

CLIMATE CHANGE

50/2024

Schlussbericht

# Operationalisierung von DAS- Indikatoren mit Fernerkundungsdaten

DASIF

von:

Katja Kuhwald, Natascha Oppelt  
Christian-Albrechts-Universität zu Kiel, Kiel

Jorrit Scholze, Kerstin Stelzer  
Brockmann-Consult GmbH, Hamburg

Herausgeber:

Umweltbundesamt



CLIMATE CHANGE 50/2024

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

Forschungskennzahl 3719 48 101 0

FB001447

Abschlussbericht

# **Operationalisierung von DAS-Indikatoren mit Fernerkundungsdaten**

DASIF

von

Katja Kuhwald, Natascha Oppelt  
Christian-Albrechts-Universität zu Kiel, Kiel

Jorrit Scholze, Kerstin Stelzer  
Brockmann-Consult GmbH, Hamburg

Im Auftrag des Umweltbundesamtes

## Impressum

### Herausgeber

Umweltbundesamt  
Wörlitzer Platz 1  
06844 Dessau-Roßlau  
Tel: +49 340-2103-0  
Fax: +49 340-2103-2285  
[buergerservice@uba.de](mailto:buergerservice@uba.de)  
Internet: [www.umweltbundesamt.de](http://www.umweltbundesamt.de)

### Durchführung der Studie:

Christian-Albrechts-Universität zu Kiel, Geographisches Institut  
Ludewig-Meyn-Str. 8  
24118 Kiel

Brockmann-Consult GmbH  
Chrysanderstr. 1  
21029 Hamburg

### Abschlussdatum:

August 2023

### Redaktion:

Fachgebiet I 1.7 Umweltinformationssysteme und -dienste, Satellitenfernerkundung,  
Dateninfrastruktur  
Dr. Christian Schweitzer

Publikationen als pdf:

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

ISSN 1862-4359

Dessau-Roßlau, November 2024

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

## Danksagung

Das Projektteam dankt an erster Stelle allen am Projekt beteiligten Fachpersonen aus dem Umweltbundesamt, den behördlichen, kommunalen und wissenschaftlichen Einrichtungen aus den Bereichen Seen, Gründächer und Klimawandelmonitoring. In mehreren sehr gut besuchten Online-Workshops fand ein ausgesprochen produktiver und reger Austausch statt, der die Qualität der Ergebnisse unseres Projekts gestärkt hat. Ihr Engagement hat zum Erfolg des Projekts wesentlich beigetragen. Vielen Dank!

Im Detail möchten wir uns bei Dr. Christian Schweitzer und Dr. Petra van Rüth vom Umweltbundesamt für die hervorragende fachliche Betreuung und Austauschgespräche bedanken, die uns gleichzeitig viel Raum für Gestaltungsfreiheit gegeben haben. Wir danken allen Mitgliedern der Bund/Länder-Arbeitsgemeinschaft Wasser (LAWA) bzw. Landesbehörden, die uns unkompliziert Messdaten aus dem Seenmonitoring zur Verfügung gestellt haben. Ein herzlicher Dank geht auch an das Leibniz-Institut für Binnengewässer und Fischerei, die uns ebenfalls Messdaten zur Verfügung gestellt haben. Besonders danken möchten wir auch Volker Dietz und Franziska Reinfried vom Umweltamt Dresden (Bereich Stadtökologie) für das Bereitstellen der Gründachdaten aus Dresden.

Wir danken insbesondere Konstanze Schönthaler (Bosch & Partner GmbH) wie auch der LAWA Kleingruppe Klimawandel für die konstruktiven Beiträge und aufschlussreichen Diskussionen über Indikatorvorschläge. Dieser Dank gilt für Stefan von Andrian-Werburg (Bosch & Partner GmbH) für den Indikator Gründächer.

Wir bedanken uns auch bei unseren Kolleginnen und Kollegen der CAU Kiel und Brockmann Consult GmbH, die uns engagiert in der Projektarbeit unterstützt haben: Dr. Marcel König (ehemals CAU Kiel), Kim Gröschler (CAU Kiel), Dr. Martin Böttcher, Carole Lebreton und Dr. Dagmar Müller (Brockmann Consult GmbH).

Unser abschließender Dank gilt den Studierenden, die das Projekt mit Datenrecherche, -aufbereitung und -auswertung tatkräftig unterstützt haben: Jonna Lauther (CAU Kiel), Jannes Ott und Kerstin Brembach (beide ehemals CAU Kiel).

**Kurzbeschreibung: Operationalisierung von DAS-Indikatoren mit Fernerkundungsdaten**

Das ReFoPlan-Forschungsprojekt "Operationalisierung von DAS-Indikatoren mit Fernerkundungsdaten" (DASIF) verfolgte das Ziel, operationelle Fernerkundungsverfahren zu entwickeln, um eine deutschlandweite Datengrundlage für ausgewählte Indikatoren der Deutschen Anpassungsstrategie Klimawandel (DAS) zu erstellen. Die Indikatoren umfassten vier Impact-Indikatoren in Seen: Cyanobakterienbelastung von Badegewässern, Frühjahrsalgenblüte in Seen, Wassertemperatur in stehenden Gewässern, Eisbedeckung von Seen und den Response-Indikator Gründächer. Das Forschungsprojekt durchlief mehrere Schritte, darunter die Analyse von Lücken und Bedarfen der bestehenden Indikatoren, die Auswahl und Validierung von Algorithmen und Satellitendaten in Fallstudien, sowie die Entwicklung von Verfahren zur bundesweiten Indikatorbildung. Zwischenergebnisse wurden mit Fachpersonen mehrfach diskutiert und weiterentwickelt, sodass schließlich drei der fünf DASIF-Indikatoren erstmals als fernerkundungsbasierte Klimawandel-Indikatoren im DAS-Bericht 2023 veröffentlicht wurden: Cyanobakterienbelastung von Badegewässern, Frühjahrsalgenblüte in Seen und Gründächer in Großstädten. Die entwickelten Verfahren ermöglichen eine deutschlandweit vergleichbare Datengrundlage für die ausgewählten Indikatoren. Ihre Berechnung wurde auf der Copernicus-Daten und Cloud-Prozessierungsplattform für deutsche Behörden (CODE-DE) implementiert. Ein interaktives Dashboard wurde erstellt, um die Ergebnisse öffentlich zugänglich zu machen. Die Forschungsergebnisse zeigen, dass die Fernerkundung mit Satellitendaten eine effektive und präzise Methode ist, um deutschlandweite Klimawandelindikatoren zu generieren und dabei Defizite in bestehenden Datengrundlagen zu überwinden. Als Ausblick wurden weitere Indikatoren identifiziert, für die die Fernerkundung eine gute Grundlage liefern könnte.

**Abstract: Operationalisation of DAS indicators with remote sensing data**

The ReFoPlan research project "Operationalisation of DAS indicators with remote sensing data" (DASIF) aimed to develop operational remote sensing methods to create a Germany-wide data basis for selected indicators of the German Adaptation Strategy to Climate Change (DAS). The indicators comprised four impact indicators in lakes: cyanobacteria contamination of bathing waters, spring algal blooms in lakes, water temperature in standing waters, ice cover of lakes and the response indicator green roofs. The research project went through several steps, including analysing gaps and needs in the existing indicators, selecting and validating algorithms and satellite data in case studies, and developing procedures for nationwide indicator calculation. Intermediate results were discussed and further developed several times with experts. Thus, three of the five DASIF indicators were finally published for the first time as remote sensing-based climate change indicators in the DAS Report 2023: cyanobacteria contamination of bathing waters, spring algal blooms in lakes and green roofs in large cities. The developed methods enable a comparable data basis for the selected indicators across Germany. Their calculation was implemented on the Copernicus data and cloud processing platform for German authorities (CODE-DE). An interactive dashboard was created to make the results publicly accessible. The research results showed that spaceborne remote sensing is an effective and precise method for generating Germany-wide climate change indicators and overcoming deficits in existing data bases. Further indicators were identified for which remote sensing could provide a good basis.

## Inhaltsverzeichnis

Abbildungsverzeichnis.....	10
Tabellenverzeichnis.....	12
Abkürzungsverzeichnis.....	14
Zusammenfassung.....	16
Summary.....	24
1 Einleitung.....	31
2 Möglichkeiten der Fernerkundung.....	37
2.1 Cyanobakterienbelastung von Badegewässern.....	37
2.1.1 Methodischer Hintergrund.....	37
2.1.2 Algorithmische Ansätze zur Bestimmung von Cyanobakterien.....	38
2.1.3 Erkennung von Cyanobakterien durch die Kombination von in-situ Daten und Fernerkundung.....	39
2.2 Frühjahrsalgenblüte in Seen.....	39
2.2.1 Methodischer Hintergrund.....	40
2.2.2 Algorithmische Ansätze zur Bestimmung von Chlorophyll-a.....	40
2.2.3 Berücksichtigung der Seentypen bei der Algorithmik.....	41
2.3 Wassertemperatur in Seen.....	41
2.3.1 Methodischer Hintergrund.....	42
2.3.2 Anwendung der thermalen Fernerkundung.....	42
2.3.3 Operationell verfügbare Produkte der Wassertemperatur.....	43
2.4 Eisbedeckung von Seen.....	43
2.4.1 Optische Trennung von Eis und Wasser.....	44
2.4.2 Indirekte Bestimmung der Eisbedeckung über die Wassertemperatur.....	44
2.4.3 Trennung von Eis und Wasser über SAR-Daten.....	44
2.5 Gründächer in Großstädten.....	46
2.5.1 Bestimmung der begrünten Dächer.....	46
2.5.2 Bestimmung der Art der Begrünung.....	47
2.5.3 Bestimmung geeigneter Dachflächen.....	47
2.6 Vorauswahl der Algorithmen zur Berechnung geophysikalischer Parameter aus Fernerkundungsdaten.....	48
3 Entwicklung von fernerkundungsbasierten DAS-Indikatoren.....	56
3.1 Untersuchungsgebiete und Datengrundlage.....	56
3.1.1 Seen und Talsperren für Impact-Indikatoren.....	56

3.1.2	Städte für Gründachanalyse .....	58
3.2	Validierung der geophysikalischen Parameter .....	59
3.3	Cyanobakterienbelastung von Badegewässern .....	61
3.4	Frühjahrsalgenblüte in Seen .....	66
3.5	Wassertemperatur in Seen .....	72
3.6	Eisbedeckung von Seen.....	76
3.7	Gründächer in Großstädten .....	82
3.8	Qualitätskriterien für fernerkundungsbasierte DAS-Indikatoren .....	86
3.8.1	Entwicklung der Qualitätskriterien .....	86
3.8.2	Aussagen der Qualitätskriterien .....	87
3.8.3	Einfluss der Qualitätskriterien in die Trendanalyse .....	88
4	Operationalisierung der fernerkundungsbasierten Indikatoren.....	90
4.1	Auswahl einer Prozessierungsplattform.....	90
4.2	Umsetzung der Operationalisierung.....	92
4.2.1	Satellitendatenprozessierung .....	92
4.2.2	Datenextraktion und Datenanalyse .....	93
4.2.3	Trendanalyse und bundesweiter Indikator.....	95
4.3	Entwicklung eines interaktiven Dashboards.....	95
5	Forschungsbedarfe, Entwicklungen und Perspektiven .....	97
5.1	Forschungsbedarfe für die aktuellen Indikatoren.....	97
5.1.1	Cyanobakterienbelastung von Badegewässern.....	97
5.1.2	Frühjahrsalgenblüte in Seen .....	97
5.1.3	Wassertemperatur in Seen .....	98
5.1.4	Eisbedeckung von Seen.....	98
5.1.5	Gründächer in Großstädten .....	98
5.2	Synergien auf europäischer und internationaler Ebene .....	99
5.3	Perspektiven für fernerkundungsbasierte DAS Indikatoren .....	99
5.4	Entwicklungen in der Satellitenfernerkundung .....	102
6	Quellenverzeichnis .....	104
A	Übersicht über alle Untersuchungsseen .....	115
B	Ergebnisse der Fallstudien an den Seen.....	116
B.1	Cyanobakterienbelastung von Badegewässern .....	117
B.2	Frühjahrsalgenblüte in Seen .....	117
B.2.1	Ausgewählte Algorithmen .....	117

B.2.2	Ergebnisse der Validierung .....	120
B.3	Wassertemperatur in Seen .....	126
B.3.1	Ausgewählte Algorithmen .....	126
B.3.2	Ergebnisse der Validierung .....	129
B.4	Eisbedeckung von Seen.....	133
B.5	Gründächer in Großstädten .....	133
B.5.1	Ausgewählte Algorithmen und Daten.....	133
B.5.2	Ergebnisse der Validierung .....	134

## Abbildungsverzeichnis

Abbildung 1:	Überblick über die Arbeitspakete 2-4 und den Projektablauf. Arbeitspaket 1 Lücken- und Bedarfsanalyse ist aufgrund des kurzen Umfangs nicht dargestellt..	36
Abbildung 2:	Bewertungsmatrix zur Vorauswahl von Algorithmen für den Indikator Cyanobakterienbelastung von Badegewässern .....	50
Abbildung 3:	Bewertungsmatrix zur Vorauswahl von Algorithmen für den Indikator Frühjahrsalgenblüte in Seen .....	51
Abbildung 4:	Bewertungsmatrix zur Vorauswahl von Algorithmen für den Indikator Wassertemperatur in Seen.....	52
Abbildung 5:	Bewertungsmatrix zur Vorauswahl von Algorithmen für den Indikator Eisbedeckung von Seen .....	54
Abbildung 6:	Bewertungsmatrix zur Vorauswahl von Algorithmen für den Indikator Gründächer in Großstädten.....	55
Abbildung 7:	Karte mit Seen und Talsperren, die in die DASIF-Indikatoren eingehen .....	57
Abbildung 8:	Karte der deutschen Großstädte > 500 000 Einwohner*innen (inkl. Duisburg), für die in DASIF die Gründachanalyse durchgeführt wurde .....	59
Abbildung 9:	Heatmap des Cyanobakterien-Markers im Speicher Witznitz. Die Größe der Kreise zeigt die Häufigkeit gültiger Überflüge. Zu beachten ist ein Zeitsprung zwischen 2012 und 2016 in der y-Achse .....	64
Abbildung 10:	Indikatorberechnung Cyanobakterienbelastung von Badegewässern am Beispiel des Speicher Witznitz .....	65
Abbildung 11:	Bundesweiter Indikator Cyanobakterienbelastung von Badegewässern.....	66
Abbildung 12:	Heatmap der Chlorophyll-a Konzentration im Frühjahr - Kummerower See.....	69
Abbildung 13:	Zeitreihe des Indikators Frühjahrsalgenblüte für ausgewählte Seen basierend auf Satellitendaten .....	71
Abbildung 14:	Bundesweite Aggregation und Darstellung des Indikators Frühjahrsalgenblüte in stehenden Gewässern .....	72
Abbildung 15:	LSWT Zeitreihen der See-Mediane an Aufnahmetagen am Bodensee (a), Müggelsee (b) und der Talsperre Saidenbach (c).....	74
Abbildung 16:	Heatmap der monatlichen LSWT Mittelwerte von Bodensee Obersee (a), Müggelsee (b) und Talsperre Saidenbach (c) .....	75
Abbildung 17:	Indikator Wassertemperatur bundesweit aggregiert auf die drei Hauptnaturräume .....	76
Abbildung 18:	Anzahl der Pixel nach Sensoren und Klassen im Trainings- und Validierungsdatensatz .....	77
Abbildung 19:	Webcamaufnahme (a) der südlichen Webcam (b) am Freibergsee und zugehöriges Klassifikationsergebnis (c) einer Sentinel-2 MSI Aufnahme vom 27.3.2020.....	78
Abbildung 20:	Histogramme der Rückstreuwerte in der Polarisation VV (obere Zeile) und VH (untere Zeile) im gesamten Datensatz (a, d), mit Windgeschwindigkeiten < 1m/s (b, e) und Windgeschwindigkeiten > 1m/s (c, f).....	79
Abbildung 21:	Eisbedeckung am Beispiel des Freibergsees basierend auf den Webcam Bildern (a), der Klassifikation von Sentinel-2 MSI (S2), Landsat 8 OLI (L8) und Sentinel-1 Bildern vor (b) und nach der Verwendung eines Lufttemperaturfilter (c).....	81

Abbildung 22:	Darstellungsvorschlag für den Indikator Eisbedeckung von Seen für vier Fallstudienseen aus den Alpen und dem Alpenvorland. Werte nahe 0 deuten eine geringe Eisbedeckung an, Werte nahe 1 deuten eine Winterperiode mit mehr Eisbedeckung an.....	82
Abbildung 23:	Histogramme des Sentinel-2 MSI NDVI basierend auf den Trainingsdaten von Dresden der Klassen Gründach und Nicht-Gründach.....	83
Abbildung 24:	2D-Darstellung der LoD2-Daten von Dresden aller Dachflächen (a), nur der Flach- und Pultdächer (b) und Flach- und Pultdächer > 400 m <sup>2</sup> (c).....	84
Abbildung 25:	Schrittweise Erstellung des Indikators Gründächer in Großstädten an einem Raumausschnitt in Dresden mit einem Sentinel-2 MSI Datensatz. Berechnung des NDVI (a), Schwellwertklassifikationsergebnis des NDVI (b), Berechnung der Gründachanteile in den Dachumrissen (c) und Aufsummieren der Fläche auf die Stadt (d).....	85
Abbildung 26:	Indikatorabbildung Gründächer in Großstädten für das Jahr 2020.....	86
Abbildung 27:	Schematische Darstellung für die Bestimmung der Qualitätswerte.....	87
Abbildung 28:	Qualitätskriterium gesamt (a) am Beispiel der mittleren Wassertemperatur über die Sommermonate (b) am Walchensee. Die horizontalen Linien stellen die Schwellwerte für die Qualitätseinstufung dar.....	89
Abbildung 29:	Schematischer Workflow der Operationalisierung.....	92
Abbildung 30:	Jupyter Notebook Ausschnitt für die Datenanalyse des Indikators Wassertemperatur in Seen.....	94
Abbildung 31:	DASIF Dashboard.....	96
Abbildung 32:	Streudiagramme zur Validierung der Chlorophyll-a Konzentration – Sentinel-2 MSI.....	121
Abbildung 33:	Streudiagramme zur Validierung der Chlorophyll-a Konzentration – Sentinel-3 OLCI.....	122
Abbildung 34:	Streudiagramme zur Validierung der Chlorophyll-a Konzentration – ENVISAT MERIS.....	123
Abbildung 35:	Normalisierte Gütemaße der Algorithmus-Sets über alle Seen für Sentinel-2 MSI.....	125
Abbildung 36:	Normalisierte Gütemaße der Algorithmus-Sets über alle Seen für Sentinel-3 OLCI.....	125
Abbildung 37:	Normalisierte Gütemaße der Algorithmus-Sets über alle Seen für ENVISAT MERIS.....	126
Abbildung 38:	Streudiagramme zur Validierung der Landsat LSWT Werte aufgetrennt nach Sensoren (farbige Punkte) und Algorithmen (Zeile) und meteorologische Datenquellen (Spalte).....	130
Abbildung 39:	Normalisierte Gütemaße der Algorithmus-Sets über alle Seen und Landsat-Sensoren.....	132
Abbildung 40:	Streudiagramm zwischen in-situ Messwerten und CCI Lakes LSWT Werten am Bodensee.....	133
Abbildung 41:	Histogramme der Vegetationsindizes basierend auf den Trainingsdaten und PlanetScope-Daten von Dresden der Klassen Gründach und Nicht-Gründach....	134

Abbildung 42:	Ausschnitt aus Dresden, der das Klassifikationsergebnis auf Dachebene darstellt basierend auf CIR-Orthofotos (a), PlanetScope (b), Sentinel-2 MSI (c) und vergleichend eine CIR-Falschfarbendarstellung des Orthofotos (d) .....	135
---------------	--	-----

## Tabellenverzeichnis

Tabelle 1:	Kriterien differenziert nach Kategorien und Fragen, mit der verfügbare Algorithmen bewertet wurden.....	48
Tabelle 2:	Fragenkatalog, nach dem Seen für die Fallstudien ausgewählt worden sind .....	56
Tabelle 3:	Übersicht über die angefragten in-situ Daten (Quelle: eigene Zusammenstellung) .....	58
Tabelle 4:	Ausgewählte Gütemaße, um die Algorithmen quantitativ zu bewerten. Absolute Gütemaße werden tabellarisch zusammengefasst .....	60
Tabelle 5:	Übersicht und Referenzen zu den operationell umgesetzten Algorithmen und Daten für Cyanobakterien .....	61
Tabelle 6:	Gütemaße der Cyanobakterienindikation für Sensoren ENVISAT MERIS und Sentinel-3 OLCI .....	63
Tabelle 7:	Übersicht und Referenzen zu den in den Fallstudien zur Frühjahrsalgenblüte untersuchten Algorithmen und Daten .....	67
Tabelle 8:	Tabellarische Darstellung der berechneten Gütemaße über alle Messpunkte pro Sensor und Algorithmus – Chlorophyll-a Konzentration .....	68
Tabelle 9:	Tabellarische Darstellung der berechneten Gütemaße über alle Messpunkte pro Sensor– Wassertemperatur (LSWT) .....	73
Tabelle 10:	Zusammenfassung der verwendeten Features in den Random Forest Klassifikationsmodellen .....	78
Tabelle 11:	Gütemaße der ausgewählten Klassifikationsmodelle für Eis, Wasser und Wolken (nur Sentinel-2 MSI und Landsat 8 OLI .....	80
Tabelle 12:	Gütemaße des Schwellwertverfahrens mit dem NDVI basierend auf dem Validierungsdatensatz von Dresden mit Sentinel-2 MSI .....	84
Tabelle 13:	Übersicht der untersuchten Prozessierungsplattformen (Stand: 11/2023).....	91
Tabelle 14:	Übersicht der Jupyter Notebooks und deren Funktionen.....	94
Tabelle 15:	Liste der untersuchten Seen und Angabe über die an dem See gebildeten Indikatoren. Phase: 1 = Fallstudie + Operationalisierung, 2 = nur Operationalisierung. Ind. 1 = Cyanobakterienbelastung in Badegewässern, Ind. 2 = Frühjahrsalgenblüte in Seen, Ind. 3 = Wassertemperatur in Seen, Ind. 4 = Eisbedeckung in Seen .....	115
Tabelle 16:	Übersicht und Referenzen zu den in den Fallstudien zur Frühjahrsalgenblüte untersuchten Algorithmen und Daten .....	118
Tabelle 17:	Tabellarische Darstellung der berechneten Gütemaße über alle Messpunkte pro Sensor und Algorithmus – Chlorophyll-a Konzentration .....	124
Tabelle 18:	Übersicht und Referenzen zu den in den Fallstudien zur Wassertemperatur untersuchten Algorithmen und Daten .....	127

Tabelle 19:	Tabellarische Darstellung der berechneten Gütemaße über alle Messpunkte pro Sensor und Algorithmus-Set.....	131
Tabelle 20:	Gütemaße des CCI Lakes LSWT Produkt am Bodensee.....	133
Tabelle 21:	Schwellwerte (25 % Perzentil) für die Klassifikation von Gründächern .....	135
Tabelle 22:	Gütemaße des Schwellwertverfahrens mit drei Vegetationsindizes basierend auf dem Testdatensatz von Dresden mit PlanetScope (PS) und Sentinel-2 (S2).....	135

## Abkürzungsverzeichnis

<b>AE</b>	Absolute Error
<b>AP</b>	Arbeitspaket
<b>BKG</b>	Bundesamt für Kartographie und Geodäsie
<b>CAU Kiel</b>	Christian-Albrechts-Universität zu Kiel
<b>C3S</b>	Copernicus Climate Change Service
<b>CCI</b>	Climate Change Initiative
<b>CIR</b>	Colour-Infrared
<b>CLMS</b>	Copernicus Land Monitoring Service
<b>CODE-DE</b>	Copernicus Data and Exploitation Platform – Deutschland
<b>DAS</b>	Deutsche Anpassungsstrategie Klimawandel
<b>DASIF</b>	Operationalisierung von DAS-Indikatoren mit Fernerkundung
<b>DOM</b>	Digitales Oberflächenmodell
<b>DWD</b>	Deutscher Wetterdienst
<b>ENVISAT</b>	Environmental Satellite
<b>ESA</b>	European Space Agency
<b>ETM+</b>	Enhanced Thematic Mapper Plus
<b>GLCM</b>	Grey-Level Co-Occurrence Matrix
<b>GRD IW</b>	Ground range detected, interferometric wide-mode
<b>IGB</b>	Leibniz-Institut für Gewässerökologie und Binnenfischerei
<b>IMWA</b>	Improved Mono-Window Algorithm
<b>LAWA</b>	Bund/Länder-Arbeitsgemeinschaft Wasser
<b>LoD2</b>	Level of Detail 2
<b>LSWT</b>	Lake surface water temperature
<b>LWLR</b>	Lake Water-Leaving Reflectance
<b>MAPD</b>	Median absolute percentage difference
<b>MERIS</b>	Medium Resolution Imaging Spectrometer
<b>MODIS</b>	Moderate Resolution Imaging Spectrometer
<b>MPH</b>	Maximum Peak Height Algorithmus
<b>MSI</b>	Multispectral Instrument
<b>NDVI</b>	Normalised Difference Vegetation Index
<b>NIR-SWV</b>	Nahinfrarot Schwellwertverfahren

<b>AE</b>	Absolute Error
<b>OLCI</b>	Ocean and Land Colour Instrument
<b>OLI</b>	Operational Land Imager
<b>R2</b>	Bestimmtheitsmaß
<b>RMSE</b>	Root-mean-squared error
<b>SAR</b>	Synthetic Aperture Radar
<b>SAVI</b>	Soil-adjusted vegetation index
<b>SC</b>	Single channel algorithm
<b>SNAP</b>	Sentinel application platform
<b>SVM</b>	Support vector machine
<b>SW</b>	Split-window algorithm
<b>SWV</b>	Schwellwertverfahren
<b>TM</b>	Thematic Mapper
<b>TOA</b>	Top-of-Atmosphere
<b>TSAVI</b>	Transformed soil-adjusted vegetation index
<b>UBA</b>	Umweltbundesamt
<b>USGS</b>	United States Geological Survey
<b>VIIRS</b>	Visible Infrared Imaging Radiometer Suite

## Zusammenfassung

Die Deutsche Anpassungsstrategie an den Klimawandel (DAS) hat zum Ziel, „die Verwundbarkeit der Ökosysteme und der Gesellschaft gegenüber den Folgen des Klimawandels zu mindern und gleichzeitig die Widerstandskraft und Anpassungsfähigkeit dieser Systeme zu erhöhen“ (Umweltbundesamt (UBA) 2023). Die DAS beinhaltet ein Monitoring von über 100 Klimaindikatoren. Das UBA koordiniert die Erstellung der zugehörigen Monitoringberichte. Die Indikatoren umfassen Impact-Indikatoren (Auswirkungen des Klimawandels) und Response-Indikatoren (Anpassungen an den Klimawandel) in 16 Handlungsfeldern wie menschliche Gesundheit, Küsten- und Meeresschutz, Wasserhaushalt und Wasserwirtschaft, Landwirtschaft, Bauwesen, Industrie und Gewerbe etc. Die Indikatoren sollen deutschlandweit anzeigen, wie sich der Klimawandel auf das Land auswirkt und wie sich die Gesellschaft daran anpasst. Wachsendes Wissen, neue Erkenntnisse und verbesserte oder sich ändernde Datengrundlagen verlangen, dass die DAS und ihr Indikatorensystem ständig weiterentwickelt werden.

Für deutschlandweite Aussagen benötigen die Indikatoren eine deutschlandweite Datengrundlage mit möglichst langen Zeitreihen. Diese sind für sehr viele Indikatoren vorhanden wie bspw. den Indikator „Hagelschäden in der Landwirtschaft“. Andere Indikatoren werden aufgrund mangelnder deutschlandweiter Datengrundlage über Fallstudien abgebildet. Im DAS-Monitoringbericht 2019 betraf dies beispielsweise die Impact-Indikatoren „Blaualgenebelastung von Badegewässern“, „Wassertemperatur stehender Gewässer“, „Eintreten der Frühjahrsalgenblüte in stehenden Gewässern“ und den Response-Indikator „Gründächer auf Bundesgebäuden“. Ein potentieller Indikator, der häufig in der Diskussion steht, aber noch nicht im DAS-Bericht 2019 enthalten ist, ist die „Eisbedeckung von Seen“.

Für die genannten fünf Indikatoren besteht allerdings die Möglichkeit, eine deutschlandweite Datengrundlage basierend auf Satellitendaten zu erstellen. Verfügbare Satellitensensoren und Analyseverfahren haben sich in den letzten Jahren insbesondere in der Gewässerfernerkundung stark weiterentwickelt.

In diesem Kontext verfolgte das ReFoPlan-Forschungsprojekt „Operationalisierung von DAS-Indikatoren mit Fernerkundungsdaten“ (DASIF) das übergeordnete Ziel, das System der DAS-Indikatoren mithilfe von Daten bzw. Datenprodukten aus der Satellitenfernerkundung weiterzuentwickeln. Dabei verfolgte das Projekt folgende Teilziele:

1. Analyse der Lücken und Bedarfe für die Weiterentwicklung der fünf genannten DASIF-Indikatoren
2. Analyse der Möglichkeiten der Fernerkundung, um die Lücken zu schließen und Bedarfe zu erfüllen
3. Entwicklung, Validierung und Auswahl von geeigneten Fernerkundungsverfahren, um eine deutschlandweite Datengrundlage für die DASIF-Indikatoren zu generieren
4. Entwicklung von bundesweiten Indikatorvorschlägen für die DASIF-Indikatoren für den DAS-Monitoringbericht 2023
5. Operationalisierung der entwickelten Verfahren zur Indikatorableitung auf einer geeigneten Prozessierungsplattform
6. Erstellung von Empfehlungen zur Weiterentwicklung der DAS-Indikatoren und Zusammenstellung von Entwicklungen und Perspektiven in der Fernerkundung

Um diese Ziele zu erreichen, wurde zunächst eine eingehende Analyse der nationalen und internationalen Literatur durchgeführt, um geeignete Satellitensensoren und verfügbare Algorithmen zu identifizieren. Während des gesamten Projektverlaufs erfolgte ein enger Austausch mit Fachpersonen aus dem UBA, den Landesbehörden, Stadtverwaltungen und

Forschungseinrichtungen. Um Vorschläge für die Indikatorenentwicklung zu erstellen, wurden ausgewählte Algorithmen und Satellitendaten an ca. 25 Fallstudienseen und in der Stadt Dresden getestet und validiert. Die Vorschläge wurden anschließend in Online-Workshops diskutiert und darauf aufbauend weiterentwickelt. In der letzten Phase wurden die ausgewählten Verfahren zur Indikatorenentwicklung auf der Copernicus-Daten und Cloud-Prozessierung für deutsche Behörden (CODE-DE) implementiert. Drei der fünf DASIF-Indikatoren (Cyanobakterienbelastung von Badegewässern, Frühjahrsalgenblüte in Seen und Gründächer in Großstädten) wurden im Ergebnis als fernerkundungsbasierte Klimawandel-Indikatoren in den DAS-Bericht 2023 aufgenommen. Neben einer Verbesserung der Datengrundlagen für das DAS-Monitoring, hat das DASIF-Projekt somit wesentlich zur Umsetzung der Copernicus-Strategie der Bundesregierung und deren Handlungsfeld „Neue Dienste und Technologien entwickeln“ beigetragen.

### **Ergebnisse der Lücken- und Bedarfsanalyse**

Um die Lücken und Bedarfe in der Indikatorenentwicklung zu erfassen, wurden die DAS-Monitoringberichte (Umweltbundesamt (UBA) 2015, 2019) und Indikatoren-Factsheets ausgewertet sowie Fachgespräche durchgeführt.

#### ► Cyanobakterienbelastung in Badegewässern

Die geringe Anzahl an Fallstudien (n=1) minderte die Aussagekraft des Indikators. Zudem erfassen stichpunktartige Messungen nicht die räumlich heterogene Verteilung der Cyanobakterien, und es bestand Unklarheit über die Entwicklung der Toxine in Bezug auf den Klimawandel. Die Fallstudien sollten erweitert werden, um eine differenzierte Abbildung der Seetypen für verschiedene Ökoregionen vorzunehmen. Zudem sollte die räumliche Verteilung von Cyanobakterienblüten erfasst werden.

#### ► Frühjahrsalgenblüte in Seen

Der Indikator zeigte ähnliche Schwächen mit einer geringen Anzahl von Fallstudien und zeitlicher Ungenauigkeit bei zweiwöchentlichen Messungen. Die Anzahl der betrachteten Seen sollte erweitert werden und die zeitliche Auflösung der Messungen erhöht werden, um den genauen Zeitpunkt der Frühjahrsalgenblüte zu detektieren.

#### ► Wassertemperatur in stehenden Gewässern

Der Indikator wies ähnliche Schwächen auf: geringe Anzahl an Fallstudien, unterschiedliche Messfrequenzen an Seen und Unsicherheiten durch Interpolation von Fehlwerten. Entwicklungsbedarf bestand in der Ausweitung der Fallstudien und Diskussion Möglichkeiten zur deutschlandweiten Aggregation.

#### ► Eisbedeckung von Seen

Die Eisbedeckung von Seen wird als wichtiger Impact-Indikator betrachtet. Entwicklungsmöglichkeiten bestanden darin, diesen Indikator in Abstimmung mit Fachpersonen aus verschiedenen Organisationen vollständig zu entwickeln.

#### ► Gründächer von Bundesgebäuden

Gründächer werden als Anpassungsstrategie an den Klimawandel betrachtet. Schwächen des Indikators lagen zu Projektbeginn in der fehlenden Information über die Lage und Art der erfassten Gründächer. Ein weiterer wichtiger Punkt war, dass Bundesgebäude nicht zwangsläufig mit gesellschaftlicher Anpassung korrelieren. Entwicklungsbedarf bestand in

der Erfassung von Nicht-Bundesgebäuden, Informationen über die Art der Begrünung und regelmäßigen Aktualisierungen der Inventarisierung.

### Vorauswahl von Algorithmen und Satellitensensoren

Kapitel 2 zeigt, dass es viele Algorithmen gibt, um biophysikalische Daten für die fünf Klimawandelindikatoren zu erstellen. Im Projekt wurde eine Bewertungsmatrix entwickelt, um die Eignung von Datenprodukten oder Algorithmen für das DASIF-Projekt anhand verschiedener Kriterien zu bewerten. Die Kriterien beinhalteten Aspekte wie Automatisierbarkeit, Verfügbarkeit, Implementierungsaufwand, Gültigkeitsbereich, Transparenz und Anwendbarkeit auf Sensoren. Die Bewertungen wurden mithilfe geschlossener Fragen in positiven oder negativen Werten festgelegt. Algorithmen mit den höchsten Gesamtbewertungen wurden ausgewählt und detailliert in Fallstudien analysiert und mit in-situ (vor Ort erhobenen) Daten validiert.

### Entwicklung von Fallstudien

#### ► Auswahl der Untersuchungsgebiete

Es wurden zunächst potenzielle Seen anhand von Größe und Form aus, um sie mit Satellitendaten zu analysieren. Diese Liste wurde mit dem Expertenkreis Seen der Bund/Länder-Arbeitsgemeinschaft Wasser (LAWA) anhand von Fragen zur Klimawandelrelevanz, Verfügbarkeit von Messdaten diskutiert sowie der Tatsache, ob Seen bereits in einem indikatorenbasierten Monitoring vertreten sind. So wurden 27 Seen ausgewählt, die verteilt über die drei Hauptnaturräume in Deutschland lagen. Um die ausgewählten Algorithmen und Satellitendaten zu validieren, wurden zu den Seen in-situ Messdaten von den Landesbehörden zusammengetragen und in einer Datenbank harmonisiert. Die Analysen wurden im Verlauf des Projekts (Operationalisierung) auf 54 Seen ausgeweitet. Die Fallstudie für den Indikator Gründächer konzentrierte sich auf die Stadt Dresden, da hier Vergleichsdaten zur Verfügung standen. Für den bundesweiten Indikator wurden 15 Großstädte > 500 000 Einwohner\*innen ausgewählt.

Die Algorithmen und Sensoren wurden quantitativ anhand der angefragten in-situ Daten validiert. Gütemaße wie Overall Accuracy,  $R^2$  und RMSE wurden verwendet, abhängig davon, ob es sich um kategorische oder kontinuierliche Größen handelte. Die Ergebnisse basieren auf Daten von 54 Seen. Die Fallstudienresultate für 27 Seen sind im Anhang beschrieben.

#### ► Ausgewählte Algorithmen und Satellitendaten

In Fallstudien wurden an 27 Seen zunächst eine Vorauswahl an Algorithmen und Sensoren quantitativ mit in-situ Daten überprüft. Für die Cyanobakterienbelastung von Badegewässern wurde der Maximum Peak Height (MPH) Algorithmus ausgewählt. Grobskalige Ocean-Colour Sensoren wie ENVISAT MERIS und Sentinel-3 OLCI stellen die Satellitendatengrundlage dar. Für die Frühjahrsalgenblüte in Seen wurden gekoppelte Algorithmen wie MPH und C2RCC (Atmosphärenkorrektur und Chlorophyll-a Bestimmung) sowie unabhängige Band-Algorithmen für die Chlorophyll-a-Bestimmung in Kombination mit den Atmosphärenkorrekturen ACOLITE und Sen2Cor. Neben ENVISAT MERIS und Sentinel-3 OLCI kam hier auch Sentinel-2 MSI zum Einsatz. Bei der Wassertemperatur in Seen wurden das ESA CCI Lakes Produkt, zwei Single-Channel-Algorithmen auf Daten der Landsatreihe sowie das Landsat Collection 2 Level-2 surface temperature Produkt untersucht. Für die Eisbedeckung von Seen wurden maschinelle Lernverfahren zur Klassifikation von Landsat 8 OLI, Sentinel-2 MSI und Radardaten (Sentinel-1) entwickelt. Für den Indikator Gründächer in Großstädten wurden verschiedene Sensoren wie CIR-

Orthofotos, RapidEye, PlanetScope und Sentinel-2 MSI betrachtet. Die Fallstudie konzentrierte sich auf ein Schwellwertverfahren mit Vegetationsindizes und 3D-Stadtmodelldaten (LoD2-Daten).

### Entwicklung von Verfahren zur bundesweiten Indikatorbildung

#### ► Cyanobakterienbelastung von Badegewässern

Die biophysikalische Datengrundlage für den Indikator Cyanobakterienbelastung von Badegewässern stützt sich auf den MPH-Algorithmus, der Sentinel-3 OLCI und ENVISAT MERIS Sensoren verwendet. Der MPH kombiniert die Korrektur der Rayleigh-Streuung und die Berechnung des Wasserinhaltsstoffes Chlorophyll-a zur Detektion von Cyanobakterien. Die Validierung zeigt eine hohe Genauigkeit für Sentinel-3 OLCI und ENVISAT MERIS. Um von Pixelwerten zum Indikator zu gelangen, erfolgt eine räumliche Aggregation über den See und eine zeitliche Aggregation über die Badesaison. Bei der nationalen Aggregation werden Seen nach Belastungsstufen eingeteilt und die Anzahl der Seen in der jeweiligen Stufe herangezogen, wobei eine geringe Belastung vorliegt, wenn keine Cyanobakterien detektiert wurden, und eine hohe Belastung bei einer Cyanobakterienindikation von mehr als 20 % der Satellitenüberflüge. Der Indikator ermöglicht eine Bewertung der Cyanobakterienpräsenz in Badegewässern auf nationaler Ebene und bietet wichtige Einblicke in den Trend der Cyanobakterienvorkommen in deutschen Seen. Dieser Indikator wurde in den DAS-Monitoringbericht 2023 aufgenommen.

