, K., Stahl, F., & Zielinski, O. (2020). Machine learning for aquatic plastic litter detection, classification and quantification (APLastic-Q). *Environmental Research Letters*, 15(11), 114042.
- Zuur, A. F., Ieno, E. N., & Elphick, C. S. (2010). A protocol for data exploration to avoid common statistical problems. *Methods in ecology and evolution*, 1(1), 3-14.

A Anhang

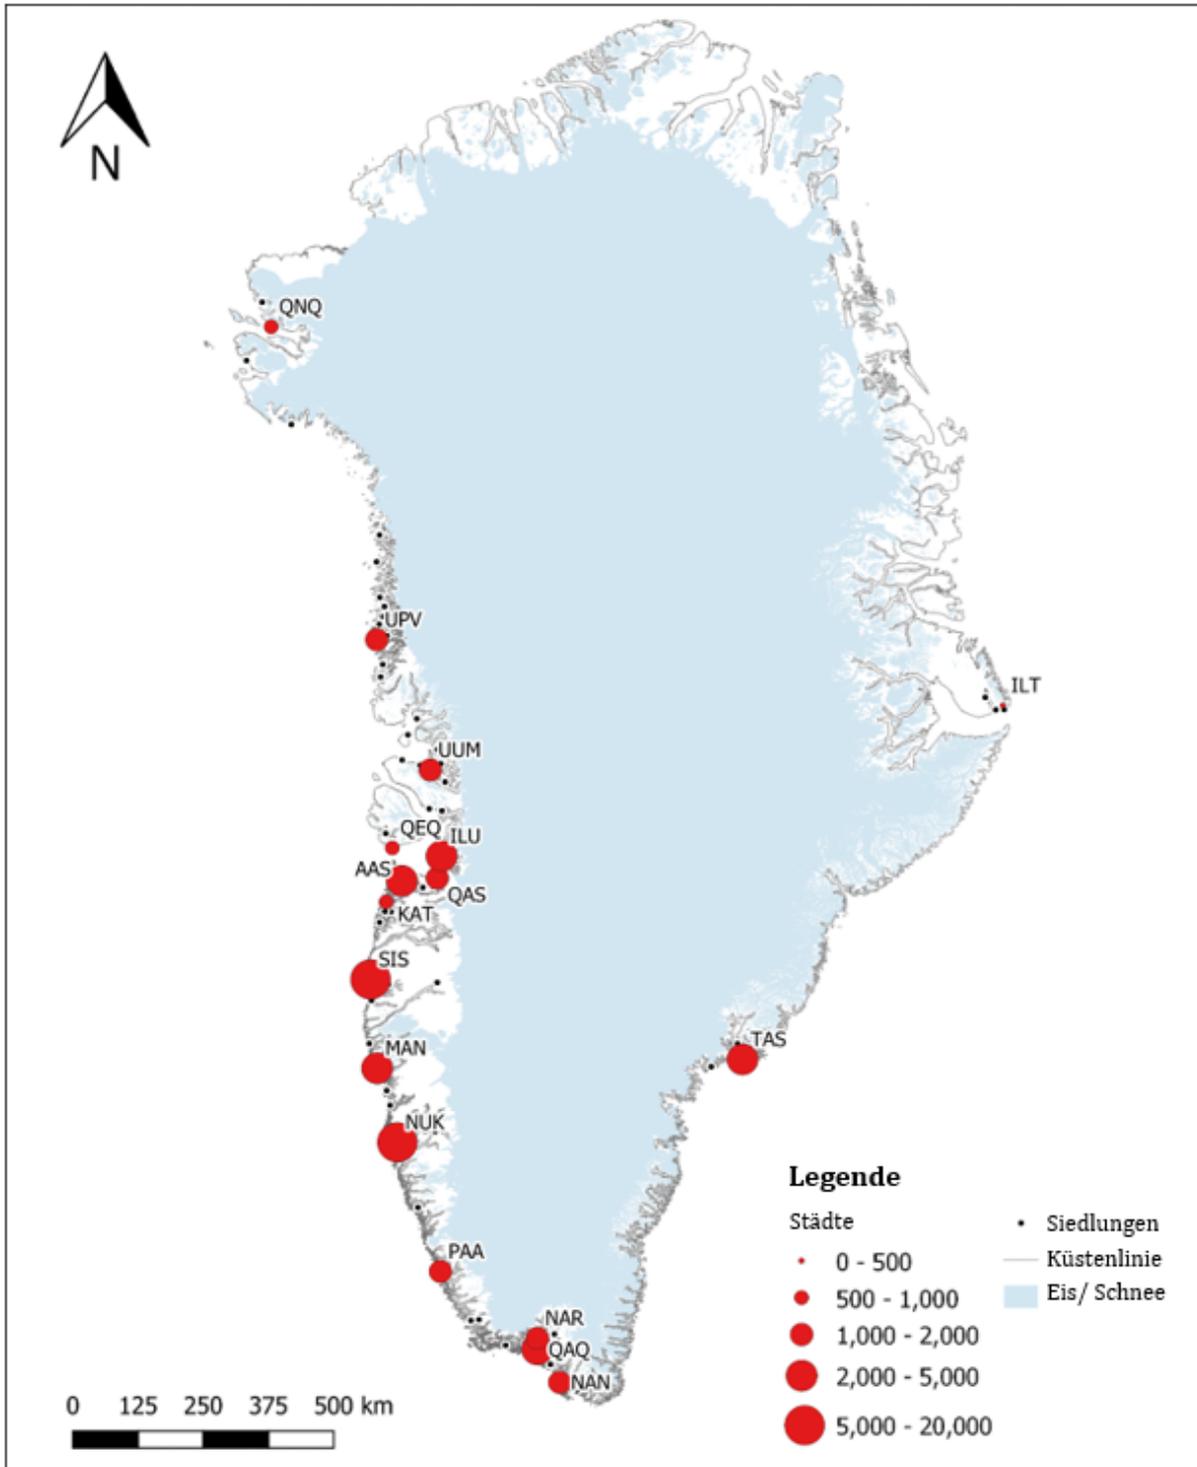
A.1 Koordinaten der OSPAR-Standorte für die Untersuchung von Strandmüll auf Grönland, Spitzbergen und Island.

Strandname	ID	Längengrad	Breitengrad
Dagmar Island North St1	GRL001	-17,5637	81,6864
Henryland - East Greenland	GRL002	-23,6400	69,6079
Sand Island, Young Sund	GRL003	-20,1526	74,2653
Kap Mary, Young Sund	GRL004	-20,1884	74,1656
Clavering Island, Young Sund	GRL005	-20,1714	74,2181
Stroem Island	GRL006	-30,6166	68,0859
Moraene Island, Taasiilaq	GRL007	-35,7887	66,0208
Nuuk Fjord St1	GRL008	-51,7491	64,0257
Nuuk Fjord St2	GRL009	-51,7303	64,0614
Nuuk Fjord St3	GRL010	-51,7614	64,0719
Disko Brededal	GRL011	-53,1853	69,3172
Disko Ippik	GRL012	-53,2417	69,3019
Sisimiut St1	GRL013	-53,6022	66,8711
Sisimiut St2	GRL014	-53,4946	66,8533
Qaqortoq St1 (Akia)	GRL015	-46,1317	60,6753
Qaqortoq St2	GRL016	-46,0990	60,7215
Upernavik	GRL017	-56,5772	73,6703
Brucebukta	NO002	78,4448	11,8602
Luftskipodden	NO003	79,6812	10,7670
Raudasandur	IS001	65,4628	-23,9555
Budavik	IS002	64,8276	-23,3572

Strandname	ID	Längengrad	Breitengrad
Bakkavik	IS003	64,1539	-22,0072
Surtsey island East	IS004	63,3058	-20,5962
Surtsey island West	IS005	63,3084	-20,6003
Rekavik bak Hofn	IS006	66,4312	-22,5162
Vikur	IS007	66,1012	-20,2333

B Anhang

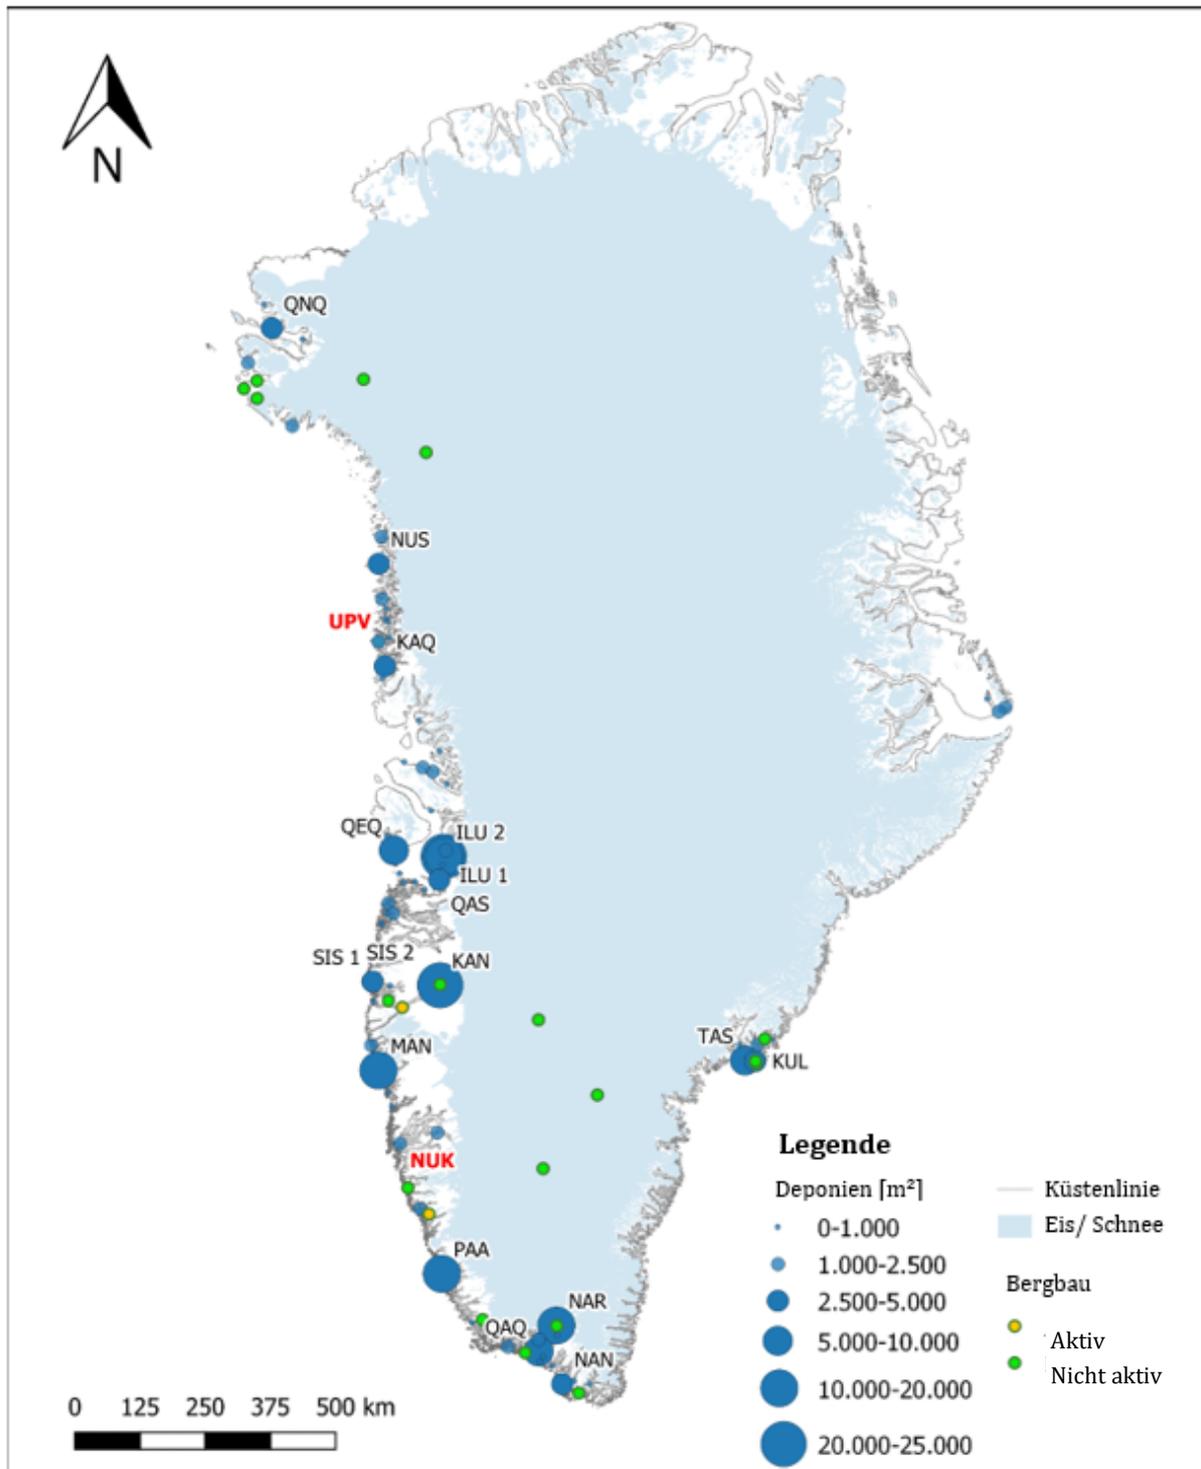
B.1 Städte und Siedlungen auf Grönland



Anzahl der Einwohner der Städte auf Grönland (<https://stat.gl/>):

AAS: Aasiaat, ILU: Ilulissat, ILT Ittoqqortoormiit, KAT: Kangaatsiaq, MAN: Maniitsoq, NAN: Nanortalik, NAR: Narsq, NUK: Nuuk, PAA: Paamiut, QAQ: Qaqortoq, QAS: Qasigianguit, QEG: Qeqertarsuaq, QNG: Qaanaaq, SIS: Sisimiut, TAS: Tasiilaq, UPV: Upernavikm, UUM: Uummannaq. Quelle: Eigene Darstellung, BCSH

B.2 Deponien und Bergbauaktivitäten auf Grönland



Deponien mit einer Fläche von mehr als 2.500 m² sind namentlich gekennzeichnet (Korrespondenz WSP Arktis):

ILU: Ilulissat, KAN: Kangerlussuaq, KAQ: Kangersuatsiaq, KUL: Kulusuk, MAN: Maniitsoq, NAN: Nanortalik, NAR: Narsq, NUS: Nuussuaq, PAA: Paamiut, QAQ: Qaqortoq, QAS: Qasigianniguit, QEG: Qeqertarsuaq, QNQ: Qaanaaq, SIS: Sisimiut, TAS: Tasiilaq;

Mülldeponien in NUK: Nuuk und UPV: Upernavik sind flächenmäßig kleiner; der aktive Bergbau findet im Tagebau statt.

Quelle: Eigene Darstellung, BCSH

C Anhang

C.1 Tägliche Strömungsintensitäten aus dem Copernicus-Datenportal

Copernicus 01.10.2009



Copernicus 01.01.2010



Copernicus 01.04.2010



Copernicus 01.07.2010



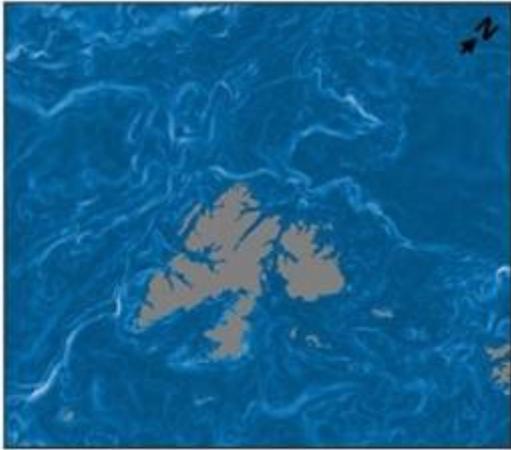
Current intensity [ms^{-1}]



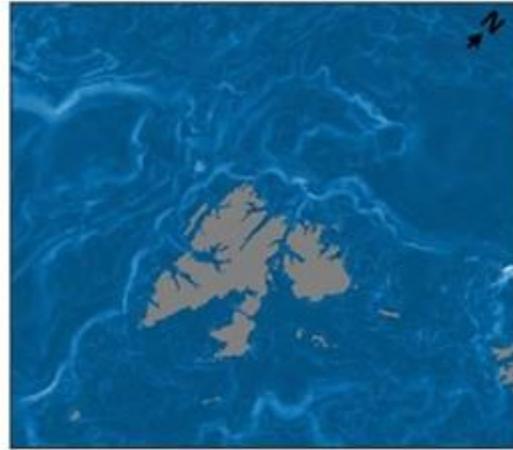
Tägliche Strömungsintensität aus dem Copernicus-Datenportal, für das Modell mit niedriger Auflösung in vier verschiedenen Zeitschritten. Quelle: Eigene Darstellung, BCSH