#### ► Frühjahrsalgenblüte in Seen

Die biophysikalische Grundlage des Indikators für die Frühjahrsalgenblüte beruht auf der Berechnung der Chlorophyll-a Konzentration als Proxy für Zeitpunkt der Blüte. Dafür wurden drei Satellitensensoren verwendet: Sentinel-2 MSI, Sentinel-3 OLCI und ENVISAT MERIS, um zeitliche und räumliche Informationen der Blüte zu erfassen. Es wurden gekoppelte Wasserqualitätsalgorithmen, wie C2RCC und MPH für die Prozessierung verwendet. Um von Pixelwerten zum Indikator zu gelangen, erfolgte eine räumliche Aggregationen über den gesamten See und es wurden tägliche Produkte zwischen März und Mai berücksichtigt. Der Zeitpunkt der Frühjahrsalgenblüte wird anhand des Perzentils 90 der räumlich aggregierten Chlorophyll-Konzentration bestimmt, um die räumliche Abdeckung der Satellitendaten zu nutzen. Der Zeitpunkt der Frühjahrsalgenblüte wird mit der Überschreitung eines Schwellwertes des jeweiligen Jahres erfasst. Die nationale Aggregation erfolgt nach Hauptnaturräumen. Die Ergebnisse zeigen einen Trend zu früheren Algenblüten in allen Naturräumen. Die Validierung für die Bestimmung des Eintrittes der Frühjahrsalgenblüte gestaltet sich aufgrund fehlender kontinuierlicher Feldmessungen schwierig, dennoch bietet der Indikator basierend auf Fernerkundungsdaten wichtige Einblicke in die zeitliche Entwicklung der Frühjahrsalgenblüte auf nationaler Ebene. Dieser Indikator wurde in den DAS-Monitoringbericht 2023 aufgenommen.

#### ► Wassertemperatur in stehenden Gewässern

Die Wassertemperatur wird aus dem operationell verfügbaren Collection 2 Level-2 surface temperature Produkt vom United States Geological Survey (USGS) abgeleitet. Das Produkt ist über alle Sensoren der Landsatreihe bestmöglich harmonisiert und seit den 1980er Jahren verfügbar. Die Validierung der Landsat Lake surface water temperature (LSWT) zeigte stark lineare Zusammenhänge mit in-situ gemessenen Temperaturen ( $R^2 > 0,9$ ). Der mittlere Fehler (Median) lag allerdings über 1 °C bei allen drei verwendeten Landsatsensoren. Um von den Pixelwerten zum Indikator zu gelangen, erfolgen zeitliche und räumliche

Aggregationen. Die erste räumliche Aggregation innerhalb eines Sees basiert auf einem 120 m nach innen gebufferten Polygonshapefile des Seeumrisses, in dem der Median einer Aufnahme berechnet wird. Die zeitliche Aggregation umfasst eine Mittelung der Seemediane auf Monatsbasis. Für den Indikator werden die Monatsmittel der Sommermonate (Juni, Juli, August) gemittelt, da hier die Verfügbarkeit der Satellitendaten am höchsten ist. Die räumliche Aggregation auf Bundesebene kann anhand verschiedener Eigenschaften erfolgen, wie Naturräume, Seentyp, Trophiestufe, Bundesland, mittlere Tiefe, maximale Tiefe, Seeoberfläche, Volumen, mittlere Höhenlage oder Mischtyp.

► Eisbedeckung von Seen

Der Indikator "Eisbedeckung von Seen" basiert auf kategorisierten Werten, die angeben, ob ein Pixel als Eis oder Wasser klassifiziert wurde oder ungültig ist. Der Untersuchungszeitraum erstreckt sich vom 01.11.2014 bis 31.3.2020 und nutzt Daten von Landsat 8 OLI, Sentinel-2 A und B MSI sowie Sentinel-1 A und B (C-Band). Webcam-Aufnahmen dienen als unabhängige Datenquelle, um einen Random Forest Klassifikationsalgorithmus zu entwickeln und validieren. Die Gütemaße für die Klassifikationsmodelle zeigen sehr hohe Genauigkeiten, wobei dies u.a. durch den Trainings- und Validierungsdatensatz zu erklären, der sehr eindeutige Fälle enthält. Fehlklassifikationen existieren dennoch und werden durch einen Lufttemperaturfilter reduziert. Um zum Indikator zu gelangen, wurde definiert, dass ein See als eisbedeckt gilt, wenn mindestens 80 % der Fläche vereist sind. Die Anzahl der Eistage wird in Bezug zur Anzahl gültiger Satellitenüberflüge gesetzt. Die Werteskala reicht von 0 bis 1, wobei niedrigere Werte weniger Eistage an einem See anzeigen. Der Indikator beruht aufgrund der schlechten in-situ Datengrundlage auf sieben Fallstudienseen, sodass keine bundesweite Aggregation stattgefunden hat. Da nur ein kurzer Zeitraum betrachtet wurde, sind keine klimawandelbedingten Schlüsse möglich.

► Gründächer in Großstädten

Um Gründächer bundesweit vergleichbar zu erfassen, wurden als Fernerkundungsdatengrundlage Sentinel-2 MSI Daten ausgewählt. Außerdem wurden 3D-Gebäudemodelldate (LoD2-Daten) verwendet, um Dachgeometrien zu definieren. Die Analyse beschränkte sich auf Dächer, die potentiell gründachgeeignet sind (Flach- und Pultdächer) und auf Dächer, die > 400 m<sup>2</sup> sind aufgrund der räumlichen Auflösung der Sentinel-2 MSI Daten (10 m x 10 m). Gründächer wurden mithilfe eines Schwellwertklassifikationsverfahrens basierend auf einem Vegetationsindex (Normalised Difference Vegetation Index) erfasst. Innerhalb der Dachgeometrien wurden die Gründachflächen berechnet und pro Stadt aufsummiert. Die Datengrundlage umfasst die 15 größten deutschen Großstädte > 500 000 Einwohner\*innen (inkl. Duisburg). Für den bundesweiten Indikator wurden die Gründachflächen aller 15 Städte aufsummiert und ins Verhältnis zur Zahl der Einwohnerinnen und Einwohner gesetzt. Als zusätzliche Information wurde die gesamte Gründachfläche ins Verhältnis zur gesamten analysierten Dachfläche gesetzt. Dieser Indikator wurde ebenfalls in den DAS-Monitoringbericht 2023 aufgenommen. Betrachtungszeitraum ist hier das Jahr 2020.

► Entwicklung von Qualitätskriterien

Basierend auf Anregungen aus den Diskussionen der Workshops wurden Qualitätskriterien für die fernerkundungsbasierte DAS-Indikatoren in Seen entwickelt. Diese Kriterien berücksichtigen verschiedene Einflüsse auf Fernerkundungsdaten wie Wolkenbedeckung, Anzahl gültiger Satellitenüberflüge und auch die räumliche Komponente zur Verfügbarkeit

von Satellitendaten. Vier Hauptkriterien wurden entwickelt, die normalisiert, aufsummiert und durch vier geteilt wurden, wodurch ein Gesamtkriterium zwischen 0-1 entsteht. Dieses wird dann kategorisch bewertet, um die Qualität der Datengrundlage eines Jahres als niedrig, neutral, oder hoch einzuschätzen.

### Operationalisierung der bundesweiten Indikatorberechnung

#### ► Auswahl der Prozessierungsplattform

Verschiedene Plattformen für die Generierung der DAS-Indikatoren aus Fernerkundungsdaten wurden analysiert. Dabei wurden Anforderungen des UBA und der ausgewählten Prozessierungsabläufe berücksichtigt. Wichtige Kriterien waren eine komplexe und parallelisierbare Prozessierung, gute Schnittstellen und die Verfügbarkeit der benötigten Satellitendaten. Nach Prüfung mehrerer Plattformen wurde CODE-DE (Copernicus Data and Exploitation Platform – Deutschland) aufgrund seiner nationalen Verfügbarkeit und kostenfreien Nutzung für das UBA sowie Calvalus (Brockmann Consult GmbH) wegen seiner Erweiterbarkeit und Erfüllung vieler Anforderungen ausgewählt.

#### ► Umsetzung der Operationalisierung

- Die Satellitendaten werden durch das Prozessierungssystem Calvalus selektiert und verarbeitet. Die Prozesse laufen parallel, wodurch der zeitliche Aufwand minimiert wird. Die resultierenden Data Cubes enthalten die geophysikalischen Größen (bspw. Wassertemperatur, Chlorophyll-a Konzentration, Cyanobakterien-Marker) und werden durch drei interaktive Jupyter Notebooks (Python 3.8) zugänglich gemacht. Mit einem ersten Notebook, "Datenextraktion", werden aus den Data Cubes Tabellen im CSV-Format erzeugt. Diese Tabellen enthalten für jeden Indikator die biophysikalische Größe, die über jeden See und jede Satellitenaufnahme gemittelt werden. Das zweite Notebook, "Analyse", ermöglicht die Berechnung des bundesweiten Indikators, wobei verschiedene Seen oder Städte ausgewählt und nach verschiedenen Merkmalen aggregiert werden können. Das dritte Notebook, "Qualitätsparameter", berechnet die Qualitätskriterien see- und indikatorweise und gibt sie als Tabelle aus. Die Jupyter Notebooks sind Werkzeuge, um Zeitreihen der prozessierten Satellitendaten zu extrahieren und zu visualisieren, Trends zu identifizieren und die Qualität der Eingangsdaten zu überprüfen. Die tatsächliche Trendberechnung erfolgt durch das UBA und Projektnehmer. Die Datacubes und die Jupyter Notebooks wurden in CODE-DE umgesetzt und dem UBA zur Verfügung gestellt. Entwicklung eines interaktiven Dashboards

Ein benutzungsfreundliches Dashboard wurde erstellt, um die Ergebnisse einem breiten Publikum zugänglich zu machen. Das Dashboard bietet eine interaktive räumliche Darstellung und zeitliche Analyse der fünf DASIF-Indikatoren. Mit unterschiedlichen Aggregierungsmethoden ermöglicht es vielfältige Datendarstellungen. Es ist browserbasiert und ermöglicht eine flexible und einfache Nutzung auf verschiedenen Endgeräten. Das Dashboard ist unter folgendem Link erreichbar:

<https://dasif-dashboard.brockmann-consult.de/>

### Empfehlungen, Weiterentwicklungen und Perspektiven

- Forschungsbedarfe für die aktuellen DASIF-Indikatoren aus Sicht der Fernerkundung

*Cyanobakterienbelastung von Badegewässern:* In den Jahren 2012-2016 besteht eine Datenlücke aufgrund fehlender geeigneter Sensoren. Empfohlene Maßnahmen für die

Fortschreibung umfassen die Prüfung der Kombination verschiedener Satelliten und die Integration von in-situ Messungen.

*Frühjahrsalgenblüte in Seen:* Eine Datenlücke von 2012-2016 besteht, da verfügbare Sensoren eingeschränkt nutzbar sind. Es wird empfohlen, verschiedene Satelliten zu kombinieren und in-situ-Messungen zu integrieren, um zeitliche Lücken zu schließen.

*Wassertemperatur in Seen:* Aktuell verfügbare thermale Satellitensensoren weisen räumliche oder zeitliche Einschränkungen auf. Die Fortschreibung sollte die Implementierung von Landsat 9 TIRS-2 Daten, deren Validierung, den Vergleich mit Landsat 8 TIRS und die Analyse von Interpolationsmethoden einschließen.

*Eisbedeckung von Seen:* Die Empfehlungen für die Fortschreibung umfassen die Erweiterung der in-situ Datengrundlage, die Implementierung von Landsat 9 OLI sowie die Integration von Thermaldaten der Landsatsensoren.

*Gründächer in Großstädten:* Empfohlene Schritte für die Fortführung sind die Berechnung eines zweiten Zeitschritts, ein Vergleich mit einem räumlich höher aufgelösten Deutschlandmosaik, beispielsweise anhand der PlanetScope Datenbasis und die eigene Erhebung von in-situ Daten, um verschiedene Begrünungsarten zu unterscheiden (intensive und extensive Begrünung).

► Synergien auf internationaler Ebene

Das ESA CCI Lakes Projekt (<https://climate.esa.int/en/projects/lakes/about/>) entwickelt globale Seenprodukte, darunter Klimavariablen wie Wasserstand, Wasserfläche, Wasseroberflächentemperatur, Eisbedeckung, Eisdicke und Reflektanzen. In Projektphase zwei wird ein Use Case namens "AGGREGATED CLIMATE INDICATORS FOR THE GLOBAL LAKES" behandelt, der auf den DASIF-Ansätzen basiert. Hierbei werden Indikatoren für Frühjahrsalgenblüte, Eisbedeckung und Temperatur entwickelt und an den Lakes CCI Datensatz angepasst. Ein Austausch zwischen dem CCI Lakes Team und dem DAS Monitoring Team wird empfohlen, um Synergien zu nutzen und Ergebnisse beider Projekte für die Anwendung in Deutschland zu berücksichtigen.

► Perspektiven der Fernerkundung für weitere DAS-Indikatoren

Die Fortschritte in der Satellitenfernerkundung, zusammen mit dem Austausch der DAS-Expertinnen und Experten zeigten, dass die Fernerkundung nicht nur die bestehenden DAS-Indikatoren unterstützen kann, sondern auch Potenzial für neue Klimawandelindikatoren in verschiedenen Umweltbereichen bietet. Die Integration von Satellitendaten ermöglicht eine Erweiterung der Indikatoren, die über Gewässer und Gründächer hinausgehen und auch die Landbedeckung abdecken können. Mögliche Beispiele sind Indikatoren zur Küstenmorphologie, Algenblüten und Cyanobakterien in Fließgewässern, Badetemperaturen an der Küste, Vegetation im Gewässerumfeld, Dauergrünlandflächen, Landbedeckung im Deichvorland oder versiegelte Fläche (vgl. Kapitel 5.3).

► Entwicklungen in der Satellitenfernerkundung

Die Satellitenfernerkundung hat sich als entscheidendes Instrument in der Klimaforschung und Umweltüberwachung etabliert. Zukünftige Entwicklungen versprechen noch präzisere Datenerfassung. Hyperspektrale Sensoren wie EnMAP und Prisma und künftig CHIME ermöglichen die genaue Identifizierung von Vegetationstypen und klimarelevanten Veränderungen. Fortschritte in räumlich hochauflösenden Aufnahmen bieten detaillierte

Einblicke in lokale Klimaphänomene wie urbane Hitzeinseln und Gletscherschwund. Advanced Machine Learning-Algorithmen vereinfachen die automatisierte Ableitung von Datengrundlagen für Klimawandelindikatoren. Das Copernicus-Programm und der Copernicus Climate Change Service (C3S) verfolgen ambitionierte Ziele für eine umfassende Beobachtung der Erde und Klimaüberwachung. Die ESA CCI Initiative plant, ihre Klima-Analysen und -Modelle zu erweitern, kontinuierlich Daten zu erfassen, Erdbeobachtungsdaten zu integrieren und die internationale Zusammenarbeit zu stärken, um das Verständnis des Klimasystems zu fördern. Die Initiative betont auch die Wichtigkeit der Kommunikation und Sensibilisierung, um das Bewusstsein für den Klimawandel zu schärfen.

Im Rahmen des DASIF-Projekts wurden erstmals fernerkundungsbasierte DAS- Indikatoren in den Monitoringbericht integrieren. Damit konnte ein wesentlicher Beitrag zur Umsetzung der Copernicus-Strategie der Bundesregierung und deren Handlungsfeld „Neue Dienste und Technologien entwickeln“ geleistet werden. Im letzten DAS-Monitoringbericht 2019 (Umweltbundesamt (UBA) 2019) basierten die drei implementierten Indikatoren auf Fallstudien an ein bis fünf Seen mit Daten, die an einer Messstelle pro See gewonnen wurden. Gründächer wurden räumlich nicht verortet und bezogen sich ausschließlich auf Bundesgebäude.

DASIF konnte basierend auf Satellitendaten Datenreihen für ca. 50 Seen und 15 Großstädte auf bundesweit vergleichbarer Datengrundlage erstellen. Die untersuchten Seen und Städte sind räumlich über ganz Deutschland verteilt und decken alle Hauptnaturräume ab. Mit den Satellitendaten wird die gesamte Seeoberfläche betrachtet und nicht nur eine Messstelle und mit Einschränkungen zur Dachgröße die gesamte Stadtoberfläche. Die Verfahren sind validiert und damit auch übertragbar auf Seen ohne in-situ Datengrundlage. Damit ist eine weiterführende retrospektive Auswertung teilweise möglich, da Satellitendaten archiviert vorliegen. Die Weiterentwicklung und Fortführung von Satellitenprogrammen sichert die Datengrundlage langfristig und die zeitliche Datendichte nimmt aktuell und künftig zu. Dadurch bietet die Fernerkundung großes Potential, um weitere DAS-Indikatoren zu entwickeln.

## Summary

The German Strategy for Adaptation to Climate Change (DAS) aims to "reduce the vulnerability of ecosystems and society to the consequences of climate change and at the same time increase the resilience and adaptability of these systems" (Umweltbundesamt (UBA) 2023). The DAS includes the monitoring of more than 100 climate indicators. The UBA coordinates the preparation of the associated monitoring reports. The indicators include impact indicators (effects of climate change) and response indicators (adaptation to climate change) in 16 fields of action such as human health, coastal and marine protection, water balance and water management, agriculture, construction, industry and commerce, etc. The indicators are intended to show throughout Germany how climate change is affecting the country and how society is adapting to it. Growing knowledge, new findings and improved or changing data bases require the DAS and its indicator system to be constantly developed further.

For nationwide statements, the indicators require a nationwide data basis with the longest possible time series. These are available for many indicators, such as the indicator "hail damage in agriculture". Other indicators are mapped using case studies due to a lack of nationwide data. In the penultimate DAS Monitoring Report 2019, this applied, for instance, to the impact indicators "blue-green algae pollution of bathing waters", "water temperature of standing waters", "occurrence of spring algal blooms in standing waters" and the response indicator "green roofs on federal buildings". One potential indicator is "ice cover on lakes", which is frequently discussed but not yet included in the DAS report 2019.

Nevertheless, it is possible to create a Germany-wide database based on satellite data for the five indicators mentioned. Available satellite sensors and analysis methods have developed considerably in recent years, particularly in aquatic remote sensing.

In this context, the ReFoPlan research project "Operationalisation of DAS indicators with remote sensing data" (DASIF) aimed at further developing the system of DAS indicators using data and data products from satellite remote sensing. In detail, the project had the following specific objectives:

1. analysing gaps and needs to further develop the five DASIF indicators mentioned above
2. analysing how remote sensing can close the gaps and meet requirements
3. developing, validating and selecting suitable remote sensing methods to generate a Germany-wide data basis for the DASIF indicators
4. developing nationwide indicator proposals for the DASIF indicators for the DAS report 2023
5. operationalising the developed procedures for indicator derivation on a suitable processing platform
6. preparing recommendations to further develop DAS indicators, compiling developments and perspectives in remote sensing

In order to achieve these goals, the project team first intensively analysed national and international literature to assess available satellite sensor algorithms. The project team was in close dialogue with experts from the UBA, the state authorities, municipal administrations and research institutions throughout the course of the project. The project team tested and validated selected algorithms and satellite data at around 25 case study lakes and in the city of Dresden to draw up proposals for indicator development. These were discussed in online workshops and further developed on this basis. In the final phase, the selected procedures for developing indicators were implemented on the Copernicus data and cloud processing for German authorities (CODE-DE). Three of the five DASIF indicators (cyanobacteria contamination of bathing waters, spring algal blooms in lakes and green roofs in large cities) are published for the

first time as remote sensing-based climate change indicators in the DAS Report 2023. The DASIF project thus significantly contributed to the implementation of the German government's Copernicus strategy and its "Develop new services and technologies" field of action.

### Results of the gap and needs analysis

To identify gaps and needs in indicator development, the DAS monitoring reports and indicator factsheets were analysed and expert discussions were held.

#### ► Cyanobacteria contamination in bathing waters

The low number of case studies (n=1) reduced the significance of the indicator. Additionally, point measurements do not capture the spatially heterogeneous distribution of cyanobacteria. There was a lack of clarity about the development of toxins in relation to climate change. The case studies should be expanded to provide a differentiated representation of lake types for different ecoregions. In addition, the spatial distribution of cyanobacterial blooms should be recorded.

#### ► Spring algal bloom in lakes

The indicator showed similar weaknesses with a small number of case studies and temporal inaccuracy in fortnightly measurements. The number of lakes analysed should be expanded and the temporal resolution of the measurements increased to detect the exact time of the spring algal bloom.

#### ► Water temperature in standing waters

The indicator had similar weaknesses: small number of case studies, different measurement frequencies at lakes and uncertainties due to interpolating missing values. There was a need for expanding the number of lakes and discussion of possibilities for Germany-wide aggregation.

#### ► Ice cover of lakes

The ice cover of lakes is considered as an important impact indicator. The indicator needs to be fully developed in consultation with experts from various organisations.

#### ► Green roofs on federal buildings

Green roofs are a strategy to adapt to climate change. At the start of the project, the indicator's weaknesses lay in the lack of information on the location and type of green roofs recorded. Another important point was that federal buildings do not necessarily correlate with social adaptation. There was a need to develop the recording of non-federal buildings, information on the type of green roofs and regular updates of the inventory.

### Preselection of algorithms and satellite sensors

Chapter 2 shows that there are many algorithms available to generate biophysical data for the five climate change indicators. The project team developed an evaluation matrix to assess the suitability of data products or algorithms for the DASIF project based on various criteria. The criteria included aspects such as automatability, availability, implementation effort, scope of validity, transparency and applicability to sensors. The ratings were determined in positive or negative values using closed questions. Algorithms with the highest overall scores were selected and analysed in detail in case studies and validated with in-situ (on-site) data.

## Development of case studies

### ► Selection of the study areas

The project team first selected potential lakes based on size and shape to be analysed with satellite data. This list was discussed with the expert group on lakes of the German Federal/State Working Group on Water (LAWA) based on questions relating to climate change relevance, available measurement data and whether lakes are already represented in an indicator-based monitoring. Approximately 25 lakes were selected, distributed across the three main natural areas in Germany. To validate the selected algorithms and satellite data, in-situ measurement data for the lakes were collected by the state authorities and harmonised in a database. The analyses were extended to 50 lakes in the course of the project (operationalisation). The case study for the green roofs indicator focussed on the city of Dresden, as comparative data was available here. For the nationwide indicator, 15 large cities with more than 500,000 inhabitants were selected.

The algorithms and sensors were quantitatively validated using the requested in-situ data. Quality measures such as overall accuracy,  $R^2$  and RMSE were used, depending on whether categorical or continuous variables were involved. The results are based on data from around 50 lakes, and the case study results for around 25 lakes are described in the Appendix.

### ► Selected algorithms and satellite data

In case studies, the project team initially analysed a preselected algorithms and sensors quantitatively with in-situ data at around 25 lakes. The Maximum Peak Height (MPH) algorithm was selected for the cyanobacteria contamination of bathing waters. Coarse-scale ocean colour sensors such as ENVISAT MERIS and Sentinel-3 OLCI provide the satellite data basis. For the spring algal bloom in lakes, coupled algorithms such as MPH and C2RCC (atmospheric correction and chlorophyll-a determination) as well as independent band algorithms for chlorophyll-a determination in combination with the atmospheric corrections ACOLITE and Sen2Cor were tested. In addition to ENVISAT MERIS and Sentinel-3 OLCI, Sentinel-2 MSI was also used here. For the water temperature in lakes, the ESA CCI Lakes product, two single-channel algorithms on data from the Landsat series and the Landsat Collection 2 Level 2 surface temperature product were analysed. Machine learning methods for the classification of Landsat 8 OLI, Sentinel-2 MSI and radar data (Sentinel-1) were developed for the ice cover of lakes. For the indicator green roofs in large cities, different sensors such as CIR orthophotos, RapidEye, PlanetScope and Sentinel-2 MSI were considered. The case study focussed on a threshold method with vegetation indices and 3D city model data (LoD2 data).

## Development of procedures for nationwide indicator formation

### ► Cyanobacteria contamination of bathing water

The MPH algorithm is the basis to generate a biophysical data basis for the indicator cyanobacteria pollution of bathing waters and uses Sentinel-3 OLCI and ENVISAT MERIS sensors. The MPH combines the correction of Rayleigh scattering and the calculation of the water constituent chlorophyll-a for detecting cyanobacteria. The validation shows highly accurate results for Sentinel-3 OLCI and ENVISAT MERIS. To obtain the indicator, pixel values must be spatially and temporally aggregated across the lake and the bathing season. The national aggregation categorised lakes according to pollution levels and the number of

lakes in the respective level. Low pollution means no cyanobacteria are detected. High pollution is present if cyanobacteria are detected in more than 20 % of valid satellite overflights. The indicator enables assessing cyanobacteria presence in bathing waters at a national level and provides important insights into the trend of cyanobacteria occurrence in German lakes. This indicator was included in the DAS Monitoring Report 2023.

► Spring algal bloom in lakes

Chlorophyll-a concentration is the biophysical basis of the indicator spring algal bloom. Three satellite sensors were used, i.e. Sentinel-2 MSI, Sentinel-3 OLCI and ENVISAT MERIS to collect temporal and spatial information of the blooms. Coupled water quality algorithms such as C2RCC and MPH were used for processing. Valid imagery on a daily basis were considered between March and May for the indicator. The percentile 90 of the chlorophyll-a concentration was calculated for each valid image within the lake boundaries. The time of the spring algal bloom is recorded when chlorophyll-a concentrations exceed a threshold value of the respective year. The national aggregation is done by main natural areas. The results show a trend towards earlier algal blooms in all natural areas. Validation for determining the onset of the spring algal bloom is difficult due to a lack of continuous field measurements, but the indicator provides important insights into the temporal development of the spring algal bloom at a national level based on remote sensing data. This indicator was included in the 2023 DAS monitoring report.

► Water temperature in standing waters

The water temperature is derived from the operationally available Collection 2 Level 2 surface temperature product from the United States Geological Survey (USGS). The product is harmonised as best as possible across all sensors in the Landsat series and started in the 1980s. The validation of the Landsat LSWT showed strong linear correlations with in-situ measured temperatures ( $R^2 > 0.9$ ). The mean error (median) was over 1 °C for all three Landsat sensors used. Temporal and spatial aggregations were performed to retrieve an indicator. The first spatial aggregation within a lake is based on a 120 m inwards buffered polygon shapefile of the lake outline, in which the median of a recording is calculated. The temporal aggregation comprises an averaging of the lake medians on a monthly basis. The monthly means of the summer months (June, July, August) are averaged for the indicator. During this period, satellite data are most available. Spatial aggregation at national level can be based on various properties, such as natural areas, lake type, trophic level, federal state, mean depth, maximum depth, lake surface, volume, mean altitude or mixed type.

► Ice cover of lakes

The "Ice cover of lakes" indicator is based on categorised values that indicate whether a pixel is ice, water or invalid. The study period ranges from 1<sup>st</sup> November 2014 to 31<sup>rd</sup> March 2020 and uses data from Landsat 8 OLI, Sentinel-2 A and B MSI and Sentinel-1 A and B (C-band). Webcam images served as an independent data source to develop and validate a Random Forest classification algorithm. The quality measures for the classification models showed very high accuracies. This can be explained by the training and validation dataset, which only contains very clear cases. Misclassifications nevertheless exist and are reduced by an air temperature filter. It was defined that a lake is considered ice-covered if at least 80 % of the surface is iced over. The number of ice days is set in relation to the number of valid satellite overflights. The value scale ranges from 0 to 1, with lower values indicating fewer ice days on a lake. Due to the poor in-situ data basis, the indicator is based on seven case study lakes,

meaning that no nationwide aggregation took place. As only a short period of time was considered, no climate change-related conclusions can be drawn.

► Green roofs in large cities

To record green roofs nationwide in a comparable manner, the project team selected Sentinel-2 MSI data as the remote sensing data basis and 3D building model data (LoD2 data) to define roof geometries. The analysis was limited to roofs that are potentially suitable for green roofs (flat and monopitch roofs) and roofs that are > 400 m<sup>2</sup> due to the spatial resolution of the Sentinel-2 MSI data (10 m x 10 m). Green roofs were recorded using a threshold classification method based on a vegetation index (Normalised Difference Vegetation Index). The green roof areas were calculated within the roof geometries and totalled per city. The data basis comprises the 15 largest German cities with more than 500,000 inhabitants (including Duisburg). For the nationwide indicator, the green roof areas of all 15 cities were summed up and set in relation to the number of inhabitants. As additional information, the total green roof area was set in relation to the total roof area analysed. This indicator was included in the DAS Monitoring Report 2023 based on the year 2020.

► Development of quality criteria

The project team developed quality criteria for remote sensing-based DAS indicators in lakes based on suggestions from the workshop discussions. These criteria consider various influences on remote sensing data such as cloud cover, number of valid satellite overflights and also the spatial component of satellite data availability. Four main criteria were developed, which were normalised, summed and divided by four, resulting in an overall criterion between 0-1. This criterion is then categorically evaluated to assess the quality of the data basis of a year as low, neutral or high.

### Operationalisation of the nationwide indicator calculation

► Selection of the processing platform

The project team analysed various platforms for generating DAS indicators from remote sensing data. The analysis considered the requirements of the UBA and the selected processing workflows. Important criteria were complex and parallelisable processing, good interfaces and the availability of the required satellite data. After examining several platforms, CODE-DE (Copernicus Data and Exploitation Platform - Germany) was selected due to its national availability and free use for the UBA and Calvalus (Brockmann Consult GmbH) as it can be easily expanded and fulfils many requirements.

► Implementation of the operationalisation

The satellite data is selected and processed by the Calvalus processing system. The processes run in parallel, which minimises the time required. The resulting data cubes contain the biophysical variables (e.g. water temperature, chlorophyll-a concentration, cyanobacteria markers) and are made accessible by three interactive Jupyter notebooks (Python 3.8). The first notebook, "Data extraction", is used to generate tables in CSV format from the data cubes. These tables contain the biophysical values for each indicator, which are averaged over each lake and each satellite image. The second notebook, "Analysis", calculates the nationwide indicator, whereby different lakes or cities can be selected and aggregated according to various characteristics. The third notebook, "Quality parameters", calculates the quality criteria by lake and indicator and displays them as a table. The Jupyter notebooks are

tools for extracting and visualising time series of the processed satellite data, identifying trends and checking the quality of the input data. However, the actual trend calculation is carried out by the UBA or the project contractor for the DAS monitoring report. The data cubes and the Jupyter notebooks were made available via CODE-DE.

► Development of an interactive dashboard

A user-friendly dashboard was created to make the results accessible to a wide audience. The dashboard provides an interactive spatial visualisation and temporal analysis of the five DASIF indicators. Using different aggregation methods, it enables a variety of data visualisations. It is browser-based and enables flexible and easy use on different devices. The dashboard can be accessed via the following link:

<https://dasif-dashboard.brockmann-consult.de/>

**Recommendations, further developments and perspectives**

► Research needs for the current DASIF indicators

*Cyanobacteria contamination of bathing waters:* There is a data gap in the years 2012-2016 due to a lack of suitable sensors. The project team recommends combining different satellites and integrating in-situ measurements to close temporal gaps.

*Spring algal bloom in lakes:* There is a data gap from 2012-2016 due to the limited use of available sensors. The project team recommends combining different satellites and integrating in-situ measurements to close temporal gaps.

*Water temperature in lakes:* Currently available thermal satellite sensors have spatial or temporal limitations. The update should include the implementation of Landsat 9 TIRS-2 data, their validation, comparison with Landsat 8 TIRS and the analysis of interpolation methods.

*Ice cover of lakes:* The recommendations for the update include the expansion of the in-situ data basis, the implementation of Landsat 9 OLI, and the integration of thermal data from Landsat sensors.

*Green roofs in large cities:* Recommended steps for continuation include to calculate a second time step, to compare results with a spatially higher-resolution mosaic of Germany based on PlanetScope data, for example, and to collect own in-situ data to differentiate between types of green roofs (extensive or intensive greening).

► Synergies at international level

The ESA CCI Lakes project is developing global lake products, including climate variables such as water level, water surface area, water surface temperature, ice cover, ice thickness and reflectance. In phase 2, a use case called "AGGREGATED CLIMATE INDICATORS FOR THE GLOBAL LAKES" will be addressed, which is based on the DASIF approaches. Indicators for spring algal bloom, ice cover and temperature are developed and adapted to the Lakes CCI data set. An exchange between the CCI Lakes Team and the DAS Monitoring Team is recommended to utilise synergies and consider the results of both projects for application in Germany.

► Remote sensing perspectives for further DAS indicators

The progress in satellite remote sensing, together with the exchange in the DAS Monitoring Working Group, showed that remote sensing can not only support the existing DAS indicators, but also offers potential for new climate change indicators in various environmental areas. Integrating satellite data makes it possible to extend the indicators beyond water bodies and green roofs to also address e.g. land cover. Possible examples include indicators for coastal morphology, algal blooms and cyanobacteria in watercourses, bathing temperatures on the coast, vegetation in the water environment, permanent grassland areas, land cover in the dyke foreland or sealed areas (see Chapter 5.3).

► Developments in satellite remote sensing

Satellite remote sensing has established itself as a key instrument in climate research and environmental monitoring. Future developments promise even more precise data acquisition. Hyperspectral sensors such as EnMAP and Prisma and, in future, CHIME will enable to precisely identify vegetation types and climate-relevant changes. Advances in high-resolution spatial imaging offer detailed insights into local climate phenomena such as urban heat islands and glacier retreat. Advanced machine learning algorithms simplify the automated derivation of data bases for climate change indicators. The Copernicus programme and the Copernicus Climate Change Service (C3S) are pursuing ambitious goals for comprehensive Earth observation and climate monitoring. The ESA CCI initiative plans to expand its climate analyses and models, continuously collect data, integrate Earth observation data and strengthen international cooperation to advance the understanding of the climate system. The initiative also emphasises the importance of communication and awareness-raising to increase awareness of climate change.

As part of the DASIF project, the project team was able to integrate remote sensing-based DAS indicators into the DAS monitoring report for the first time. This result significantly contributed to the implementation of the federal government's Copernicus strategy and its field of action "Developing new services and technologies". In the last DAS monitoring report in 2019, the three indicators implemented were based on case studies at one to five lakes with data collected at one measurement point per lake. Green roofs were related exclusively to federal buildings.

Based on satellite data, DASIF was able to compile nationwide datasets for around 50 lakes and 15 large cities. The lakes and cities studied are spatially distributed throughout Germany and cover all main natural areas. With satellite data, the entire lake surface is considered and not just one measuring point and for green roofs, with restrictions on roof size, the entire city surface. The methods are validated and therefore transferable to other lakes. This means that further retrospective evaluation is possible, as satellite data are archived. The further development and continuation of satellite programs secures the data basis in the long term and the temporal data density is currently increasing and will continue to do so in the future. As a result, remote sensing offers great potential for developing further DAS indicators.

# 1 Einleitung

Das Umweltbundesamt (UBA) koordiniert im Rahmen der Deutschen Anpassungsstrategie Klimawandel (DAS) die Erstellung der zugehörigen Monitoringberichte. Um die im DAS-Monitoringbericht zugrundeliegenden DAS-Indikatoren abzuleiten, bedarf es konsistenter, langjähriger und deutschlandweiter Datensätze. Die Indikatoren unterscheiden sich in Impact-Indikatoren, die anzeigen, ob und wie sich der Klimawandel in Deutschland auswirkt und sogenannte Response-Indikatoren, die anzeigen, welche Maßnahmen ergriffen werden, um sich an den Klimawandel anzupassen. Die Indikatoren gehören übergeordneten Handlungsfeldern an, wie bspw. „Menschliche Gesundheit“, „Wasserhaushalt, Wasserwirtschaft, Küsten- und Meeresschutz“, „Bauwesen“, „Biologische Vielfalt“ (Umweltbundesamt (UBA) 2011). Aufgrund des dynamisch wachsenden Wissens, der besseren Verfügbarkeit von Erdbeobachtungsdaten und der sich ändernden technischen Möglichkeiten sollen die Anpassungsstrategie und ihre Indikatoren kontinuierlich weiterentwickelt werden.

Im Hinblick auf eine mögliche Weiterentwicklung hat ein ReFoPlan-Forschungsprojekt analysiert, welche DAS-Indikatoren durch Satellitenfernerkundung, insbesondere Copernicus-Daten, ergänzt und weiterentwickelt werden können (Schönthaler et al. 2017). Aus diesem Vorhaben ergab sich eine Auswahl an Indikatoren, die unterschiedlich gut geeignet sind, um operationell mit Fernerkundungsdaten abgebildet zu werden. Potentiale ergaben sich in den Handlungsfeldern „Menschliche Gesundheit“, „Wasserhaushalt, Wasserwirtschaft, Küsten- und Meeresschutz“ und „Bauwesen“.

Auf Basis dieser Vorarbeiten und weiterer Diskussionen, fokussierte sich das Projekt „Operationalisierung von DAS-Indikatoren mit Fernerkundung“ (DASIF) auf fünf DAS-Indikatoren. Im Handlungsfeld „Menschliche Gesundheit“ steht der Impact-Indikator „Cyanobakterienbelastung von Badegewässern“ im Vordergrund. Im Handlungsfeld „Wasserhaushalt, Wasserwirtschaft, Küsten- und Meeresschutz“ analysierte das DASIF-Vorhaben drei Impact-Indikatoren in Seen: „Frühjahrsalgenblüte in Seen“, „Wassertemperatur in Seen“ und „Eisbedeckung von Seen“. Für das Handlungsfeld „Bauwesen“ untersuchte das Projekt den Indikator „Gründächer in Großstädten“.

Die betrachteten Indikatoren wiesen zu Beginn des Projekts inhaltliche Schwächen und Weiterentwicklungsbedarfe auf. Diese werden im Folgenden zusammengefasst.

## **Cyanobakterienbelastung von Badegewässern**

Viele Cyanobakterien, auch bekannt als Blaualgen, enthalten sogenannte Cyanotoxine. Als Folge eines Kontakts mit Cyanobakterien sowohl nach dem Verschlucken von Wasser als auch beim direkten Hautkontakt mit belastetem Wasser sind lokale Symptome wie Haut-/ Schleimhautreizungen, Bindehautentzündungen, Ohrenscherzen und allergische Reaktionen bekannt (Liyanage et al. 2016). Das CyanoCenter des UBA stellt umfassende Hintergrundinformationen zu Cyanobakterien und ihre Wirkungen auf Mensch und Tier bereit (siehe <https://toxische-cyanobakterien.de/>). Temperaturänderungen können die Artenzusammensetzung der Phytoplanktongemeinschaft in Richtung temperaturliebende Organismen (z. B. Cyanobakterien) verschieben (Kosten et al. 2012). Auch veränderte Windverhältnisse können Cyanobakterien beeinflussen (Kutser 2004). Daher können beobachtete Veränderungen der Cyanobakterienbelastung auch ein Hinweis auf Klimaänderung sein, sofern sich die Nährstoffverfügbarkeit im Gewässer nicht deutlich verändert. Denn damit sich Cyanobakterienblüten bilden, müssen außerdem Nährstoffe, insbesondere Phosphor, verfügbar sein (J.M. O’Neil et al. 2012).