C.2 Tägliche Strömungsintensität vom Norwegischen Polarinstitut

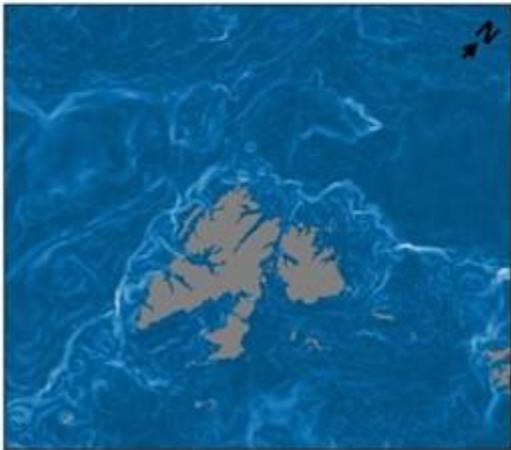
API 01.10.2009



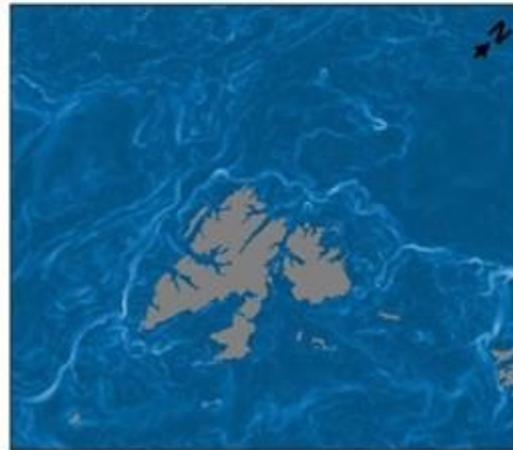
API 01.01.2010



API 01.04.2010



API 01.07.2010



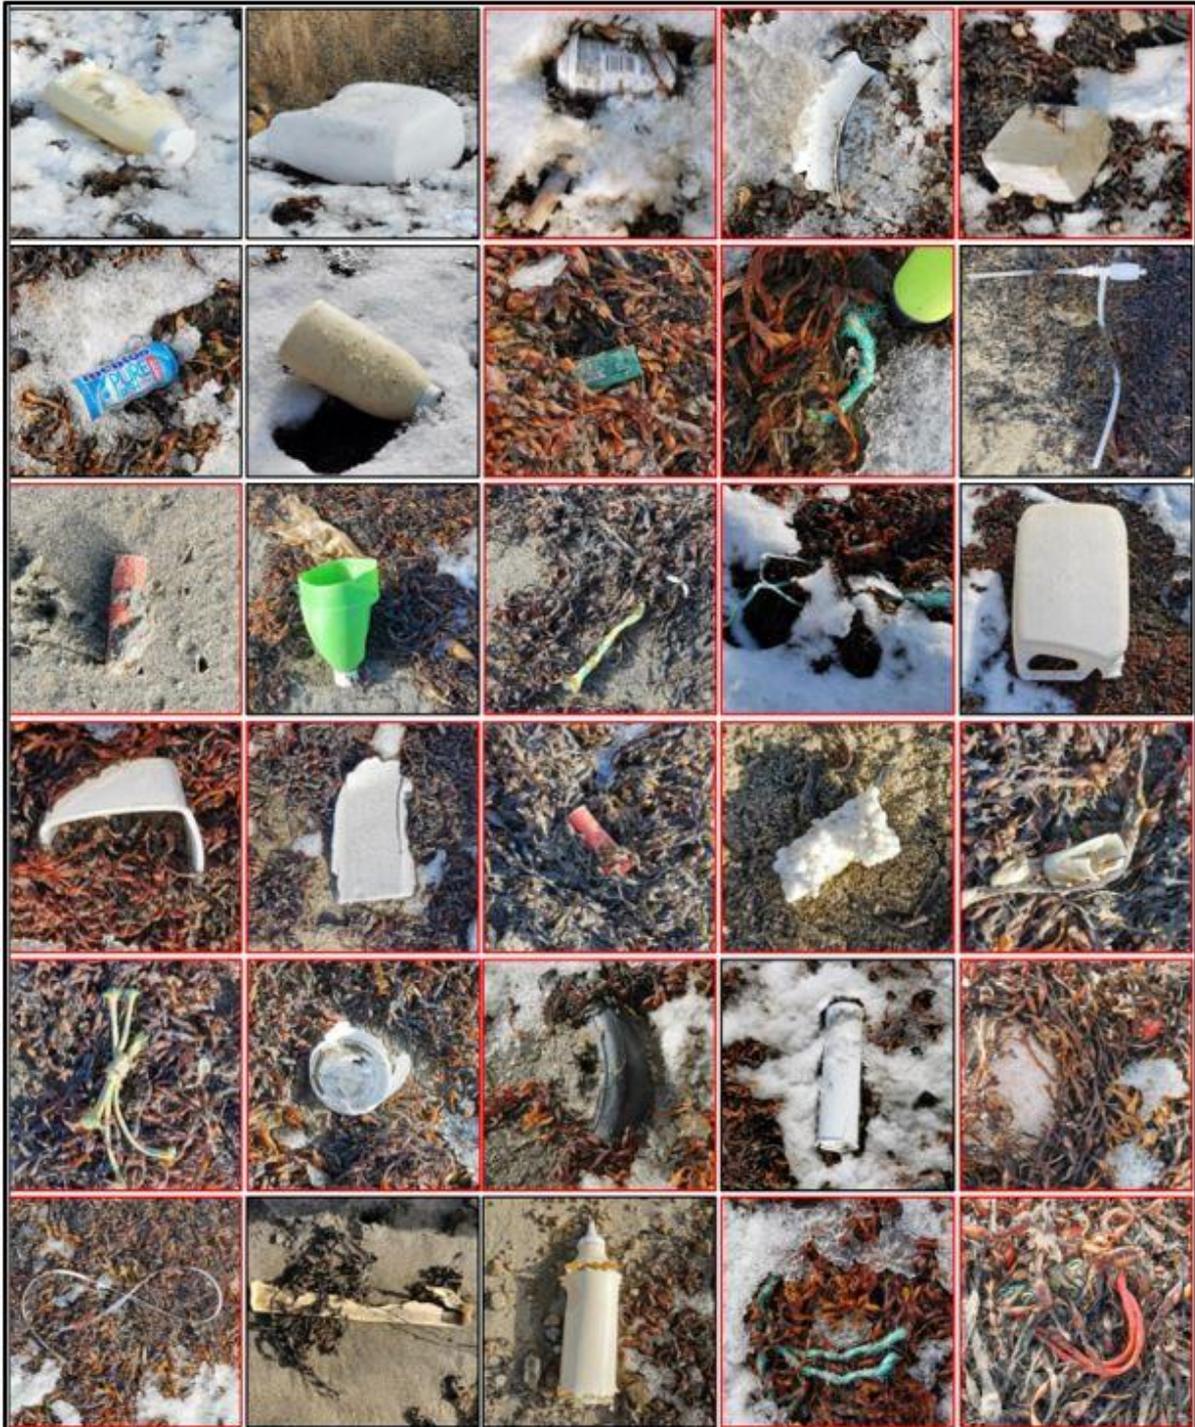
Current intensity [ms^{-1}]



Tägliche Strömungsintensität aus dem Datenportal des Norwegischen Polarinstituts, für das hochauflösende Modell (API) in 4 verschiedenen Zeitschritten. Beachten Sie die unterschiedliche räumliche Projektion (Süden in der unteren linken Ecke).
Quelle: Eigene Darstellung, BCSH

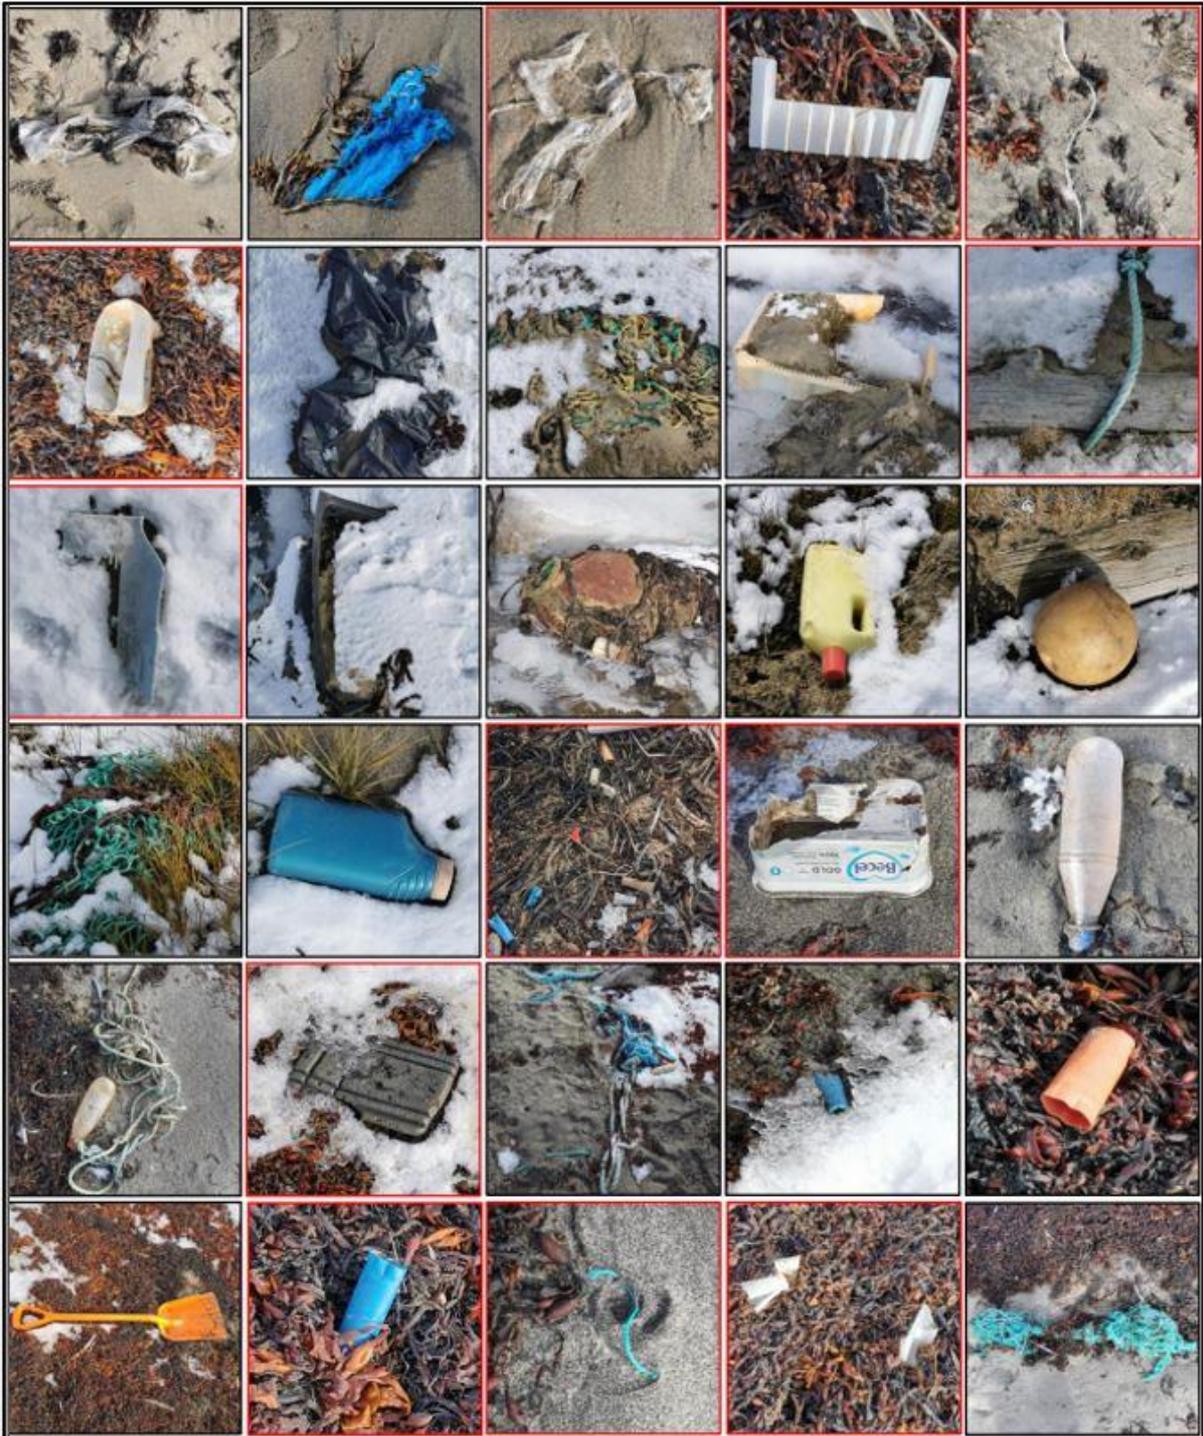
D Anhang

D.1 Fotos der mit einem GNSS-Empfänger gemessenen Müllobjekte im Untersuchungsgebiet Sisimiut Tag 4, aufgenommen mit einer Digitalkamera



In Rot umrandet Objekte, die bei der manuellen Sichtung der Drohnenbilder nicht gefunden wurden.

Quelle: Eigene Darstellung, BCSH



In Rot umrandet Objekte, die bei der manuellen Sichtung der Drohnenbilder nicht gefunden wurden.
Quelle: Eigene Darstellung, BCSH



In Rot umrandet Objekte, die bei der manuellen Sichtung der Drohnenbilder nicht gefunden wurden.

Quelle: Eigene Darstellung, BCSH



In Rot umrandet Objekte, die bei der manuellen Sichtung der Drohnenbilder nicht gefunden wurden.
Quelle: Eigene Darstellung, BCSH

D.2 Fotos der mit einem GNSS-Empfänger gemessenen Müllobjekte im Untersuchungsgebiet Sisimiut Tag 5, aufgenommen mit einer Digitalkamera



In Rot umrandet Objekte, die bei der manuellen Sichtung der Drohnenbilder nicht gefunden wurden.