### *Schwächen*

- ▶ Geringe Anzahl an Fallstudien mindert die Aussagekraft des Indikators, der Fokus liegt stark auf dem ausgewählten See
- ▶ Räumlich heterogene Verteilung bzw. ein Auftreten von Cyanobakterien im See wird durch stichpunktartige in-situ Messung nicht erfasst
- ▶ Unklarheit darüber, wie sich Toxine in Bezug auf Klimaänderung entwickeln

### *Entwicklungsbedarf*

- ▶ Ausweitung der Fallstudien: Größere Zahl an vollständigen Datensätzen, um Seetypen der Bund/Länder-Arbeitsgemeinschaft Wasser (LAWA) für die drei Ökoregionen Alpen/Alpenvorland, Mittelgebirge und Norddeutsches Tiefland differenziert abzubilden
- ▶ Erfassung der räumlichen Verteilung und Ausdehnung von Cyanobakterienblüten

### **Frühjahrsalgenblüte in Seen**

Algen beginnen im Frühjahr zu wachsen, wenn die Frühjahrzirkulation nährstoff- und sauerstoffreiches Tiefenwasser an die Seeoberfläche transportiert. Solange ausreichend Nährstoffe vorhanden sind, hält das Wachstum der Frühjahrsalgenblüte an; sie wird aber durch Fraßdruck und Aufbrauchen der Nährstoffe zeitlich reduziert und geht in die Klarwasserphase über. Zwischen Klimawandel, Eisbedeckung, Einsetzen der thermischen Schichtung und Wassertemperatur (direkter Temperatureffekt eher klein) eines Sees und dem zeitlichen Eintreten der Frühjahrsalgenblüte besteht ein direkter Zusammenhang. Verschiebungen der Frühjahrsalgenblüte könnten durch veränderte Wintertemperaturen, Dauer der Eisbedeckung und Windverhältnisse hervorgerufen werden. Es kann zu einem früheren Eintreten der Algenblüte kommen, das Algenwachstum kann sich verstärken (Biomasse) und die Artenzusammensetzung in Richtung temperaturliebende Organismen (z. B. Cyanobakterien) verschieben (Leibniz-Institut für Gewässerökologie und Binnenfischerei (IGB) 2018).

### *Schwächen*

- ▶ Geringe Anzahl an Fallstudien mindert die Aussagekraft des Indikators. Der Fokus liegt stark auf den ausgewählten Seen
- ▶ Kalenderwoche zeitlich zu ungenau für die exakte Bestimmung der Frühjahrsalgenblüte bei zweiwöchentlichen Messungen

### *Entwicklungsbedarf*

- ▶ Ausweitung der Fallstudien: Größere Zahl an vollständigen Datensätzen, um LAWA-Seetypen für die drei Ökoregionen Alpen/Alpenvorland, zentrale Mittelgebirge und Norddeutsches Tiefland differenziert abzubilden
- ▶ hohe zeitliche Auflösung von Messungen, um genauen Zeitpunkt der Frühjahrsalgenblüte zu detektieren

### **Wassertemperatur in Seen**

Die Wassertemperatur steuert in Seen diverse biologische, chemische und physikalische Prozesse wie Stoffkreisläufe von Kohlenstoff und Nährstoffen, Mixis, Wasserchemie,

Zusammensetzung der Arten oder Pflanzenwachstum (Woolway et al. 2020). Die Wassertemperatur von Seen ist eng gekoppelt mit der Lufttemperatur. Im Allgemeinen erhöhen demnach durch den Klimawandel regional steigende Lufttemperaturen auch die Wassertemperatur in Seen (Leibniz-Institut für Gewässerökologie und Binnenfischerei (IGB) 2018). Mit höheren Wassertemperaturen steigt das Risiko, dass Seen eutrophieren und schädliche Algenblüten entstehen, die wiederum die menschliche Gesundheit gefährden und das Ökosystem See beeinträchtigen (Brooks et al. 2016). Da der Klimawandel die Wassertemperatur direkt beeinflusst (Adrian et al. 2009), wird diese als DAS Impact-Indikator verwendet. Falls vorhanden, schränken andere signifikante anthropogene Eingriffe, die die Wassertemperatur verändern, die Interpretation des Indikators ein, wie bspw. Kühlwassereinleitungen.

#### *Schwächen*

- ▶ Geringe Anzahl an Fallstudien mindert die Aussagekraft des Indikators. Der Fokus liegt stark auf den ausgewählten Seen
- ▶ Unterschiedliche Messfrequenz an Seen beeinflusst den gebildeten Mittelwert
- ▶ Fehlwerte werden durch Verfahren ersetzt, die im Indikator-Factsheet festgeschrieben sind. Diese Verfahren bringen Unsicherheiten mit sich

#### *Entwicklungsbedarf*

- ▶ Ausweitung der Fallstudien: Größere Zahl an vollständigen Datensätzen, um LAWA-Seetypen für die drei Ökoregionen Alpen/Alpenvorland, Mittelgebirge und Norddeutsches Tiefland differenziert abzubilden
- ▶ Diskussion und Testen verschiedener Möglichkeiten, um den Indikator deutschlandweit zu aggregieren
- ▶ Vervollständigung von lückenhaften Datensätzen zu ganzjährige Messzeitreihen, am besten > 30 Jahre

#### **Eisbedeckung von Seen**

Die Dauer der Eisbedeckung in temporär vereisten Seen kann ein bedeutsamer zusätzlicher Indikator für die Auswirkungen des Klimawandels sein (Adrian et al., 2009). Mit steigenden Luft- und Wassertemperaturen infolge des Klimawandels wird erwartet, dass viele Seen zukünftig kürzere oder sogar eisfreie Winterperioden aufweisen (Hampton et al., 2017). Die Länge der Eisbedeckung in den Wintermonaten beeinflusst das Lichtklima unter Wasser sowie den Austausch von Gasen, Nährstoffen und Wärmeenergie zwischen dem See und seiner Umgebung. Sie beeinflusst auch die Prozesse in den Monaten außerhalb der kalten Monate, wie den Beginn und die Intensität der Frühjahrsalgenblüte (Adrian et al., 2009), die Mixis (Croley II et al., 1998) und die Wasserqualität (Weyhenmeyer, 2009).

Die Dauer der Eisbedeckung wird definiert als Zeitraum zwischen zwei wichtigen eisphänologischen Ereignissen: dem "Eisbeginn" und dem "Eisende" (Brown und Duguay, 2010). Der "Eisbeginn" bezeichnet das Datum, an dem ein See im Herbst oder Winter erstmals eine geschlossene Eisdecke aufweist (Brown und Duguay, 2010; Kirillin et al., 2012). Bei größeren Seen kann sich diese geschlossene Eisdecke auch auf bestimmte Bereiche oder Buchten beschränken (Magnuson, 2000). Das "Eisende" ist das Datum, an dem die geschlossene Eisdecke

aufbricht und der See in der Regel innerhalb weniger Tage eisfrei wird (Brown und Duguay, 2010; Kirillin et al., 2012).

Verschiedenen Faktoren beeinflussen den Zeitpunkt von "Eisbeginn" und "Eisende". „Eisbeginn“ wird v.a. durch die Lufttemperatur, atmosphärische Zirkulationsmuster (z. B. die Nordatlantische Oszillation für Europa; Prowse et al., 2011), morphologische Faktoren wie die Größe und Tiefe des Sees, die Lage und die Abflussstärke der Zuflüsse sowie interne Strömungen und die Wärmespeicherkapazität bestimmt (Brown und Duguay, 2010). Die Lufttemperatur ist die ausschlaggebende Größe für den Zeitpunkt des "Eisendes" (Lopez et al., 2019). Daher ist der Zeitpunkt des "Eisendes" besser als der „Eisbeginn“ geeignet, um die Auswirkungen des Klimawandels zu beobachten (Lopez et al., 2019).

Die z. T. variablen Ursachen des „Eisbeginns“ wie Stärke des Zuflusses beeinflussen folglich auch die Dauer der Eisbedeckung, was berücksichtigt werden muss, wenn dieser Indikator entwickelt wird.

#### *Entwicklungsbedarf*

- ▶ Bisher nicht als eigenständiger Indikator berücksichtigt, indirekt über den Indikator Wassertemperatur in Seen abgebildet
- ▶ Vollständige Entwicklung des Indikators notwendig unter Abstimmung mit Fachpersonen aus LAWA, UBA und projektbegleitende Expertengruppe

#### **Gründächer in Großstädten**

Gründächer stellen ein wichtiges Element von Anpassungsstrategien von Ballungsräumen an den Klimawandel dar (Berardi et al. 2014). Sie verringern Treibhausgase und Schadstoffe in den bodennahen Luftschichten (Rowe 2011; Sempel et al. 2013), vermindern den Effekt der urbanen Hitzeinsel (Alexandri und Jones 2008) und reduzieren Abwässer (Mentens et al. 2006). Gründächer steigern die biologische Vielfalt in der Stadt (Köhler 2006) bzw. wirken vorbeugend gegen Habitatverlust (Francis und Lorimer 2011) und verringern Belastungen durch Geräusche bzw. Lärm (van Renterghem et al. 2013). Begrünte Dächer kühlen Gebäude im Sommer, während sie im Winter dämmend wirken (Umweltbundesamt (UBA) 2020). Der Report 30 des Climate Service Centers Germany (GERICS) fasst in deutscher Sprache umfassend zusammen wie sich Dachbegrünungen klimarelevant auswirken (Brune et al. 2017).

Der DAS-Monitoringbericht 2019 führte den Indikator „BAU-R-2 Dachbegrünung von Bundesgebäuden“ als Response-Indikator neu ein.

#### *Schwächen*

- ▶ Der Indikator bildet nicht ab, wo die erfassten Dachflächen liegen. Dadurch lässt sich der Zusammenhang nicht herstellen, welchen Einfluss die bekannten Gründächer auf das spezifische Stadtklima haben bzw. welche positiven Effekte damit verknüpft werden können
- ▶ Die Bundesgebäude beinhalten sehr viele Militärgebäude, die außerhalb von Städten liegen und folglich das Stadtklima nicht beeinflussen
- ▶ Der Datensatz informiert nicht über die Art der Begrünung, bspw. extensiv, intensiv oder bewässert. Die Art der Dachbegrünung beeinflusst wesentlich wie stark sich ein begrüntes Dach auf das Stadtklima auswirkt.


### *Entwicklungsbedarf*

- ▶ Es müssen auch Nicht-Bundesgebäude erfasst werden, um zu erkennen, wie Gebäude an die Folgen des Klimawandels angepasst werden müssen.
- ▶ Um abzuschätzen, wie die vorhanden Gründächer das Stadtklima beeinflussen, werden Information über die Art der Begrünung benötigt.
- ▶ Regelmäßige (bspw. 4-jährig) Aktualisierung der Inventarisierung sowie Potentialanalysen von Dachbegrünungen

Das DASIF-Vorhaben sollte durch operationelle Fernerkundungsmethoden und -daten eine bundesweit, einheitliche Datengrundlage schaffen, um die Impact-Indikatoren „Cyanobakterienbelastung von Badegewässern“, „Wassertemperatur in Seen“, „Frühjahrsalgenblüte in Seen“ und „Eisbedeckung von Seen“ zu berechnen. Als Response-Indikator sind „Gründächer in Großstädten“ wichtige Anpassungsmöglichkeiten, um in Städten klimatische und wasserhaushaltstechnische Auswirkungen zu dämpfen. Diese sind seit dem DAS-Monitoringbericht 2019 durch „Gründächer auf Bundesgebäuden“ approximiert. Ziel hierfür ist es, mit Fernerkundungsdaten bundesweit Informationen über die Fläche von Gründächern in Großstädten zu erhalten.

Um operationelle, fernerkundungsbasierte Algorithmen für die fünf Indikatoren zu entwickeln, verfolgte das DASIF-Vorhaben vier Arbeitspakete (APs). Nach einer Lücken- und Bedarfsanalyse (AP 1) wurden Fallstudien für die einzelnen Indikatoren entwickelt (AP 2). Die am besten validierten Algorithmen wurden dann in operationelle Routinen umgesetzt (AP 3). Abschließend wurden Empfehlungen gegeben (AP 4), inwiefern neue Entwicklungen auf dem Gebiet der Fernerkundung das DAS-Monitoring weiter unterstützen können. Den Projektablauf veranschaulicht Abbildung 1.

**Abbildung 1: Überblick über die Arbeitspakete 2-4 und den Projektablauf. Arbeitspaket 1 Lücken- und Bedarfsanalyse ist aufgrund des kurzen Umfangs nicht dargestellt**



Quelle: eigene Darstellung, CAU Kiel, Brockmann Consult GmbH

Der vorliegende Abschlussbericht stellt Möglichkeiten der Fernerkundung für die fünf Indikatoren vor (Kapitel 2). Kapitel 3 beschreibt, wie die Indikatoren mit Methoden und Daten der Fernerkundung im Projekt weiterentwickelt wurden. Dazu werden zunächst die Untersuchungsgebiete und Daten (Kapitel 3.1) sowie die Validierungsmethoden (Kapitel 3.2) vorgestellt. Anschließend wird für jeden Indikator beschrieben, wie der Prozess abläuft, um aus den Satellitendaten eine deutschlandweite Indikatorabbildung zu erhalten. Kapitel 3.8 beschreibt den Aufbau und den Nutzen von Qualitätskriterien für Indikatorwerte. Kapitel 4 fasst zusammen, wie die Berechnung der Indikatoren operationalisiert wurde. Kapitel 5 gibt einen Ausblick auf Fortschreibungsmöglichkeiten der Indikatoren, Synergien und weiteren Entwicklungen in der Fernerkundung.

## 2 Möglichkeiten der Fernerkundung

Die nachstehenden Kapitel fassen für jeden Indikator Algorithmen und Sensoren zusammen, die für eine fernerkundliche Datengrundlage geeignet sein können.

### 2.1 Cyanobakterienbelastung von Badegewässern

Verschiedene Studien haben gezeigt, dass Satellitendaten herangezogen werden können, um Cyanobakterienblüten in Seen und Küstengewässern zu quantifizieren (Kutser 2004, 2009; Kahru et al. 2007; Simis et al. 2020a; Alikas et al. 2010; Matthews et al. 2012; Lunetta et al. 2015). Diese Ansätze umfassen die Erfassung von Blüten und Oberflächenfilmen von aufgeschwemmten Cyanobakterien (Kahru et al. 2007), die Abschätzung von Phycocyanin (Ruiz-Verdú et al. 2008) oder das Vorhandensein von Phycocyanin (Matthews et al. 2012; Simis et al. 2005) und die Biomasse des Chlorophyll-a in Cyanobakterienblüten (Matthews et al. 2012) oder auch die Anzahl der Zellen (Hunter et al. 2010; Lunetta et al. 2015). Phycocyanin ist der blaue Farbstoff, der den Cyanobakterien auch ihren Namen Blau-Grünalge bzw. Blaualge gibt.

Um Cyanobakterienblüten mit Satellitendaten zu erfassen, ist es essentiell zwischen im Wasser befindlichen und aufgeschwemmten Cyanobakterien zu differenzieren. Beide Fälle unterscheiden sich deutlich sowohl bei der Auswahl möglicher Sensoren als auch den anzuwendenden Algorithmen.

#### 2.1.1 Methodischer Hintergrund

Die fernerkundliche Detektion von Cyanobakterien im Wasser beruht auf dem Absorptionsverhalten von Phycocyanin. Im Vergleich zu Chlorophyll-a zeigt Phycocyanin ein deutliches Absorptionsmaximum bei 620 nm, das mit einem Absorptionsminimum bei 650 nm und 700 nm einhergeht (Richardson, 1996; Richardson und LeDREW, 2006; Dekker, 1993; Kutser, 2004). Damit diese Absorptionseigenschaften mit einem optischen Sensor erkannt werden können und von Chlorophyll-a trennbar sind, muss der Sensor schmale Aufnahmebänder in den entsprechenden Wellenlängenbereichen aufweisen. Besonders wichtig ist ein Band bei 620 nm, das nur wenigen Sensoren besitzen, wie bspw. bei dem Medium Resolution Imaging Spectrometer (MERIS) an Bord des Environmental Satellite (ENVISAT) von 2002 bis 2012 und dem Ocean and Land Colour Instrument (OLCI) an Bord von Sentinel-3 seit 2016. Diese Sensoren wurden speziell für Anwendungen im Wasser konzipiert (Simis et al., 2005; Lunetta et al., 2015), wobei sie mit einer räumlichen Auflösung von 300 m eher für größere Seen geeignet sind. Sensoren mit höherer räumlicher Auflösung wie Sentinel-2 haben oft breitere spektrale Bänder und der Bereich um 620 nm ist nicht separat mit einem eigenen Band abgedeckt. Dadurch ist es schwieriger Cyanobakterien mit diesen Sensoren spektral zu erkennen. Hier können zusätzliche Informationsquellen helfen, wie beispielsweise in-situ-Daten oder das Wissen, dass Cyanobakterien in einigen Gewässern typischerweise hohe Chlorophyll-a-Konzentrationen im Juli und August verursachen. Hyperspektrale Satellitenmissionen wie EnMAP und PRISMA zeichnen sich durch eine höhere spektrale und räumliche Auflösung im Vergleich zu MERIS und OLCI aus, was sie besonders geeignet für Anwendungen in Binnengewässern macht. Allerdings bieten sie eine geringere zeitliche Abdeckung. Auch wenn diese Satelliten derzeit noch nicht für Klimaindikatoren genutzt werden können, ist zu erwarten, dass sie in Zukunft eine entscheidende Rolle spielen werden. Sind Cyanobakterien aufgeschwemmt, können die Algorithmen zur Bestimmung der Wasserinhaltsstoffe (z. B. Chlorophyll-a-Konzentration) nicht mehr angewendet werden, da sowohl die Atmosphärenkorrektur als auch die Bestimmung der Wasserinhaltsstoffe fehlschlägt (Matthews

et al. 2012). Dennoch gibt es Untersuchungen, die die Höhe eines Vegetationsindex mit gemessener Chlorophyll-a-Konzentration in Zusammenhang bringen (Kutser 2004).

Neben der räumlichen und spektralen Eigenschaft eines Sensors ist die Empfindlichkeit der Detektoren (radiometrische Auflösung und Signal-Rauschverhältnis) eine dritte wichtige Größe, um Wasserinhaltsstoffen mit Satellitensensoren zu erfassen. Die vorwiegend für Landanwendungen konzipierten Sensoren wie Landsat Enhanced Thematic Mapper Plus (ETM)/ Operational Land Imager (OLI) oder Sentinel-2 Multispectral Instrument (MSI) sind im Gegensatz zu Ocean Colour Sensoren weniger sensitiv zu dunklen Oberflächen wie Gewässer und die Daten weisen dadurch ein höheres Rauschen auf (Mouw et al. 2015). Diese räumlichen, spektralen und radiometrischen Grundvoraussetzungen an die Sensoreigenschaften sind zu berücksichtigen, wenn über die Verwendung verschiedener Sensoren für die Erfassung von Cyanobakterien (und auch Frühjahrsalgenblüten) gesprochen wird.

### 2.1.2 Algorithmische Ansätze zur Bestimmung von Cyanobakterien

Algorithmen für die Erfassung von Cyanobakterien nutzen vorwiegend das Band bei 620 nm (Matthews et al. 2012; Matthews 2011). Dies wird z. B. bereits durch Simis et al. (2005) angewendet und mit zahlreichen Untersuchungen und Anwendungen auch durch den „Maximum Peak Height-Algorithmus“ (MPH) (Matthews et al. 2012; Matthews und Odermatt 2015), der im Wasser befindliche und aufgeschwemmte Cyanobakterien identifiziert. Die Chlorophyll-a-Konzentration wird über empirische Regressionen aus dem MPH-Wert bestimmt, wobei eine gesonderte Kalibrierung für Cyanobakterienvorkommen und andere Algenblüten angewendet wird. Der Algorithmus berechnet aus den schmalen Bändern von ENVISAT MERIS und Sentinel-3 OLCI bei 681, 709 and 753 nm die Peak-Höhe (MPH-Wert) bei 709 nm und identifiziert mit dem Band bei 620 nm Cyanobakterien. Um aufgeschwemmten Cyanobakterien zu identifizieren, werden ein Vegetationsindex (Normalized Difference Vegetation Index; NDVI) und der MPH-Wert kombiniert.

Lunetta et al. (2015) kalibrierten den „Cyanobacteria Index“ (Wynne et al. 2010) mit Cyanobakterien cell counts in US-amerikanischen Seen. Der Cyanobacteria Index nutzt die 2. Ableitung des Fluoreszenz-Bands bei 681 nm von ENVISAT MERIS basierend auf Rayleigh-korrigierten Reflexionen. Der Cyanobacteria Index basiert darauf, dass sich das Verhältnis von Chlorophyll-a Absorption und Fluoreszenz bei Algen anders verhält als bei vorkommenden Cyanobakterien. Vorkommen von niedrigen und hohen Konzentrationen konnten gut bestimmt werden. Allerdings war der Fehler bei mittleren Konzentrationen von Cyanobakterien hoch (Lunetta et al. 2015). Auch Urquhart et al. (2017) nutzten den Cyanobacteria Index, um ENVISAT MERIS Zeitreihen zu analysieren und um abzuschätzen, wie sich die Cyanobakterienbelastung von Badegewässern in den vergangenen Jahren verändert hat.

Räumlich höher aufgelöste Sensoren, z. B. Sentinel-2 MSI, haben eine geringere spektrale Auflösung und es fehlen die schmalen Bänder, die für die zuvor genannten Algorithmen benötigt werden, um die Absorptionseigenschaften von Phycocyanin präzise zu registrieren. Sòria-Perpinyà et al. (2020) entwickelten einen mit in-situ kalibrierten Algorithmus für die Bestimmung von Phycocyaninkonzentrationen mit Sentinel-2 MSI, der das Verhältnis der Bänder bei 665 nm und bei 704 nm nutzt. Beck et al. (2017) nutzten hyperspektrale Flugzeugdaten, um Cyanobakterienabschätzungen für verschiedene, räumliche hochaufgelöste Sensoren zu entwickeln.

Cyanobakterien müssen in ausreichend hoher Konzentration vorkommen, damit sie fernerkundlich erfasst werden können. Grenzwerte beim MPH-Algorithmus werden hier beispielsweise mit  $20 \text{ mg/m}^3$  angegeben (Matthews und Odermatt 2015). Auch sollten

Cyanobakterien die dominierende Art im betrachteten Wasserkörper sein, um sie verlässlich zu identifizieren.

### 2.1.3 Erkennung von Cyanobakterien durch die Kombination von in-situ Daten und Fernerkundung

Die Validierung der Chlorophyll-a-Konzentration in Cyanobakterienblüten ist durch die charakteristischen kleinräumigen Strukturen und die ungleichmäßige vertikale Verteilung in der Wassersäule sehr schwierig (Kutser 2004). Hier macht es sich sehr deutlich bemerkbar, dass man bei der Validierung von Fernerkundungsprodukten mit in-situ Messungen eine punktuelle Information mit einer flächenhaften, integrierten Messgröße vergleicht. Page et al. (2018) schlagen ein Protokoll zur synoptischen Erfassung von Cyanobakterien in Binnengewässern aus einer Kombination verschiedener Satelliten vor. Bresciani et al. (2016) demonstrieren, wie die Konstellation verschiedener Satelliten und ihrer spezifischen räumlichen und spektralen Eigenschaften für die Erfassung von Cyanobakterien in Seen genutzt werden können.

Nachstehend wird aufgelistet, welche Lücken und Bedarfe der DAS-Indikator aufweist und wie die Fernerkundung diese schließen kann, aber auch welche Herausforderungen damit verbunden sind.

#### *Lücken und Bedarfe*

- ▶ Höhere Anzahl an Fallstudien erforderlich, deutschlandweite Aggregierung testen
- ▶ Räumliche Verteilung erfassen

#### *Möglichkeiten der Fernerkundung*

- ▶ Vorhandene algorithmische Ansätze nutzen
- ▶ Kombination verschiedener Sensoren
- ▶ Kombination mit in-situ Daten

#### *Herausforderungen der Fernerkundung*

- ▶ Geringere spektrale Auflösung für räumlich hoch aufgelöste Sensoren
- ▶ Homogenisierung verschiedener Sensoren notwendig
- ▶ Unregelmäßig auswertbare Daten durch Wolken

## 2.2 Frühjahrsalgenblüte in Seen

Für die Fernerkundung von Gewässern sind alle optisch relevanten Prozesse von Bedeutung, die durch die Streu- und Absorptionseigenschaften des Wassers und seiner Inhaltsstoffe verursacht werden. Satellitensensoren messen das daraus resultierende spezifische Absorptionsverhalten des Wassers und seiner Bestandteile in verschiedenen Wellenlängen. Zu den optisch aktiven Bestandteilen zählen Schwebstoffe (organisch und anorganisch), Chlorophyll-a in Algen und gelöste Gelbstoffe. Jeder dieser Bestandteile zeigt spezifische optische Merkmale und entsprechend ein charakteristisches Streu- und Absorptionsverhalten in den verschiedenen Wellenlängen (Mobley, 1994). Die Chlorophyll-a-Konzentration kann als optisch aktiver Proxy-Parameter verwendet werden, um Frühjahrsalgenblüten zu identifizieren. Eine andere Möglichkeit ist die Sichttiefe, die aus dem Attenuationskoeffizienten abgeleitet wird. Dieser gibt

an, wie viel der solaren Einstrahlung durch Absorptions- und Streuprozesse im Wasser zurückgehalten wird (Kirk, 2011).

### 2.2.1 Methodischer Hintergrund

Ein wesentlicher Verarbeitungsschritt zur Berechnung der Chlorophyll-a Konzentration ist die Atmosphärenkorrektur. Auch in der Atmosphäre unterliegt die solare Strahlung Streu- und Absorptionsprozessen, die von denen im Wasser getrennt werden müssen. Das Signal, das der Sensor am Satelliten misst, enthält über einer Wasserfläche im Durchschnitt 90 % Signal aus der Atmosphäre und nur 10 % aus dem Wasser (Gitelson und Kondratyev 1991). Dieses Verhältnis zeigt, wie wichtig eine gute Atmosphärenkorrektur ist.

Die optische Gewässerfernerkundung hat ihre Ursprünge im offenen Ozean und für komplexere Gewässer in den Küstengewässern. Der Schritt zu den Binnengewässern hat sich relativ spät vollzogen mit der Verfügbarkeit räumlich höher aufgelöster Sensoren (Palmer et al. 2015). Seen sind optisch vielfältiger, haben ein größeres Spektrum an Inhaltstoffen und können höhere Konzentrationen dieser Stoffe aufweisen, als dies bei Küstengewässern der Fall ist. Daher sind nicht alle Algorithmen der Küstengewässerfernerkundung auch in Binnengewässern anwendbar. Dennoch sind viele geeignete Algorithmen zur Bestimmung von Wasserinhaltsstoffen in komplexen Gewässern verfügbar. Grundlegend wird zwischen empirischen und physikalisch basierten Algorithmen unterschieden, wobei die Spannbreite der Anwendbarkeit und Möglichkeit der Übertragbarkeit groß ist (Ogashawara et al. 2017). Methodische Hintergründe und Beispiele in deutscher Sprache finden sich in Baschek et al. (2018). Einen guten Überblick zu Algorithmen geben Odermatt et al. (2012) und Dörnhöfer und Oppelt (2016). Neuere vergleichende Untersuchungen liefern auch Neil et al. (2019). Gerade globale Anwendungen setzen mitunter auf eine Kombination verschiedener Algorithmen, die für verschiedene optische Seenkategorien optimiert sind (Spyrakos et al. 2017; Moore et al. 2001; Neil et al. 2019).

### 2.2.2 Algorithmische Ansätze zur Bestimmung von Chlorophyll-a

Für den Indikator „Frühjahrsalgenblüte in Seen“ konzentrierte sich die Untersuchung in diesem Projekt auf Algorithmen, die die Chlorophyll-a Konzentration und die Sichttiefe bestimmen können. Die Anforderungen der Algorithmen an die spektralen und räumlichen Auflösungen der Sensoren sind ähnlich wie bei der Detektion von Cyanobakterien (siehe Kapitel 2.1). Viele der in den Überblicksartikeln genannten Algorithmen benötigen atmosphärisch korrigierte Bilddaten als Eingangsdaten. Hierfür gibt es mittlerweile eine Vielzahl an Algorithmen, die spezifisch für Gewässer entwickelt wurden, wie z. B. Polymer (Steinmetz et al. 2011) oder C2RCC (Doerffer und Schiller 2007; Brockmann et al. 2016), ACOLITE (Vanhellemont 2019) oder iCOR (Sterckx et al. 2015). Daneben existieren gekoppelte Algorithmen, die die Bestimmung der Chlorophyll-a Konzentration und die Atmosphärenkorrektur durchführen, wie z. B. C2RCC, FUB WeW (Schroeder et al. 2007a) oder MIP (Heege et al. 2014). Die Algorithmen liegen fast alle sowohl für die Gewässersensoren ENVISAT MERIS und Sentinel-3 OLCI vor als auch für die räumlich höher aufgelösten Sensoren der Landsat-8 und Sentinel-2 Satelliten. MIP wird zudem auch für räumlich sehr hoch aufgelöste Daten angewendet, wie z. B. WorldView.

Des Weiteren existieren viele empirischer Algorithmen, um Chlorophyll-a Konzentrationen zu bestimmen. Meist wurden sie auf einer begrenzten Anzahl von Seen kalibriert und gelten auch nur unter bestimmten Bedingungen (z. B. Gons 2004; Gitelson et al. 2008; Moses et al. 2009). Diese Algorithmen bedingen eine Vorabbestimmung des Seentyps, damit sichergestellt ist, dass sie für ihren Gültigkeitsbereich angewendet werden.

Eine weitere Kategorie sind biophysikalische-optische Inversionsmodelle, die eine recht genaue Vorabanschätzung der Seen bzw. Parametrisierung der Aufnahmebedingungen voraussetzen,

wie z. B. BOMBER (Giardino et al. 2012) oder WASI2D (Gege 2014b). Das Anwendungsgebiet dieser Modelle sind wissenschaftliche Einzelstudien und eine Operationalisierung ist daher nur bedingt geeignet.

Das Copernicus Datenprodukt „Lake Water Quality“ aus dem Copernicus Landmonitoring Dienst bietet die Trophiestufe von global verteilten Seen in 10-Tages Mittelwerten. Es sind ca. 30 deutsche Seen in diesem globalen Datensatz integriert. Algorithmisch wird zunächst eine optischen Wasserkategorie definiert, über die dann der anzuwendende Algorithmus ausgewählt wird (Simis et al. 2020a).

### 2.2.3 Berücksichtigung der Seentypen bei der Algorithmik

Algorithmen zur Chlorophyll-a-Bestimmung, die auf atmosphärenkorrigierten Reflexionen basieren, setzen häufig das Verhältnis der Reflexion zwischen blauen und grünen Wellenlängen ein, um die Chlorophyll-a-Absorption zu quantifizieren. Diese Methode ist jedoch nur in oligotrophen Seen geeignet, in denen Phytoplankton der vorherrschende optisch aktive Bestandteil ist. Wenn jedoch Schwebstoffe und insbesondere Gelbstoffe vorhanden sind, sollten Bänder genutzt werden, die das sekundäre Absorptionsmaximum von Chlorophyll-a im roten Wellenlängenbereich erfassen. Für eutrophe Binnengewässer und Küstenregionen sind beispielhaft die Algorithmen von Gons (1999) und Lee et al. (2002) zu erwähnen.

Nachstehend wird aufgelistet, welche Lücken und Bedarfe der DAS-Indikator aufweist und wie die Fernerkundung diese schließen kann, aber auch welche Herausforderungen damit verbunden sind.

#### *Lücken und Bedarfe*

- ▶ höhere Anzahl an Fallstudien erforderlich, Aggregierung testen
- ▶ hohe zeitliche Auflösung, um genauen Zeitpunkt zu detektieren

#### *Möglichkeiten der Fernerkundung*

- ▶ Vorhandene algorithmische Ansätze nutzen
- ▶ Kombination verschiedener Sensoren

#### *Herausforderungen der Fernerkundung*

- ▶ Abdeckung unterschiedlicher Seentypen
- ▶ Homogenisierung verschiedener Sensoren notwendig
- ▶ Bestimmung des genauen Zeitpunktes durch Wolkenbedeckung nicht möglich

## 2.3 Wassertemperatur in Seen

Seen emittieren abhängig von ihrer Wassertemperatur Energie im langwelligen Wellenlängenbereich. Diverse Satellitensysteme (bspw. Landsat-Reihe, Sentinel-3, Terra/Aqua, NOAA Polar Orbiting Operational Environmental Satellites) tragen Sensoren, die diese Strahlung erfassen können. Um auf die Wasseroberflächentemperatur schließen zu können, müssen der Emissionsgrad der Wasseroberfläche ( $\sim 0.991$ , Wang et al. 2015) berücksichtigt sowie atmosphärische Einflüsse (Absorption, Streuung, Transmission, Temperatur der Atmosphäre) korrigiert werden.

### 2.3.1 Methodischer Hintergrund

In Abhängigkeit der verfügbaren thermalen Bänder werden hierfür sog. Mono-window oder Split-window Verfahren die Atmosphärenprofile approximierend parametrisiert oder analytische Strahlungstransfermodelle verwendet (Li et al. 2013). Mono-window Verfahren sind für Sensoren ausgelegt, die nur ein thermales Band (bspw. Landsat 5 TM; Qin et al. 2001), oder aufgrund von technischen Problemen nur ein nutzbares Band haben (bspw. Landsat 8 TIRS; Wang et al. 2015). Häufig benötigen die Algorithmen noch zusätzliche Daten wie den Wasserdampfgehalt und die Temperatur der Atmosphäre (Wang et al. 2015), welche aus Satellitenprodukten (bspw. Sentinel-3 integrated water vapor product, Moderate Resolution Imaging Spectrometer (MODIS) MOD05/MYD05) abgeleitet werden oder von nahe gelegenen Wetterstationen bezogen werden. Wenn Bänder aus zwei atmosphärischen Fenstern im Thermalbereich genutzt werden können (Split-window Verfahren), kann die Transmission der Atmosphäre besser und dadurch die Oberflächentemperatur genauer bestimmt werden (Rozenstein et al. 2014).

Bei der Betrachtung von Wasseroberflächen ist zu berücksichtigen, dass die abgeleitete Strahlungstemperatur der sogenannten "Skin Temperature" entspricht. Diese stammt aus einem etwa 500  $\mu\text{m}$  dünnen Bereich, der sich an der Grenzfläche zwischen Wasser und Luft befindet (Pareeth et al., 2017). Aufgrund von Schichtungen und Windeinwirkung an der Wasseroberfläche ist die "Skin Temperature" typischerweise kühler als die kinetische "Bulk Temperature", die in-situ mit einem Thermometer gemessen wird. Dennoch zeigen zahlreiche Studien eine starke Korrelation zwischen beiden Temperaturen (oft mit einem  $R^2$ -Wert von  $> 0.9$ ), wie beispielsweise für das Landsat-Archiv (Simon et al., 2014), MODIS (Pareeth et al., 2017) oder AVHRR (Lieberherr und Wunderle, 2018). Es ist jedoch wichtig, methodische und absolute Unterschiede zu bedenken und gegebenenfalls zu homogenisieren, insbesondere wenn in-situ gemessene und satellitenbasierte Wasseroberflächentemperaturen verglichen werden. Ein weiterer relevanter Aspekt ist der Tagesgang der Temperatur. Bei der kombinierten Nutzung verschiedener Datenquellen (in-situ, verschiedene Satelliten mit unterschiedlichen Aufnahmetermen) sollten die Wassertemperaturen auf eine einheitliche Uhrzeit korrigiert werden (Lieberherr und Wunderle, 2018).

### 2.3.2 Anwendung der thermalen Fernerkundung

Satellitenbasierte Wasseroberflächentemperaturen von Seen wurden in den letzten Jahren zunehmend in thermodynamische Modelle integriert (bspw. Allan et al. 2016; Huang et al. 2017; Li et al. 2017). Weitere Forschungen erstellten synergetische Zeitreihen aus verschiedenen Sensoren, um Trendanalysen der Temperaturentwicklung bestimmen zu können (bspw. Pareeth et al. 2016; Pareeth et al. 2017; Politi et al. 2012). Von Odermatt&Brockmann wurde mit Unterstützung von Brockmann Consult das MuSenAlp-Verfahren zur Bestimmung von Temperatur aus Landsat 8 TIRS und AVHRR Daten entwickelt, welches als SNAP (Sentinel Application Platform) Plug-In verfügbar ist. Hierbei werden die spektral unterschiedlichen Absorptionscharakteristika von Wasserdampf in den Thermalbändern ausgenutzt, um den thermischen Beitrag der Atmosphäre abzutrennen und die Wasseroberflächentemperatur aus dem Signal zu extrahieren.

Die grobe räumliche Auflösung der meisten thermalen Sensoren ( $> 1 \text{ km}^2$  bei Sentinel-3 SLSTR, MODIS, AVHRR etc.) stellt eine Herausforderung für die Analyse vieler Seen dar. Auf Bundesebene eignen sie sich vermutlich nur für die größten Seen (Bodensee, Müritz). Für kleinere Seen muss daher auf die räumlich höher aber zeitlich geringer aufgelösten Landsat-Sensoren zurückgegriffen werden. Hier stellt sich die Frage, ob groß- und kleinskalige Sensoren in Zeitreihen kombiniert werden können, wenn wenigstens ein reines Wasserpixel detektiert

werden kann. Solche Kombinationen könnten auch Probleme im Zusammenhang mit häufiger Wolkenbedeckung reduzieren (Dörnhöfer et al. 2018).

### 2.3.3 Operationell verfügbare Produkte der Wassertemperatur

Ebenfalls auf grober räumlicher Auflösung (1 km) existieren Temperaturprodukte aus den vorgenannten Sensoren, wie das LSWT Produkt des globalen Copernicus Landmonitoring Dienstes. Zwischen 2002-2012 wurde der Dienst auf Basis von ENVISAT AATSR Daten aufgebaut und wird seit April 2018 mit Sentinel-3 SLSTR alle 10 Tage fortgeführt. Das MODIS „Land surface temperature“ Produkt (MOD11/MYD11) wird auf Basis eines split-window Algorithmus berechnet und täglich bzw. als 8-Tage Komposit zur Verfügung gestellt. Bei diesen Produkten gilt es zu analysieren, inwiefern sie sich durch ihre räumliche Auflösung für nationale Gewässer im DAS-Monitoring eignen.

Im Verlauf des Projekts (Jahr 2020) veröffentlichte der United States Geological Survey (USGS) das Landsat Collection 2 Level 2 Science Product „Surface temperature“ (Crawford et al. 2023). Damit stellt der USGS nun atmosphärisch korrigierte Oberflächentemperaturprodukte operationell und global basierend auf Landsatdaten zur Verfügung.

Nachstehend wird aufgelistet, welche Lücken und Bedarfe der DAS-Indikator aufweist und wie die Fernerkundung diese schließen kann, aber auch welche Herausforderungen damit verbunden sind.

#### *Lücken und Bedarfe*

- ▶ höhere Anzahl an Fallstudien erforderlich, Aggregation testen
- ▶ monatlicher Messwert der Wasseroberflächentemperatur
- ▶ vollständige Zeitreihe > 30 Jahre
- ▶ gleichmäßige Messfrequenz

#### *Möglichkeiten der Fernerkundung*

- ▶ Ableitung der Wasseroberflächentemperatur aus thermalen Daten
- ▶ Kombination verschiedener Sensoren
- ▶ Landsatdaten ab Mitte 1980er verfügbar

#### *Herausforderungen der Fernerkundung*

- ▶ grobe räumliche Auflösung vieler thermaler Sensoren
- ▶ Homogenisierung verschiedener Sensoren notwendig
- ▶ lückenhaft vorhandene Landsatdaten
- ▶ unregelmäßig auswertbare Daten durch Wolken

## 2.4 Eisbedeckung von Seen

Gemäß der Lücken- und Bedarfsanalyse ist es erforderlich, diesen Indikator vollständig zu entwickeln. In-situ-Daten zur Eisbedeckung existieren in Deutschland kaum (zum Beispiel am Großen Müggelsee, durch Eisdickenmessungen der Wasserwacht und Beobachtungen an Trinkwassertalsperren). Untersuchungen haben gezeigt, dass Satellitensensoren großflächig

eingesetzt werden können, um die Eisbedeckung von Seen über mehrere Jahre hinweg seit etwa 1980 zu erfassen (zum Beispiel Latifovic und Pouliot, 2007). Duguay et al. (2015) stellt in einem Reviewartikel wesentliche Grundlagen, Fortschritte und Methoden der Fernerkundung zur Überwachung der Eisbedeckung vor. Die meisten veröffentlichten Studien nutzen passive optische Sensoren (Barbieux et al., 2018) oder aktive SAR-Sensoren (Engram et al., 2018). Gelegentlich werden auch Thermalsensoren und seltener passive Mikrowellensensoren verwendet (Kang et al., 2012; Cai et al., 2017). Letztere weisen eine räumliche Auflösung von etwa 25 km auf, die für die Größe deutscher Seen zu grob ist.