Quelle: Eigene Darstellung, BCSH



In Rot umrandet Objekte, die bei der manuellen Sichtung der Drohnenbilder nicht gefunden wurden.

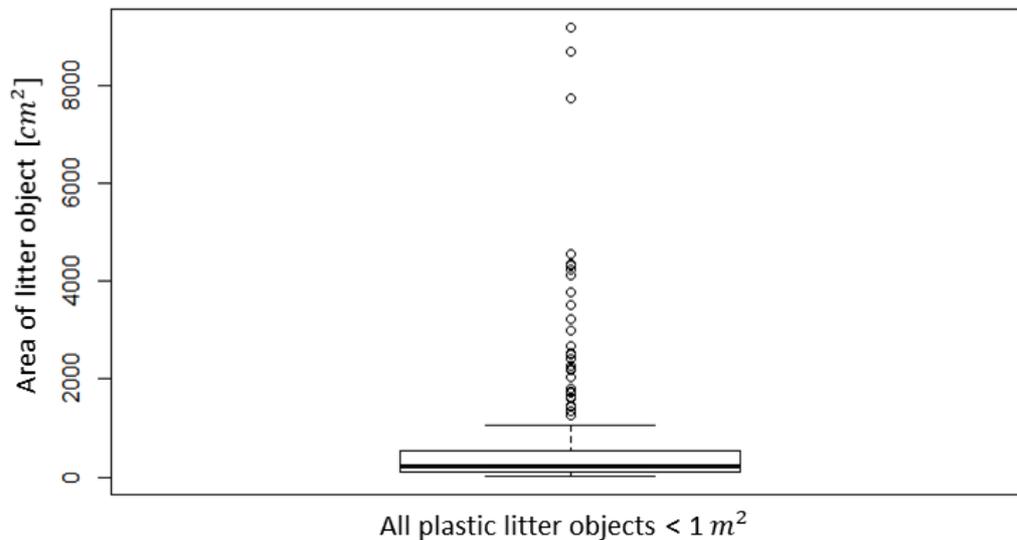
Quelle: Eigene Darstellung, BCSH

E Anhang

E.1 Anzahl der gefundenen Objekte für jede ermittelte Materialkategorie

Material	Glas	Metall	Plastik	Holz
Anzahl	1	4	357	165

E.2 Größenverteilung aller Plastikmüllobjekte, die kleiner als 1 m² waren



Quelle: Eigene Darstellung, BCSH

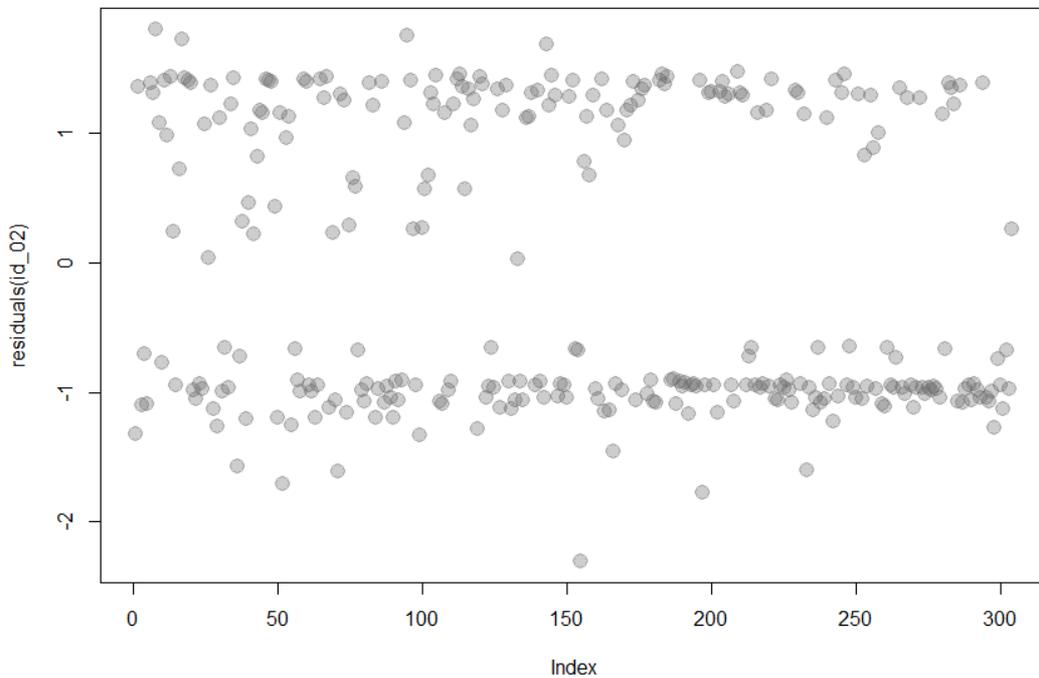
E.3 Übersichtstabelle der Modellrangliste nach AIC für die Auswirkungen mehrerer Parameter auf die Wahrscheinlichkeit, die Art eines Plastikobjekts zu identifizieren. Das für die Darstellung gewählte Modell ist fett hervorgehoben.

Modell	Variablen	df	AIC
Id_01	Fläche + Farbe + Fläche * Farbe	8	383,47
Id_02	Fläche + Farbe	5	393,72
Id_03	Fläche	2	392,02

E.4 Übersichtstabelle der Modellrangliste nach AIC für die Auswirkungen mehrerer Parameter auf die Wahrscheinlichkeit, dass ein Plastikmüllobjekt mit Sicherheit als solches identifiziert werden kann. Das für die Darstellung gewählte Modell ist fett hervorgehoben.

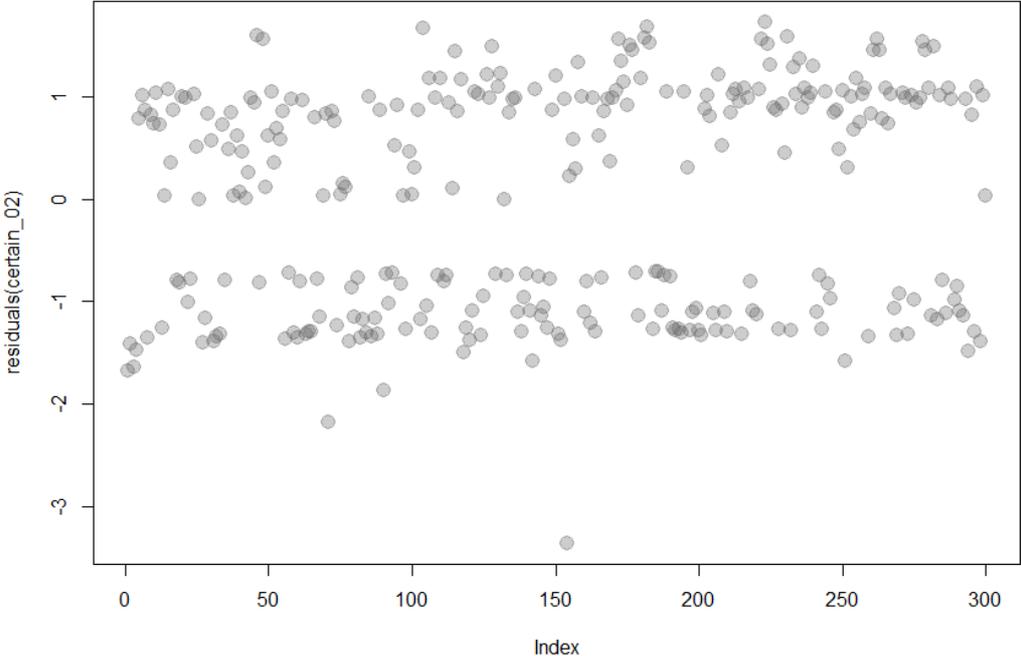
Modell	Variablen	df	AIC
Certain_01	Fläche + Farbe + Fläche * Farbe	8	348,51
Certain_02	Fläche + Farbe	5	361,07
Certain_03	Fläche	2	379,76

E.5 Streudiagramm der Residuen des finalen Modells (id_02), dass die Wahrscheinlichkeit beschreibt, die Art eines Plastikmüllobjekts zu identifizieren.



Quelle: Eigene Darstellung, BCSH

E.6 Streudiagramm der Residuen des finalen Modells (caertain_02), dass die Wahrscheinlichkeit beschreibt, dass ein Plastikmüllobjekt mit Sicherheit als solches identifiziert wurde



Quelle: Eigene Darstellung, BCSH

F Anhang - Konfusionsmatrizen: (Halb-)automatische Klassifikation

F.1 Grönland Random Forest v1

	Algen	Plastik	Steine	Sand	Schatten	Schnee	Vegetation	Wasser	Holz	Summe	PA [%]
Algen	416	3	11	5	34	30	0	1	0	500	83,2
Plastik	9	252	73	8	28	15	13	87	15	500	50,4
Steine	19	46	259	7	42	24	2	95	6	500	51,8
Sand	7	4	5	470	0	6	0	8	0	500	94,0
Schatten	22	15	18	1	365	23	3	5	0	452	80,8
Schnee	38	6	22	26	14	386	0	12	0	504	76,6
Vegetation	0	9	0	0	24	0	488	0	0	521	93,7
Wasser	4	58	104	22	16	17	1	267	11	500	53,4
Holz	0	6	0	0	0	0	0	4	451	461	97,8
Summe	515	399	492	539	523	501	507	479	483		
UA [%]	80,8	63,2	52,6	87,2	69,8	77,0	96,3	55,7	93,4		OA: 75,6%

F.2 Grönland Support Vector Machine v1

	Algen	Plastik	Steine	Sand	Schatten	Schnee	Vegetation	Wasser	Holz	Summe	PA [%]
Algen	432	2	7	10	27	22	0	0	0	500	86,4
Plastik	6	263	74	14	28	12	10	80	13	500	52,6
Steine	18	33	288	13	40	20	2	78	8	500	57,6
Sand	8	1	3	477	0	7	0	4	0	500	95,4
Schatten	22	11	13	2	378	20	4	2	0	452	83,6
Schnee	40	4	33	25	15	380	2	5	0	504	75,4
Vegetation	0	4	1	0	22	0	494	0	0	521	94,8
Wasser	2	51	108	25	17	14	0	270	13	500	54,0
Holz	0	5	0	0	0	0	0	6	450	461	97,6
Summe	528	374	527	566	527	475	512	445	484	OA: 77,3%	
UA [%]	81,8	70,0	54,6	84,3	71,7	80,0	96,5	60,7	93,0		

F.3 Grönland Neuronales Netzwerk v1a

	Algen	Plastik	Steine	Sand	Schatten	Schnee	Vegetation	Wasser	Holz	Summe	PA [%]
Algen	433	8	5	11	21	0	20	0	2	500	86,6
Plastik	7	264	72	10	27	17	14	14	75	500	52,8
Steine	15	42	291	7	35	5	27	2	76	500	58,2
Sand	7	2	5	474	0	0	8	0	4	500	94,8
Schatten	22	13	15	1	370	0	22	5	4	452	81,9
Schnee	0	8	0	0	0	448	0	0	5	461	97,2
Vegetation	33	6	21	19	16	0	399	3	7	504	79,2
Wasser	0	4	1	0	22	0	0	494	0	521	94,8
Holz	3	46	101	18	12	14	17	0	289	500	57,8
Summe	520	393	511	540	503	484	507	518	462	OA:78,0%	
UA [%]	83,3	67,2	56,9	87,8	73,6	92,6	78,7	95,4	62,6		

F.4 Grönland Neuronales Netzwerk k v1b

	Algen	Plastik	Steine	Sand	Schatten	Schnee	Vegetation	Wasser	Holz	Summe	PA [%]
Algen	433	8	7	9	21	0	21	0	1	500	86,6
Plastik	7	264	73	10	26	18	12	13	77	500	52,8
Steine	16	37	284	9	38	7	26	3	80	500	56,8
Sand	7	1	7	471	0	0	10	0	4	500	94,2
Schatten	23	16	21	1	362	0	19	6	4	452	80,1
Schnee	0	7	0	0	0	448	0	0	6	461	97,2
Vegetation	36	3	22	17	17	0	398	3	8	504	79,0
Wasser	0	6	1	0	22	0	0	491	1	521	94,2
Holz	3	48	103	20	10	13	19	1	283	500	56,6
Summe	525	390	518	537	496	486	505	517	464	OA: 77,3%	
UA [%]	82,5	67,7	54,8	87,7	73,0	92,2	78,8	95,0	61,0		

F.5 Grönland Neuronales Netzwerk v1c

	Algen	Plastik	Steine	Sand	Schatten	Schnee	Vegetation	Wasser	Holz	Summe	PA [%]
Algen	371	81	5	6	22	0	15	0	0	500	74,2
Plastik	3	463	3	4	8	2	10	3	4	500	92,6
Steine	14	390	61	5	11	0	12	2	5	500	12,2
Sand	9	76	0	408	0	0	6	0	1	500	81,6
Schatten	11	152	1	2	275	0	8	3	0	452	60,8
Schnee	0	89	0	0	0	372	0	0	0	461	80,7
Vegetation	39	107	12	11	8	0	324	3	0	504	0,0
Wasser	0	42	0	0	22	0	1	456	0	521	0,2
Holz	1	422	8	11	3	2	8	0	45	500	0,0
Summe	448	1822	90	447	349	376	384	467	55	OA: 62,5%	
UA [%]	82,8	25,4	67,8	91,3	78,8	98,9	84,4	97,6	81,8		

F.6 Grönland Random Forest v2

	Algen	Plastik	Steine	Sand	Schnee	Vegetation	Wasser	Holz	Summe	PA [%]
Algen	479	2	0	0	0	19	0	0	500	95,8
Plastik	6	339	64	6	1	7	1	76	500	67,8
Steine	0	27	414	18	1	3	3	34	500	82,8
Sand	0	0	8	491	0	0	0	1	500	98,2
Schnee	0	1	6	0	486	0	0	7	500	97,2
Vegetation	12	3	2	0	0	482	0	2	501	96,2
Wasser	0	2	3	0	0	0	495	0	500	99,0
Holz	3	35	45	5	1	12	0	399	500	79,8
Summe	500	409	542	520	489	523	499	519	OA: 89,6%	
UA [%]	95,8	82,9	76,4	94,4	99,4	92,2	99,2	76,9		

F.7 Grönland Support Vector Machine v2

	Algen	Plastik	Steine	Sand	Schnee	Vegetation	Wasser	Holz	Summe	PA [%]
Algen	489	0	1	0	0	9	0	1	500	97,8
Plastik	7	320	76	5	1	11	1	79	500	64,0
Steine	0	29	414	26	1	3	3	24	500	82,8
Sand	0	1	3	496	0	0	0	0	500	99,2
Schnee	0	1	8	0	485	0	0	6	500	97,0
Vegetation	16	3	3	0	0	475	0	3	500	95,0
Wasser	0	4	3	0	0	0	493	0	500	98,6
Holz	3	34	38	3	1	11	1	409	500	81,8
Summe	515	392	546	530	488	509	498	522	OA: 89,5%	
UA [%]	95,0	81,6	75,8	93,6	99,4	93,3	99,0	78,4		

F.8 Grönland Neuronales Netzwerk v2a

	Algen	Plastik	Steine	Sand	Schnee	Vegetation	Wasser	Holz	Summe	PA [%]
Algen	485	1	0	0	0	13	0	1	500	97,0
Plastik	6	360	56	2	2	8	1	65	500	72,0
Steine	0	37	413	21	2	2	0	25	500	82,6
Sand	0	1	6	493	0	0	0	0	500	98,6
Schnee	0	0	6	0	486	0	0	8	500	97,2
Vegetation	10	3	1	0	0	483	0	4	501	96,4
Wasser	0	2	3	0	0	0	495	0	500	99,0
Holz	4	49	45	1	0	11	1	389	500	77,8
Summe	505	453	530	517	490	517	497	492		OA: 90,1%
UA [%]	96,0	79,5	77,9	95,4	99,2	93,4	99,6	79,1		

F.9 Grönland Neuronales Netzwerk v2b

	Algen	Plastik	Steine	Sand	Schnee	Vegetation	Wasser	Holz	Summe	PA [%]
Algen	483	3	0	0	0	13	0	1	500	96,6
Plastik	4	418	31	4	2	5	1	35	500	83,6
Steine	0	105	349	22	0	1	1	22	500	69,8
Sand	0	3	10	487	0	0	0	0	500	97,4
Schnee	0	7	10	0	477	0	0	6	500	95,4
Vegetation	13	6	2	0	0	480	0	0	501	95,8
Wasser	0	3	3	0	0	0	494	0	500	98,8
Holz	3	124	25	1	1	9	1	336	500	67,2
Summe	503	669	430	514	480	508	497	400		OA: 88,1%
UA [%]	96,0	62,5	81,2	94,7	99,4	94,5	99,4	84,0		

F.10 Grönland Neuronales Netzwerk v2c

	Algen	Plastik	Steine	Sand	Schnee	Vegetation	Wasser	Holz	Summe	PA [%]
Algen	476	12	0	0	0	12	0	0	500	95,2
Plastik	4	476	5	4	0	3	0	8	500	95,2
Steine	0	297	172	23	0	0	1	7	500	34,4
Sand	0	17	8	474	0	0	0	1	500	94,8
Schnee	0	19	5	0	474	0	0	2	500	94,8
Vegetation	13	36	0	0	0	452	0	0	501	90,2
Wasser	0	8	0	0	0	0	492	0	500	98,4
Holz	2	306	3	4	0	9	1	175	500	35,0
Summe	495	1171	193	505	474	476	494	193		OA: 79,8%
UA [%]	96,2	40,6	89,1	93,9	100,0	95,0	99,6	90,7		

F.11 Grönland Random Forest v3

	Algen	Plastik	Steine	Sand	Schatten	Schnee	Vegetation	Wasser	Holz	Summe	PA [%]
Algen	486	2	0	0	3	0	9	0	0	500	97,2
Plastik	6	362	56	2	10	0	6	0	58	500	72,4
Steine	0	27	411	13	22	2	2	1	22	500	82,2
Sand	0	0	8	491	0	0	0	0	1	500	98,2
Schatten	8	15	15	1	459	0	8	4	2	512	89,6
Schnee	0	2	0	0	0	497	0	0	1	500	99,4
Vegetation	12	1	4	0	7	0	475	0	4	503	99,4
Wasser	0	1	0	0	4	0	0	495	0	500	99,0
Holz	1	34	34	1	5	0	12	0	413	500	82,6
Summe	513	444	528	508	510	499	512	500	501	OA:90,6%	
UA [%]	94,7	81,5	77,8	96,7	90,0	99,6	92,8	99,0	82,4		

F.12 Grönland Support Vector Machine v3

	Algen	Plastik	Steine	Sand	Schatten	Schnee	Vegetation	Wasser	Holz	Summe	PA [%]
Algen	485	2	0	0	1	0	11	0	1	500	97,0
Plastik	6	360	64	3	9	0	5	0	53	500	72,0
Steine	0	33	403	24	19	0	1	0	20	500	80,6
Sand	0	0	6	494	0	0	0	0	0	500	98,8
Schatten	7	12	8	1	460	0	9	3	0	500	92,0
Schnee	0	2	1	0	0	495	0	0	2	500	99,0
Vegetation	11	5	4	0	13	0	463	0	4	500	92,6
Wasser	0	1	0	0	2	0	0	497	0	500	99,4
Holz	1	36	44	0	2	0	6	0	411	500	82,2
Summe	510	451	530	522	506	495	495	500	491	OA: 90,4%	
UA [%]	95,1	79,8	76,0	94,6	90,9	100,0	93,5	99,4	83,7		

F.13 Grönland Neuronales Netzwerk v3a

	Algen	Plastik	Steine	Sand	Schatten	Schnee	Vegetation	Wasser	Holz	Summe	PA [%]
Algen	484	2	0	0	1	0	13	0	0	500	96,8
Plastik	4	358	57	4	10	0	6	1	60	500	71,6
Steine	0	40	392	20	22	1	1	0	24	500	78,4
Sand	0	1	5	494	0	0	0	0	0	500	98,8
Schatten	5	12	12	1	465	0	12	3	2	512	90,8
Schnee	0	0	0	0	0	499	0	0	1	500	99,8
Vegetation	10	3	2	0	11	0	470	0	7	503	93,4
Wasser	0	1	0	0	3	0	0	496	0	500	99,2
Holz	1	52	35	0	2	0	6	0	404	500	80,8
Summe	504	469	503	519	514	500	508	500	498	OA: 89,9%	
UA [%]	96,0	76,3	77,9	95,2	90,5	99,8	92,5	99,2	81,1		