#### **2.4.1 Optische Trennung von Eis und Wasser**

Passive optische Systeme beruhen auf den unterschiedlichen Reflexionseigenschaften von Wasser, Schnee und Eis im (nah-) infraroten Wellenlängenbereich. Das Datenprodukt des globalen Copernicus Landmonitoring Dienstes „Lake Ice Extent“ basiert auf einem einfachen Schwellwertverfahren, das als Eingangsdaten Top-of-Atmosphäre (TOA)-Strahldichten des Terra-MODIS Band (850 nm) nutzt (Heinilä et al. 2017). Diverse Studien auf Grundlage von optischen Daten von AVHRR (Weber et al. 2016), MODIS (Qi et al. 2019; Guo et al. 2018) oder der Landsat-Sensoren (Barbieux et al. 2018; Qi et al. 2019) nutzen ähnliche Schwellwertverfahren mit Bändern im nahinfraroten Wellenlängenbereich. Barbieux et al. (2018) zeigte, dass es mit diesen Ansätzen sehr gut gelingt, lichtundurchlässiges oder schneebedecktes Eis von offenen Wasserflächen zu trennen. Die Intensität der Reflexion von lichtdurchlässigem, klarem Eis ist ähnlich niedrig wie von Wasserflächen, wodurch die Eisbedeckung unterschätzt werden kann. Daher entwickelten sie ein Verfahren, das zusätzlich zur Reflexion Texturmaße einbezieht, da Eisflächen im Vergleich zu offenem Wasser eine höhere lokale Variabilität aufweisen (Barbieux et al. 2018). Darüber hinaus konnten mit dem MODIS-Schneeprodukt (MOD10A2) Zeitpunkte der Eisphänologie in tibetischen (Guo et al. 2018; Kropáček et al. 2013) und kanadischen (Murfit und Brown 2017) Seen über Zeitreihenanalysen großskalig bestimmt werden. Die räumliche Auflösung von MODIS und AVHRR beschränkt ihre Anwendbarkeit auf größere Seen. ENVISAT MERIS-Daten könnten auf ähnlicher räumlicher Skala Zeitreihen der Eisbedeckung rückblickend ergänzen. Auf Sentinel-3 OLCI sollten die Schwellwertansätze ebenfalls übertragbar sein.

#### **2.4.2 Indirekte Bestimmung der Eisbedeckung über die Wassertemperatur**

Darüber hinaus ist es möglich, die Eisbedeckung indirekt über die Wassertemperatur abzuleiten. Die Algorithmen und Sensoren entsprechen den genannten zur Ableitung der Wassertemperatur in Kapitel 2.3. Der Emissionsgrad von Eis und Wasser unterscheidet sich geringfügig an den betrachteten Wellenlängen. Fällt die ermittelte Temperatur unter 0 °C kann man von einer Eisbedeckung ausgehen. Guo et al. (2018) nutzten bspw. Thermaldaten (MODIS Land surface temperature Produkt), um eisphänologische Merkmale in tibetischen Seen zu analysieren.

#### **2.4.3 Trennung von Eis und Wasser über SAR-Daten**

Wolken beeinträchtigen die zeitliche Auflösung erheblich, wenn passive Systemen (thermisch oder optisch) genutzt werden. Besonders der Anfang und das Ende der Eisperiode erfordern eine engmaschige Überwachung, um die Gefrier- und Auftauprozesse so präzise wie möglich zu erfassen (Arp et al., 2013). Zusätzlich erschweren niedrige Sonnenwinkel im Herbst und Winter die Analyse (Latifovic und Pouliot, 2007). Zahlreiche Studien nutzen deswegen passive Synthetic Aperture Radar (SAR)-Sensoren. Das Radarsignal kann Wolken durchdringen und ist unabhängig vom Sonnenstand. SAR-Studien zur Eisbedeckung von Seen nutzen hauptsächlich die Radar-Rückstreuung im C-Band und gelegentlich auch im X-Band, Ku-Band und L-Band

(Duguay et al., 2015). Die am häufigsten verwendeten SAR-Sensoren zur Detektion der Eisbedeckung von Seen sind RADARSAT-1 (1995-2013), RADARSAT-2 (seit 2007), ERS-1 (1991-2000), ERS-2 (1995-2011) und ENVISAT-ASAR (2002-2012) (Murfit et al., 2018; Murfit und Duguay, 2021) oder Sentinel-1 (Barbieux et al., 2018; Engram et al., 2018; Murfit und Duguay, 2020).

Die Grundlage für SAR-Analysen sind markante Unterschiede in der Intensität der Radar-Rückstreuung aufgrund der unterschiedlichen dielektrischen Eigenschaften (Gunn et al., 2018). Eisfreies, glattes Wasser zeigt eine geringe Rückstreuung und erscheint daher in einem dunklen, texturlosen Ton. Eisflächen weisen aufgrund ihrer variablen Oberflächenstruktur eine hohe Rückstreuung auf und erscheinen daher in einem helleren, texturreichen Grauton. Unruhiges, vom Wind aufgerautes, welliges Wasser kann jedoch zu klare Unterscheidungen erschweren (Murfit et al., 2018).

Schwellwertverfahren nutzen als Eingangsdaten die Intensität von gleichpolarisierter (HH, VV) oder kreuzpolarisierter (v.a. HV) Radarrückstreuung (Zakhvatkina et al. 2017; Antonova et al. 2016; Murfit et al. 2018). Geldsetzer et al. (2010) definierte beispielsweise HH- und HV-Rückstreuwerte, um die Auftauphase in kanadischen Seen in verschiedene Stadien zu klassifizieren. Häufig gehen in überwachte Klassifikationsverfahren wie „support vector machines“ oder „decision trees“ zusätzlich lokale Texturmaße ein. Zakhvatkina et al. (2017) berechnete hierfür als Grundlage die „grey level co-occurrence matrix“, und darauf aufbauend verschiedenen Texturmaße wie Entropie, Standardabweichung, Homogenität.

SAR-Sensoren sind jedoch hinsichtlich der zeitlichen Auflösung begrenzt. Zum Beispiel beträgt die Repetitionsrate bei Sentinel-1 12 Tage, und es können nur alle 6 Tage mit 2 Satelliten Bilder aufgenommen werden, um die Eisbedeckung von Seen zu erfassen (Murfit et al., 2018). Mit der im Juni 2019 gestarteten kanadischen RADARSAT-Konstellation aus drei baugleichen Sensoren kann die Wiederholrate erhöht werden, wobei die Daten nicht per se frei verfügbar sind (Canadian Space Agency 2023). Eis auf Seen in den mittleren Breiten kann sich in kurzen Zeiträumen bilden und wieder auftauen (Weber et al., 2016), daher ist es ratsam, mehr als eine Datenquelle zu verwenden (Barbieux et al., 2018). In der Vergangenheit wurden bereits unterschiedliche Radarsensoren kombiniert, um detaillierte Zeitreihen über 25 Jahre zu generieren (Engram et al. 2018). Nolan et al. (2003) kombinierten ERS-2, RADARSAT-1 und Landsat 7 ETM+ Daten, um die Eisdynamik in einem sibirischen See zu analysieren.

Angesichts der Ausdehnung deutscher Seen, der Möglichkeit von Wolkenbedeckung und der aktuellen Verfügbarkeit geeigneter Sensoren erscheint eine Kombination aus thermischen, optischen und SAR-Daten vielversprechend für ein Eisbedeckungsmonitoring.

Nachstehend wird aufgelistet, welche Lücken und Bedarfe der DAS-Indikator aufweist und wie die Fernerkundung diese schließen kann, aber auch welche Herausforderungen damit verbunden sind.

#### *Lücken und Bedarfe*

- ▶ Dauer der Eisbedeckung erfassen
- ▶ Termin Ice-on, Ice-off identifizieren
- ▶ hohe zeitliche Auflösung erforderlich
- ▶ Erfassung betroffener Seen

#### *Möglichkeiten der Fernerkundung*

- ▶ Trennung Wasser/Eis über SAR und optische Daten
- ▶ Bestimmung über Temperatur aus thermalen Daten
- ▶ Kombination der Methoden erhöht Chance auf verwendbare Datensätze
- ▶ archivierte Daten ab 1980er verfügbar

#### *Herausforderungen der Fernerkundung*

- ▶ niedriger Sonnenstand erschwert optische Analyse
- ▶ Homogenisierung verschiedener Datenquellen notwendig
- ▶ Bewölkung reduziert zeitliche Auflösung
- ▶ Sensoren mit hoher zeitlicher Auflösung haben eine grobe räumlicher Auflösung
- ▶ Vergleichsdaten aus in-situ Messungen für die Algorithmenentwicklung

## **2.5 Gründächer in Großstädten**

Um den Indikator mithilfe von Fernerkundungsdaten weiterzuentwickeln, müssen entsprechend der Lücken- und Bedarfsanalyse flächenhaft und deutschlandweit die Fläche der begrünten Dächer bestimmt sowie die Fläche der geeigneten Dächer auffindig gemacht werden. Darüber hinaus ist die Art der Begrünung von Interesse.

### **2.5.1 Bestimmung der begrünten Dächer**

Die meisten der verfügbaren Studien, die Gründächer mit Fernerkundung identifizieren, beruhen auf der spektralen Unterscheidbarkeit von Vegetationsflächen und Nicht-Vegetation im sichtbaren und nahinfraroten Wellenlängenbereich und verwenden Vegetationsindizes sowie räumlich sehr hochauflösenden flugzeug- (Ansel et al. 2015; Coenradie et al. 2016; Mallinis et al. 2014) oder drohnengestützten Daten (Moroni et al. 2019; Piro et al. 2017; Zhao et al. 2018). Die flugzeuggetragenen Studien nutzen in der Regel Ortho-Luftbilder und kombinieren sie mit zusätzlichen Datenquellen wie Digitalen Geländemodellen oder Katasterdaten.

Drohnengestützte Ansätze sind meist mit abbildenden Spektrometern bestückt und verfolgen neben der Identifikation von Gründächern die Analyse des Zustandes der Vegetation über die Anwendung von designierten, hyperspektralen Indizes.

In Deutschland wurde eine erstmalige Inventarisierung vorhandener Flächen vorgenommen und Potentialanalysen wurden bereits im Rahmen eines von der Deutschen Bundesstiftung Umwelt geförderten Projektes durchgeführt (Ansel et al. 2015). Auf kommunaler Ebene sind ebenfalls Methodenentwicklungen vorangetrieben worden. So wurde im Jahr 2016 im Auftrag der Berliner Senatsverwaltung für Stadtentwicklung ein Auswertungsverfahren erstellt, um den Gründachbestands der Stadt Berlin zu erfassen (Coenradie et al. 2016). Das Auswertungskonzept beruht in beiden Fällen auf der kombinierten Auswertung von digitalen Falschfarben-Luftbildern, Fachplanungs- und weiteren Geodaten. In einem ersten Schritt werden Verdachtsflächen basierend auf einem Vegetationsindex (hier NDVI) beruhenden Schwellwertverfahren ermittelt (Vorkartierung). Diese automatisiert generierten Ergebnisse der Vorkartierung werden danach mittels Luftbildinterpretationen geprüft und ggf. verbessert. Mögliche Ergebnisse dieser Untersuchung umfassen die Anzahl der Gebäude mit Dachbegrünung im Stadtgebiet, den prozentualen Anteil dieser begrünten Dächer an der Gesamtzahl aller Dachflächen, die Gesamtfläche der Vegetation auf den begrünten Dächern, die

Anzahl der Gebäude im Stadtgebiet, deren Dächer potenziell für eine Begrünung geeignet sind, den prozentualen Anteil dieser potenziell begrünbaren Dächer an der Gesamtzahl aller Dächer sowie die Gesamtfläche dieser potenziell begrünbaren Dächer (Bundesverband Gebäudegrün e.V. (BuGG), 2019). Die Methodik ist inzwischen erfolgreich in Städten wie Karlsruhe, Stuttgart, Nürtingen, München, Nürnberg und Frankfurt implementiert worden (Deutsches Zentrum für Luft- und Raumfahrt (DLR) 25.04.2018). Inzwischen vertreibt die EFTAS Fernerkundung Technologietransfer GmbH auch eine lizenzrechtliche Lösung des Verfahrens gemeinsam mit dem Bundesverband GebäudeGrün e.V. (Bundesverband Gebäudegrün e.V. (BuGG) 2019).

Daneben gibt es auch Studien, die auf objektbasierten Auswerteverfahren von Ortho-Luftbildern (z. B. Mallinis et al. 2014 für Griechische Agglomerationen am Beispiel von Thessaloniki) oder hochauflösenden satellitengestützten Sensoren wie IKONOS und Quickbird (z. B. Salehi et al. 2012 für Fredericton (Kanada)), WorldView-2 (Santos et al. 2016 für Lissabon) oder sensorunspezifisch GoogleEarth (Luo et al. 2011 für Dujiangyan (China)) beruhen. Diese nutzen neben der spektralen Information auch Parameter, wie bspw. die Form und Textur einer identifizierten Dachfläche. Dies zeigt, dass Ansätze basierend auf Satellitendaten erfolgreich sein können, um Gründächer zu erkennen. Die erforderliche räumliche Auflösung beschränkt das Spektrum nutzbarer Sensoren allerdings auf kommerzielle, räumlich sehr hochauflösende Systeme, deren Nutzung mit Kosten verbunden ist. Eine Ausnahme bildet die Plattform GoogleEarth, welche zwar räumlich hochaufgelöste Satellitendaten verwendet, diese sind allerdings nicht spezifiziert und enthalten keine Informationen zum Aufnahmezeitpunkt. Darüber hinaus zeichnen sich alle in der Literatur beschriebenen Ansätze dadurch aus, dass Hilfsdaten wie 3D-Geländemodelle oder Katasterinformationen als zusätzliche Datenquellen hinzugezogen werden.

### 2.5.2 Bestimmung der Art der Begrünung

Grundlegend ist es möglich, mithilfe der NIR-Schwellwertfahren und Colour-Infrared (CIR)-Orthofotos die Art der Begrünung zu ermitteln. Coenradie et al. (2016) verwenden dieses Verfahren, um zwischen „intensiven“ und „extensiven“ Dachbegrünungen zu unterscheiden. Intensiv begrünte Flächen weisen eine dichte Vegetation auf, die vital ist und ggf. bewässert wird. Extensive Gründächer werden nicht bewässert, die Vegetation wächst weniger und ist möglicherweise trockenere. Diese Kategorien unterscheidet ebenfalls das von EFTAS und BuGG e.V. vertriebene Verfahren zur Inventarisierung und Potentialanalyse.

Darüber hinaus nutzen diverse Studien drohnengestützte, hyperspektrale Daten. Die höhere spektrale Information ermöglicht detaillierter Aussagen darüber, wie sich der Vegetationsbestand zusammensetzt und in welchem Zustand er sich befindet (Moroni et al. 2019; Piro et al. 2017; Zhao et al. 2018).

### 2.5.3 Bestimmung geeigneter Dachflächen

Ob ein Dach geeignet ist, begrünt zu werden, hängt wesentlich von der Dachneigung und der Statik des Gebäudes ab. Digitale Oberflächenmodelle können kombiniert mit Gebäudegeometrien verwendet werden, um Neigungswinkel von Dächern zu berechnen. Grundsätzlich eignen sich neben Flachdächern, auch Dächer, die bis max. 45° geneigt sind. Aufgrund hoher Kosten bei stärker geneigten Dachflächen werden Dächer mit einem Neigungswinkel <math><10^\circ</math> bis <math><20^\circ</math> als potentiell geeignet eingestuft. Die Stadt Bremen veröffentlichte im Januar 2020 ein webbasiertes Kataster, welches Potentiale einer Dachbegrünung darstellt (Freie Hansestadt Bremen 2020). Ein Indiz für die Statik kann Kiesbelag sein, der evtl. spektral von anderen Belägen unterscheidbar ist. Die erhöhte Last durch den Kies spricht für ein statisch geeignetes Gebäude (Bundesverband Gebäudegrün e.V. (BuGG) 2019).

Nachstehend wird aufgelistet, welche Lücken und Bedarfe der DAS-Indikator aufweist und wie die Fernerkundung diese schließen kann, aber auch welche Herausforderungen damit verbunden sind.

#### *Lücken und Bedarfe*

- ▶ Erfassung geeigneter und begrünter Dächer
- ▶ Lageinformation
- ▶ regelmäßige Aktualisierung
- ▶ Art der Begrünung (extensiv, intensiv)
- ▶ Erfassung in Städten bundesweit

#### *Möglichkeiten der Fernerkundung*

- ▶ genaue Lage bestimmbar
- ▶ Trennung der Begrünungsart potentiell möglich
- ▶ Verfahren mit Vegetationsindizes sind bereits operationell verfügbar

#### *Herausforderungen der Fernerkundung*

- ▶ Zeitliche Auflösung abhängig von Befliegungsintervall bei Orthofotos
- ▶ Zeitpunkt der Befliegung kann ungünstig sein, bspw. außerhalb der Vegetationsperiode
- ▶ Räumliche Auflösung frei verfügbarer Satellitendaten oft nicht geeignet

## **2.6 Vorauswahl der Algorithmen zur Berechnung geophysikalischer Parameter aus Fernerkundungsdaten**

Die Kapitel 2.1 bis 2.5 zeigen, dass viele Algorithmen existieren, um eine biophysikalische Datengrundlage für die fünf Klimawandelindikatoren zu erstellen. Im Projekt wurde eine Bewertungsmatrix entwickelt, um anhand verschiedener Kriterien einzuschätzen, inwiefern sich ein Datenprodukt oder ein Algorithmus für das DASIF Projekt eignet und in den Fallstudien näher untersucht wird. Tabelle 1 fasst die betrachteten Kriterien zusammen. Anschließend wurden diese Kriterien basierend auf veröffentlichter Literatur und eigenen Erfahrungen mit den Algorithmen bewertet. Die Matrix besteht aus geschlossenen Fragen, d.h. die möglichen Antworten wurden vorab definiert. Jede Antwort ist verbunden mit einem positiven (geeignet für DASIF) oder negativen (weniger geeignet für DASIF) Wert. Anhand der aufsummierten Werte wurden die Algorithmen eingeordnet. Die Algorithmen mit den höchsten Werten (am besten geeignet) wurden ausgewählt, um sie in den Fallstudien detaillierter zu analysieren und mit in-situ Daten zu validieren.

**Tabelle 1: Kriterien differenziert nach Kategorien und Fragen, mit der verfügbare Algorithmen bewertet wurden**

Kategorie	Frage
Operationalisierung	Ist der Algorithmus automatisierbar?
	Ist der Algorithmus frei verfügbar?

Kategorie	Frage
Implementierung	Wie gut lässt sich der Algorithmus auf einer Prozessierungsplattform implementieren?
	Müssen weitere Schnittstellen zu anderen Datenquellen implementiert werden?
	Wie groß ist der Aufwand, um die Datengrundlage des Indikators zu aktualisieren?
	Ist der Gültigkeitsbereich eingeschränkt?
	Ist eine gekoppelte Prozessierungskette vorhanden?
Transparenz	Ist ein Service/Produkt vorhanden?
	Wie geeignet ist der Algorithmus basierend auf veröffentlichten und eigenen Validierungen?
	Besteht Weiterentwicklungsbedarf?
Sensoren	Liefert der Algorithmus eine Abschätzung der Unsicherheit?
	Gibt es veröffentlichte Validierungsergebnisse?
	Wie gut ist die Dokumentation?
	Auf welche Sensoren ist der Algorithmus anwendbar?


Quelle: eigene Zusammenstellung, CAU Kiel, Brockmann Consult GmbH

Die nachfolgenden Abbildungen zeigen die Ergebnisse der Bewertungsmatrix für die betrachteten Indikatoren, einmal das aufsummierte Gesamtergebnis und einmal detaillierter die Punkte, die ein Algorithmus oder Datenprodukt in den übergeordneten Kategorien erhalten hat.

### Cyanobakterienbelastung von Badegewässern

Abbildung 2 zeigt die Bewertung für Algorithmen, mit denen Cyanobakterien detektiert werden können. Die verfügbaren Algorithmen sind nachstehend aufgelistet:

- ▶ 1 Simis 2005 (Simis et al. 2005)
- ▶ 2 Maximum Peak Height (Matthews et al. 2012; Matthews und Odermatt 2015)
- ▶ 3 Single band ratio, bested band ratio (Ruiz-Verdú et al. 2008)
- ▶ 4 Cyanobacteria Index (Lunetta et al. 2015)
- ▶ 5 S2Be162Bsub (Beck et al. 2017)
- ▶ 6 Simple Band ratio (Sòria-Perpinyà et al. 2020)
- ▶ 7 EOMAP Harmful Algal Bloom Indikator (EOMAP 2016)
- ▶ 8 L8Be15Flhviolet (Beck et al. 2017)
- ▶ 9 orange contra-band retrieval algorithm (Castagna et al. 2020)

**Abbildung 2: Bewertungsmatrix zur Vorauswahl von Algorithmen für den Indikator Cyanobakterienbelastung von Badegewässern**

Quelle: eigene Darstellung, CAU Kiel, Brockmann Consult GmbH

### Frühjahrsalgenblüte in Seen

Abbildung 3 zeigt die Bewertung für Algorithmen, die für den Indikator Frühjahrsalgenblüte in Seen ausgewählt wurden. Dabei handelt es sich zum einen um Algorithmen zur Atmosphärenkorrektur als wesentlichen ersten Prozessierungsschritt und Algorithmen zur Bestimmung der Chlorophyll-a Konzentration. Eine andere Kategorie sind gekoppelte Algorithmen, die die Atmosphärenkorrektur und Chlorophyll-a Bestimmung gemeinsam vornehmen. Eine weitere Kategorie sind verfügbare Produkte oder Dienste. Die verfügbaren Algorithmen sind:

#### *Gekoppelte Algorithmen (Atmosphärenkorrektur + Chlorophyll-a):*

- ▶ 1 MPH (Matthews et al. 2012; Matthews und Odermatt 2015)
- ▶ 2 MPH Pitarch (Matthews et al. 2012; Pitarch et al. 2017)
- ▶ 3 C2RCC (Doerffer und Schiller 2007; Brockmann et al. 2016)
- ▶ 4 MIP (Heege et al. 2014)
- ▶ 5 FUB WeW (Schroeder et al. 2007b)

#### *Atmosphärenkorrekturalgorithmen:*

- ▶ 6 iCOR (Sterckx et al. 2015)
- ▶ 7 ACOLITE (Vanhellemont 2019)
- ▶ 8 Sen2COR (Louis et al. 2016)
- ▶ 9 Polymer (Steinmetz et al. 2011)

*Bandalgorithmen zur Bestimmung der Chlorophyll-a Konzentration (Atmosphärenkorrektur als Vorabschritt notwendig):*

- ▶ 10 Band Algorithmus (Gons 2004)
- ▶ 11 Three-band model (Gitelson et al. 2008)
- ▶ 12 Three-band model, two-band Model (Moses et al. 2009)
- ▶ 13 OC4 (O'Reilly et al. 2000)


*Biophysikalisch-optische Inversionsmodelle zur Chlorophyll-a Bestimmung (Atmosphärenkorrektur als Vorabschritt notwendig):*

- ▶ 14 WASI2D (Gege 2014a)
- ▶ 15 Bomber (Giardino et al. 2012)

*Dienste/ verfügbare Produkte für Chlorophyll-a:*

- ▶ 16 Binnengewässerprodukte des Copernicus Global Land Monitoring Service (CGLOPS) (Simis et al. 2020b)

**Abbildung 3: Bewertungsmatrix zur Vorauswahl von Algorithmen für den Indikator Frühjahrsalgenblüte in Seen**



Quelle: eigene Darstellung, CAU Kiel, Brockmann Consult GmbH


### Wassertemperatur in Seen

Abbildung 4 zeigt die Bewertung für Algorithmen, die für die Berechnung der Wassertemperatur berücksichtigt wurden. Die verfügbaren Algorithmen und Produkte sind:

- ▶ 1 MOD11/MYD11: MODIS Landoberflächentemperaturprodukt
- ▶ 2 CCI Lakes Lake Surface Water Temperature Produkt (<https://climate.esa.int/en/projects/lakes/about/>)

- ▶ 3 Sentinel-3 Level 2 land surface temperature Produkt (<https://sentinels.copernicus.eu/web/sentinel/user-guides/sentinel-3-slstr/product-types/level-2-lst>)
- ▶ 4 AST\_08 ASTER Landoberflächentemperaturprodukt ([https://lpdaac.usgs.gov/products/ast\\_08v003/#:~:text=Description,and%2012%20%C2%B5m%20spectral%20range](https://lpdaac.usgs.gov/products/ast_08v003/#:~:text=Description,and%2012%20%C2%B5m%20spectral%20range))
- ▶ 5 SW L8 I Split-Window-Algorithmus für Landsat 8 TIRS (Rozenstein et al. 2014)
- ▶ 6 SW L8 II Split-Window-Algorithmus für Landsat 8 TIRS (Jimenez-Munoz et al. 2014)
- ▶ 7 SW L8 III Split-Window-Algorithmus für Landsat 8 TIRS (Du et al. 2015)
- ▶ 8 Multi-Sensor-Prozessierungskette (Pareeth et al. 2017)
- ▶ 9 NLSST (Politi et al. 2012)
- ▶ 10 MCSST (Politi et al. 2012)
- ▶ 11 IMWA: Improved Mono-Window Algorithm (Wang et al. 2015; Qin et al. 2001)
- ▶ 12 SC: Single-Channel Algorithm (Sobrino et al. 2004)
- ▶ 13 RTE NASA (Barsi et al. 2006)
- ▶ 14 Pre-operationelles Landsat Land surface temperature Produkt (Schaeffer et al. 2018)
- ▶ 15 PyQGIS Plugin (Ndossi und Avdan 2016)
- ▶ 16 MuSenAlp SNAP Plugin (Verfahren basieren auf Lieberherr und Wunderle 2018)

**Abbildung 4: Bewertungsmatrix zur Vorauswahl von Algorithmen für den Indikator Wassertemperatur in Seen**




Quelle: eigene Darstellung, CAU Kiel, Brockmann Consult GmbH

### Eisbedeckung von Seen

Abbildung 5 zeigt die Bewertung für Algorithmen, die für die Eisdetektion berücksichtigt wurden. Die verfügbaren Algorithmen und Produkte sind:

- ▶ 1 CGlobS LIE: Copernicus Global Land Service Lake Ice Extent Produkt (Heinilä et al. 2017)
- ▶ 2 MOD10A1: MODIS Schneeprodukt (<https://modis-snow-ice.gsfc.nasa.gov/?c=MOD10A1>)
- ▶ 3 MODIS LST: MODIS Land surface temperature Produkt (<https://modis.gsfc.nasa.gov/data/dataproduct/mod11.php>)
- ▶ 4 Sen2Cor Klassifikationsmaske
- ▶ 5 Landsat Fmask: Qualitätsband des Landsat Level 1C Produkts
- ▶ 6 Nahinfrarot-Schwellwertverfahren (nach Heinilä et al. 2017)
- ▶ 7 Red-Schwellwertverfahren (Zhang und Pavelsky 2019)
- ▶ 8 WICI (Barbieux et al. 2018)
- ▶ 9 Brightness Temperatur Profil (Latifovic und Pouliot 2007)
- ▶ 10 LSWT-Schwellwertverfahren (Weber et al. 2016)
- ▶ 11 HH-HV-Schwellwertverfahren (Geldsetzer et al. 2010)
- ▶ 12 Temporal (Murfit et al. 2018)
- ▶ 13 Grey-Level Co-Occurrence Matrix (GLCM), HH-HV SVM (Support Vector Machine-Klassifikation) (Zakhvatkina et al. 2017)
- ▶ 14 GLCM, VV-VH SVM (Support Vector Machine-Klassifikation) (Barbieux et al. 2018)
- ▶ 15 InSAR Coherence (van der Sanden et al. 2018)
- ▶ 16 HH-HV deep neural network (Tom et al. 2020)

**Abbildung 5: Bewertungsmatrix zur Vorauswahl von Algorithmen für den Indikator Eisbedeckung von Seen**

Quelle: eigene Darstellung, CAU Kiel, Brockmann Consult GmbH

Auf Basis der Bewertungen wurden die geeigneten Algorithmen (höchste Gesamtbewertung) für die Fallstudien ausgewählt. Für die Cyanobakterien war das der MPH Algorithmus. Bei der Wassertemperatur untersuchten wir das European Space Agency (ESA) CCI Lakes Produkt „Lake surface water temperature“ genauer sowie den Single-Channel-Algorithmus (SC) und Improved-Mono-Window-Algorithmus (IMWA). Im Verlauf des Projekts veröffentlichte der USGS das Collection 2 Level 2 Science Product „Surface temperature“ (Crawford et al. 2023), das ebenfalls validiert wurde. Für die Frühjahrsalgenblüte wurden gekoppelten Algorithmen zur Bestimmung der Chlorophyll-a Konzentrationen und Durchführung der Atmosphärenkorrektur genutzt (C2RCC, C2X-Complex, MPH, MPH Pitarch). Daneben wurden vier unabhängige Algorithmen zur Chlorophyll-a Bestimmung getestet (OC3, OC4, Gilerson, Gons), bei denen vorab eine Atmosphärenkorrektur mit ACOLITE und C2RCC durchgeführt wurde. Für die Eisbedeckung wurden maschinelle Lernverfahren (insbesondere SVM) zur Klassifikation herangezogen. Fallstudien an 27 Seen dienten dazu, die Verfahren zu validieren und die genauesten und am besten geeignetsten in operationelle Routinen umzusetzen. Die Ergebnisse der Validierungen aus den Fallstudien befinden sich im Anhang (Kapitel B). Die Validierungsergebnisse im Hauptteil des Schlussberichts basieren auf allen Seen, die im AP Operationalisierung untersucht wurden.

### Gründächer in Großstädten

Um Gründächer zu erfassen, benötigt man Sensoren mit einer räumlichen Auflösung, die deutlich feiner ist als die zu betrachtenden Dachflächen. Für die Fallstudien wurden Colour-Infrarot (CIR)-Orthofotos (40 cm), RapidEye (ca. 5 m) und PlanetScope (ca. 3,5 m) sowie Sentinel-2 MSI (10 m) in Betracht gezogen.


Um in diesen Daten Gründächer zu klassifizieren, gibt es zwei unterschiedliche Verfahren: Nahinfrarot-Schwellwertverfahren (NIR-SWV; bspw. Ansel et al. 2016) und objektbasierte Klassifikationen (Mallinis et al. 2014). Zusätzlich benötigt man Hausumringe oder -umrisse, um

die Dachfläche von anderen Grünflächen abzugrenzen und Dachinformationen, bspw. aus Schwellwertverfahren (SWV) mit digitalen Oberflächenmodellen (DOM; Ansel et al. 2016) oder 3D-Stadtmodell-Daten, sog. Level of Detail 2 (LoD2) Daten. Alternativ könnte für den Indikator bei Städten, die Gründächer regelmäßig erfassen, der jeweilige Stand des Monitorings abgefragt werden (Recherche). Da dies nur in wenigen Städten wie bspw. Hamburg und Berlin der Fall ist, wurde diese Variante für den Indikator ausgeschlossen. Für die anderen Verfahren wurde dasselbe Bewertungsschema wie für die See-Indikatoren angewendet. Die bewerteten Daten und Algorithmen sind

- ▶ 1 NDVI Schwellwertverfahren
- ▶ 2 Objektbasierte Luftbilddauswertung
- ▶ 3 Schwellwertverfahren mit DOM
- ▶ 4 LoD2-Daten
- ▶ 5 Recherche

Abbildung 6 stellt die Ergebnisse der Bewertungsmatrix graphisch dar. Für die Fallstudien konzentrierte sich das Projektteam demnach auf ein Schwellwertverfahren mit Vegetationsindizes und LoD2 Daten.

**Abbildung 6: Bewertungsmatrix zur Vorauswahl von Algorithmen für den Indikator Gründächer in Großstädten**



Quelle: eigene Darstellung, CAU Kiel, Brockmann Consult GmbH

## 3 Entwicklung von fernerkundungsbasierten DAS-Indikatoren

### 3.1 Untersuchungsgebiete und Datengrundlage

#### 3.1.1 Seen und Talsperren für Impact-Indikatoren

Zunächst wurde eine Liste potenzieller Seen erstellt, die aufgrund von Größe und Form in Frage kamen, um diese mit Satellitendaten zu analysieren. Es wurde darauf geachtet, Seen aus den drei Hauptnaturräumen mit unterschiedlichen Eigenschaften zusammen zu stellen. Diese Liste wurde dem Expertenkreis (EK) Seen der LAWA vorgelegt, um weitere Kriterien (Tabelle 2) einschätzen und neue Seen vorschlagen zu können. Aus dieser wurden zunächst 27 Seen ausgewählt, an denen die Fallstudien von AP2 ausgearbeitet wurden. Im Rahmen der Operationalisierung wurde diese Liste nach erneuter Rücksprache mit den Fachpersonen der Länder auf 54 Seen erweitert (Abbildung 7).

**Tabelle 2: Fragenkatalog, nach dem Seen für die Fallstudien ausgewählt worden sind**

Kategorie	Frage
Relevanz	Wird der See als Fallstudie im DAS-Monitoringbericht 2019 verwendet?
	Wird der See vom LAWA Expertenkreis Seen als relevant für ein künftiges Klimawandelmonitoring angesehen?
Messdaten	Mit welcher räumlichen Auflösung kann der See erfasst werden? (maximale Pixelgröße)
	Sind Messdaten aus einem behördlichen Monitoringprogramm vorhanden?
	Sind Messdaten von Forschungseinrichtungen/ anderen Organisationen vorhanden?
Indikatorbildung	In welchem Hauptnaturraum liegt der See?
	Welchem LAWA-Seetyp ist er zugeordnet?
	Wie häufig treten in dem See Cyanobakterien auf?
	Wie regelmäßig bildet sich Eis auf dem See?

Quelle: eigene Zusammenstellung, CAU Kiel, Brockmann Consult GmbH

Im Anhang befindet sich eine Tabelle (Tabelle 15), die alle Seen und die jeweils betrachteten Indikatoren zusammenfasst.

**Abbildung 7: Karte mit Seen und Talsperren, die in die DASIF-Indikatoren eingehen**



Quelle: Geobasisdaten: © GeoBasis-DE / BKG 2022, Darstellung: CAU Kiel, Brockmann Consult GmbH

Die Validierung verschiedener Sensoren und Algorithmen war ein wesentlicher Bestandteil des Projekts. Dafür wurden in-situ Messdaten benötigt, mit denen die Ergebnisse aus den Satellitendaten verglichen wurden. Aufgrund länderspezifischer Messprogramme und den Vorgaben der Europäischen Wasserrahmenrichtlinie halten die Länder teils umfangreiche Messreihen. Daher fragte das Projektteam erneut per E-Mail über den LAWA Expertenkreis Seen

an, inwiefern für das DASIF-Projekt in-situ Messdaten bereitgestellt werden können. Außerdem wurden gezielt Forschungseinrichtungen wie das Leibniz-Institut für Gewässerökologie und Binnenfischerei (IGB) angeschrieben. Tabelle 3 fasst die angefragten Daten zusammen.

**Tabelle 3: Übersicht über die angefragten in-situ Daten (Quelle: eigene Zusammenstellung)**


Kategorie	Frage
Parameter	Chlorophyll-a Konzentration
	Phaeophytin-Konzentration, falls vorhanden
	Phytoplanktonzusammensetzung nach Algenklassen, Biovolumen
	Trübung, Schwebstoffe, Sichttiefe
	Huminstoffe, Gelbstoffe
	Infos zur Eisbedeckung
Zeitraum	Messbeginn bis Ende 2021
Probentiefe	Alle Messtiefen, wenn mehrere vorhanden sind
Metadaten	Uhrzeit und Datum der Probennahme
	Koordinaten der Messstelle
	Messgerät, falls vorhanden

Der Rücklauf war insgesamt sehr gut, sodass für den Großteil der untersuchten Seen (Ausnahme: Eisbedeckung) in-situ Daten vorlagen. Daten zur Eisbedeckung waren nur am Großen Müggelsee durch das IGB vorhanden und vereinzelt als Kommentar bei Messungen an den Talsperren. Die übermittelten Datensätze waren unterschiedlich aufgebaut und wurden in einer Datenbank harmonisiert zusammengeführt.

### 3.1.2 Städte für Gründachanalyse

Die Fallstudie zu Gründächern wurde in der Stadt Dresden durchgeführt, da hier Vergleichsdaten durch das Umweltamt – Bereich Stadtökologie vorlagen. Innerhalb der Diskussion zur Indikatorentwicklung für den DAS-Bericht 2023 wurde die Analyse auf 15 Städte mit einer Bevölkerung von mehr als 500 000 Personen (vgl. Abbildung 8) ausgeweitet. Duisburg ist als 15. Stadt, die sich nahe der 500 000-Marke befindet, mit eingeschlossen in der Analyse.

**Abbildung 8: Karte der deutschen Großstädte > 500 000 Einwohner\*innen (inkl. Duisburg), für die in DASIF die Gründachanalyse durchgeführt wurde**



Quelle: Geobasisdaten: © GeoBasis-DE / BKG 2022, Darstellung: CAU Kiel, Brockmann Consult GmbH

### 3.2 Validierung der geophysikalischen Parameter

Um die Algorithmen quantitativ zu bewerten, wurden Vergleichsdaten aus in-situ Messungen und Beobachtungen (Kapitel 3.1) genutzt. Details zu den Datensätzen stehen in den einzelnen

Kapiteln zu den Indikatoren. Zwischen den Vergleichsdaten und den per Fernerkundung ermittelten Werten wurden verschiedene Gütemaße berechnet (Tabelle 4). Die Chlorophyll-a Konzentration, verwendet als Proxy für die Frühjahrsalgenblüte, und Wassertemperatur sind kontinuierliche Variablen, bei denen von einem linearen Zusammenhang zwischen in-situ Messungen und Fernerkundungsergebnis ausgegangen wird. Die berechnete Gütemaße basieren auf Streudiagrammen und der Verteilung der Daten. Bei den Indikatoren Eisbedeckung von Seen, Cyanobakterienbelastung von Badegewässern und Gründächer in Großstädten sind die Fernerkundungsergebnisse und ggf. in-situ Daten in kategorische Variablen klassifiziert. Die berechneten Gütemaße beruhen auf Kreuztabellen oder Konfusionsmatrizen. Die absoluten Gütemaße wurden in tabellarischer Form zusammengefasst.

Die nachfolgenden Kapitel beschreiben die Validierungsergebnisse für die operationell implementierten Algorithmen und basieren auf der Datengrundlage der 54 Seen. Die Ergebnisse der Fallstudien, in denen mehrere Algorithmen in 27 Seen verglichen wurden, sind im Anhang (Kapitel B) beschrieben.

**Tabelle 4: Ausgewählte Gütemaße, um die Algorithmen quantitativ zu bewerten. Absolute Gütemaße werden tabellarisch zusammengefasst**

Gütemaß	Einheit	Link zur Berechnungsquelle oder Formel
<b>Kontinuierliche Variablen</b>		
R <sup>2</sup> (Bestimmtheitsmaß)	[-]	<a href="#">Scipy LinRegress</a> (Funktion aus dem Python Modul Scipy)
Steigung der Regressionsgeraden	[-]	<a href="#">Scipy LinRegress</a> (Funktion aus dem Python Modul Scipy)
y-Achsen Schnittpunkt der Regressionsgeraden	wie Variable	<a href="#">Scipy LinRegress</a> (Funktion aus dem Python Modul Scipy)
RMSE (Root-mean-squared error)	wie Variable	$\sqrt{\sum_{i=1}^n \frac{(insitu - FE)^2}{n}}$
Mean AE (Mean absolute error)	wie Variable	<a href="#">Sklearn Mean Absolute Error</a> (Funktion aus dem Python Modul Sklearn)
Median AE (Median absolute error)	wie Variable	<a href="#">Sklearn Median Absolute Error</a> (Funktion aus dem Python Modul Sklearn)
Bias	wie Variable	$\left  \frac{\sum_{i=1}^n (insitu - FE)}{n} \right $
MAPD (Median absolute percentage difference)	[%]	$\frac{1}{n} \sum_{i=1}^n \left  \frac{insitu - FE}{insitu} \right  * 100$
<b>Kategorische Variablen</b>		
Overall Accuracy	[%]	<a href="#">Sklearn Classification Report</a> (Funktion aus dem Python Modul Sklearn)
Balanced Accuracy	[%]	<a href="#">Sklearn Balanced Accuracy</a> (Funktion aus dem Python Modul Sklearn)

Gütemaß	Einheit	Link zur Berechnungsquelle oder Formel
F1-Score	[-]	<a href="#">Sklearn Classification Report</a> (Funktion aus dem Python Modul Sklearn)
Sensitivity	[%]	<a href="#">Sklearn Classification Report</a> (Funktion aus dem Python Modul Sklearn)
Specifity	[%]	<a href="#">Sklearn Classification Report</a> (Funktion aus dem Python Modul Sklearn)
Precision	[%]	<a href="#">Sklearn Classification Report</a> (Funktion aus dem Python Modul Sklearn)

Quelle: eigene Zusammenstellung, CAU Kiel, Brockmann Consult GmbH

### 3.3 Cyanobakterienbelastung von Badegewässern

#### Biophysikalische Datengrundlage

Der Indikator Cyanobakterienbelastung von Badegewässern betrachtet die Cyanobaktierenvorkommen für die beiden Zustände „im Wasser gelöste Cyanobakterien“ und „aufgerahmte Cyanobakterien“. Beide bedürfen unterschiedlicher Algorithmen und ihre Erfassung stellt unterschiedliche Anforderungen an die Sensoreigenschaften dar. Um Cyanobakterien zu erkennen, wurde der MPH-Algorithmus ausgewählt, der für die beiden Sensoren Sentinel-3 OLCI und ENVISAT MERIS verwendet wird (Tabelle 5). Algorithmen für die Erkennung von Cyanobakterien mit dem räumlich hochaufgelösten Satellitensensor Sentinel-2 MSI wurden ebenfalls in Betracht gezogen. Eigene Untersuchungen haben gezeigt, dass die Unsicherheiten für diesen Sensor aufgrund fehlender Kanäle in wichtigen Wellenlängenbereichen zu hoch sind. Die nachfolgenden Analysen beziehen sich daher ausschließlich auf die räumlich grob aufgelösten Ocean-Colour-Sensoren.

**Tabelle 5: Übersicht und Referenzen zu den operationell umgesetzten Algorithmen und Daten für Cyanobakterien**

Name	Sensor	Quelle
MPH	Sentinel-3 OLCI	Matthews et al. 2012; Matthews und Odermatt 2015
	ENVISAT MERIS	Matthews et al. 2012; Matthews und Odermatt 2015

Quelle: eigene Zusammenstellung, CAU Kiel, Brockmann Consult GmbH

Die biophysikalische Datengrundlage für den Indikator ist ein Cyanobakterien-Marker, der angibt, ob für ein Satellitenpixel Cyanobakterien erkannt werden oder nicht. Der Cyanobakterien-Marker wird mit dem MPH-Algorithmus bestimmt. Der Algorithmus MPH (Matthews und Odermatt 2015; Matthews et al. 2012) kombiniert die Korrektur der Rayleigh-Streuung und die Berechnung des Wasserinhaltsstoffes Chlorophyll-a. Die Korrektur der Rayleigh-Streuung normalisiert das Top-of-Atmosphere (TOA) Signal für Gas- und Rayleigh-Effekte, insbesondere wird die Absorption von Wasserdampf bei 709 nm korrigiert. Die Rayleigh-Korrektur vernachlässigt den Einfluss von absorbierenden Aerosolen. MPH steht für Maximum Peak-Height, da der Algorithmus die Magnitude und die Position der Chlorophyll-a-Fluoreszenz und der Absorptionspeaks im roten, den red-edge und den nahinfraroten Bändern bei 681, 709 und 753 nm verwendet. Der MPH-Algorithmus deckt verschiedene Zustände von Gewässern ab: eutrophe Zustände mit dominanten Eukaryoten oder dominanten Cyanobakterien und hoch eutrophen Zuständen mit aufgeschwemmten Algen oder aufgerahmten Cyanobakterien. Da der Algorithmus mit den roten und red-edge Bändern

arbeitet, kann er für oligotrophe Gewässer, in denen Chlorophyll-a vor allem im blauen Spektralbereich absorbiert, keine verlässlichen Konzentrationen erfassen. Die untere Erfassbarkeitsgrenze liegt bei etwa  $10\text{mg}/\text{m}^3$ .

Für die Cyanobakterienerfassung selbst wird die Reflexion im Band bei 620 nm genutzt, basierend auf dem spektralen Verhalten von Phycocyanin, das im Gegensatz zu Chlorophyll-a ein deutlicheres Absorptionsmaximum bei 620 nm aufweist. Um zwischen den im Wasser befindlichen und den aufgerahmten Cyanobakterien zu unterscheiden, verwendet der MPH-Algorithmus einen Schwellwert, der aus dem NDVI ermittelt wird. Bei dem ausgewählten MPH-Algorithmus handelt es sich ausschließlich um eine Bestimmung von Cyanobakterienvorkommen und der Berechnung der gesamten Chlorophyll-a-Konzentration im Wasser und im aufgerahmten Zustand. Das Biovolumen von Cyanobakterien wird hingegen nicht berechnet. Aus den Satellitendaten wird ein Cyanobakterien-Marker bestimmt, der angibt, ob Cyanobakterien in einem Pixel detektiert wurden (1) oder nicht detektiert wurden (0). Eine zusätzliche Bedingung für einen positiven Cyanobakterien-Marker ist eine berechnete Chlorophyll-a-Konzentration von mindestens  $10\ \mu\text{g}/\text{L}$ .

### Ergebnisse der Validierung

Für die Cyanobakterienerkennung wird angenommen, dass das aus den Satellitendaten bestimmte Cyanobakterienvorkommen aus der oberen Schicht der Wassersäule stammt. Cyanobakterien, die in tieferen Schichten der Wassersäule vorkommen, können nicht mit Hilfe von Satellitendaten detektiert werden, sofern sie sich unterhalb der Sichttiefe befinden.

Um den Cyanobakterien-Marker mit den in-situ Daten zu vergleichen, mussten zunächst die in-situ Daten ebenfalls in eine ja/nein Kategorie einsortiert werden. Für die Validierung der Satellitendaten wurden bestimmte Bedingungen für die in-situ Messungen gesetzt, u. a. ab wann eine dominante Cyanobakterienblüte vorherrscht. Unterschiedliche Bedingungen wurden im ersten Workshop mit den Fachpersonen diskutiert.

Die folgenden Bedingungen wurden erarbeitet und müssen erfüllt sein, damit die Cyanobakterienerkennung positiv für die in-situ Messungen zählt:

- ▶ Chlorophyll-a Konzentration von mindestens  $10\ \mu\text{g}/\text{L}$  und
- ▶ Cyanobakterienbiovolumen größer als 55 % des Gesamtbiovolumens und
- ▶ Cyanobakterienbiovolumen größer als  $1\ \text{mm}^3/\text{L}$  oder
- ▶ Wenn die Cyanobakterienkonzentration gegeben ist, muss diese größer als 55 % der gesamten Chlorophyll-a Konzentration sein

Für die Validierung wurden die Messdaten von Cyanobakterienvorkommen aus der DASIF Datenbank ausgewählt, die am nächsten zur Oberfläche gemessen wurden und eine Tiefe von 5 m nicht überschreiten. Eine weitere Bedingung war die zeitliche Messung innerhalb von zwei Tagen vor oder nach der Satellitenaufnahme. Bei den manuell erfassten in-situ Cyanobakterien Messungen wurden nicht immer die Information der Aufnahmeuhrzeit mitgeliefert. Es wurde davon ausgegangen, dass die Beprobung am Tag durchgeführt wurde. Bei den Sondendaten an der Alster in Hamburg wurde der Tagesmittelwert der Cyanobakterienkonzentration verwendet. Für die Validierung wurden die Satellitenmessungen eines Pixelbereiches von  $3 \times 3$  Pixeln um die Koordinaten der Messstellen extrahiert. Die verwendete räumliche Auflösung beträgt bei Sentinel-3 OLCI und ENVISAT MERIS 300 m. Eine Aufnahme wurde berücksichtigt, wenn mindestens 3 von 9 Pixeln gültig waren. Ausreißer innerhalb dieses Ausschnittes wurden

identifiziert und eliminiert. Dadurch wurden nur repräsentative Pixel mit guter Abdeckung berücksichtigt. Aus den gültigen Pixeln der verbliebenen Aufnahmen wurde der Median und das arithmetische Mittel des 3 x 3 Pixelbereiches berechnet. Wenn der Mittelwert für den Cyanobakterien-Marker über 0,3 lag, wurde von einer Cyanobakterienblüte ausgegangen. Dies lässt sich übersetzen mit mindestens 30% der gültigen Pixel, die einen Cyanobakterien-Marker aufweisen müssen.

Die so ermittelten Ergebnisse von Cyanobakterienvorkommen aus Satellitendaten und in-situ Daten wurden einander gegenübergestellt. Tabelle 6 fasst die Gütemaße der Cyanobakterienindikation für die beiden Sensoren ENVISAT MERIS und Sentinel-3 OLCI zusammen. Die Gütemaße für Sentinel-3 OLCI sind generell höher als für ENVISAT MERIS. Die niedrigeren Gütemaße für ENVISAT MERIS zeigen, dass der Algorithmus nicht immer funktioniert. Mögliche Gründe für geringere Gütemaße sind Fehlidentifikationen durch flache oder zu schmale/kleine Gewässer oder starker Makrophytenbewuchs auf dem Gewässergrund.

**Tabelle 6: Gütemaße der Cyanobakterienindikation für Sensoren ENVISAT MERIS und Sentinel-3 OLCI**

Gütemaß	ENVISAT MERIS MPH, n=31	Sentinel-3 OLCI MPH, n=24
Overall accuracy	0.835	0.925
Precision	0.775	0.899
Recall	0.765	0.895
F1-Score	0.77	0.9
balanced overall accuracy	0.765	0.895

Quelle: eigene Zusammenstellung, CAU Kiel, Brockmann Consult GmbH


### Vom Pixel zum Indikator

Um von den einzelnen Pixelwerten zum Indikator zu gelangen, müssen verschiedene zeitliche und räumliche Aggregierungsstufen durchlaufen werden. Die erste räumliche Aggregation findet innerhalb eines Sees zum Aufnahmezeitpunkt statt. Die räumliche Grundfläche ist ein Polygonshapefile des Seeumrisses, der Bereiche des Sees mit Bodenreflexion, also Flachwasserbereiche, ausschließt. Diese Bodenreflexion wurde manuell ausgeschlossen und auf alle optischen Sensoren angewendet. Für den verbliebenen Bereich wurde der Median, das arithmetische Mittel und die Perzentile 5, 10, 90 und 95 für jede Aufnahme für jeden See berechnet. Damit eine Aufnahme in die Zeitserie mit eingeht, müssen mindestens 30 % der maximal möglichen Pixel des Sees pro Aufnahme valide sein. Für eine gesamte Aufnahme wird ein positiver Cyanobakterien-Marker detektiert, wenn von allen gültigen Pixeln wiederum mindestens 30 % einen positiven Cyanobakterien-Marker aufweisen und eine Chlorophyll-a Konzentration von mindestens 10µg/L berechnet wurde. Aus den berechneten Cyanobakterien-Markern der Aufnahmen ergibt sich pro See eine Zeitreihe mit unterschiedlicher Aufnahmefrequenz. Die Wolkenbedeckung am Aufnahmezeitpunkt, die Lage und Größe des Sees beeinflussen die Anzahl der gültigen Aufnahmen.

Abbildung 9 zeigt den Jahresverlauf des berechneten Cyanobakterien-Markers im Speicher Witznitz in Sachsen mittels einer Heatmap. Die Farbe zeigt, bei wie viel Prozent der gültigen Überflüge Cyanobakterien registriert wurden. Die Größe der Kreise symbolisiert die gesamte Anzahl der gültigen Überflüge je Monat. Dadurch kann eingeschätzt werden, ob es sich um ein

Jahr mit vielen gültigen Überflügen handelt oder um ein Jahr mit starken Einschränkungen durch die Wetterverhältnisse. Die Abbildung weist einen Zeitsprung von 2012 - 2016 auf, da hier keine für die Cyanobakterienerkennung nutzbaren Sensoren verfügbar waren.

**Abbildung 9: Heatmap des Cyanobakterien-Markers im Speicher Witznitz. Die Größe der Kreise zeigt die Häufigkeit gültiger Überflüge. Zu beachten ist ein Zeitsprung zwischen 2012 und 2016 in der y-Achse**




Quelle: eigene Darstellung, CAU Kiel, Brockmann Consult GmbH

Aus der Heatmap wird deutlich, dass im Speicher Witznitz regelmäßig Cyanobakterien detektiert werden. Allerdings fehlen v.a. bei schlechten Wetterbedingungen Daten für ganze Monate, wie im Jahr 2017. Das verringert die Möglichkeiten, Cyanobakterien zu erkennen und vergrößert die Unsicherheiten in Bezug auf die Repräsentativität der erfassten Blüten. Es ist nicht immer möglich, Ergebnisse zu überprüfen, da in-situ Messungen für Cyanobakterien unregelmäßig stattfinden. Ein Beispiel sind die Jahre 2007 und 2008, bei denen keine Cyanobakterien im Sommer detektiert wurden und für die keine in-situ Daten vorliegen, um dies zu belegen.

Der Indikator Cyanobakterienbelastung von Badegewässern beschreibt die Entwicklung von Cyanobakterienvorkommen im Verlauf der Jahre. Für die Berechnung des Indikators wird die Anzahl der Tage mit Cyanobakterienvorkommen bestimmt und kein Biovolumen und auch keine Konzentration herangezogen. Die Anzahl der Tage mit einem positiven Cyanobakterien-Marker wird ins Verhältnis zu den gültigen Überflügen gesetzt, um die Cyanobakterienbelastung des Gewässers einzuschätzen. Je höher das Verhältnis der beiden zueinander ist, desto höher ist die Cyanobakterienbelastung eines Sees in einem Zeitraum.

Abbildung 10 stellt die Ergebnisse des Indikators Cyanobakterienbelastung von Badegewässern für den Speicher Witznitz dar. Dargestellt werden die Cyanobakterien-Marker Tage und die gültigen Aufnahme tage als Säulendiagramm, um die Datenverfügbarkeit für das Jahr einschätzen zu können. Als Zeitserie (Linie) ist das Verhältnis der beiden Parameter für jedes Jahr dargestellt, was den Verlauf der Cyanobakterienbelastung über die Jahre abbilden soll. Die Zeitserie zeigt, dass die Cyanobakterienbelastung sehr variabel ist. In den Jahren 2007-2009 wurden sehr wenige Cyanobakterien registriert, obwohl es ausreichend gültige Überflüge für diese Jahre gibt. Die Jahre 2016 - 2019 zeigen ein sehr stabiles und hohes Niveau der Cyanobakterienbelastung. Im Workshop wurde diskutiert, welcher Zeitraum bedeutend für die Cyanobakterienerkennung und den Indikator ist. Es wurden unterschiedliche Zeiträume festgehalten, die wichtig sind, um die Entwicklung von Vorkommen zu untersuchen. In Abbildung 10 wurden die beiden Zeiträume Sommer (Juli, August, September) und Saison (Mai-Oktober) dargestellt. Aufgrund der geringeren Unsicherheit durch einen längeren Betrachtungszeitraum und betonter Wichtigkeit in Fachgesprächen wurde die Saison als Zeitraum ausgewählt.


**Abbildung 10: Indikatorberechnung Cyanobakterienbelastung von Badegewässern am Beispiel des Speicher Witznitz**



Quelle: eigene Darstellung, CAU Kiel, Brockmann Consult GmbH

Für die bundesweite Aggregation erfolgt die Einteilung der Seen in verschiedene Belastungsstufen basierend auf dem Cyanobakterien-Indikatorwert. Eine geringe bzw. keine Belastung wurde definiert, wenn keinerlei Indikation von Cyanobakterien bei Überflügen festgestellt wurde. Die mittlere Belastung wurde festgelegt, wenn höchstens 20 % der gültigen Überflüge auf Cyanobakterien hinwiesen, während eine hohe Belastung vorlag, wenn mehr als 20 % der Überflüge eine entsprechende Indikation zeigten. Der Indikator setzt sich nun aus der Summe der betrachteten Seen in jeder Kategorie zusammen. Abbildung 11 zeigt die finale Abbildung des bundesweiten Cyanbakterien Indikators. Eine höhere Anzahl an Seen einer hohen oder mittleren Belastungsstufe entspricht Jahren mit besonders häufiger Cyanobakterien-Indikation.

**Abbildung 11: Bundesweiter Indikator Cyanobakterienbelastung von Badegewässern**



\* keine geeigneten Satelliten in Betrieb

Datenquelle: CAU Kiel, Brockmann Consult GmbH (Auswertung von Satellitendaten)

Quelle: Umweltbundesamt (UBA) 2023

### 3.4 Frühjahrsalgenblüte in Seen

#### Biophysikalische Datengrundlage

Die biophysikalische Grundlage des Indikators für die Frühjahrsalgenblüte basiert auf der Berechnung der Chlorophyll-Konzentration und deren zeitlichem Verlauf als Proxy für den Zeitpunkt des Frühjahrsblüteeintrittes.

Es wurden drei verschiedene Satellitensensoren verwendet, um die Frühjahrsalgenblüte zu bestimmen. Hierzu gehören der Sentinel-2 MSI, Sentinel-3 OLCI sowie ENVISAT MERIS. Der Einsatz verschiedener Satellitensensoren trägt dazu bei, zeitliche und räumliche Informationen über die Frühjahrsalgenblüte zu erfassen.

Für die Berechnung der Chlorophyll-a Konzentration wurden **gekoppelte Algorithmen verwendet**, die neben der Atmosphärenkorrektur auch die Berechnung der Chlorophyll-a Konzentration beinhalten (Tabelle 7).

**Tabelle 7: Übersicht und Referenzen zu den in den Fallstudien zur Frühjahrsalgenblüte untersuchten Algorithmen und Daten**

Name	Sensor	Quelle
C2RCC v2.0	Sentinel 3 OLCI	Doerffer und Schiller 2007; Brockmann et al. 2016
	MERIS	Doerffer und Schiller 2007; Brockmann et al. 2016
C2X-COMPLEX	Sentinel-2 MSI	Doerffer und Schiller 2007; Brockmann et al. 2016
MPH (BRR + CHL)	Sentinel-3 OLCI	Matthews et al. 2012; Matthews und Odermatt 2015
MPH Pitarch	Sentinel-3 OLCI	Pitarch et al. 2017

Quelle: eigene Zusammenstellung, CAU Kiel, Brockmann Consult GmbH

Der C2RCC Algorithmus (Doerffer und Schiller 2007; Brockmann et al. 2016) hat sich aus dem ursprünglich für MERIS entwickelten Algorithmus „Case 2“ entwickelt. Ein Modell für wasserinhärente optische Eigenschaften und ein gekoppeltes Wasser-Atmosphäre-Strahlungstransfermodell werden verwendet, um eine sehr große Anzahl von simulierten Wasserreflexions- und TOA-Reflexionsspektren aus verschiedenen Kombinationen von Konzentrationen der Wasserinhaltsstoffe und unterschiedliche atmosphärische Bedingungen zu erzeugen. Diese simulierten TOA-Reflexionsspektren werden verwendet, um neuronale Netze zu trainieren, die dann jedes eingegebene TOA-Reflexionsspektrum schnell invertieren kann, um optimale Schätzungen von Wasserreflexion und den Konzentrationen der Wasserinhaltsstoffe darzustellen. Der C2RCC Algorithmus zeigt robuste Leistung unter einer Reihe von Wasser- und Atmosphärenbedingungen, einschließlich extrem absorbierendem und extrem streuendem Wasser. Eine Einschränkung von C2RCC besteht darin, dass das Verfahren davon ausgeht, dass das Wasserreflexionsvermögen den Spektren entspricht, die im Trainingssatz für neuronale Netze vorhanden waren. Wenn ein ungewöhnliches Wasserreflexionsspektrum auftritt, ist die Ausgabe des Algorithmus möglicherweise fehlerhaft. Diese Fälle werden mit "Out-of-Scope" oder „Out-of-Range“ gekennzeichnet. C2RCC ist ein gekoppelter Algorithmus, da er sowohl atmosphärisch korrigierte Wasserreflexionen als auch die Wasserinhaltsstoffe berechnet. Für MERIS und für OLCI werden die Standardnetze in Version 2.0 verwendet und für Sentinel-2 werden die C2X-COMPLEX Netze verwendet. Die trainierten Netze sind besonders von Binnengewässern und deren Konzentrationsbereiche für die Chlorophyll-a Konzentration und die Trübung abdecken. Für Sentinel-3 OLCI wurde zusätzlich der MPH-Algorithmus berechnet, der vermehrt bei nährstoffreichen Gewässern angewendet und mit dem C2RCC gekoppelt wird. Der MPH-Algorithmus wird für nährstoffreiche und der C2RCC Algorithmus für nährstoffärmere Gewässer angewendet.

### Ergebnisse der Validierung

Die Tiefe, für die die aus den Satellitendaten berechnete Chlorophyll-a Konzentration repräsentativ ist, hängt von der Klarheit des Gewässers ab. Bei eutrophen oder schwebstoffhaltigen Gewässern ist die Eindringtiefe des Lichts geringer als bei klaren Gewässern. Es wird davon ausgegangen, dass diese Eindringtiefe für Seen zwischen 0 - 5 m liegt, weswegen die verfügbaren in-situ Daten entsprechend auf die Oberflächenmessungen reduziert wurden.

Für den Indikator Frühjahrsalgenblüte in Seen stellt die Chlorophyll-a-Konzentration im Gewässer die biophysikalische Datengrundlage dar. Tabelle 8 zeigt die Validierungsergebnisse für die in der Operationalisierung verwendeten Algorithmen.


**Tabelle 8: Tabellarische Darstellung der berechneten Gütemaße über alle Messpunkte pro Sensor und Algorithmus – Chlorophyll-a Konzentration**

R <sup>2</sup>	Steigung	y-Achse [µg/L]	RMSE [µg/L]	Mean AE [µg/L]	Median AE [µg/L]	Bias [µg/ L]	MAPD [%]	n	Set
Sentinel 2									
0.75	0.76	4.35	16.75	2.55	9.78	3.69	298	386	C2X COMPLEX
Sentinel 3 OLCI									
0.73	1.07	3.89	24.33	5.12	11.24	4.59	199	698	C2RCC - MPH Pitarch
MERIS									
0.69	1.04	3.77	22.78	3.89	11.39	4.35	123	813	C2RCC

Quelle: eigene Zusammenstellung, CAU Kiel, Brockmann Consult GmbH

### Vom Pixel zum Indikator

Um von den einzelnen Pixelwerten zum Indikator zu gelangen, werden verschiedene zeitliche und räumliche Aggregierungsstufen durchlaufen. Die erste räumliche Aggregation findet innerhalb eines Sees zum Aufnahmezeitpunkt statt. Die räumliche Grundfläche ist ein Polygonshapefile des Seeumrisses, welches Bereiche des Sees mit Bodenreflexion ausschließt. Diese Bodenreflexion wurde, basierend auf Sentinel 2 Daten, manuell definiert und die resultierende Umgrenzung wird auf alle optischen Sensoren angewandt. Der Median, das arithmetische Mittel und die Perzentile 5, 10, 90 und 95 der Chlorophyll Konzentration wurden pro Sensor, See und Aufnahmetag berechnet. Damit eine Aufnahme in die Zeitserie mit eingeht, müssen mindestens 20 % der maximal möglichen Pixel pro Aufnahme valide sein. So ergibt sich pro See eine Zeitreihe mit unregelmäßiger Aufnahmefrequenz. Die Wetterverhältnisse am Aufnahmezeitpunkt beeinflussen die Anzahl der gültigen Aufnahmen. Für die Berechnung der Frühjahrsalgenblüte werden nur Aufnahmen aus den Monaten März, April und Mai berücksichtigt. Analysen haben gezeigt, dass der Monat Februar unverlässliche Ergebnisse liefert und daher nicht im Indikator berücksichtigt wird. Abbildung 12 zeigt den berechneten Wochenmedian der Chlorophyll-a-Konzentration des Kummerower Sees in einer Heatmap im Betrachtungszeitraum Frühjahr. Es gibt einen Zeitsprung zwischen 2012 und 2016 aufgrund der Datenlücke in den Satellitendaten.

**Abbildung 12: Heatmap der Chlorophyll-a Konzentration im Frühjahr - Kummerower See**

Quelle: eigene Darstellung, CAU Kiel, Brockmann Consult GmbH

Aus den Heatmaps wird deutlich, dass für den Kummerower See regelmäßige Messungen im Frühjahr vorhanden sind. Allerdings fehlen v.a. bei schlechten Wetterbedingungen Daten für ganze Monate. Das erschwert die Bestimmung der Frühjahrsalgenblüte und erhöht die Unsicherheit, dass der genaue Zeitpunkt der Algenblüte erfasst wird.

Stellvertretend für diesen Zeitpunkt wird die Kalenderwoche und der Tag des Jahres ermittelt. Um dieses Datum automatisiert aus den Zeitverläufen zu bestimmen, wird das Perzentil 90 der Chlorophyll-a-Konzentration des gesamten Sees verwendet. Damit wird die komplette räumliche Abdeckung der Seen durch die Satellitendaten genutzt. Es ist allerdings bekannt, dass Frühjahrsalgenblüten nicht im gesamten See auftreten müssen und daher nur lokal erscheinen können. Durch das Perzentil 90 wird diese Möglichkeit mitberücksichtigt, um eine verlässliche Einschätzung einer auftretenden Frühjahrsalgenblüte im See zu erhalten. Gleichzeitig wird der Einfluss von fehlerhaften Extremwerten reduziert. In Fachgesprächen wurde festgelegt, dass für den Indikator die erste auftretende Frühjahrsalgenblüte verwendet wird und nicht die Blüte mit der maximalen Chlorophyll-a Konzentration. Teilnehmende in Workshop-Diskussionen konnten bestätigen, dass die erste Frühjahrsalgenblüte nicht die mit der maximalen Konzentration sein muss. Um dennoch sicherzustellen, dass es sich um eine signifikante Frühjahrsblüte handelt,

wurde festgelegt, dass die Chlorophyll-a Konzentration im Betrachtungszeitraum (Frühjahrsmonate März – Mai) über dem Perzentil 70 der mittleren See- Chlorophyll-a Konzentrationen aller gemessenen Zeitpunkte des Jahres liegen muss. Dies sorgt dafür, dass Algenblüten mit sehr geringer Konzentration und mögliche Fehlmessungen nicht berücksichtigt werden. Damit ergeben sich für den Indikator Frühjahrsalgenblüte in Seen folgende Bedingungen:


- ▶ Die Monate März, April, Mai werden verwendet
- ▶ Der Perzentil 90 des gesamten Sees jeder nutzbaren Aufnahme wird als Chlorophyll-a Wert verwendet
- ▶ Die Chlorophyll-a Konzentration muss größer sein als das Perzentil 70 aller Tageswerte gemittelt über alle Seemittelwerte in dem Betrachtungszeitraum
- ▶ Die Kalenderwoche der Aufnahme, an der das Perzentil 90 zum ersten Mal im Beobachtungszeitraum das Perzentil 70 überschreitet, wird als Zeitpunkt der Frühjahrsalgenblüte festgelegt.

Eine direkte Validierung der Frühjahrsalgenblüte ist auf Grund der unterschiedlichen zeitlichen Auflösungen der in-situ Messungen und der Satellitenmessungen nicht möglich. Aus den einmal monatlich gemessenen in-situ Daten ist es nicht möglich, einen ausreichend genauen Zeitpunkt für die Frühjahrsalgenblüte zu ermitteln. Abbildung 13 stellt die Ergebnisse des Indikators Frühjahrsalgenblüte für die Seen Starnberger See, Müggelsee und Kummerower See basierend auf Satellitendaten dar. Die Zeitreihen zeigen, dass die Zeitpunkte der Frühjahrsalgenblüten zwischen den Jahren und den Seen sehr variabel sind. Der Starnberger See zeigt generell ein früheres Eintreten einer Algenblüte als die beiden anderen Seen. Die grauen Balken zeigen die Anzahl der gültigen Aufnahmen in Tagen. So kann eine erste Einschätzung über die Güte der Bestimmung erfolgen.

**Abbildung 13: Zeitreihe des Indikators Frühjahrsalgenblüte für ausgewählte Seen basierend auf Satellitendaten**

Quelle: eigene Darstellung, CAU Kiel, Brockmann Consult GmbH

Nach ausführlichen Diskussionen wurde vom Expertenkreis vorgeschlagen, die bundesweite Aggregation auf Grundlage der Hauptnaturräume durchzuführen. Dafür wurde der Zeitpunkt der Frühjahrsalgenblüte aller Seen des jeweiligen Naturraums aggregiert (siehe Abbildung 14). Diese Entscheidung wurde aufgrund ihrer Übersichtlichkeit und Relevanz getroffen.

**Abbildung 14: Bundesweite Aggregation und Darstellung des Indikators Frühlingsalgenblüte in stehenden Gewässern**

\* keine Daten, da keine geeigneten Satellitensensoren im Einsatz

Datenquelle: Brockmann Consult GmbH, CAU Kiel (Auswertung von Satellitendaten)

Quelle: Umweltbundesamt (UBA) 2023

### 3.5 Wassertemperatur in Seen

#### Biophysikalische Datengrundlage

Für den Indikator Wassertemperatur in Seen stellt die Landoberflächentemperatur abgeleitet aus thermalen Landsatdaten die biophysikalische Datengrundlage dar. Sie wird aus Daten des vom USGS bereitgestellten Landsat Collection 2 Level 2 Surface Temperatur Produkt abgeleitet (Crawford et al. 2023). Mit der Veröffentlichung der Collection 2 stellt der USGS über alle Landsatsensoren harmonisierte Datensätze mit verbesserter Geolokalisierung zur Verfügung. Außerdem werden erstmalig in globaler Abdeckung atmosphärisch korrigierte Level 2 Produkte bereitgestellt. Um die Oberflächentemperatur abzuleiten, wird ein single-band Algorithmus basierend auf MODTRAN verwendet. Die Ergebnisse werden in Kelvin auf 30 m Pixelgröße ausgegeben. Zu beachten ist, dass je nach Sensor die tatsächliche räumliche Auflösung bei 60 – 120 m liegt (Crawford et al. 2023).

#### Ergebnisse der Validierung

Bei der Interpretation der Temperaturen ist zu beachten, dass es sich bei der Landsat LSWT um Strahlungstemperatur handelt, die aufgrund der Energie, die die Wasseroberfläche emittiert, gemessen wird. Sie bezieht sich auf eine etwa 500 µm feine Grenzschicht zwischen Luft und Wasser (skin temperature). Die in-situ gemessene Temperatur dagegen entspricht der kinetischen ‚bulk‘ Temperatur, die meist wärmer als die LSWT ist (Li et al. 2013). Die Validierungen in DASIF zeigten aber, dass die Messwerte durchaus linear miteinander zusammenhängen und die Differenzen akzeptabel sind (Tabelle 9). Als Grundlage für die in-situ Daten wurden oberflächennahe Messungen zwischen 0 und 0,5 m Tiefe verwendet. Tabelle 9 zeigt die Validierungsergebnisse für die in der Operationalisierung analysierten Seen.

**Tabelle 9: Tabellarische Darstellung der berechneten Gütemaße über alle Messpunkte pro Sensor– Wassertemperatur (LSWT)**

R <sup>2</sup>	Steigung	y-Achse [°C]	RMSE [°C]	Mean AE [°C]	Median AE [°C]	Bias [°C]	MAPD [%]	n
Landsat 5								
0,91	0,96	0,69	2,7	2,1	1,6	0,1	13,1	238
Landsat 7								
0,90	0,99	0,97	3,3	2,2	1,4	0,8	11,1	670
Landsat 8								
0,91	1,0	0,95	3,5	2,3	1,6	1,3	11,0	547


Quelle: eigene Zusammenstellung, CAU Kiel, Brockmann Consult GmbH

### Vom Pixel zum Indikator

Um von den einzelnen Pixelwerten zum Indikator zu gelangen, müssen verschiedene zeitliche und räumliche Aggregierungsstufen durchlaufen werden. Die erste räumliche Aggregation findet innerhalb eines Sees zum Aufnahmezeitpunkt statt. Die räumliche Grundfläche ist ein Polygonshapefile des Seeumrisses, der nach innen 120 m gepuffert ist, um Land-Wasser-Mischpixel und besonders flache Wasserbereiche auszuschließen. Der Median innerhalb dieser Fläche hat sich als robustes Maß erwiesen. Mindestens 45 % der Seepixel müssen valide sein, damit die Aufnahme in die Zeitreihe eingeht.


Aus den Medianwerten der Aufnahmen ergibt sich pro See eine Zeitreihe mit unterschiedlicher Aufnahmefrequenz, je nach Bewölkung und der Lage des Sees in ein oder zwei Landsat-Orbits. Im bestmöglichen Fall (Abdeckung durch zwei Orbits, zwei Sensoren und keine Bewölkung) gibt es sechs Aufnahmen pro Monat und See, meist sind es aber eine oder keine Aufnahme. Abbildung 15 stellt eine solche Zeitreihe am Müggelsee, Bodensee und der Talsperre Saldenbach dar. In den Wintermonaten treten teilweise negative LSWT Temperaturen auf. Es kann sich hierbei um Eisbedeckung handeln, bei der die gemessenen Werte dann nicht mehr die eigentlichen LSWT Werte abbilden. Nach Rücksprache mit dem Fachteam Klimawandel des LAWA AK Seen werden für den Indikator negative Werte auf 0 °C gesetzt. Die negativen Werte könnten die Mittelwertbildung und Trendberechnung verzerren und entsprechen auch nicht der tatsächlichen LSWT.

**Abbildung 15: LSWT Zeitreihen der See-Mediane an Aufnahmetagen am Bodensee (a), Müggelsee (b) und der Talsperre Saidenbach (c)**



Quelle: eigene Darstellung, CAU Kiel, Brockmann Consult GmbH


Die nächste zeitliche Aggregation fasst die Mediane der Aufnahmetermine auf Monatsbasis zu arithmetischen Mitteln zusammen. Abbildung 16 zeigt in einer Heatmap das Ergebnis exemplarisch für den Bodensee, Müggelsee und die Talsperre Saidenbach.

**Abbildung 16: Heatmap der monatlichen LSWT Mittelwerte von Bodensee Obersee (a), Müggelsee (b) und Talsperre Saldenbach (c)**

Quelle: eigene Darstellung, CAU Kiel, Brockmann Consult GmbH

Aus den Heatmaps wird deutlich, dass das Landsat-Archiv für viele Seen lange und vergleichbare Zeitreihen ermöglicht. Allerdings fehlen v.a. in den Winter- und Herbstmonaten wie auch im frühen Frühjahr Daten für ganze Monate. Da Frühjahrsmonate sehr variabel sind und in der Entwicklung der Wassertemperatur große Sprünge auftreten können, wurde in den Diskussionsrunden mit den Fachpersonen eine Interpolation der Frühjahrestemperaturwerte ausgeschlossen. Aufgrund der besseren Datenlagen bieten sich die Sommermonate für einen fernerkundungsbasierten Indikator Wassertemperatur an. Daher bildet das arithmetische Mittel aus den Monatsmitteln der Monate Juni, Juli und August die Datengrundlage für den Indikator.

Die räumliche Aggregation auf Bundesebene kann auf Basis der Naturräume, des LAWA Seentyps, der Trophiestufe, des Bundeslandes, der mittleren Tiefe, maximalen Tiefe, der Seeoberfläche, des Volumens, der mittleren Höhenlage oder des Mischtyps vorgenommen werden. Abbildung 17 zeigt den Indikator beispielhaft bundesweit aggregiert basierend auf der Eigenschaft Hauptnaturräume.

**Abbildung 17: Indikator Wassertemperatur bundesweit aggregiert auf die drei Hauptnaturräume**

Quelle: eigene Darstellung, CAU Kiel, Brockmann Consult GmbH

### 3.6 Eisbedeckung von Seen

#### Biophysikalische Datengrundlage

Für den Indikator Eisbedeckung von Seen sind kategorisierte Werte die Grundlage, d. h. Informationen ob ein Pixel Eis, Wasser oder ungültig (bspw. bei Wolkenbedeckung) ist. Der Indikator Eisbedeckung von Seen konzentriert sich auf den Zeitraum vom 1.11.2014 bis 31.3.2020. In diesem Zeitraum ist die größte Datendichte an räumlich hochauflösenden optischen und Radar-Satelliten verfügbar, d.h. Landsat 8 OLI, Sentinel-2 A und B MSI sowie Sentinel-1 A und B (C-Band). Außerdem gelang es, für diesen Zeitraum am besten alternative Datenquellen zu in-situ Messungen zu finden, insbesondere öffentlich zugängliche Webcam-Aufnahmen.

Wolkenfreie und teilweise bedeckte Sentinel-2 MSI und Landsat 8 OLI Level 1C Daten wurden in 10 bzw. 30 m räumlicher Auflösung mithilfe der GoogleEarth Engine (Gorelick et al. 2017) und Geometrien der Fallstudienseen gesucht und heruntergeladen. Sentinel-1 GRD IW (Ground range detected, interferometric wide-mode) Daten wurden ebenfalls über die GoogleEarth Engine in 10 m räumlicher Auflösung bezogen. Die Vorprozessierung der Sentinel-1 Daten entspricht in der GoogleEarth Engine den Schritten die in der Sentinel-1 Toolbox in SNAP implementiert sind: Update der Orbit-Datei, Reduzierung des Rauschens an Szenenrändern, Korrektur des thermalen Rauschens, radiometrische Kalibrierung und Geländekorrektur mit dem SRTM 30 m Digital Elevation Model.

#### Datensatz zum Trainieren und Validieren eines Klassifikationsalgorithmus


Für den Indikator Eisbedeckung von Seen wurde ein Random Forest Klassifikationsalgorithmus entwickelt. Er zielt darauf ab, Pixel von optischen und/oder Radar-Satellitenbilder in die Klassen Eis und Wasser und evtl. Wolken bzw. ungültig zu klassifizieren. Um zu bestimmen, welche Reflexionswerte (optisch) oder Rückstreuwerte (Radar) Wasser und Eis in verschiedenen Bändern haben, braucht es einen räumlich und zeitlich verorteten Vergleichsdatensatz. Flächendeckende Eisbedeckungsdaten sind allerdings kaum vorhanden. Am Müggelsee wird seit den 1990er Jahren die Eisdicke punktuell erfasst, wenn der See mehr als 80 % eisbedeckt ist. An einigen Thüringer Talsperren sind ähnliche Daten vorhanden. Eisdickenmessungen der Wasserwacht im Allgäu passten zeitlich mit den Satellitendaten nicht zusammen. Die vorhandenen Daten sagen nicht aus, welche Pixel nun tatsächlich eisbedeckt oder eisfrei sind.

Daher entschied das Projektteam basierend auf den vorhandenen optischen Datensätzen mithilfe von Echt- und Falschfarben-RGB Darstellungen Eis und offene Wasserflächen manuell zu digitalisieren. Transparentes Eis ohne Schneebedeckung ist schwierig visuell von Wasser zu trennen. Daher wurden für die Klasse offenes Wasser ausschließlich Monate einbezogen, in denen es unwahrscheinlich ist, dass Eis auftritt, zum Beispiel zwischen Mai und September. Außerdem wurden als unabhängige Datenquelle online archivierte Webcam-Bilder hinzugezogen, die am Brombachsee, Freibergsee, Großen Alpsee und Rottachspeicher verfügbar waren. Verfügbare Webcam-Bilder wurden auf Tagesbasis visuell interpretiert in Eis, kein Eis, teilweise eisbedeckt.