F.14 Grönland Neuronales Netzwerk v3b

	Algen	Plastik	Steine	Sand	Schatten	Schnee	Vegetation	Wasser	Holz	Summe	PA [%]
Algen	483	4	0	0	1	0	12	0	0	500	96,6
Plastik	3	448	19	3	5	1	5	0	16	500	89,6
Steine	0	195	249	17	24	0	2	0	13	500	49,8
Sand	0	11	6	482	0	0	0	0	1	500	96,4
Schatten	6	35	7	0	450	0	9	5	0	512	87,9
Schnee	0	2	0	0	0	497	0	0	1	500	99,4
Vegetation	13	21	0	0	14	0	451	0	4	503	89,7
Wasser	0	0	0	0	6	0	0	494	0	500	98,8
Holz	2	205	21	0	3	0	6	0	263	500	52,6
Summe	507	921	302	502	503	498	485	499	298	OA: 84,5%	
UA [%]	95,3	48,6	82,5	96,0	89,5	99,8	93,0	99,0	88,3		

F.15 Grönland Neuronales Netzwerk v3c

	Algen	Plastik	Steine	Sand	Schatten	Schnee	Vegetation	Wasser	Holz	Summe	PA [%]
Algen	485	3	0	0	1	0	11	0	0	500	97,0
Plastik	4	420	33	4	6	0	6	0	27	500	84,0
Steine	0	101	326	20	32	1	1	1	18	500	65,2
Sand	0	0	7	493	0	0	0	0	0	500	98,6
Schatten	10	23	10	1	455	0	7	5	1	512	88,9
Schnee	0	2	0	0	0	497	0	0	1	500	99,4
Vegetation	14	7	1	0	15	0	459	0	7	503	91,3
Wasser	0	1	0	0	3	0	0	496	0	500	99,2
Holz	1	116	30	0	3	0	12	0	338	500	67,6
Summe	514	673	407	518	515	498	496	502	392	OA: 87,9%	
UA [%]	94,4	62,4	80,1	95,2	88,3	99,8	92,5	98,8	86,2		

F.16 Spitzbergen Random Forest v1

	Plastik	Steine	Vegetation	Wasser	Holz	Summe	PA [%]
Plastik	96	13	9	7	25	150	64,0
Steine	8	102	5	0	35	150	68,0
Vegetation	1	7	139	3	0	150	92,7
Wasser	2	0	5	143	0	150	95,3
Holz	19	14	7	0	110	150	73,3
Summe	126	136	165	153	170	OA: 78,6%	
UA [%]	76,2	75,0	84,2	93,5	64,7		

F.17 Spitzbergen Random Forest v2

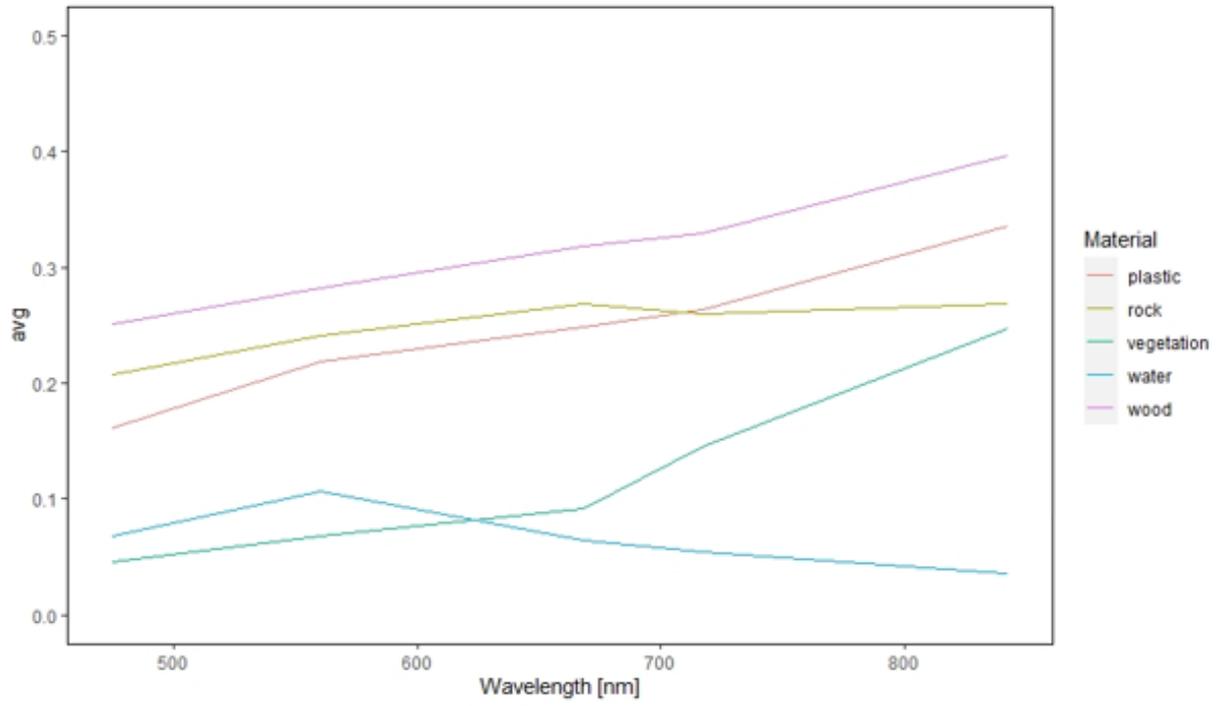
	Plastik	Steine	Vegetation	Wasser	Holz	Summe	PA [%]
Plastik	95	13	15	0	27	150	63,3
Steine	15	121	0	0	14	150	80,7
Vegetation	6	0	142	0	2	150	94,7
Wasser	2	0	0	148	0	150	98,7
Holz	19	7	1	0	123	150	82,0
Summe	137	141	158	148	166	OA: 85,9%	
UA [%]	69,3	85,8	89,9	100,0	74,1		

F.18 Spitzbergen Random Forest v3

	Plastik	Steine	Vegetation	Wasser	Holz	Summe	PA [%]
Plastik	98	7	15	0	30	150	65,3
Steine	5	132	0	1	12	150	88,0
Vegetation	7	0	141	0	2	150	94,0
Wasser	0	0	0	150	0	150	100,0
Holz	21	3	3	0	123	150	82,0
Summe	131	142	159	151	167	OA: 85,9%	
UA [%]	74,8	93,0	88,7	99,3	73,7		

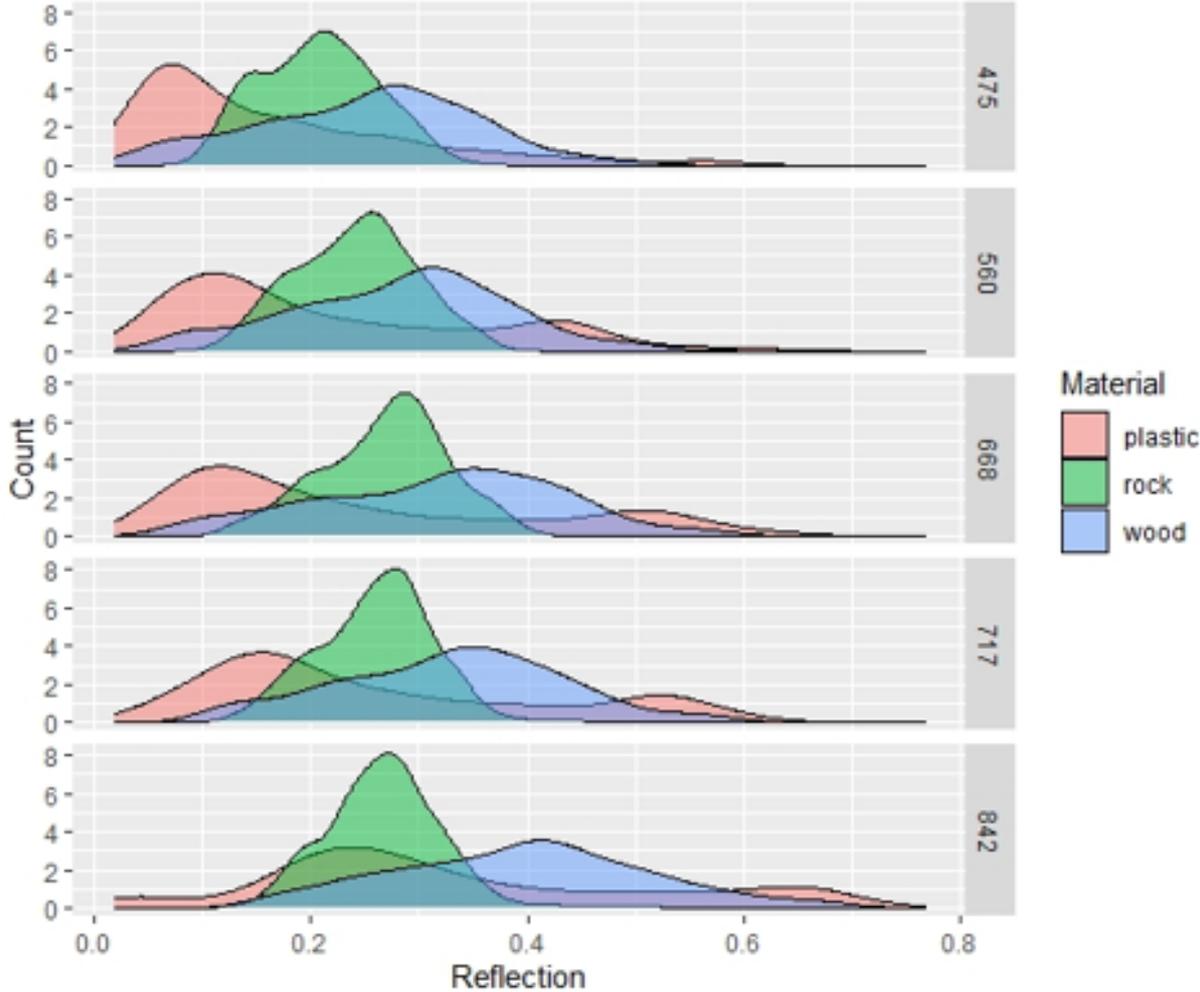
G Anhang - Spektrales Signal von Drohnen-Referenzdaten auf Spitzbergen