Die Termine wurden mit den optischen Satellitendaten zeitlich verschnitten, um die Polygone der visuell interpretierten Klassen zu verifizieren oder korrigieren. Transparentes Eis blieb allerdings problematisch. Der erstellte Trainings- und Validierungsdatensatz enthält vorwiegend Fälle, in denen eindeutig erkennbar ist, ob es sich um Eis oder Wasser handelte. Das muss bei der Interpretation des Trainings und der Validierung der Klassifikationsmodelle berücksichtigt werden.

Im nächsten Schritt wurden die Polygone mit den Zeitstempeln der Sentinel-1 Daten verschnitten, um einen Trainings- und Validierungsdatensatz für die Radardaten zu erhalten. Ausschließlich Übereinstimmungen am selben Tag gingen in den Datensatz ein, da die Interpretation der Webcam-Bilder zeigte, dass sich die Eisverhältnisse teilweise innerhalb eines Tages stark verändern. Außerdem schränkte die Windgeschwindigkeit den Radardatensatz weiter ein (vgl. Absatz zur Radarklassifikation). Abbildung 18 fasst die verfügbaren Pixel im Trainings- und Validierungsdatensatz nach Sensoren und Klassen zusammen.

**Abbildung 18: Anzahl der Pixel nach Sensoren und Klassen im Trainings- und Validierungsdatensatz**



Quelle: eigene Darstellung, CAU Kiel, Brockmann Consult GmbH

### Maschinelles Lernverfahren

Der im vorigen Abschnitt beschriebene Datensatz wurde in 30 % Validierungs- und 70 % Trainingspixel zufällig geteilt. Auf Basis dieses Datensatzes wurden vier verschiedene Random Forest Modelle trainiert, eines für Landsat-8 OLI, eines für Sentinel-2 MSI und zwei für Sentinel-1, getrennt nach aufsteigendem (ascending) und absteigendem (descending) Orbit. Tabelle 10 fasst die verwendeten Features und Modelle zusammen.


**Tabelle 10: Zusammenfassung der verwendeten Features in den Random Forest Klassifikationsmodellen**

Modell	Landsat 8 OLI	Sentinel-2 MSI	Sentinel-1 ascending	Sentinel-1 descending
Feature	B1, B2, B3, B4, B5, B6, B7, B9	B1, B2, B3, B4, B5, B6, B7, B8, B10, B11, B12	VV, VH, VV_GLCM_Mean	VV, VH, VH_GLCM_Variance, VH_Contrast

Quelle: eigene Zusammenstellung, CAU Kiel, Brockmann Consult GmbH

Die optischen Satellitendaten von Landsat 8 OLI und Sentinel-2 MSI gehen als Level 1 C Daten in den Klassifikationsalgorithmus ein, d. h. sie sind nicht atmosphärisch korrigiert, aber als TOA-Reflexionen ist der Sonnenstand korrigiert. Abbildung 19 zeigt beispielhaft ein Klassifikationsergebnis einer Sentinel-2 MSI Aufnahme vom 27.3.2020 am Freibergsee und im Vergleich dazu das zugehörige Webcam Bild.


**Abbildung 19: Webcamaufnahme (a) der südlichen Webcam (b) am Freibergsee und zugehöriges Klassifikationsergebnis (c) einer Sentinel-2 MSI Aufnahme vom 27.3.2020**



Quelle: Webcam-Aufnahme: [www.foto-webcam.eu](http://www.foto-webcam.eu), Kartenhintergrund: ©2021 Google, Darstellung: CAU Kiel, Brockmann Consult GmbH

Grundlage für die Radarklassifikation sind vorprozessierte Sentinel-1 GRD IW VV (vertikal-vertikal polarisiert) und VH (vertikal-horizontal polarisiert) Bänder. Diese wurden zunächst mit einem Speckle-Filter (Median 5 x 5) geglättet, um Rauschen zu reduzieren. Der Trainings- und Validierungsdatensatz wurde von den ursprünglich verfügbaren Pixeln mithilfe der zum Aufnahmezeitpunkt vorherrschenden Windgeschwindigkeit reduziert. Hintergrund ist, dass durch Wind die Wasseroberfläche aufgeraut wird. Mit leichten Wellen und Wasserbewegungen ist die Wasseroberfläche bezogen auf die Wellenlängen vom C-Band (ca. 10 cm) nicht mehr glatt. Dadurch entsteht ein erhöhtes Rückstreusignal, das sich in den Polarisationen VV und VH mit dem von Eis überlagert (Abbildung 20). Bis zu einer Windgeschwindigkeit von 1 m/s unterscheiden sich die beiden Klassen in den Radardaten. Die Windgeschwindigkeiten wurden aus ERA-5- Land Daten zum Zeitpunkt der Sentinel-1 Aufnahme und im Mittelpunkt des jeweiligen Sees extrahiert.

**Abbildung 20: Histogramme der Rückstreuwerte in der Polarisation VV (obere Zeile) und VH (untere Zeile) im gesamten Datensatz (a, d), mit Windgeschwindigkeiten < 1m/s (b, e) und Windgeschwindigkeiten > 1m/s (c, f)**



Quelle: eigene Darstellung, CAU Kiel, Brockmann Consult GmbH

Über die Sentinel-1 Toolbox in SNAP wurden Grey Level Co-Occurrence Matrizen (GLCM) für die VV- und VH-Bänder berechnet. Basierend auf diesen Matrizen wurden in SNAP diverse Texturmaße berechnet. Der Orbit (ascending oder descending) beeinflusst die Rückstreuwerte und Texturmaße der Sentinel-1 Daten. Daher wurden zwei Klassifikationsmodelle für Sentinel-1 Daten entwickelt. Das eine gilt für Aufnahmen im ascending Orbit und nutzt das VV, VH und GLCM Mean, das andere gilt für Aufnahmen im descending Orbit und nutzt VV, VH, GLCM Variance und Contrast (vgl. Tabelle 10). Beide Modelle gelten nur für Aufnahmen mit Windgeschwindigkeiten unter 1 m/s.

## Validierung

Tabelle 11 fasst die Gütemaße der ausgewählten Klassifikationsmodelle für Sentinel-2 MSI, Landsat 8 OLI und Sentinel-1 Daten zusammen. Die Gütemaße unterscheiden sich kaum und sind durchweg sehr hoch. Wie vorab beschrieben begründen sich die hohen Werte durch den Validierungsdatensatz, der vorwiegend eindeutig trennbare Verhältnisse beinhaltet.

**Tabelle 11: Gütemaße der ausgewählten Klassifikationsmodelle für Eis, Wasser und Wolken (nur Sentinel-2 MSI und Landsat 8 OLI)**

Gütemaß	Sentinel-2 MSI	Landsat 8 OLI	Sentinel-1 ascending	Sentinel-1 descending
Overall Accuracy	1.000	0.998	0.991	1.000
Precision	1.000	0.997	0.990	1.000
Recall	1.000	0.994	0.991	1.000
F1-Score	1.000	0.995	0.990	1.000
balanced overall accuracy	1.000	0.997	0.991	1.000

Quelle: eigene Zusammenstellung, CAU Kiel, Brockmann Consult GmbH

Um die Ergebnisse der Klassifikatoren besser einzuschätzen, ist der zeitliche Verlauf der Eis-Wasser-Klassifikation in Kombination mit den interpretierten Webcam-Bildern hilfreich. Abbildung 21 stellt exemplarisch für den Freibergsee eine solche Zeitreihe dar. Nach den Webcam-Bildern friert der Freibergsee meist im Dezember oder zum Jahreswechsel zu. Die Eisdecke bleibt bis Ende März geschlossen. Die Periode der Eisbedeckung wird im Wesentlichen auch von den Satellitendaten erfasst. Allerdings fällt vor allem bei den Sentinel-1 Daten auf, dass in den Herbstmonaten fälschlicherweise Eis klassifiziert wird (ca. 50 % Eisbedeckung). Trotz der Beschränkung auf relativ windstille Szenen bleiben Probleme bestehen, Eis und Wasser mit Sentinel-1 Daten zuverlässig zu trennen.


Vereinzelte treten solche Fehlklassifikationen auch bei den optischen Daten auf (bspw. Herbst 2017 und 2019). Probleme bereiten vor allem Szenen, in denen ein See nicht vollständig eisbedeckt ist, sowie glattes, transparentes Eis. Schneebedecktes Eis wird relativ sicher erkannt. Die Fehlklassifikationen können durch Nachbearbeitungen verfeinert werden.

Um Fehlklassifikationen von Eis zu reduzieren wurden die Zeitreihen mit einem Lufttemperaturfilter in Anlehnung an Zhang und Pavelsky (2019) überarbeitet. ERA5-Land Lufttemperaturen auf Tagebasis an der Zentralkoordinate eines Sees sind dafür die Datengrundlage. Aus diesen Daten wurden 4-wöchentliche gleitende Mittelwerte gebildet. Im nächsten Schritt wurden zwei Bedingungen für den Lufttemperaturfilter definiert:

- ▶ Die Eisbedeckung [%] eines Sees muss gleichbleiben oder ansteigen zwischen zwei Aufnahmen, wenn der gleitende Mittelwert der Lufttemperatur  $< 0$  °C fällt.
- ▶ Die Eisbedeckung [%] eines Sees darf nicht ansteigen zwischen zwei Aufnahmetermen, wenn der gleitende Mittelwert der Lufttemperatur über einem seeabhängigen Schwellwert liegt. Dieser seeabhängige Schwellwert ist der Mittelwert + eine Standardabweichung der Lufttemperatur an allen Aufnahmetermen mit 20 – 80 % Eisbedeckung

Wenn diese Bedingungen nicht erfüllt sind, wird der Wert der Eisbedeckung der zeitlich vorangehenden Aufnahme übernommen.

**Abbildung 21: Eisbedeckung am Beispiel des Freibergsees basierend auf den Webcam Bildern (a), der Klassifikation von Sentinel-2 MSI (S2), Landsat 8 OLI (L8) und Sentinel-1 Bildern vor (b) und nach der Verwendung eines Lufttemperaturfilter (c)**




Quelle: eigene Darstellung, CAU Kiel, Brockmann Consult GmbH

### Vom Pixel zum Indikator

Um von den einzelnen Pixelwerten zum Indikator zu gelangen, müssen verschiedene zeitliche und räumliche Aggregierungsstufen durchlaufen werden. Die erste räumliche Aggregation findet innerhalb eines Sees zum Aufnahmezeitpunkt statt. Die räumliche Grundfläche ist ein Polygonshapefile des Seeumrisses. Innerhalb dieses Umrisses wird pro Klassifikationsergebnis die Anzahl der Pixel gezählt, die als Eis, Wasser oder Wolke (ungültig) klassifiziert wurden. Im ersten Aggregationsschritt wird dann pro Aufnahmetag der prozentuale Anteil der Eisbedeckung in einem See berechnet. Ein wesentlicher Diskussionspunkt mit den Fachpersonen war, ab wann ein See als eisbedeckt gilt. Die Möglichkeiten reichten von „Eis in einzelnen Buchten ausreichend“, über 50 % bis mind. 80 % Eisbedeckung. Für den Indikator wurde sich darauf geeinigt, einen Tag als Eistag zu betrachten, wenn die betrachtete Seefläche zu mindestens 80 % eisbedeckt ist. Pro See wurde dann die Anzahl der Eistage und die Anzahl der validen Aufnahmetage innerhalb einer Winterperiode (1.11.-31.3.) gezählt und ins

Verhältnis zueinander gesetzt. Aufgrund der geringen Anzahl an untersuchten Seen ( $n = 7$ ) wurde auf weitere räumliche Aggregationen verzichtet. Abbildung 22 stellt den Indikatorvorschlag für Eisbedeckung von Seen für vier ausgewählte Seen in den Alpen/ Alpenvorland dar. Die Werteskala reicht von 0 bis 1. Der Wert stellt das Verhältnis zwischen der Anzahl der Eistage und der Anzahl der gültigen Überflüge dar. Ein niedriger Wert deutet auf eine geringe Eisbedeckung in einem See in der Winterperiode hin. Es ist wichtig zu beachten, dass diese Fallstudien einen kurzen Zeitraum von sieben aufeinanderfolgenden Wintern untersuchen. Aus dieser begrenzten Zeitreihe können keine Schlussfolgerungen hinsichtlich des Klimawandels gezogen werden. Seen in den mittleren Breiten durchlaufen oft mehrere Gefrier- und Auftauprozesse innerhalb einer Saison, was der Indikator nur teilweise erfassen kann.

**Abbildung 22: Darstellungsvorschlag für den Indikator Eisbedeckung von Seen für vier Fallstudienseen aus den Alpen und dem Alpenvorland. Werte nahe 0 deuten eine geringe Eisbedeckung an, Werte nahe 1 deuten eine Winterperiode mit mehr Eisbedeckung an**



Quelle: eigene Darstellung, CAU Kiel, Brockmann Consult GmbH

### 3.7 Gründächer in Großstädten

#### Bestimmung von geeigneten Dächern und der Dachfläche

Ob ein Dach geeignet ist, begrünt zu werden, hängt wesentlich von Dachneigung und der Statik des Gebäudes ab. Grundsätzlich eignen sich neben Flachdächern, auch Dächer, die bis max. 45° geneigt sind, bspw. Pultdächer. Diese Dachformen liegen standardisiert in 3D-Gebäudemodellen, sog. LoD2-Daten vor. Zur Ermittlung der Gesamtdachfläche der Städte wurde die Summe aller Dachflächen basierend auf den LoD2-Daten berechnet. Die Fläche aller Pult- und Flachdächer, auf denen potenziell ein Gründach detektiert werden kann, lässt sich ebenso aus dem Datensatz ableiten. Aufgrund der räumlichen Auflösung (10 m) der gewählten Satellitendaten wurden nur Flach- und Pultdächer > 400 m<sup>2</sup> analysiert. Innerhalb dieser Polygone wurde bestimmt, ob und wieviel Fläche begrünt ist.


### Schwellwertverfahren mit Vegetationsindizes

Um festzustellen, ob ein Dach begrünt ist, wurde ein Schwellwertklassifikationsverfahren mit dem Vegetationsindex NDVI implementiert (vgl. Ansel et al. 2016). Während des Projekts wurden weitere Vegetationsindizes (bspw. soil-adjusted vegetation index SAVI, transformed soil-adjusted vegetation index TSAVI) verglichen, die aber keine deutlichen Unterschiede zum NDVI aufwiesen (siehe Anhang Kapitel B.5).

Grundlegend ist es möglich, mithilfe der Schwellwertverfahren die Art der Begrünung zu ermitteln. Höhere Vegetationsindex-Werte deuten eine höhere Dichte der Vegetationsbedeckung oder photosynthetischen Aktivität in einem Pixel an. Coenradie et al. (2016) verwenden ein solches Verfahren, um die Dachbegrünung in „intensiv“ oder „extensiv“ begrünt zu kategorisieren. Als intensiv begrünzte Flächen gelten dabei stark bewachsene Flächen mit vitaler Vegetation (höherer NDVI). Extensiv begrünzte Flächen weisen einen schwächeren und ggf. trockeneren Bewuchs auf (niedrigerer NDVI). Diese Möglichkeiten wurden im Projekt getestet, allerdings fehlen Vergleichsdaten, um Genauigkeiten abzuschätzen. Im Gründach-Workshop wurde diskutiert, dass es für den Indikator sinnvoller ist, einen robusten Schwellwert für Gründächer zu finden und die Art der Begrünung nicht weiter zu differenzieren.

Abbildung 23 zeigt basierend auf den Trainingsdaten von Dresden (70 % des Datensatzes) wie die NDVI-Werte zwischen den beiden Klassen Gründach und Nicht-Gründach verteilt sind. Grundlegend lassen sie sich gut trennen, es gibt aber einen kleinen Überlappungsbereich. Um Gründächer zu klassifizieren, entschieden wir uns für das 25 % Perzentil der Gründach-Trainingsdaten als Schwellwert, d. h. 0,37.

**Abbildung 23: Histogramme des Sentinel-2 MSI NDVI basierend auf den Trainingsdaten von Dresden der Klassen Gründach und Nicht-Gründach**



Quelle: eigene Darstellung, CAU Kiel, Brockmann Consult GmbH

Tabelle 12 fasst die Gütemaße der Schwellwertklassifikation für Sentinel-2 MSI zusammen. Die Genauigkeiten sind insgesamt sehr hoch. Mit Sentinel-2 MSI Daten konnte eine deutschlandweit vergleichbare Fernerkundungsdatengrundlage geschaffen werden, allerdings können nur Flach- und Pultdächer > 400 m<sup>2</sup> analysiert werden. Durchschnittlich wurden damit ca. 30 % der

Gesamtdachfläche, aber immerhin 59 % der Flach- und Pultdachfläche in Deutschland untersucht.

**Tabelle 12: Gütemaße des Schwellwertverfahrens mit dem NDVI basierend auf dem Validierungsdatensatz von Dresden mit Sentinel-2 MSI**


Gütemaß	
Overall Accuracy	0,9212
Precision	0,9415
Recall	0,8627
F1-Score	0,8924
balanced overall accuracy	0,8627

Quelle: eigene Zusammenfassung, CAU Kiel, Brockmann Consult GmbH

**Vom Pixel zum Indikator**

Abbildung 24 visualisiert die Gesamtdachflächen (Abbildung 24a) und Flach- und Pultdächer (Abbildung 24b) in Dresden basierend auf den LoD2-Daten. Da Sentinel-2 MSI Pixel eine räumliche Auflösung von 10 m aufweisen, werden die zu analysierenden Dachflächen auf Dächer mit einer Mindestgröße von 400 m<sup>2</sup> reduziert (Abbildung 24c), die ebenfalls als Fläche aufsummiert werden.

**Abbildung 24: 2D-Darstellung der LoD2-Daten von Dresden aller Dachflächen (a), nur der Flach- und Pultdächer (b) und Flach- und Pultdächer > 400 m<sup>2</sup> (c)**




Quelle: Geobasisdaten: © GeoBasis-DE / BKG 2022, Darstellung: CAU Kiel, Brockmann Consult GmbH


Diese Polygone (Abbildung 24c) werden mit dem Ergebnis der NDVI-Schwellwertklassifikation eines Sentinel-2 MSI Datensatz aus dem Juni 2020 verschnitten. Für jedes Flach- oder Pultdach größer 400 m<sup>2</sup> wird der Grünflächenanteil in % und m<sup>2</sup> berechnet. Um evtl. Fehlklassifikationen durch überstehende Bäume zu minimieren, muss eine Dachfläche zu mindestens 20 % begrünt sein, um in die Statistik einzugehen. Innerhalb der Stadt werden im nächsten Schritt alle Grünflächen auf den Dächern aufsummiert (Abbildung 25).

Für die deutschlandweite Aggregation wird die ermittelte Gründachfläche aufsummiert und ins Verhältnis zur untersuchten Dachfläche > 400 m<sup>2</sup> gesetzt. Als zweiter Wert wird die Summe der Gründachfläche ins Verhältnis zur Summe der Einwohner\*innen der 15 Großstädte gesetzt (vgl. Abbildung 26).

**Abbildung 25: Schrittweise Erstellung des Indikators Gründächer in Großstädten an einem Raumausschnitt in Dresden mit einem Sentinel-2 MSI Datensatz. Berechnung des NDVI (a), Schwellwertklassifikationsergebnis des NDVI (b), Berechnung der Gründachanteile in den Dachumrissen (c) und Aufsummieren der Fläche auf die Stadt (d)**



Quelle: Geobasisdaten: © GeoBasis-DE / BKG 2022, modifizierte Copernicus Sentinel 2 Daten, Darstellung: CAU Kiel, Brockmann Consult GmbH

**Abbildung 26: Indikatorabbildung Gründächer in Großstädten für das Jahr 2020**

\* bezogen auf 15 Großstädte mit einer Bevölkerungszahl >500.000 Menschen

Datenquelle: CAU Kiel, Brockmann Consult GmbH (Auswertung von Satellitenbildern und LoD2-Daten des BKG)

Quelle: Umweltbundesamt (UBA) 2023

### 3.8 Qualitätskriterien für fernerkundungsbasierte DAS-Indikatoren

#### 3.8.1 Entwicklung der Qualitätskriterien

Innerhalb des DASIF Projektes wurden Qualitätskriterien für die See-Indikatoren entwickelt, um die Güte der Indikatorwerte zu beurteilen. Dies erfolgte auch durch die Anregung während der Workshops. Die Qualitätskriterien wurden nach folgenden Überlegungen ausgewählt und entwickelt:

- ▶ Indikatorübergreifend
- ▶ Vergleichbar
- ▶ Zeitliche Abdeckung
- ▶ Räumliche Abdeckung
- ▶ Indikatorspezifisches Ausschlusskriterium


Die Qualitätskriterien sollen widerspiegeln, dass die Indikatorwerte verschiedener Jahre unterschiedliche Gütestufen haben, da Fernerkundungsdaten unterschiedlichen Einflüssen unterliegen. Dazu gehören die Wolkenbedeckung, die Häufigkeit von Satellitenüberflügen oder unterschiedliche räumliche und zeitliche Auflösung von Sensoren. Es wurden vier Kriterien entwickelt, um die Qualität der Indikatorwerte zu bestimmen:

- ▶ Durchschnittlicher zeitlicher Abstand der Satellitenbildaufnahmen
- ▶ Anzahl valide Monate/Anzahl Monate
- ▶ Valide Gesamtpixel/maximale Gesamtpixel
- ▶ Valide Gesamtpixel/maximale Gesamtpixel valider Aufnahmen

Die ersten beiden Kriterien charakterisieren dabei die zeitliche Komponente und die letzten beiden Kriterien die räumliche Komponente zur Verfügbarkeit von Satellitendaten.

Für eine Gesamtaussage werden die einzelnen Kriterien normalisiert, aufsummiert und durch vier geteilt. Die Summe der Kriterien ist somit ein Wert zwischen 0-1. Aus diesem Gesamtkriterium wird ein kategorischer Wert für jeden Indikator abgeleitet, der die Qualität des Indikatorwertes mit niedrig, neutral, hoch oder sehr hoch einstuft (siehe Abbildung 27). Bei Bedarf können einzelne Kriterien auch als Ausschlusskriterium indikatorweise definiert werden.

**Abbildung 27: Schematische Darstellung für die Bestimmung der Qualitätswerte**



Quelle: eigene Darstellung, CAU Kiel, Brockmann Consult GmbH

### 3.8.2 Aussagen der Qualitätskriterien

#### Durchschnittlicher zeitlicher Abstand

Der durchschnittliche zeitliche Abstand soll eine Aussage über die Güte der zeitlichen Komponente geben. Dafür wird für den Berechnungszeitraum der mittlere zeitliche Abstand

zwischen den Messwerten ermittelt. Ein geringer Wert bedeutet, dass es in einem Jahr lange Perioden mit ungünstigen Messwerten gab, z. B. durch dauerhafte Wolkenbedeckung.

#### **Anzahl valider Monate/Anzahl Monate**

Die Anzahl valider Monate soll ebenfalls eine Aussage über die Güte der zeitlichen Komponente geben. Für jeden Indikator wird eine Bedingung formuliert, ab wann ein Monat als gültig angesehen wird. Ist die Anzahl der validen Monate/Anzahl der gesamten Monate im Betrachtungszeitraum hoch, so handelt es sich um ein Jahr mit regelmäßigen validen Messwerten und das Qualitätskriterium ist entsprechend hoch.

#### **Valide Gesamtanzahl/maximale Gesamtpixel**

Das Kriterium valide Gesamtanzahl/maximale Gesamtpixel soll eine Aussage über die Güte der räumlichen Komponente geben. Dafür werden alle validen Pixel aller Aufnahmen ins Verhältnis zu der höchstmöglichen Gesamtpixelanzahl gesetzt. Das Kriterium zeigt damit auf, ob Teile eines Sees dauerhaft als ungünstig klassifiziert werden. Dies kann durch Wolkenbedeckung, Eisbedeckung oder auch durch das Trockenfallen von Seebereichen verursacht werden.

#### **Valide Gesamtanzahl/maximale Gesamtpixel valider Aufnahmen**

Das Kriterium valide Gesamtanzahl/maximale Gesamtpixel valider Aufnahmen soll ebenfalls eine Aussage über die Güte der räumlichen Komponente geben. Das Kriterium wird ähnlich wie das vorhergehende Kriterium bestimmt, nur dass für das Verhältnis nicht alle Aufnahmen, sondern nur valide Aufnahmen verwendet werden. Aufnahmen mit kompletter Wolkenbedeckung werden dadurch nicht berücksichtigt. Somit wird noch einmal deutlicher, ob ein See häufig durch Wolkenbedeckung beeinflusst ist oder in einer wolkenarmen Region liegt. Sind selten Teile des Sees mit Wolken bedeckt, so ist der Wert für das Kriterium hoch.


#### **Qualitätswert gesamt**

Die zwischen 0 und 1 normalisierten Qualitätskriterien werden aufsummiert und gemittelt. Abbildung 28 stellt den gesamten Qualitätswert beispielhaft am Indikator Wassertemperatur für den Walchensee dar. Es gibt kein Jahr, in dem der Qualitätswert als niedrig eingestuft wird (< 0,3), sehr viele mittlere Jahre (0,3-0,5) und einzelne Jahre, die eine hohe Qualität aufweisen. Diese Informationen können genutzt werden, um die Wertausprägung einzelner Jahre besser einschätzen zu können (Abbildung 28b) oder um bestimmte Jahre aufgrund unzureichender Datenlage aus den Trendanalysen auszuschließen (siehe Kapitel 3.8.3).

### **3.8.3 Einfluss der Qualitätskriterien in die Trendanalyse**

Die entwickelten Kriterien wurden im DASIF Projekt dafür genutzt, um die Güte der jährlichen Indikatorwerte an einem See zu bestimmen. So kann individuell für jeden Datenpunkt entschieden werden, ob er in den bundesweiten Indikator einfließt oder nicht. Dafür werden Schwellwerte definiert, die für jeden Indikator einzeln aufgestellt werden. Zusätzlich können indikatorspezifische Ausschlusskriterien definiert werden. In die für den DAS-Bericht 2023 ausgewählten fernerkundungsbasierten Indikatoren fließen die Qualitätskriterien allerdings noch nicht ein.

**Abbildung 28: Qualitätskriterium gesamt (a) am Beispiel der mittleren Wassertemperatur über die Sommermonate (b) am Walchensee. Die horizontalen Linien stellen die Schwellwerte für die Qualitätseinstufung dar**



Quelle: eigene Darstellung, CAU Kiel, Brockmann Consult GmbH

## 4 Operationalisierung der fernerkundungsbasierten Indikatoren

### 4.1 Auswahl einer Prozessierungsplattform

Um sich für eine geeigneten Prozessierungsplattform für die künftige Generierung der Klimaindikatoren aus Fernerkundungsdaten zu entscheiden, untersuchte das Projektteam auf Basis der Anforderungen seitens des UBAs und den Anforderungen durch die Prozessierungsabläufe verschiedene Plattformen.

Für die Generierung der Indikatorwerte bedarf es komplexer Prozessierungsketten, performante und parallelisierbare Prozessierungen sowie gut ansprechbare Schnittstellen zwischen Daten, Algorithmus und Output. Die zu prozessierenden Satellitendaten müssen auf der jeweiligen Plattform vorliegen. Des Weiteren war zu diskutieren, ob graphische Oberflächen notwendig sein werden, um die Prozesse zu starten oder ob der Betrieb skript-basiert durchgeführt werden soll. Auf diese Anforderungen hin wurden verschiedene Prozessierungsplattformen analysiert und mit dem UBA diskutiert. Tabelle 13 zeigt eine Übersicht der Prozessierungsplattformen, die in der Analyse in Betracht gezogen wurden. Dabei wurde darauf geachtet, welche räumliche Abdeckung und welche Sensoren auf den jeweiligen Plattformen vorhanden sind. Die meisten Ansprüche können die dunkelgrün markierten Plattformen erfüllen. Aus dieser Liste wurde eine Vorauswahl für die Plattformen CODE-DE (Copernicus Data and Exploitation Platform – Deutschland) und Calvalus (Brockmann Consult GmbH Prozessierungsumgebung) getroffen, da sie jeweils ein sehr wichtiges Kriterium erfüllen. Das interne Prozessierungscluster Calvalus der Brockmann Consult GmbH ist beliebig erweiterbar für fehlende Sensoren und erfüllt eine Vielzahl von Ansprüchen an eine Prozessierungsplattform (Prozessmonitoring, Speicherplatzmanagement, Fehlerbehebung und Reprozessierung von Fehlprozessierungen, etc.). CODE-DE hat den großen Vorteil, dass es als nationales Konzept dem UBA als Bundesbehörde für Prozessierungen kostenfrei zur Verfügung steht.

**Tabelle 13: Übersicht der untersuchten Prozessierungsplattformen (Stand: 11/2023)**


Prozessierungs- plattform	Konzept	Räumliche Abdeckung	Fehlende Satelliten/ Sensoren	Besonderheit
CODE-DE	National	Deutschland	ENVISAT MERIS, Landsat Collection 2 Level 2	Freie Verfügbarkeit für Bundesbehörden und - einrichtungen
CreoDias	Copernicus Dias	Global, Landsat – Europa	Landsat Collection 2 Level 2	
WekEO	Copernicus Dias	Global	ENVISAT MERIS, Landsat Collection 2 Level 2	
Sobloo	Copernicus Dias	Global	ENVISAT MERIS, Landsat Collection 2 Level 2	
Onda	Copernicus Dias	Global, Landsat- Europa	Landsat Collection 2 Level 2	
Mundi	Copernicus Dias	Global, Landsat- Europa	Landsat Collection 2 Level 2	
Calvalus	Brockmann Consult GmbH intern	unterschiedlich je nach Sensor, DE ist für alle Sensoren abgedeckt		Beliebig erweiterbar

Quelle: eigene Zusammenstellung, CAU Kiel, Brockmann Consult GmbH

## 4.2 Umsetzung der Operationalisierung

In diesem Abschnitt werden die Komponenten der Operationalisierung beschrieben, um ein Gesamtbild der Umsetzung zu zeigen. Dafür dient der Workflow aus Abbildung 29 als Wegweiser durch die Umsetzung.

**Abbildung 29: Schematischer Workflow der Operationalisierung**



Quelle: eigene Darstellung, CAU Kiel, Brockmann Consult GmbH

### 4.2.1 Satellitendatenprozessierung

Die Auswahl der Satellitendaten erfolgt durch das Prozessierungssystem Calvalus. Alle Sensoren, die für die Indikatorberechnung benötigt werden, stehen dort zur Verfügung oder wurden für das DASIF Vorhaben erweitert. Die Maskierung und die Anwendung der Algorithmen ist in Kapitel 3 beschrieben und wurde nach diesem Prinzip angewendet. Die Prozesse auf Calvalus laufen parallelisiert ab, was die Prozessierungszeit der Produkte minimiert. Das Endprodukt der Komponente „Satellitendatenprozessierung“ sind Data Cubes, die alle validen Datenpixel enthalten, die für die ausgewählten Seen zum jeweiligen Aufnahmezeitpunkt vorhanden sind. Als Parameter enthalten sie die für den jeweiligen Indikator relevanten geophysikalischen Größen.

#### Data Cubes

Data Cubes werden im Zusammenhang mit der Fernerkundung für den schnellen Zugriff auf Daten über mehrere Dimensionen wie den Raum und die Zeit genutzt. Dabei ermöglicht die Cubisierung von Rasterdaten in einen Data Cube eine effiziente räumlich-zeitliche Abfrage und Analyse von Zeitreihen der Satellitenbilder. Data Cubes wandeln multimodale Erdbeobachtungsdaten in analysebereite Daten um und bieten Werkzeuge zur Durchführung von Analysen zur Erkennung von Trends und Durchführung von Analysen in großem Maßstab, indem reine In-Memory-Operations vermieden werden. Zu den erweiterten Funktionalitäten von Data Cubes gehören die Handhabung von gerasterten Daten aus verschiedenen Quellen in Raum und Zeit, die Einbeziehung kategorialer Datentypen, Optimierungen des Zeitreihenzugriffs und Schnittstellen zu Algorithmen für maschinelles Lernen (z. B. Chunking und Batch-Generierung) mit sowohl räumlichen als auch zeitliche Faltungen. Data Cubes der Fernerkundung werden daher genutzt, um den Zugang und die Nutzung multivariater Datensätze in den Geo- und Umweltwissenschaften zu erleichtern, indem Daten in analysebereiter Form zur Verfügung gestellt werden.


#### **4.2.2 Datenextraktion und Datenanalyse**

Für den Zugriff auf die Data Cubes und die darauf aufbauende Datenextraktion und Datenanalyse wurden im Rahmen von DASIF Jupyter Notebooks entworfen, die als interaktive Schnittstelle zwischen Data Cube und Anwender\*innen genutzt werden.

##### **Jupyter Notebooks**

Jupyter Notebooks sind ein interaktives und browser-basiertes Werkzeug, um Daten über eine Programmiersprache zu verarbeiten und zu visualisieren. Jupyter Notebooks lassen sich gut strukturieren mit Codefeldern und ergänzenden Textfeldern zur Dokumentation, wodurch fachkundige Nutzer\*innen Datenanalysen relativ einfach durchführen können. Abbildung 30 zeigt einen Ausschnitt aus einem Jupyter Notebook für die Datenanalyse des Indikators Wassertemperatur in Seen.

**Abbildung 30: Jupyter Notebook Ausschnitt für die Datenanalyse des Indikators Wassertemperatur in Seen**



Quelle: eigene Darstellung, CAU Kiel, Brockmann Consult GmbH

Die erstellten Data Cubes können über eine Schnittstelle von den Jupyter Notebooks erreicht werden, sodass in den Notebooks die Daten der Data Cubes analysiert werden können. Die in den Notebooks verwendete Programmiersprache ist Python 3.8. Für das DASIF Vorhaben wurden verschiedene Notebooks erstellt, die unterschiedliche Analyseverfahren abdecken. Eine Übersicht zu den Notebooks findet sich in Tabelle 14.

**Tabelle 14: Übersicht der Jupyter Notebooks und deren Funktionen**

Komponente	Jupyter Notebook	Eingangsdaten	Ausgabedaten	Indikatoren
Datenextraktion	1	Data Cubes	Tabelle mit täglichen Werten der biophysikalischen Parameter	Cyanobakterienbelastung, Frühjahrsalgenblüte, Wassertemperatur, Eisbedeckung, Gründächer
Analyse	2	Tabelle aus Notebook 1 „Datenextraktion“	Bundesweiter Indikator als Tabelle und Abbildung	Cyanobakterienbelastung, Frühjahrsalgenblüte, Wassertemperatur, Eisbedeckung, Gründächer
Qualitätsparameter	3	Tabelle aus Notebook 1 „Datenextraktion“	Bundesweiter Indikator und Qualitätsparameter als Tabelle und Abbildung	Cyanobakterienbelastung, Frühjahrsalgenblüte, Wassertemperatur, Eisbedeckung

Quelle: eigene Zusammenstellung, CAU Kiel, Brockmann Consult GmbH

Das Jupyter Notebook „Datenextraktion“ erzeugt als finale Produkte aus den Data Cubes Tabellen (csv-Format). Diese Tabellen enthalten für jeden Indikator die am Aufnahmetag über einen See gemittelten, biophysikalischen Parameter. Für Gründächer in Großstädten werden die Flächeninformation über Flachdächer und Gründächer extrahiert und die Einwohnerzahl der jeweiligen Stadt angefügt. Dieser Schritt ist nur einmal pro DAS-Zyklus notwendig, also alle drei Jahre. Im zweiten Jupyter Notebook „Analyse“ kann aus den extrahierten Tabellen der bundesweite Indikator berechnet werden. Dabei ist es möglich verschiedene Seen auszuwählen und anhand verschiedener Merkmale zu aggregieren. Mit dem dritten Jupyter Notebook „Qualitätsparameter“ können see- und indikatorweise die Qualitätskriterien (Kapitel 3.8) berechnet und als Tabelle ausgegeben werden. Die Jupyter Notebooks zur Analyse bieten dadurch ein Werkzeug, die gesamten Zeitreihen der prozessierten Satellitendaten zu visualisieren und mögliche Trends abzuschätzen, die im bundesweiten Indikator nicht deutlich werden. Durch die Betrachtung verschiedener Gruppierungen können gegebenenfalls Trends entdeckt werden und durch die Analyse der Qualitätskriterien kann die Verlässlichkeit der Eingangsdaten in die finale Trendanalyse überprüft werden. Somit können Empfehlungen für die Weiterentwicklung des Indikators gegeben werden. Für den Indikator Gründächer wurden keine Qualitätskriterien berechnet, da es sich bisher nur um einen Zeitpunkt handelt.

#### 4.2.3 Trendanalyse und bundesweiter Indikator

Die statistischen Trendschätzung zu allen Monitoring-Indikatoren für den DAS-Monitoringbericht 2023 war Teil des UBA-Vorhabens „Monitoring zur DAS – Technische und inhaltliche Weiterentwicklung“ (FKZ 3720 48 101 0) und wird nicht in den vom DASIF-Projekt erstellten Jupyter Notebooks durchgeführt.


### 4.3 Entwicklung eines interaktiven Dashboards

Im Anschluss an die Indikatorenentwicklung wurde ein benutzerfreundliches Dashboard entwickelt, das die Indikatorergebnisse einem breiten Publikum zugänglich macht. Dieses intuitive Dashboard bietet nicht nur eine interaktive räumliche Darstellung der Indikatoren, sondern ermöglicht auch eine zeitliche Analyse. Durch die Integration unterschiedlicher Aggregationsmethoden für die Indikatoren Frühjahrsalgenblüte, Wassertemperatur und Eisbedeckung erhalten die Nutzer\*innen vielfältige Möglichkeiten zur Datenauswertung. Die browserbasierte Struktur des Dashboards gewährleistet dabei eine flexible und einfache Nutzung von verschiedenen Endgeräten, was einen weiteren Vorteil für die Zugänglichkeit und Verbreitung der Ergebnisse darstellt. Das Dashboard ist erreichbar unter folgendem Link (Stand: 01/2024):

<https://dasif-dashboard.brockmann-consult.de/>

Abbildung 31 gibt einen umfassenden Überblick über das Dashboard. Im oberen Bereich stehen den Nutzer\*innen verschiedene Auswahlmöglichkeiten zur Verfügung, um die gewünschte Darstellungsform individuell anzupassen. Links im Zentrum erfolgt die räumliche Visualisierung der Indikatorwerte. Auf der rechten Seite sind drei verschiedene Grafikdarstellungen der Indikatoren verfügbar. Die erste zeigt die Zeitreihe des Indikators, die zweite den basierenden Indikatortrend und die dritte präsentiert die Indikatorverteilung als Violinendarstellung. Zusätzlich bietet das Dashboard einen Info-Knopf, der bei Bedarf weitere detaillierte Informationen über den betrachteten Indikator bereitstellt. Dieses Design gewährleistet eine nutzerfreundliche und interaktive Erforschung der Indikatordaten.

Abbildung 31: DASIF Dashboard



Quelle: eigene Darstellung, CAU Kiel, Brockmann Consult GmbH

## 5 Forschungsbedarfe, Entwicklungen und Perspektiven

Die erfolgreiche Entwicklung von Indikatoren ist grundlegend für eine effektive Entscheidungsfindung und die Formulierung von Richtlinien in verschiedenen Bereichen, von Umweltschutz bis zur sozioökonomischen Entwicklung. Diese Indikatoren dienen als entscheidende Maßstäbe und liefern wertvolle Erkenntnisse über den aktuellen Zustand, wodurch Interessengruppen den Fortschritt in Richtung definierter Ziele und Zielvorgaben bewerten können.