G.1 Durchschnittlicher Reflektionswert der Eingangsklassen aus den Referenzdaten von Spitzbergen



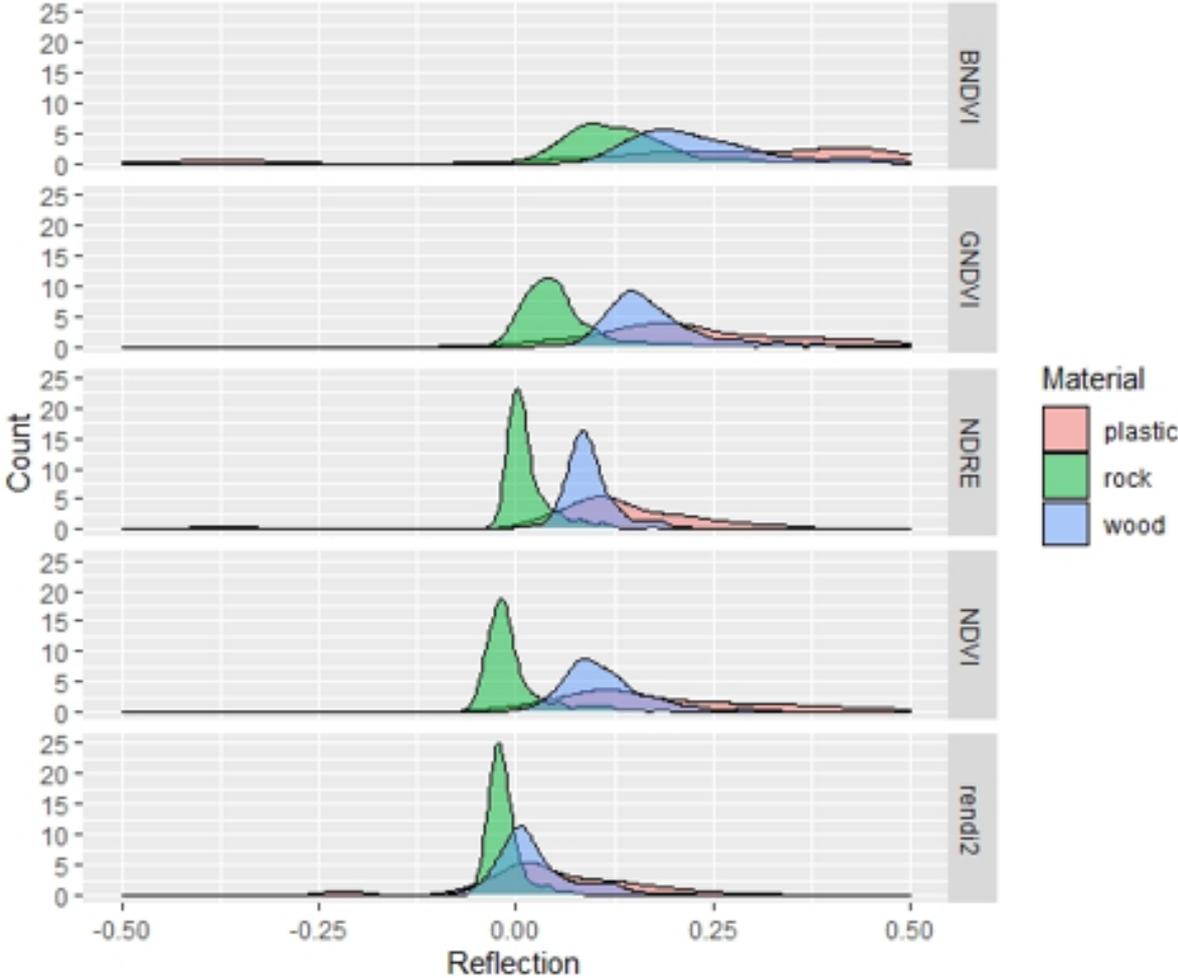
Quelle: Eigene Darstellung, BCSH

G.2 Dichtefunktionen der aus den Referenzdaten auf Spitzbergen extrahierten Reflektionswerte



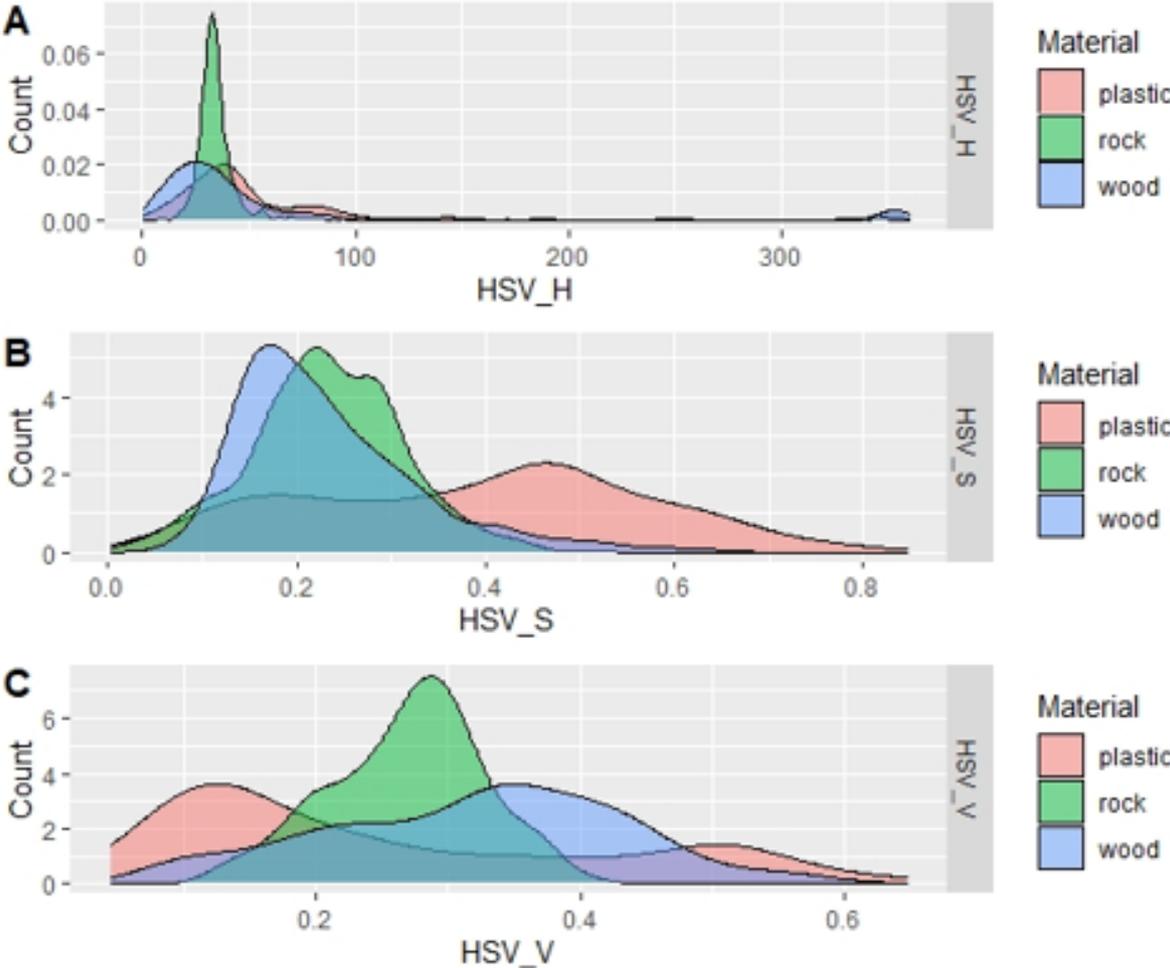
Quelle: Eigene Darstellung, BCSH

G.3 Dichtefunktionen der angewandten Indizes, die aus den Referenzdaten auf Spitzbergen extrahiert wurden



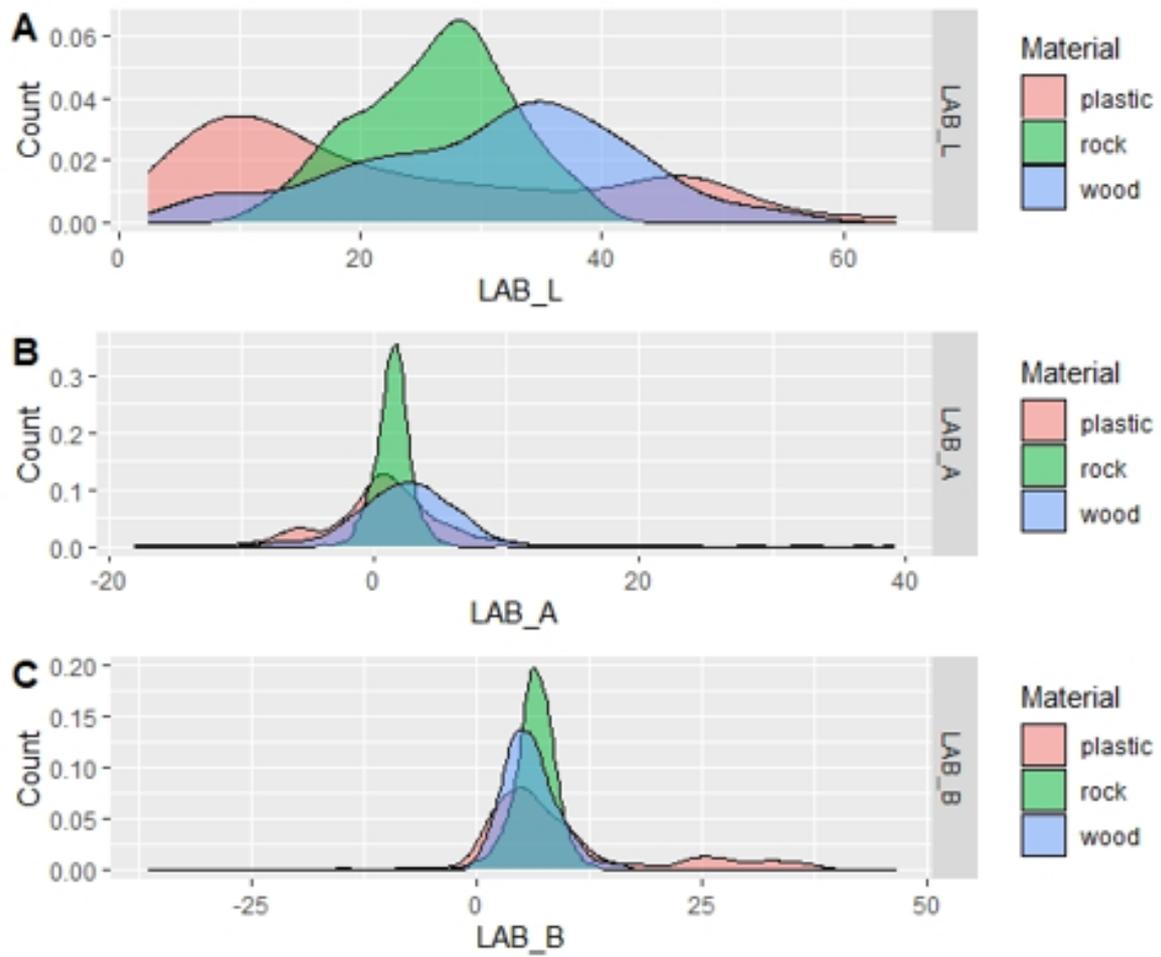
Quelle: Eigene Darstellung, BCSH

G.4 Dichtefunktionen des HSV-Farbraums, die aus den Referenzdaten von Spitzbergen extrahiert wurden