Dieses Kapitel befasst sich damit, die bestehenden Indikatorenberechnungen zu bewerten und Bereiche aufzudecken, in denen Verbesserungen erforderlich sind. Durch eine gründliche Analyse der bisherigen Arbeit werden Schwachstellen und Lücken aufgedeckt, die die Effektivität der Indikatoren bei der genauen Abbildung der Realität vor Ort beeinträchtigen könnten. Die fernerkundungsbasierten Berechnungen der Indikatoren unterliegen dem aktuellen Stand der Forschung und Datengrundlage. Laufende Entwicklungen in der Fernerkundung sollten berücksichtigt werden, um die Indikatoren auf dem aktuellen Stand der Technik fortzuführen und beizubehalten.

Zusätzlich wird ein Fokus auf Synergien auf europäischer und internationaler Ebene und potenzielle zukünftige Entwicklungen der Satellitenfernerkundung für zusätzliche Indikatoren gelegt. Die Entwicklung und Integration neuer Indikatoren sind von entscheidender Bedeutung, um die Überwachung und Bewertung von Umwelt-, sozioökonomischen und anderen relevanten Prozessen in unserer Gesellschaft zu verbessern.

Das Hauptziel besteht darin, das Potenzial zukünftiger Entwicklungen der Satellitenfernerkundung für zusätzliche Indikatoren zu erkunden und aufzuzeigen, wie vielversprechende Technologien, Forschungsansätze und Datenerfassungsmethoden das bestehende Überwachungssystem erweitern und verbessern können.

### 5.1 Forschungsbedarfe für die aktuellen Indikatoren

#### 5.1.1 Cyanobakterienbelastung von Badegewässern

Der Indikator Cyanobakterienbelastung von Badegewässern weist eine Datenlücke in den Jahren 2012-2016 auf. Aufgrund fehlender geeigneter Satellitendaten in dieser Zeitperiode konnte die Datenlücke nicht geschlossen werden. Mögliche Satellitensensoren, um die Datenlücke zu schließen, sind MODIS, welcher jedoch mit einer Auflösung von 1 km räumlich nicht geeignet ist für die Größe der meisten deutschen Seen. Auch wenn Landsat 8 OLI in einigen Studien (Castagna et al. 2020) verwendet wurde um Cyanobakterien zu detektieren, so fehlen dem Sensor elementare Bänder bzw. die notwendige spektrale Auflösung, um Cyanobakterien sicher von anderem Phytoplankton zu unterscheiden (siehe Kapitel 2.1.1).

Für die Fortschreibung des Indikators wird empfohlen:

- ▶ Untersuchung, ob trotzdem die Kombination verschiedener Satellitensensoren genutzt werden kann, um Datenlücken zu schließen
- ▶ Kombination der Satellitendaten mit in-situ Messungen

#### 5.1.2 Frühjahrsalgenblüte in Seen

Der Indikator Frühjahrsalgenblüte in Seen weist eine Datenlücke in den Jahren 2012-2016 auf. Aufgrund fehlender geeigneter Satellitendaten in dieser Zeitperiode konnte die Datenlücke nicht geschlossen werden. Mögliche Satellitensensoren, um die Datenlücke zu schließen, sind VIIRS

(Visible Infrared Imaging Radiometer Suite) oder MODIS, welche jedoch mit einer Auflösung von 750 m bzw. 1 km räumlich nur sehr eingeschränkt geeignet sind für diesen Indikator. Landsat 8 OLI, der nur eingeschränkt für die Ermittlung der Chlorophyll-a-Konzentration, jedoch sehr gut für die Trübung herangezogen werden könnte, verfügt über eine zu geringe zeitliche Auflösung, um Frühjahrsalgenblüten angemessen zu erfassen.

Für die Fortschreibung des Indikators wird empfohlen:

- ▶ Kombination verschiedener Satelliten, um Datenlücken zu schließen (z. B. Kombination von Landsat-8 OLI und VIIRS durch Nutzung von räumlich hochaufgelösten Daten mit zeitlich hochaufgelösten Daten)
- ▶ Kombination der Satellitendaten mit in-situ Messungen
- ▶ Fortführung der Untersuchungen für Interpolationsmethoden zur Schließung kurzen zeitlichen Lücken

### 5.1.3 Wassertemperatur in Seen

Geeignete Satellitensensoren für die Wassertemperatur haben entweder eine zu geringe räumliche Auflösung (Sentinel-3 SLSTR, MODIS) oder eine relative grobe zeitliche Auflösung (Landsat 5 Thematic Mapper (TM) - 8 OLI). Seit Start des Landsat-9 liegen hat sich die zeitliche Auflösung der Landsatdaten verbessert.

Für die Fortschreibung des Indikators wird empfohlen:

- ▶ die Implementierung von Landsat 9 TIRS-2 Daten
- ▶ Validierung von Landsat 9 TIRS-2 Daten
- ▶ Vergleich von Landsat 8 TIRS und Landsat 9 TIRS-2 Ergebnissen
- ▶ Analyse und Auswertung weiterer Interpolationsmethoden

### 5.1.4 Eisbedeckung von Seen

Die finale Berechnung für den Indikator Eisbedeckung von Seen erfolgte mit den entwickelten Klassifikationsmodellen. Die Modelle wurden angepasst (bspw. Ausschluss des panchromatischen Bands bei Landsat 8 OLI).

Für die Fortschreibung des Indikators wird empfohlen:

- ▶ Erweiterung der in-situ Datengrundlage und Seen durch eigene Messungen und Drohnenbefliegungen
- ▶ Implementierung von Landsat 9 OLI
- ▶ Implementierung von Thermaldaten der Landsatsensoren

### 5.1.5 Gründächer in Großstädten

Die finale Berechnung der Dachbegrünung erfolgt mit dem NDVI-Schwellwertverfahren. Wir konzentrieren uns auf Sentinel-2 MSI Daten und Dachflächen > 400 m<sup>2</sup> aus LoD2-Daten, da diese für Bundesbehörden frei zur Verfügung stehen.

Für die Fortschreibung des Indikators wird empfohlen:

- ▶ Eigene Erhebung von in-situ Daten zur Art der Begrünung (intensiv und extensiv)

- ▶ Vergleichsanalyse unter Verwendung von PlanetScope und RapidEye Daten für die ausgewählten 15 Städte
- ▶ Bei Bedarf räumliche Ausdehnung der Analyse
- ▶ Berechnung eines weiteren Zeitschritts mit Sentinel-2 MSI Daten (bspw. 2024)

## 5.2 Synergien auf europäischer und internationaler Ebene

Das ESA CCI Lakes Projekt (<https://climate.esa.int/en/projects/lakes/about/>) entwickelt als ein globales Seenprodukt die essenziellen Klimavariablen

- ▶ Lake Water Level (LWL): Wasserstand
- ▶ Lake Water Extent (LWE): Wasserfläche
- ▶ Lake Surface Water Temperature (LSWT): Wasseroberflächentemperatur
- ▶ Lake Ice Cover (LIC): Eisbedeckung
- ▶ Lake Ice Thickness (LIT): Eisdicke
- ▶ Lake Water-Leaving Reflectance (LWLR): Reflektanzen

In der Phase 2 des CCI Lakes Projektes wird, basierend auf dem DASIF Projekt, ein Use Case mit dem Titel „Aggregated climate indicators for the global lakes“ behandelt, der die DASIF Ansätze auf globaler Ebene anwendet.

Die Ziele des Use Case sind die Generierung von Indikatoren, die dabei helfen, die Klimaauswirkungen auf Seengruppen zu bewerten. Der Use Case baut auf den bereits im DASIF Projekt behandelten Indikatoren auf, die bei Bedarf an den Lakes CCI Datensatz angepasst werden. Anfänglich werden die Indikatoren Frühjahrsalgenblüte, Eisbedeckung und Temperatur (jährliche Bewertung) (LWLR, LIC, LSWT) erarbeitet und zusätzlich Ideen für weitere Indikatoren entwickeln. Es wird ein jährlicher Qualitätsindikator berechnet, der Auskunft über die Datenverfügbarkeit und damit die Zuverlässigkeit des jährlichen Indikatorwerts gibt. Die Ergebnisse werden für nicht-fachkundige Personen aufbereitet (Dashboards, Storymaps, Factsheets), um wichtige Informationen aus dem CCI Lakes Datensatz zusammenzufassen.

Ein Austausch zwischen dem CCI Lakes Team und dem DAS Monitoring Team wird empfohlen, um Synergien und Ergebnisse aus beiden Projekten zu nutzen. So können die Ergebnisse und Erfahrung von der globalen Sichtweise in künftige Überlegungen für die Anwendung für Deutschland zurückfließen. Auch die Anwendung auf die zusätzlichen Parameter, die im CCI Lakes Datensatz berücksichtigt werden, könnten für die DAS Indikatoren interessante Erweiterungen zeigen.

## 5.3 Perspektiven für fernerkundungsbasierte DAS Indikatoren

Entwicklungen in der Satellitenfernerkundung und der Austausch mit der DAS Monitoring Arbeitsgruppe zeigen, dass die Fernerkundung Unterstützung für weitere DAS Indikatoren bieten kann. Satellitenbeobachtungen haben Potential für unterschiedliche Klimaindikatoren, die nicht nur im Bereich von Gewässern und ihrem Umland liegen, sondern auch auf weitere Bereiche, wie die Landbedeckung, übertragen werden können. Im Folgenden sind potenzielle Indikatoren aufgelistet, die als wichtige Klimaindikatoren herangezogen und mit Hilfe von Satellitendaten erhoben werden können.

## Gewässerindikatoren

### ► Küstenmorphologie

Küstenmorphologie dient als wertvoller Klimaindikator auf der Grundlage von Fernerkundungsdaten und bietet wesentliche Einblicke in Umweltveränderungen. Durch Satellitenbeobachtungen liefert sie wichtige Informationen über Küstenerosion, Landgewinnung und Sedimentdynamik, um die Auswirkungen klimabezogener Ereignisse wie Meeresspiegelanstieg und Sturmfluten zu überwachen. Diese Daten unterstützen Küstenschutz-Bewertungen und informieren Anpassungsstrategien für die Auswirkungen des Klimawandels. Die kontinuierliche und hochauflösende Überwachung durch Fernerkundung ermöglicht die stetige Beobachtung und rechtzeitige Erkennung von Küstenveränderungen und bietet Entscheidungsträgern die notwendigen Informationen, um Herausforderungen im Küstenmanagement anzugehen und Küstengemeinden und Ökosysteme zu schützen.

### ► Wassertemperatur des Meeres

Wassertemperatur in Ozeanen dient wie der Indikator in Seen als bedeutender Klimaindikator, der durch Fernerkundungsdaten erfasst wird. Satellitenbeobachtungen ermöglichen eine flächendeckende Erfassung der Oberflächentemperatur in den deutschen Meeren. Diese Informationen erweitert den Indikator Wassertemperatur und ist für die Klimaforschung und die Entwicklung wirksamer Maßnahmen zur Anpassung an die Auswirkungen des Klimawandels von großer Bedeutung. Initiativen wie die ESA CCI und der Copernicus Climate Change Service (C3S) bieten bereits Daten und Dienste an, die auf Fernerkundungsdaten basieren, und erleichtern so die Bereitstellung des Indikators.

### ► Algenblüte und Cyanobakterien in Fließgewässer

Algenblüten und Cyanobakterien in Fließgewässern erweitern die bisherigen biologischen Indikatoren, die durch Fernerkundungsdaten erfasst werden können. Satellitenbeobachtungen liefern entscheidende Erkenntnisse über das Wachstum von Algen und ermöglichen eine frühzeitige Erkennung und Überwachung schädlicher Blüten. Diese Ereignisse beeinträchtigen die Wasserqualität und die Gesundheit des Ökosystems und stellen eine Gefahr für die menschliche Gesundheit dar. Die Fernerkundung unterstützt die Kartierung und Verfolgung des räumlichen Ausmaßes von Algenblüten und Cyanobakterienausbrüchen und liefert wertvolle Daten für das Umweltmanagement und den Schutz der Fließgewässer.

### ► Badetemperaturen an der Küste

Die Veränderungen der Wassertemperatur können Auswirkungen auf das Ökosystem und die Gesundheit der Badegäste haben und dienen als wertvolle Informationen für das Küstenmanagement und den Tourismussektor. Fernerkundung ermöglicht eine zusätzliche Informationsquelle für die Erfassung der Wassertemperatur, um die Sicherheit und Qualität der Badestellen zu gewährleisten. In Kombination mit in-situ Messungen können Fernerkundungsdaten wertvolle räumliche Verteilungsmuster beisteuern.

### ► Uferbewuchs/ Struktur im Gewässerumfeld

Satellitenbeobachtungen ermöglichen eine umfassende Kartierung und Überwachung der Ufervegetation und ihrer Veränderungen entlang von Wasserläufen. Besonders räumlich hochaufgelöste Daten bieten wichtige Informationen über den Gesundheitszustand und die Dynamik von Ufer-Ökosystemen. Veränderungen in der Ufervegetation können auf Klimaveränderungen, Wassermanagementpraktiken und menschliche Eingriffe hinweisen. Die

Fernerkundung unterstützt die Bewertung von Ökosystemfunktionen und trägt zur Entwicklung von Schutz- und Wiederherstellungsmaßnahmen für diese wertvollen Lebensräume bei.

### **Landindikatoren**

#### ► Dauergrünlandfläche

Durch Satellitenbeobachtungen wird eine präzise Erfassung und kontinuierliche Überwachung von Dauergrünlandflächen ermöglicht. Diese Daten sind von entscheidender Bedeutung, um die Auswirkungen des Klimawandels auf die Landnutzung zu verstehen und nachhaltige Agrarpraktiken zu fördern. Die Fernerkundung spielt eine wesentliche Rolle bei der Erhaltung dieser wertvollen Flächen und dem Schutz der biologischen Vielfalt.

#### ► Ackerfläche/ Landbedeckung im Deichvorland

Das Deichvorland ist ein potenzieller Klimaindikator, der durch Fernerkundungsdaten gezielt untersucht werden kann. Satellitenbeobachtungen ermöglichen eine präzise Erfassung und kontinuierliche Überwachung dieser vitalen Küstenregion. Die Fokussierung auf das Deichvorland eröffnet Einblicke in die Veränderungen der Landnutzung, Erosionsraten und das Zusammenspiel zwischen Land und Wasser.

#### ► Siedlungsnutzung/ Landbedeckung in Hochwassergefahrenbereichen

Die fernerkundliche Analyse der Landnutzung und Landbedeckung in Hochwassergefahrenbereichen ermöglicht es, gefährdete Gebiete zu identifizieren und potenzielle Risiken besser zu verstehen. Hierzu zählen unter anderem die Auswirkungen des Klimawandels wie steigende Pegelstände, häufigere Starkregenereignisse und verstärkte Hochwasser. Die Fernerkundung unterstützt auch die Evaluierung bestehender Hochwasserschutzmaßnahmen und ermöglicht es, gezielte Anpassungsstrategien zu entwickeln, um die Resilienz von Siedlungen gegenüber Hochwasser zu stärken.

#### ► Versiegelte Fläche

Mithilfe von Satellitenbeobachtungen können versiegelte Flächen wie bebaute Gebiete, Straßen und Parkplätze genau identifiziert und überwacht werden. Die Fernerkundung ermöglicht die Bewertung der Auswirkungen von Versiegelung auf das lokale Klima, den Wasserhaushalt und die Umweltqualität. Die genaue Erfassung dieser Veränderungen trägt zur Entwicklung von nachhaltigen Stadtplanungsstrategien und zum Schutz wertvoller Ökosysteme bei. Hier kann auf bereits operationell verfügbare Produkte wie der hochaufgelöste Copernicus Land Monitoring Service (CLMS) Imperviousness Datensatz.

#### ► Schneebedeckung (in Wintersportgebieten)

Dieser mögliche Indikator ist entscheidend, um die Auswirkungen des Klimawandels auf die Schneesituation zu verstehen, wie zum Beispiel die Verschiebung der Schneesaison und den Rückgang der Schneemengen. Die genaue Erfassung der Schneebedeckung ermöglicht die Beobachtung von Veränderungen im Schneeregime, die oft in direktem Zusammenhang mit dem Klimawandel stehen und unterstützt die Planung von nachhaltigen Maßnahmen im Tourismussektor und den Schutz der empfindlichen alpinen Ökosysteme.

#### ► Phänologie der Vegetation

Satellitenbeobachtungen ermöglichen es, die Phänologie der Vegetation auf globaler, regionaler und lokaler Ebene zu erfassen. Diese Daten sind entscheidend, um die Auswirkungen des

Klimawandels auf die Pflanzenentwicklung zu erfassen und Rückschlüsse auf Veränderungen in den Ökosystemen zu ziehen. Die Phänologie der Vegetation reagiert sehr empfindlich auf Veränderungen in Temperatur, Niederschlag und anderen Umweltbedingungen, die mit dem Klimawandel einhergehen.

## **5.4 Entwicklungen in der Satellitenfernerkundung**

Die Satellitenfernerkundung hat sich in den letzten Jahren als ein unverzichtbares Instrument in der Klimaforschung und Umweltüberwachung etabliert. Mit der ständigen Weiterentwicklung der Technologie eröffnen sich immer wieder faszinierende Möglichkeiten, die Reichweite und Leistungsfähigkeit dieser Methodik zu erweitern.

Ein Blick in die vielversprechenden zukünftigen Entwicklungen in der Satellitenfernerkundung zeigt, dass diese es uns ermöglichen werden, noch präzisere und umfassendere Informationen über Klimaindikatoren zu gewinnen. Von hyperspektralen Sensoren bis hin zu verbesserten Analysetechniken und höheren Auflösungen versprechen diese Innovationen, unsere Forschung und unser Verständnis des Klimawandels und seiner Auswirkungen auf unsere Erde auf ein neues Niveau zu heben.

### **Hyperspektrale Fernerkundung**

Hyperspektrale Satellitenmissionen (EnMAP, Prisma) erfassen Daten über zahlreiche schmale und zusammenhängende spektrale Bänder, was eine präzise Identifizierung spezifischer Vegetationstypen, Veränderungen der Landbedeckung und Konzentrationen von Schadstoffen ermöglicht. Die Daten können zwischen verschiedenen Materialien anhand ihrer spektralen Signaturen unterscheiden und helfen bei der Identifizierung spezifischer klimarelevanter Veränderungen wie Vegetationsstress, Algenblüten oder Bodenfeuchte. Zurzeit sind Hyperspektralsensoren zumeist auf Forschungssatelliten verfügbar. Mit PACE (NASA, Ozeanerfassung), CHIME (Copernicus/ESA, Landerfassung) und SBG (NASA, Landerfassung) werden in naher und mittlerer Zukunft hyperspektrale Satellitendaten auch operationell zur Verfügung stehen. Hinzu kommen kleine private Cube Satelliten mit Hyperspektralsensoren an Bord.

### **Räumlich hochaufgelöste Daten**

Sehr hochauflösende Aufnahmen bieten detaillierte Ansichten kleinerer Gebiete und ermöglichen die Überwachung lokaler Klimaphänomene wie urbane Hitzeinseln, Küstenerosion oder Gletscherschwund mit außergewöhnlicher Klarheit. Klimasensible Merkmale wie Gletscherbewegungen, Veränderungen der Küstenvegetation oder Entwaldung können in feiner räumlicher Auflösung genau verfolgt und analysiert werden, um die Auswirkungen des Klimawandels vor Ort besser zu verstehen.

### **Fortgeschrittene Datenverarbeitungstechniken**

Fortgeschrittene Algorithmen (Machine Learning) können große Mengen an Fernerkundungsdaten verarbeiten und ermöglichen eine automatisierte Identifizierung und Verfolgung von Klimaindikatoren, vereinfachen die Datenanalyse und bieten nahezu Echtzeit-Aktualisierungen. Hinzu kommen Hochleistungssysteme mit immer höheren Rechen- und Speicherleistungen, die auf effiziente Weise genutzt werden können. Prozessierungsplattformen ermöglichen die Prozessierung auf existierenden Datenpools, so dass große Datenmengen verarbeitet werden können, ohne dass diese zunächst heruntergeladen werden müssen.

### **Copernicus-Programm**

Das europäische Copernicus-Programm, als führende Initiative für umfassende Erdbeobachtung und Umweltüberwachung, hat in der Zukunft ambitionierte Ziele und wird weiterhin auf verschiedene Weisen voranschreiten. Ziele des Programms sind unter anderem die Fortführung der Sentinel Missionen, die Erweiterung des Satellitennetzwerks mit neuen Satellitenmissionen, die Sicherstellung einer kontinuierlichen Datenerfassung und -verfügbarkeit sowie die Erweiterung der Anwendungsbereiche.

### **Copernicus Climate Change Service (C3S)**

C3S ist der Klimaschutzservice der EU und hat es sich zur Aufgabe gemacht, die Anpassungs- und Maßnahmenpolitik der Europäischen Union zu unterstützen, indem konsistente und verlässliche Informationen über den Klimawandel bereitgestellt werden. Es besteht freier und offener Zugang zu den Klimadaten und -instrumenten, die auf den besten wissenschaftlichen Erkenntnissen basieren. Die Klimaindikatoren werden aus Fernerkundungsdaten, Modelldaten und in-situ Daten gewonnen. C3S ist der operationelle Dienst für Essential Climate Variables, während ESA CCI den Schwerpunkt auf der Entwicklung der Essential Climate Variables hat. C3S wird durch das Europäische Zentrum für mittelfristige Wettervorhersage betrieben.

### **ESA CCI Initiative**

Das ESA CCI Programm ist eine Initiative der ESA, die sich der umfassenden Untersuchung des Klimawandels widmet. Die ESA CCI Initiative wird seine Bemühungen fortsetzen, wichtige Klimadaten zu erfassen und zu verbessern. Hierzu gehören beispielsweise Satellitendaten zu Temperatur, Meeresspiegel, Eisbedeckung und atmosphärischen Gasen. Durch die kontinuierliche Datenerfassung und -analyse können langfristige Trends und Veränderungen des Klimas besser erfasst und verstanden werden.

Die ESA CCI Initiative wird sich verstärkt auf die Integration von Erdbeobachtungsdaten verschiedener Quellen konzentrieren. Neben Satellitendaten werden auch Daten aus bodenbasierten Messungen und Modellen herangezogen, um ein umfassendes Verständnis des Klimasystems zu ermöglichen und Unsicherheiten zu reduzieren. Nachdem ein CCI Indikator als operationell eingestuft wurde, kann er in den C3S Dienst übergehen.

Die Fernerkundung bietet ein umfangreiches Potenzial für die Erfassung von Klimaindikatoren, insbesondere im Bereich der Gewässer und Landbedeckung. Die Überwachung von Küstenmorphologie, Wassertemperaturen, Algenblüten oder Landnutzungen ermöglicht wichtige Einblicke in den Zustand unserer Umwelt und dessen Veränderungen. Bestehende Datensätze wie ESA CCI und Copernicus Climate Change Service bieten bereits umfangreiche Informationen für diese Analysen auf globaler Ebene. Die Weiterentwicklung der Satellitenfernerkundung, einschließlich hyperspektraler Sensoren und räumlich hochauflösender Daten, verspricht in Zukunft präzisere Erkenntnisse über Klimaentwicklungen und unterstützt dadurch effektive Anpassungsstrategien.

## 6 Quellenverzeichnis

- Adrian, R., O'Reilly, C. M., Zagarese, H., Baines, S. B., Hessen, D. O., Keller, W., Livingstone, D. M., Sommaruga, R., Straile, D., Van Donk, E., Weyhenmeyer, G. A. & Winder, M. (2009): Lakes as sentinels of climate change. *Limnology and Oceanography*, 54(6), S. 2283–2297. [https://doi.org/10.4319/lo.2009.54.6\\_part\\_2.2283](https://doi.org/10.4319/lo.2009.54.6_part_2.2283)
- Alexandri, E. & Jones, P. (2008): Temperature decreases in an urban canyon due to green walls and green roofs in diverse climates. *Building and Environment*, 43(4), S. 480–493. <https://doi.org/10.1016/j.buildenv.2006.10.055>
- Alikas, K., Kangro, K. & Reinart, A. (2010): Detecting cyanobacterial blooms in large North European lakes using the Maximum Chlorophyll Index. *Oceanologia*, 52(2), S. 237–257. <https://doi.org/10.5697/oc.52-2.237>
- Allan, M. G., Hamilton, D. P., Trolle, D., Muraoka, K. & McBride, C. (2016): Spatial heterogeneity in geothermally-influenced lakes derived from atmospherically corrected Landsat thermal imagery and three-dimensional hydrodynamic modelling. *International Journal of Applied Earth Observation and Geoinformation*, 50, S. 106–116. <https://doi.org/10.1016/j.jag.2016.03.006>
- Ansel, W., Zeidler, J. & Esch, T. (2015): Fernerkundliche Identifizierung von Vegetationsflächen auf Dächern zur Entwicklung des für die Bereiche des Stadtklimas, der Stadtentwässerung und des Artenschutzes aktivierbaren Flächenpotenzials in den Städten. Abschlussbericht des Entwicklungsprojektes gefördert unter dem Az 30299 von der Deutschen Bundesstiftung Umwelt. Abgerufen am 3. Februar 2020 von <https://www.dbu.de/OPAC/ab/DBU-Abschlussbericht-AZ-30299.pdf>
- Ansel, W., Zeidler, J., Esch, T., Bornholdt, H., Ludwig, F. & Schönle, D. (2016): Kommunale Gründach-Strategien Inventarisierung, Potentialanalyse, Praxisbeispiele. Deutscher Dachgärtnerverband [Hrsg.]. Abgerufen am 14. Mai 2024 von <https://nbn-resolving.de/urn:nbn:de:kobv:109-1-8422873>
- Antonova, S., Duguay, C., Kääh, A., Heim, B., Langer, M., Westermann, S. & Boike, J. (2016): Monitoring Bedfast Ice and Ice Phenology in Lakes of the Lena River Delta Using TerraSAR-X Backscatter and Coherence Time Series. *Remote Sensing*, 8(11), S. 903. <https://doi.org/10.3390/rs8110903>
- Arp, C. D., Jones, B. M. & Grosse, G. (2013): Recent lake ice-out phenology within and among lake districts of Alaska, U.S.A. *Limnology and Oceanography*, 58(6), S. 2013–2028. <https://doi.org/10.4319/lo.2013.58.6.2013>
- Barbieux, K., Charitsi, A. & Merminod, B. (2018): Icy lakes extraction and water-ice classification using Landsat 8 OLI multispectral data. *International Journal of Remote Sensing*, 39(11), S. 3646–3678. <https://doi.org/10.1080/01431161.2018.1447165>
- Baret, F. & Guyot, G. (1991): Potentials and limits of vegetation indices for LAI and APAR assessment. *Remote Sensing of Environment*, 35(2-3), S. 161–173. [https://doi.org/10.1016/0034-4257\(91\)90009-U](https://doi.org/10.1016/0034-4257(91)90009-U)
- Barsi, J. A., Hook, S. J., Palluconi, F. D., Schott, J. R. & Raqueno, N. G. (2006): Landsat TM and ETM+ thermal band calibration. In: Butler, J. J. und Xiong, J. [Hrsg.]. *SPIE Optics + Photonics*. San Diego, California, USA, Sunday 13 August 2006: SPIE (SPIE Proceedings), 62960F. <https://doi.org/10.1117/12.683212>
- Baschek, B., Dörnhöfer, K., Fricke, K. & Oppelt, N. (2018): Grundlagen und Möglichkeiten der passiven Fernerkundung von Binnengewässern. In: Calmano, W., Hupfer, M., Fischer, H. und Klapper, H. [Hrsg.]: *Handbuch Angewandte Limnologie. Grundlagen - Gewässerbelastung - Restaurierung - Aquatische Ökotoxikologie - Bewertung - Gewässerschutz*. Weinheim, Germany: Wiley-VCH Verlag GmbH & Co. KGaA. <https://doi.org/10.1002/9783527678488.hbla2018001>
- Beck, R., Xu, M., Zhan, S., Liu, H., Johansen, R., Tong, S., Yang, B., Shu, S., Wu, Q., Wang, S., Berling, K., Murray, S., Emery, E., Reif, M., Harwood, J., Young, J., Martin, M., Stillings, G., Stumpf, ... Huang, Y. (2017): Comparison of Satellite Reflectance Algorithms for Estimating Phycocyanin Values and Cyanobacterial Total Biovolume in a

- Temperate Reservoir Using Coincident Hyperspectral Aircraft Imagery and Dense Coincident Surface Observations. *Remote Sensing*, 9(6), S. 538. <https://doi.org/10.3390/rs9060538>
- Berardi, U., GhaffarianHoseini, A. & GhaffarianHoseini, A. (2014): State-of-the-art analysis of the environmental benefits of green roofs. *Applied Energy*, 115, S. 411–428. <https://doi.org/10.1016/j.apenergy.2013.10.047>
- Bresciani, M., Giardino, C., Lauceri, R., Matta, E., Cazzaniga, I., Pinardi, M., Lami, A., Austoni, M., Viaggiu, E., Congestri, R. & Morabito, G. (2016): Earth observation for monitoring and mapping of cyanobacteria blooms. Case studies on five Italian lakes. *Journal of Limnology*, 76(S1), S. 127-139. <https://doi.org/10.4081/jlimnol.2016.1565>
- Brockmann, C., Doerffer, R., Peters, M., Stelzer, K., Embacher, S. & Ruescas, A. B. (2016): Evolution of the C2RCC neural network for Sentinel 2 and 3 for the retrieval of ocean colour products in normal and extreme optically complex waters. In: Ouwehand, L. [Hrsg.]: Living planet symposium 2016. Proceedings. Noordwijk: ESA Communications (SP / ESA, 740). Abgerufen am 7. Mai 2024 von [http://step.esa.int/docs/extra/Evolution%20of%20the%20C2RCC\\_LPS16.pdf](http://step.esa.int/docs/extra/Evolution%20of%20the%20C2RCC_LPS16.pdf)
- Brooks, B. W., Lazorchak, J. M., Howard, M. D. A., Johnson, M.-V. V., Morton, S. L., Perkins, D. A. K. Reavie, E. D., Scott, G. I., Smith, S. A. & Steevens, J. A. (2016): Are harmful algal blooms becoming the greatest inland water quality threat to public health and aquatic ecosystems? *Environmental toxicology and chemistry*, 35(1), S. 6–13. <https://doi.org/10.1002/etc.3220>
- Brown, L. C. & Duguay, C. R. (2010): The response and role of ice cover in lake-climate interactions. *Progress in Physical Geography*, 34(5), S. 671–704. <https://doi.org/10.1177/0309133310375653>
- Brune, M., Bender, S. & Groth, M. (2017): Gebäudebegrünung und Klimawandel – Anpassung an die Folgen des Klimawandels durch klimataugliche Begrünung. Report 30. Climate Service Center Deutschland [Hrsg.]. Hamburg. Abgerufen am 7. Mai 2024 von <https://www.climate-service-center.de/imperia/md/content/csc/report30.pdf>.
- Bundesverband Gebäudegrün e.V. (BuGG) (2019): Inventarisierung und Potenzialanalyse von Dachbegrünungen. Bundesverband Gebäudegrün e.V. (BuGG). Abgerufen am 27. Februar 2024 von [https://www.gebaeudegruen.info/fileadmin/website/Kontakt/Prospektanforderung/Potentialanalyse\\_4Seiter\\_20200407DE.pdf](https://www.gebaeudegruen.info/fileadmin/website/Kontakt/Prospektanforderung/Potentialanalyse_4Seiter_20200407DE.pdf)
- Cai, Y., Ke, C.-Q. & Duan, Z. (2017): Monitoring ice variations in Qinghai Lake from 1979 to 2016 using passive microwave remote sensing data. *The Science of the total environment*, 607-608, S. 120–131. <https://doi.org/10.1016/j.scitotenv.2017.07.027>
- Canadian Space Agency (2023): RADARSAT Constellation Mission. Abgerufen am 27. Februar 2024 von <https://www.asc-csa.gc.ca/eng/satellites/radarsat/>
- Castagna, A., Simis, S., Dierssen, H., Vanhellefont, Q., Sabbe, K. & Vyverman, W. (2020): Extending Landsat 8. Retrieval of an Orange contra-Band for Inland Water Quality Applications. *Remote Sensing*, 12(4), S. 637. <https://doi.org/10.3390/rs12040637>
- Coenradie, B., Haag, L., Streng, B., Schiffner, S. & Müller, K. (2016): Erhebung und Aufbereitung von Informationen zum Gründachbestand in Berlin. Abschlussbericht. Abgerufen am 3. Februar 2020 von [http://www.stadtentwicklung.berlin.de/umwelt/umweltatlas/download/AB\\_Gruendaecher\\_2016.pdf](http://www.stadtentwicklung.berlin.de/umwelt/umweltatlas/download/AB_Gruendaecher_2016.pdf)
- Crawford, C. J., Roy, D. P., Arab, S., Barnes, C., Vermote, E., Hulley, G. et al. (2023): The 50-year Landsat collection 2 archive. *Science of Remote Sensing*, 8, S. 100103. <https://doi.org/10.1016/j.srs.2023.100103>
- Crétau, J.-F., Merchant, C. J., Duguay, C., Simis, S., Calmettes, B., Bergé-Nguyen, M., Wu, Y., Zhang, D., Carrea, L., Liu, X., Selmes, N. & Warren, M. (2020): ESA Lakes Climate Change Initiative (Lakes\_cci). Lake products, Version 1.0: Centre for Environmental Data Analysis (CEDA). <https://doi.org/10.5285/3c324bb4ee394d0d876fe2e1db217378>

- Croley II, T. E., Quinn, F. H., Kunkel, K. E. & Changnon, S. a. (1998): Great Lakes Hydrology Under Transposed Climates. *Climatic Change*, 38(4), S. 405–433. <https://doi.org/10.1023/A:1005344010723>
- Dekker, A. G. (1993): Detection of optical water quality parameters for eutrophic waters by high resolution remote sensing. [Dissertation, Free University Amsterdam, Acad. Pruefschrift: 1993.] Abgerufen am 8. Mai 2024 von <https://research.vu.nl/en/publications/detection-of-optical-water-quality-parameters-for-eutrophic-water>
- Deutsches Zentrum für Luft- und Raumfahrt (DLR) (25.04.2018): EOC nominiert: Blauer Kompass für grüne Dächer! Esch, Thomas. Abgerufen am 24. Februar 2024 von [https://www.dlr.de/eoc/de/desktopdefault.aspx/tabid-12632/22039\\_read-51552/](https://www.dlr.de/eoc/de/desktopdefault.aspx/tabid-12632/22039_read-51552/)
- Doerffer, R. & Schiller, H. (2007): The MERIS Case 2 water algorithm. *International Journal of Remote Sensing*, 28(3-4), S. 517–535. <https://doi.org/10.1080/01431160600821127>
- Dörnhöfer, K., Klinger, P., Heege, T. & Oppelt, N. (2018): Multi-sensor satellite and in situ monitoring of phytoplankton development in a eutrophic-mesotrophic lake. *Science of The Total Environment*, 612, S. 1200–1214. <https://doi.org/10.1016/j.scitotenv.2017.08.219>
- Dörnhöfer, K. & Oppelt, N. (2016): Remote sensing for lake research and monitoring – Recent advances. *Ecological Indicators*, 64, S. 105–122. <https://doi.org/10.1016/j.ecolind.2015.12.009>
- Du, C., Ren, H., Qin, Q., Meng, J. & Zhao, S. (2015): A Practical Split-Window Algorithm for Estimating Land Surface Temperature from Landsat 8 Data. *Remote Sensing*, 7(1), S. 647–665. <https://doi.org/10.3390/rs70100647>
- Duguay, C. R., Bernier, M., Gauthier, Y. & Kouraev, A. (2015): Remote sensing of lake and river ice. In: Tedesco, M. [Hrsg.]: *Remote Sensing of the Cryosphere*: John Wiley & Sons, Ltd, S. 273–306. <https://doi.org/10.1002/9781118368909.ch12>
- Engram, M., Arp, C. D., Jones, B. M., Ajadi, O. A. & Meyer, F. J. (2018): Analyzing floating and bedfast lake ice regimes across Arctic Alaska using 25 years of space-borne SAR imagery. *Remote Sensing of Environment*, 209, S. 660–676. <https://doi.org/10.1016/j.rse.2018.02.022>
- EOMAP (2016): EOMAP Validation Report. Abgerufen am 27. Februar 2024 von [www.eomap.com/exchange/pdf/EOMAP\\_Validation\\_Examples\\_Water\\_Quality.pdf](http://www.eomap.com/exchange/pdf/EOMAP_Validation_Examples_Water_Quality.pdf)
- Francis, R. A., Lorimer, J. (2011): Urban reconciliation ecology. The potential of living roofs and walls. *Journal of environmental management*, 92(6), S. 1429–1437. <https://doi.org/10.1016/j.jenvman.2011.01.012>
- Freie Hansestadt Bremen (2020): Gründachkataster Bremen. Abgerufen am 27. Februar 2024 von <https://gruendach.bremen.de/#s=map>
- Gege, P. (2014a): A case study at Starnberger See for hyperspectral bathymetry mapping using inverse modelling. IEEE [Hrsg.]: *Proceedings of the WHISPERS conference*. Lausanne, Switzerland, 25-27June 2014. <https://doi.org/10.1109/WHISPERS.2014.8077635>
- Gege, P. (2014b): WASI-2D: A software tool for regionally optimized analysis of imaging spectrometer data from deep and shallow waters. *Computers & Geosciences*, 62, S. 208–215. <https://doi.org/10.1016/j.cageo.2013.07.022>
- Geldsetzer, T., van der Sanden, J. & Brisco, B. (2010): Monitoring lake ice during spring melt using RADARSAT-2 SAR. *Canadian Journal of Remote Sensing*, 36 (sup2), S391-S400. <https://doi.org/10.5589/m11-001>
- Giardino, C., Candiani, G., Bresciani, M., Lee, Z. P., Gagliano, S. & Pepe, M. (2012): BOMBER: A tool for estimating water quality and bottom properties from remote sensing images. *Computers & Geosciences*, 45, S. 313–318. <https://doi.org/10.1016/j.cageo.2011.11.022>