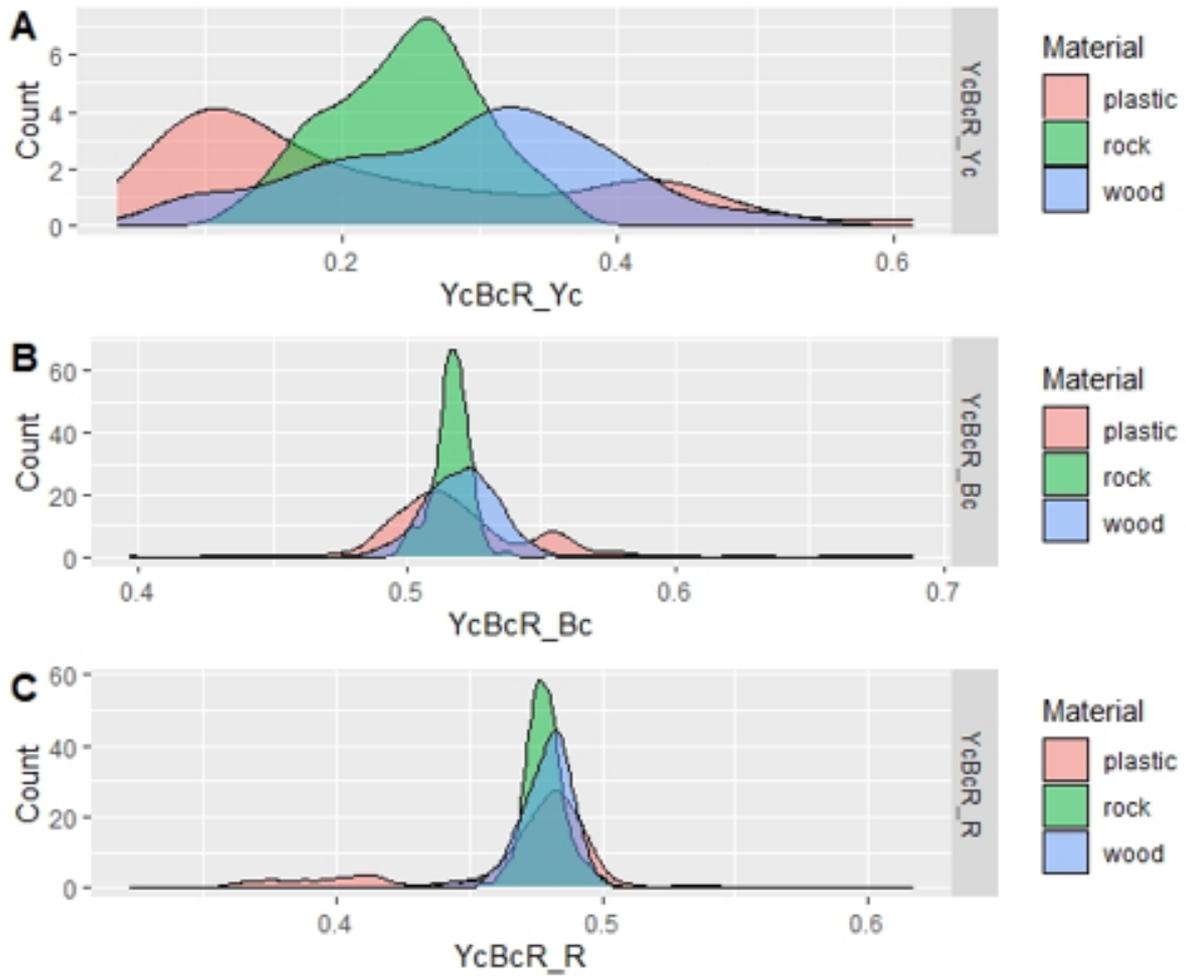
Quelle: Eigene Darstellung, BCSH

G.5 Dichtefunktionen des LAB-Farbraums, die aus den Referenzdaten von Spitzbergen extrahiert wurden



Quelle: Eigene Darstellung, BCSH

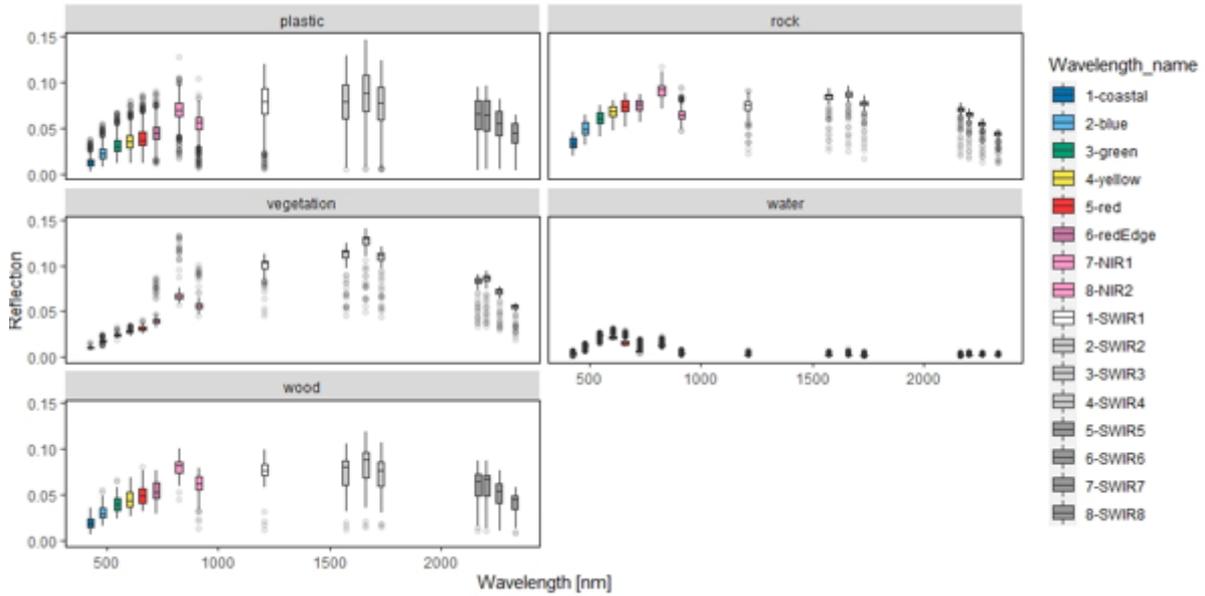
G.6 Dichtefunktionen des YcBcR-Farbraums, die aus den Referenzdaten von Spitzbergen extrahiert wurden



Quelle: Eigene Darstellung, BCSH

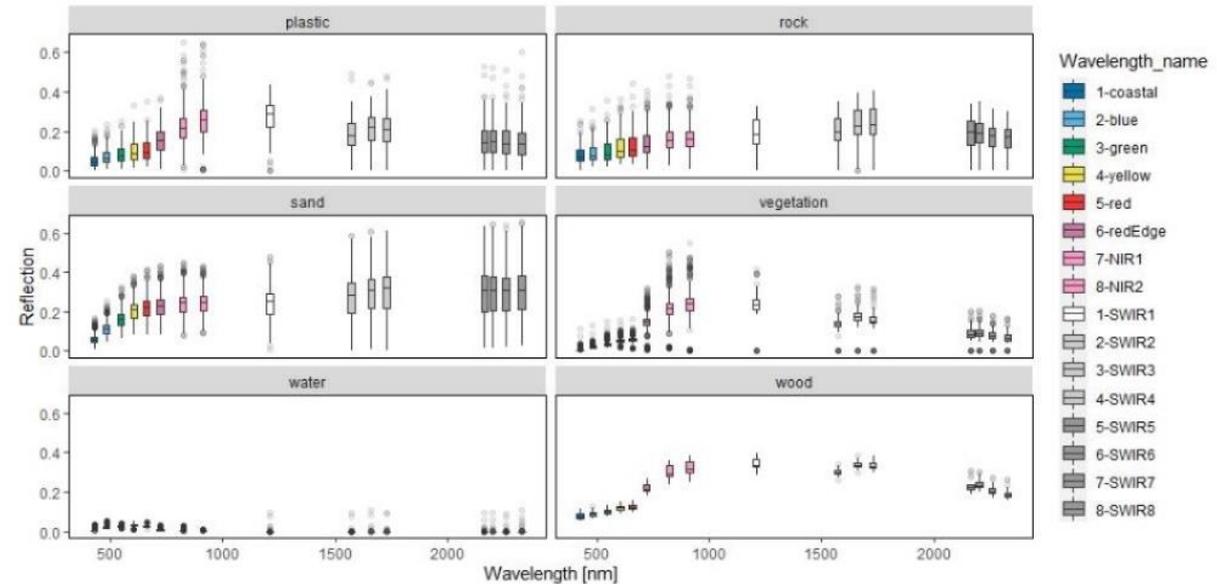
H Anhang

H.1 Spektrale Reflektionswerte von WV3-Bildern auf Spitzbergen, die die Streuung innerhalb der einzelnen Klassen zeigen



Quelle: Eigene Darstellung, BCSH

H.2 Spektrale Reflektionswerte von WV3-Bildern auf Grönland, die die Streuung innerhalb der einzelnen Klassen zeigen



Quelle: Eigene Darstellung, BCSH