- Gilerson, A. A., Gitelson, A. A., Zhou, J., Gurlin, D., Moses, W., Ioannou, I. & Ahmed, S. A. (2010): Algorithms for remote estimation of chlorophyll-a in coastal and inland waters using red and near infrared bands. *Optics Express*, 18(23), S. 24109–24125. <https://doi.org/10.1364/OE.18.024109>
- Gitelson, A., Dall’Olmo, G., Moses, W., Rundquist, D. C., Barrow, T., Fisher, T. R., Gurlin, D. & Holz, J. (2008): A simple semi-analytical model for remote estimation of chlorophyll-a in turbid waters. *Validation. Remote Sensing of Environment*, 112(9), S. 3582–3593. <https://doi.org/10.1016/j.rse.2008.04.015>
- Gitelson, A. & Kondratyev, K. Y. (1991): Optical models of mesotrophic and eutrophic water bodies. *International Journal of Remote Sensing*, 12(3), S. 373–385. <https://doi.org/10.1080/01431169108929659>
- Gons, H. J. (1999): Optical Teledetection of Chlorophyll a in Turbid Inland Waters. *Environmental Science & Technology*, 33(7), S. 1127–1132. <https://doi.org/10.1021/es9809657>
- Gons, H. J. (2004): Effect of a waveband shift on chlorophyll retrieval from MERIS imagery of inland and coastal waters. *Journal of Plankton Research*, 27(1), S. 125–127. <https://doi.org/10.1093/plankt/fbh151>
- Gorelick, N., Hancher, M., Dixon, M., Ilyushchenko, S., Thau, D. & Moore, R. (2017): Google Earth Engine. Planetary-scale geospatial analysis for everyone. *Remote Sensing of Environment*, 202(3), S. 18–27. <https://doi.org/10.1016/j.rse.2017.06.031>
- Gunn, G. E., Duguay, C. R., Atwood, D. K., King, J. & Toose, P. (2018): Observing Scattering Mechanisms of Bubbled Freshwater Lake Ice Using Polarimetric RADARSAT-2 (C-Band) and UW-Scat (X- and Ku-Bands). *IEEE Transactions on Geoscience and Remote Sensing*, 56(5), S. 2887–2903. <https://doi.org/10.1109/TGRS.2017.2786158>
- Guo, L., Wu, Y., Zheng, H., Zhang, B., Li, J., Zhang, F. & Shen, Q. (2018): Uncertainty and Variation of Remotely Sensed Lake Ice Phenology across the Tibetan Plateau. *Remote Sensing*, 10(10), S. 1534. <https://doi.org/10.3390/rs10101534>
- Häckel, H. (2021): *Meteorologie*. 9. vollst. überarb. u. erw. Auflage, revidierte Ausgabe, erweiterte Ausgabe. ISBN: 9783825255046
- Hampton, S. E., Galloway, A. W. E., Powers, S. M., Ozersky, T., Woo, K. H., Batt, R. D., Labou, S. G., O’Reilly, C. M., Sharma, S., Lottig, N. R., Stanley, E. H., North, R. L., Stockwell, J. D., Adrian, R., Weyhenmeyer, G. A., Arvola, L., Baulch, H. M., Bertani, I., Bowmann Jr., L. L., ... Xenopoulos, M. A. (2017): Ecology under lake ice. *Ecology letters*, 20(1), S. 98–111. <https://doi.org/10.1111/ele.12699>
- Heege, T., Kiselev, V., Wettle, M. & Hung, N. N. (2014): Operational multi-sensor monitoring of turbidity for the entire Mekong Delta. *International Journal of Remote Sensing*, 35(8), S. 2910–2926. <https://doi.org/10.1080/01431161.2014.890300>
- Heinilä, K., Metsämäki, S. & Mattila, O.-P. (2017): Copernicus Global Land Operations “Cryosphere and Water” “CGLOPS-2” Framework Service Contract N° 199496 (JRC). Algorithm theoretical basis document lake ice extent (LIE) collection 250 Baltic Sea Region Version 1.0.1. Abgerufen am 8. Mai 2024 von <https://land.copernicus.eu/en/technical-library/algorithm-theoretical-basis-document-for-lake-ice-extent-baltic-250-m-raster/@@download/file>
- Huang, Y., Liu, H., Hinkel, K., Yu, B., Beck, R. & Wu, J. (2017): Analysis of Thermal Structure of Arctic Lakes at Local and Regional Scales Using in Situ and Multidate Landsat-8 Data. *Water Resources Research*, 53(11), S. 9642–9658. <https://doi.org/10.1002/2017WR021335>
- Huete, A. (1988): A soil-adjusted vegetation index (SAVI). *Remote Sensing of Environment*, 25(3), S. 295–309. [https://doi.org/10.1016/0034-4257\(88\)90106-X](https://doi.org/10.1016/0034-4257(88)90106-X)

- Hunter, P. D., Tyler, A. N., Carvalho, L., Codd, G. A. & Maberly, S. C. (2010): Hyperspectral remote sensing of cyanobacterial pigments as indicators for cell populations and toxins in eutrophic lakes. *Remote Sensing of Environment*, 114(11), S. 2705–2718. <https://doi.org/10.1016/j.rse.2010.06.006>
- O’Neil, J.M., Davis, T.W., Burford, M.A. & Gobler, C.J. (2012): The rise of harmful cyanobacteria blooms: The potential roles of eutrophication and climate change. *Harmful Algae*, 14, S. 313–334. <https://doi.org/10.1016/j.hal.2011.10.027>
- Jimenez-Munoz, J. C., Cristobal, J., Sobrino, J. A., Soria, G., Ninyerola, M. & Pons, X. (2009): Revision of the Single-Channel Algorithm for Land Surface Temperature Retrieval From Landsat Thermal-Infrared Data. *IEEE Transactions on Geoscience and Remote Sensing*, 47(1), S. 339–349. <https://doi.org/10.1109/TGRS.2008.2007125>
- Jimenez-Munoz, J. C., Sobrino, J. A., Skokovic, D., Mattar, C. & Cristobal, J. (2014): Land Surface Temperature Retrieval Methods From Landsat-8 Thermal Infrared Sensor Data. *IEEE Geoscience and Remote Sensing Letters*, 11(10), S. 1840–1843. <https://doi.org/10.1109/LGRS.2014.2312032>
- Kahru, M., Savchuk, O. P. & Elmgren, R. (2007): Satellite measurements of cyanobacterial bloom frequency in the Baltic Sea. Interannual and spatial variability. *Marine Ecology Progress Series*, 343, S. 15–23. <https://doi.org/10.3354/meps06943>
- Kang, K.-K., Duguay, C. R. & Howell, S. E. (2012): Estimating ice phenology on large northern lakes from AMSR-E. Algorithm development and application to Great Bear Lake and Great Slave Lake, Canada. *The Cryosphere*, 6(2), S. 235–254. <https://doi.org/10.5194/tc-6-235-2012>
- Kirillin, G., Leppäranta, M., Terzhevik, A., Granin, N., Bernhardt, J., Engelhardt, C., Efremova, T., Golosov, S., Palshin, N., Sherstyankin, P., Zdorovenova, G. & Zdorovenov, R. (2012): Physics of seasonally ice-covered lakes. A review. *Aquatic Sciences*, 74(4), S. 659–682. <https://doi.org/10.1007/s00027-012-0279-y>
- Kirk, J. T. O. (2010): *Light and photosynthesis in aquatic ecosystems*. 3rd ed. Cambridge, UK, New York: Cambridge University Press. <https://doi.org/10.1017/CBO9781139168212>
- Köhler, M. (2006): Long-Term Vegetation Research on Two Extensive Green Roofs in Berlin. *Urban Habitats*, 4(1), S. 3–26. Abgerufen am 8. Mai 2024 von [https://www.urbanhabitats.org/v04n01/berlin\\_pdf.pdf](https://www.urbanhabitats.org/v04n01/berlin_pdf.pdf)
- Kosten, S., Huszar, V. L. M., Bécares, E., Costa, L. S., Donk, E., Hansson, L.-A., Jeppesen, E., Kruk, C., Lacerot, G., Mazzeo, N., De Meester, L., Moss, B., Lürling, M., Nöges, T., Romo, S. & Scheffer, M. (2012): Warmer climates boost cyanobacterial dominance in shallow lakes. *Global Change Biology*, 18(1), S. 118–126. <https://doi.org/10.1111/j.1365-2486.2011.02488.x>
- Kropáček, J., Maussion, F., Chen, F., Hoerz, S. & Hochschild, V. (2013): Analysis of ice phenology of lakes on the Tibetan Plateau from MODIS data. *The Cryosphere*, 7(1), S. 287–301. <https://doi.org/10.5194/tc-7-287-2013>
- Kutser, T. (2004): Quantitative detection of chlorophyll in cyanobacterial blooms by satellite remote sensing. *Limnology and Oceanography*, 49(6), S. 2179–2189. <https://doi.org/10.4319/lo.2004.49.6.2179>
- Kutser, T. (2009): Passive optical remote sensing of cyanobacteria and other intense phytoplankton blooms in coastal and inland waters. *International Journal of Remote Sensing*, 30(17), S. 4401–4425. <https://doi.org/10.1080/01431160802562305>
- Latifovic, R. & Pouliot, D. (2007): Analysis of climate change impacts on lake ice phenology in Canada using the historical satellite data record. *Remote Sensing of Environment*, 106(4), S. 492–507. <https://doi.org/10.1016/j.rse.2006.09.015>
- Lee, Z., Carder, K. L. & Arnone, R. A. (2002): Deriving inherent optical properties from water color. A multiband quasi-analytical algorithm for optically deep waters. *Applied Optics*, 41(27), S. 5755. <https://doi.org/10.1364/AO.41.005755>

- Leibniz-Institut für Gewässerökologie und Binnenfischerei (IGB) (2018): Seen im Klimawandel. Diagnosen und Prognosen aus der Langzeitforschung. IGB Dossier. Leibniz-Institut für Gewässerökologie und Binnenfischerei (IGB). Abgerufen am 5. März 2020 von [https://www.igb-berlin.de/sites/default/files/media-files/download-files/IGB\\_Dossier\\_Seen\\_im\\_Klimawandel\\_2018\\_WEB.pdf](https://www.igb-berlin.de/sites/default/files/media-files/download-files/IGB_Dossier_Seen_im_Klimawandel_2018_WEB.pdf)
- Li, Y., Zhang, Q., Zhang, L., Tan, Z. & Yao, J. (2017): Investigation of Water Temperature Variations and Sensitivities in a Large Floodplain Lake System (Poyang Lake, China) Using a Hydrodynamic Model. *Remote Sensing*, 9(12), S. 1231. <https://doi.org/10.3390/rs9121231>
- Li, Z.-L., Tang, B.-H., Wu, H., Ren, H., Yan, G., Wan, Z., Trigo, I.F. & Sobrino, J.A. (2013): Satellite-derived land surface temperature. Current status and perspectives. *Remote Sensing of Environment*, 131, S. 14–37. <https://doi.org/10.1016/j.rse.2012.12.008>
- Lieberherr, G. & Wunderle, S. (2018): Lake Surface Water Temperature Derived from 35 Years of AVHRR Sensor Data for European Lakes. *Remote Sensing*, 10(7), S. 990. <https://doi.org/10.3390/rs10070990>
- Liyanaage, H. M., Arachchi, D. N. M., Abeysekara, T. & Guneratne, L. (2016): Toxicology of freshwater cyanobacteria. *Journal of environmental science and health. Part C, Environmental carcinogenesis & ecotoxicology reviews*, 34(3), S. 137–168. <https://doi.org/10.1080/10590501.2016.1193923>
- Lopez, L. S., Hewitt, B. A. & Sharma, S. (2019): Reaching a breaking point. How is climate change influencing the timing of ice breakup in lakes across the northern hemisphere? *Limnology and Oceanography*, 108, S. 437. <https://doi.org/10.1002/lno.11239>
- Louis, J., Debacker, V., Pflu, B., Main-Knorn, M., Bieniarz, J. & Müller-Wilm, U. (2016): Sentinel-2 SEN2COR: L2A Processor for Users. In: ESA Communications [Hrsg.]: Proceedings of the Living Planet Symposium 2016. SP-740 August 2016. Unter Mitarbeit von L. Ouwehand. Prague, Czech Republic, 9-13 May 2016. Abgerufen am 14. Mai 2024 von [https://elib.dlr.de/107381/1/LPS2016\\_sm10\\_3louis.pdf](https://elib.dlr.de/107381/1/LPS2016_sm10_3louis.pdf)
- Lunetta, R. S., Schaeffer, B. A., Stumpf, R. P., Keith, D., Jacobs, S. A. & Murphy, M. S. (2015): Evaluation of cyanobacteria cell count detection derived from MERIS imagery across the eastern USA. *Remote Sensing of Environment*, 157, S. 24–34. <https://doi.org/10.1016/j.rse.2014.06.008>
- Luo, H., Huang, B., Liu, X. & Zhang, K. (2011): Green Roof Assessment by GIS and Google Earth. *Procedia Environmental Sciences*, 10, S. 2307–2313. <https://doi.org/10.1016/j.proenv.2011.09.360>
- Magnuson, J. J. (2000): Historical Trends in Lake and River Ice Cover in the Northern Hemisphere. *Science*, 289(5485), S. 1743–1746. <https://doi.org/10.1126/science.289.5485.1743>
- Mallinis, G., Karteris, M., Theodoridou, I., Tsioukas, V. & Karteris, M. (2014): Development of a nationwide approach for large scale estimation of green roof retrofitting areas and roof-top solar energy potential using VHR natural colour orthoimagery and DSM data over Thessaloniki, Greece. *Remote Sensing Letters*, 5(6), S. 548–557. <https://doi.org/10.1080/2150704X.2014.933276>
- Matthews, M. W. (2011): A current review of empirical procedures of remote sensing in inland and near-coastal transitional waters. *International Journal of Remote Sensing*, 32(21), S. 6855–6899. <https://doi.org/10.1080/01431161.2010.512947>
- Matthews, M. W., Bernard, S. & Robertson, L. (2012): An algorithm for detecting trophic status (chlorophyll-a), cyanobacterial-dominance, surface scums and floating vegetation in inland and coastal waters. *Remote Sensing of Environment*, 124, S. 637–652. <https://doi.org/10.1016/j.rse.2012.05.032>
- Matthews, M. W. & Odermatt, D. (2015): Improved algorithm for routine monitoring of cyanobacteria and eutrophication in inland and near-coastal waters. *Remote Sensing of Environment*, 156, S. 374–382. <https://doi.org/10.1016/j.rse.2014.10.010>

- Mentens, J., Raes, D. & Hermy, M. (2006): Green roofs as a tool for solving the rainwater runoff problem in the urbanized 21st century? *Landscape and Urban Planning*, 77(3), S. 217–226.  
<https://doi.org/10.1016/j.landurbplan.2005.02.010>
- Mobley, C. D. (1994): *Light and water. Radiative transfer in natural waters*; based in part on collaborations with Preisendorfer, R. W.. San Diego, London: Academic Press. Abgerufen am 14. Mai 2024 von <https://www.scirp.org/reference/referencespapers?referenceid=1303203>
- Moore, T. S., Campbell, J. W. & Feng, H. (2001): A fuzzy logic classification scheme for selecting and blending satellite ocean color algorithms. *IEEE Transactions on Geoscience and Remote Sensing*, 39(8), S. 1764–1776.  
<https://doi.org/10.1109/36.942555>
- Moroni, M., Porti, M. & Piro, P. (2019): Design of a Remote-Controlled Platform for Green Roof Plants Monitoring via Hyperspectral Sensors. *Water*, 11(7), S. 1368. <https://doi.org/10.3390/w11071368>
- Moses, W. J., Gitelson, A. A., Berdnikov, S. & Povazhnyy, V. (2009): Estimation of chlorophyll- a concentration in case II waters using MODIS and MERIS data—successes and challenges. *Environmental Research Letters*, 4(4), S. 45005. <https://doi.org/10.1088/1748-9326/4/4/045005>
- Mouw, C. B., Greb, S., Aurin, D., DiGiacomo, P. M., Lee, Z., Twardowski, M., Binding, C. E., Hu, C., Ma, R., Moore, T.S., Moses, W. J. & Craig, S. (2015): Aquatic color radiometry remote sensing of coastal and inland waters. Challenges and recommendations for future satellite missions. *Remote Sensing of Environment*, 160, S. 15–30.  
<https://doi.org/10.1016/j.rse.2015.02.001>
- Murfitt, J., Brown, L. & Howell, S. (2018): Evaluating RADARSAT-2 for the Monitoring of Lake Ice Phenology Events in Mid-Latitudes. *Remote Sensing*, 10(10), S. 1641. <https://doi.org/10.3390/rs10101641>
- Murfitt, J. & Brown, L. C. (2017): Lake ice and temperature trends for Ontario and Manitoba. 2001 to 2014. *Hydrological Processes*, 31(21), S. 3596–3609. <https://doi.org/10.1002/hyp.11295>
- Murfitt, J. & Duguay, C. R. (2020): Assessing the Performance of Methods for Monitoring Ice Phenology of the World’s Largest High Arctic Lake Using High-Density Time Series Analysis of Sentinel-1 Data. *Remote Sensing*, 12(3). <https://doi.org/10.3390/rs12030382>
- Murfitt, J. & Duguay, C. R. (2021): 50 years of lake ice research from active microwave remote sensing. Progress and prospects. *Remote Sensing of Environment*, 264, S. 112616. <https://doi.org/10.1016/j.rse.2021.112616>
- Ndossi, M. & Avdan, U. (2016): Inversion of Land Surface Temperature (LST) Using Terra ASTER Data. A Comparison of Three Algorithms. *Remote Sensing*, 8(12), S. 993. DOI: 10.3390/rs8120993
- Neil, C., Spyrakos, E., Hunter, P. D. & Tyler, A. N. (2019): A global approach for chlorophyll-a retrieval across optically complex inland waters based on optical water types. *Remote Sensing of Environment*, 229, S. 159–178. <https://doi.org/10.1016/j.rse.2019.04.027>
- Nolan, M., Liston, G., Prokein, P., Brigham-Grette, J., Sharpton, V. L. & Huntzinger, R. (2003): Analysis of lake ice dynamics and morphology on Lake El’gygytgyn, NE Siberia, using synthetic aperture radar (SAR) and Landsat. *Journal of Geophysical Research*, 108(D2). <https://doi.org/10.1029/2001JD000934>
- Odermatt, D., Gitelson, A., Brando, V. E. & Schaepman, M. (2012): Review of constituent retrieval in optically deep and complex waters from satellite imagery. *Remote Sensing of Environment*, 118, S. 116–126.  
<https://doi.org/10.1016/j.rse.2011.11.013>
- Ogashawara, I., Mishra, D. R. & Gitelson, A. A. (2017): Remote Sensing of Inland Waters: Background and Current State-of-the-Art. In: Mishra, D. R., Ogashawara, I. und Gitelson, A. A. [Hrsg.]: *Bio-optical modeling and remote sensing of inland waters*. Amsterdam: Elsevier, S. 1–24. <https://doi.org/10.1016/B978-0-12-804644-9.00001-X>

- O'Reilly, J. E., Maritorena, S., O'Brien, M. C., Siegel, D. A., Toole, D., Menzies, D., Smith, R. C., Mueller, J., Mitchell, B.G., Kahru, M., Chavez, F. P., Strutton, P., Cota, G. F., Hooker, S. B., McClain, C. R., Carder, K. L., Müller-Karger, F., Harding, L., Magnuson, A., ... Culver, M. (2000): Ocean color chlorophyll a algorithms for SeaWiFS, OC2, and OC4: Version 4. Part 3. 9-23. NASA Technical Memorandum 2000-206892, 11.
- O'Reilly, J. E. & Werdell, P. J. (2019): Chlorophyll algorithms for ocean color sensors - OC4, OC5 & OC6. *Remote Sensing of Environment*, 229, S. 32–47. <https://doi.org/10.1016/j.rse.2019.04.021>
- Page, B. P., Kumar, A. & Mishra, D. R. (2018): A novel cross-satellite based assessment of the spatio-temporal development of a cyanobacterial harmful algal bloom. *International Journal of Applied Earth Observation and Geoinformation*, 66, S. 69–81. <https://doi.org/10.1016/j.jag.2017.11.003>
- Palmer, S. C., Kutser, T. & Hunter, P. D. (2015): Remote sensing of inland waters: Challenges, progress and future directions. *Remote Sensing of Environment*, 157, S. 1–8. <https://doi.org/10.1016/j.rse.2014.09.021>
- Pareeth, S., Bresciani, M., Buzzi, F., Leoni, B., Lepori, F., Ludovisi, A., Morabito, G., Adrian, R., Neteler, M. & Salmaso, N. (2017): Warming trends of perialpine lakes from homogenised time series of historical satellite and in-situ data. *Science of the Total Environment*, 578, S. 417–426. <https://doi.org/10.1016/j.scitotenv.2016.10.199>
- Pareeth, S., Salmaso, N., Adrian, R. & Neteler, M. (2016): Homogenised daily lake surface water temperature data generated from multiple satellite sensors: A long-term case study of a large sub-Alpine lake. *Scientific reports*, 6, S. 31251. <https://doi.org/10.1038/srep31251>
- Piro, P., Porti, M., Veltri, S., Lupo, E. & Moroni, M. (2017): Hyperspectral Monitoring of Green Roof Vegetation Health State in Sub-Mediterranean Climate. Preliminary Results. *Sensors (Basel, Switzerland)*, 17(4). <https://doi.org/10.3390/s17040662>
- Pitarch, J., Ruiz-Verdú, A., Sendra, M. D. & Santoleri, R. (2017): Evaluation and reformulation of the maximum peak height algorithm (MPH) and application in a hypertrophic lagoon. *Journal of Geophysical Research: Oceans*, 122(2), S. 1206–1221. <https://doi.org/10.1002/2016JC012174>
- Politi, E., Cutler, M. E. J. & Rowan, J. S. (2012): Using the NOAA Advanced Very High Resolution Radiometer to characterise temporal and spatial trends in water temperature of large European lakes. *Remote Sensing of Environment*, 126, S. 1–11. <https://doi.org/10.1016/j.rse.2012.08.004>
- Prowse, T., Alfredsen, K., Beltaos, S., Bonsal, B., Duguay, C., Korhola, A., McNamara, J., Pienitz, R., Vincent, W. F., Vuglinsky, V. & Weyhenmeyer, G. A. (2011): Past and Future Changes in Arctic Lake and River Ice. *Ambio*, 40(S1), S. 53–62. <https://doi.org/10.1007/s13280-011-0216-7>
- Qi, M., Yao, X., Li, X., Duan, H., Gao, Y. & Liu, J. (2019): Spatiotemporal characteristics of Qinghai Lake ice phenology between 2000 and 2016. *Journal of Geographical Sciences*, 29(1), S. 115–130. <https://doi.org/10.1007/s11442-019-1587-0>
- Qin, Z., Karnieli, A. & Berliner, P. (2001): A mono-window algorithm for retrieving land surface temperature from Landsat TM data and its application to the Israel-Egypt border region. *International Journal of Remote Sensing*, 22(18), S. 3719–3746. <https://doi.org/10.1080/01431160010006971>
- Richardson, L. L. (1996): Remote Sensing of Algal Bloom Dynamics. *BioScience*, 46(7), S. 492–501. <https://doi.org/10.2307/1312927>
- Richardson, L. L. & LeDrew E. F. (2006): Remote sensing and the science, monitoring, and management of aquatic ecosystems. In: van de Meer, F. D., Richardson, L. L. und LeDREW, E. F. [Hrsg.]: Remote sensing of aquatic coastal ecosystem processes, Bd. 9. Dordrecht: Springer Netherlands (Remote Sensing and Digital Image Processing), S. 1–7.

- Rondeaux, G., Steven, M. & Baret, F. (1996): Optimization of soil-adjusted vegetation indices. *Remote Sensing of Environment*, 55(2), S. 95–107. [https://doi.org/10.1016/0034-4257\(95\)00186-7](https://doi.org/10.1016/0034-4257(95)00186-7)
- Rowe, D. B. (2011): Green roofs as a means of pollution abatement. *Environmental Pollution*, 159(8-9), S. 2100–2110. <https://doi.org/10.1016/j.envpol.2010.10.029>
- Rozenstein, O., Qin, Z., Derimian, Y. & Karnieli, A. (2014): Derivation of land surface temperature for Landsat-8 TIRS using a split window algorithm. *Sensors (Basel, Switzerland)*, 14(4), S. 5768–5780. <https://doi.org/10.3390/s140405768>
- Ruiz-Verdú, A., Simis, S. G., Hoyos, C. de Gons, H. J. & Peña-Martínez, R. (2008): An evaluation of algorithms for the remote sensing of cyanobacterial biomass. *Remote Sensing of Environment*, 112(11), S. 3996–4008. <https://doi.org/10.1016/j.rse.2007.11.019>
- Salehi, B., Zhang, Y., Zhong, M. & Dey, V. (2012): Object-Based Classification of Urban Areas Using VHR Imagery and Height Points Ancillary Data. *Remote Sensing*, 4(8), S. 2256–2276. <https://doi.org/10.3390/rs4082256>
- Santos, T., Tenedório, J. & Gonçalves, J. (2016): Quantifying the City's Green Area Potential Gain Using Remote Sensing Data. *Sustainability*, 8(12), S. 1247. <https://doi.org/10.3390/su8121247>
- Schaeffer, B. A., Iliames, J., Dwyer, J., Urquhart, E., Salls, W., Rover, J. & Seegers, B. (2018): An initial validation of Landsat 5 and 7 derived surface water temperature for U.S. lakes, reservoirs, and estuaries. *International Journal of Remote Sensing*, 39(22), S. 7789–7805. <https://doi.org/10.1080/01431161.2018.1471545>
- Schönthaler, K., von Andrian-Werburg, S., Zebisch, M. & Becker, D. (2017): Welchen Beitrag können Satellitenfernerkundung und insbesondere Copernicus-Daten und –Dienste für die Ermittlung ausgewählter Indikatoren des Indikatoren-Sets der Deutschen Anpassungsstrategie an den Klimawandel (DAS) leisten. Umweltbundesamt (UBA) [Hrsg.]. Abgerufen am 7. Mai 2024 [https://www.umweltbundesamt.de/sites/default/files/medien/1410/publikationen/2017-02-23\\_climate-change\\_07-2017\\_copernicus.pdf](https://www.umweltbundesamt.de/sites/default/files/medien/1410/publikationen/2017-02-23_climate-change_07-2017_copernicus.pdf)
- Schroeder, T., Behnert, I., Schaale, M., Fischer, J. & Doerffer, R. (2007a): Atmospheric correction algorithm for MERIS above case-2 waters. *International Journal of Remote Sensing*, 28(7), S. 1469–1486. <https://doi.org/10.1080/01431160600962574>
- Schroeder, T., Schaale, M. & Fischer, J. (2007b): Retrieval of atmospheric and oceanic properties from MERIS measurements. A new Case-2 water processor for BEAM. *International Journal of Remote Sensing*, 28(24), S. 5627–5632. <https://doi.org/10.1080/01431160701601774>
- Sempel, F., Gorbachevskaya, O., Mewis, I. & Ulrichs, C. (2013): Modellversuch zur Feinstaubbindung. Extensive Dachbegrünung vs. Schotterdach. *Gesunde Pflanzen*, 65(3), S. 113–118. <https://doi.org/10.1007/s10343-013-0305-6>
- Simis, S., Selmes, N., Calmettes, B., Duguay, C. R., Merchant, C. J., Malnes, E., Yésou, H. & Blanco P. (2020a): D4.3: Product User Guide (PUG) CCI-LAKES-0029-PUG. Abgerufen am 15. Mai 2024 von [https://climate.esa.int/media/documents/CCI-LAKES-0029-PUG\\_v1.1\\_signed\\_CA.pdf](https://climate.esa.int/media/documents/CCI-LAKES-0029-PUG_v1.1_signed_CA.pdf)
- Simis, S., Stelzer, K., Müller, D. & Selmes, N. (2020b): Copernicus Global Land Operations “Cryosphere and Water” “CGLOPS-2”. Algorithm theoretical basis document lake waters 300 m and 1 km products Versions 1.3.0 - 1.4.0 Issue I1.12. Abgerufen am 8. Mai 2024 <https://land.copernicus.eu/en/technical-library/lake-water-quality-v1.0/@download/file>
- Simis, S. G. H., Peters, S. W. M. & Gons, H. J. (2005): Remote sensing of the cyanobacterial pigment phycocyanin in turbid inland water. *Limnology and Oceanography*, 50(1), S. 237–245. <https://doi.org/10.4319/lo.2005.50.1.0237>

- Simon, R. N., Tormos, T. & Danis, P.-A. (2014): Retrieving water surface temperature from archive LANDSAT thermal infrared data: Application of the mono-channel atmospheric correction algorithm over two freshwater reservoirs. *International Journal of Applied Earth Observation and Geoinformation*, 30, S. 247–250. <https://doi.org/10.1016/j.jag.2014.01.005>
- Sobrino, J. A., Jiménez-Muñoz, J. C. & Paolini, L. (2004): Land surface temperature retrieval from LANDSAT TM 5. *Remote Sensing of Environment*, 90(4), S. 434–440. <https://doi.org/10.1016/j.rse.2004.02.003>
- Sòria-Perpinyà, X., Vicente, E., Urrego, P., Pereira-Sandoval, M., Ruíz-Verdú, A., Delegido, J., Soria, J. M. & Moreno, J. (2020): Remote sensing of cyanobacterial blooms in a hypertrophic lagoon (Albufera of València, Eastern Iberian Peninsula) using multitemporal Sentinel-2 images. *Science of The Total Environment*, 698, S. 134305. <https://doi.org/10.1016/j.scitotenv.2019.134305>
- Spyrakos, E., O'Donnell, R., Hunter, P. D., Miller, C., Scott, M., Simis, S. G. H., Neil, C., Barbosa, C. C. F., Binding, C. E., Bradt, S., Bresciani, M., Dall'Olmo, G., Giardino, C., Gitelson, A. A., Kutser, T., Li, L., Matsushita, B., Martinez-Vicente, V., Matthews, M. W., ... Tyler, A. N. (2017): Optical types of inland and coastal waters. *Limnology and Oceanography*, 17, S. 14. <https://doi.org/10.1002/lno.10674>
- Steinmetz, F., Deschamps, P.-Y. & Ramon, D. (2011): Atmospheric correction in presence of sun glint. Application to MERIS. *Optics Express*, 19(10), S. 9783. <https://doi.org/10.1364/OE.19.009783>
- Sterckx, S., Knaeps, E., Adriaensen, S., Reusen, I., Keukelaere, L. de, Hunter, P., Giardino, C. & Odermatt, D. (2015): OPERA: An Atmospheric Correction for Land and Water. In Ouwehand, L. [Hrsg.]: *Sentinel-3 for Science Workshop*. Noordwijk, The Netherlands: ESA Communications (ESA SP, 1609-042X, 734).
- Tom, M., Aguilar, R., Imhof, P., Leinss, S., Baltsavias, E. & Schindler, K. (2020): Lake ice detection from Sentinel-1 SAR with deep learning. *ISPRS Annals of Photogrammetry, Remote Sensing and Spatial Information Sciences*, V-3-2020, S. 409–416. <https://doi.org/10.5194/isprs-annals-V-3-2020-409-2020>
- Umweltbundesamt (UBA) (2011): Entwicklung eines Indikatorensystems für die Deutsche Anpassungsstrategie an den Klimawandel (DAS). Unter Mitarbeit von Pieck, S., Tröltzsch, J., Küchenhoff H. & Rubenbauer, S. Schönthaler, K., von Andrian-Werburg S. & Nickel, D. [Hrsg.]. Abgerufen am 5. Mai 2020 von <https://www.umweltbundesamt.de/publikationen/entwicklung-eines-indikatorensystems-fuer-deutsche>
- Umweltbundesamt (UBA) (2015): *Monitoringbericht 2015 zur Deutschen Anpassungsstrategie an den Klimawandel. Bericht der Interministeriellen Arbeitsgruppe Anpassungsstrategie der Bundesregierung*. Schönthaler, K., von Andrian-Werburg, S., van Rùth, P. & Hempen, S.. [Hrsg.]. Abgerufen am 15. Mai 2024 von <https://www.umweltbundesamt.de/publikationen/monitoringbericht-2015>
- Umweltbundesamt (UBA) (2019): *Monitoringbericht 2019 zur Deutschen Anpassungsstrategie an den Klimawandel. Bericht der Interministeriellen Arbeitsgruppe Anpassungsstrategie der Bundesregierung*. Van Rùth, P., Schönthaler, K., von Andrian-Werburg, S., & Buth, M. [Hrsg.]. Abgerufen am 15. Mai 2024 von <https://www.umweltbundesamt.de/publikationen/umweltbundesamt-2019-monitoringbericht-2019-zur>
- Umweltbundesamt (UBA) (2020): Auf dem Weg zu klimagerechten kommunalen Infrastrukturen. Abschlussbericht. Climate Change. B. Mahler, T. Nusser, S. Idler, L. Traud, S. Bendiks, Dresler A. D. und Schwerdtle, B. & Vartmann, A. [Hrsg.] (9). Abgerufen am 5. Mai 2020 von <https://www.umweltbundesamt.de/publikationen/klimagerechte-kommunale-infrastrukturen>
- Umweltbundesamt (UBA) (2023): *Monitoringbericht 2023 zur Deutschen Anpassungsstrategie an den Klimawandel. Bericht der Interministeriellen Arbeitsgruppe Anpassungsstrategie der Bundesregierung*. Van Rùth, P., Schönthaler, K., von Andrian-Werburg, S., Wolf, M. & Gabriel, M. [Hrsg.]. Abgerufen am 5. Mai 2020 von <https://www.umweltbundesamt.de/publikationen/monitoringbericht-2023>

- Urquhart, E. A., Schaeffer, B. A., Stumpf, R. P., Loftin, K. A. & Werdell, P. J. (2017): A method for examining temporal changes in cyanobacterial harmful algal bloom spatial extent using satellite remote sensing. *Harmful Algae*, 67, S. 144–152. <https://doi.org/10.1016/j.hal.2017.06.001>
- van der Sanden, J. J., Short, N. H. & Drouin, H. (2018): InSAR coherence for automated lake ice extent mapping. TanDEM-X bistatic and pursuit monostatic results. *International Journal of Applied Earth Observation and Geoinformation*, 73, S. 605–615. <https://doi.org/10.1016/j.jag.2018.08.009>
- van Renterghem, T., Hornikx, M., Forssen, J. & Botteldooren, D. (2013): The potential of building envelope greening to achieve quietness. *Building and Environment*, 61, S. 34–44. <https://doi.org/10.1016/j.buildenv.2012.12.001>
- Vanhellemont, Q. (2019): Adaptation of the dark spectrum fitting atmospheric correction for aquatic applications of the Landsat and Sentinel-2 archives. *Remote Sensing of Environment*, 225, S. 175–192. <https://doi.org/10.1016/j.rse.2019.03.010>
- Vanhellemont, Q. & Ruddick, K. (2016): ACOLITE for Sentinel-2: aquatic applications of MSI imagery. In: ESA Communications [Hrsg.]: Proceedings of the Living Planet Symposium 2016. SP-740 August 2016. Unter Mitarbeit von L. Ouwehand. Prague, Czech Republic, 9-13 May 2016.
- Wang, F., Qin, Z., Song, C., Tu, L., Karnieli, A. & Zhao, S. (2015): An Improved Mono-Window Algorithm for Land Surface Temperature Retrieval from Landsat 8 Thermal Infrared Sensor Data. *Remote Sensing*, 7(4), S. 4268–4289. <https://doi.org/10.3390/rs70404268>
- Weber, H., Riffler, M., Nöges, T. & Wunderle, S. (2016): Lake ice phenology from AVHRR data for European lakes. An automated two-step extraction method. *Remote Sensing of Environment*, 174, S. 329–340. <https://doi.org/10.1016/j.rse.2015.12.014>
- Weyhenmeyer, G. A. (2009): Do warmer winters change variability patterns of physical and chemical lake conditions in Sweden? *Aquatic Ecology*, 43(3), S. 653–659. <https://doi.org/10.1007/s10452-009-9284-1>
- Woolway, R. I., Kraemer, B. M., Lenters, J. D., Merchant, C. J., O'Reilly, C. M. & Sharma, S. (2020): Global lake responses to climate change. *Nature Reviews Earth & Environment*, 1(8), S. 388–403. <https://doi.org/10.1038/s43017-020-0067-5>
- Wynne, T. T., Stumpf, R. P., Tomlinson, M. C. & Dyble, J. (2010): Characterizing a cyanobacterial bloom in Western Lake Erie using satellite imagery and meteorological data. *Limnology and Oceanography*, 55(5), S. 2025–2036. <https://doi.org/10.4319/lo.2010.55.5.2025>
- Zakhvatkina, N., Korosov, A., Muckenhuber, S., Sandven, S. & Babiker, M. (2017): Operational algorithm for ice–water classification on dual-polarized RADARSAT-2 images. *The Cryosphere*, 11(1), S. 33–46. <https://doi.org/10.5194/tc-11-33-2017>
- Zhang, S. & Pavelsky, T. M. (2019): Remote Sensing of Lake Ice Phenology across a Range of Lakes Sizes, ME, USA. *Remote Sensing*, 11(14), S. 1718. <https://doi.org/10.3390/rs11141718>
- Zhao, Z., Wang, J., Fu, C., Liu, Z., Liu, D. & Li, B. (2018): Design of a Smart Sensor Network System for Real-Time Air Quality Monitoring on Green Roof. *Journal of Sensors* 2018, S. 1–13. <https://doi.org/10.1155/2018/1987931>

## A Übersicht über alle Untersuchungsseen

**Tabelle 15:** Liste der untersuchten Seen und Angabe über die an dem See gebildeten Indikatoren. Phase: 1 = Fallstudie + Operationalisierung, 2 = nur Operationalisierung. Ind. 1 = Cyanobakterienbelastung in Badegewässern, Ind. 2 = Frühjahrsalgenblüte in Seen, Ind. 3 = Wassertemperatur in Seen, Ind. 4 = Eisbedeckung in Seen

See	Phase	Ind. 1	Ind. 2	Ind. 3	Ind. 4
Abstorfer See	1	0	1	1	0
Alster	1	0	1	0	0
Altmühlsee	2	1	1	1	0
Ammersee	1	1	1	1	0
Arendsee	1	1	1	1	0
Bleilochtalsperre	1	0	1	1	0
Bodensee Obersee	1	1	1	1	0
Bodensee Untersee	1	1	1	1	0
Borgwallsee	2	1	1	1	0
Chiemsee	2	1	1	1	0
Dahme	1	0	0	1	0
Dobersdorfer See	1	1	1	1	0
Dümmer	2	0	1	1	0
Engeratsgundsee	1	0	0	0	1
Freibergsee	1	0	0	0	1
Goldberger See	2	1	1	1	0
Grimnitzsee	2	1	1	1	0
Großer Alpsee	1	0	0	1	1
Großer Brombachsee	1	1	1	1	1
Großer Müggelsee	1	1	1	1	1
Großer Plöner See	1	1	1	1	0
Grüntensee	1	0	0	0	1
Hemmelsdorfer See	2	1	1	1	0
Königsee	2	1	0	1	0
Kummerower See	1	1	1	1	0

See	Phase	Ind. 1	Ind. 2	Ind. 3	Ind. 4
Laacher See	1	1	1	1	0
Malchiner See	2	1	1	1	0
Meerfelder Maar	2	0	0	1	0
Mindelsee	2	1	0	1	0
Müritz	1	1	1	1	0
Niedersonthofener See	1	0	0	0	1
Parsteiner See	2	1	1	1	0
Plauer See	2	1	1	1	0
Pulvermaar	2	0	0	1	0
Rappbodeltalsperre	2	0	0	1	0
Ratzeburger See	2	1	1	1	0
Rottachsee	1	0	0	1	1
Saidenbachtalsperre	1	0	1	1	0
Schalkenmehrener Maar	2	0	0	1	0
Schluchsee	2	1	0	1	0
Selenter See	2	1	1	1	0
Simssee	2	1	0	1	0
Speicher Witznitz	1	1	1	1	0
Starnberger See	1	1	1	1	0
Steinhuder Meer	1	1	1	1	0
Süßer See	2	0	1	1	0
Titisee	2	0	0	1	0
Talsperre Bautzen	1	1	1	1	0
Talsperre Zeulenroda	2	0	0	1	0
Waginger See	2	1	0	1	0
Walchensee	1	1	1	1	0
Wittensee	2	1	1	1	0
Wolziger See	2	1	1	1	0
Zwischenahner Meer	2	1	1	1	0

Quelle: eigene Zusammenstellung, CAU Kiel, Brockmann Consult GmbH

## B Ergebnisse der Fallstudien an den Seen

Anhang B fasst die Ergebnisse der Validierungsstudien an den Fallstudienseen zu den einzelnen Indikatoren zusammen.

### B.1 Cyanobakterienbelastung von Badegewässern

Unter den Algorithmen, die für die Überwachung der Cyanobakterienbelastung in der Literaturrecherche in Betracht gezogen wurden, hat es nur ein Algorithmus in die engere Auswahl geschafft. Aufgrund dessen wurden keine weiteren Validierungsstudien von anderen Algorithmen durchgeführt. Für die Fallstudien wurde der MPH ausgewählt.

### B.2 Frühjahrsalgenblüte in Seen

#### B.2.1 Ausgewählte Algorithmen

Die Vorauswahl der Algorithmen wurde durch die qualitativen Bewertungsparameter (Kapitel 2.6) bestimmt. Durch die Verknüpfung von verschiedenen Atmosphärenkorrekturen und Chlorophyllalgorithmen ergeben sich entsprechend verschiedene Kombinationsmöglichkeiten. Für die Berechnung der Chlorophyll-a Konzentration wurden zwei unterschiedliche Methoden angewandt. Zum einen der **gekoppelte Algorithmus**, der neben der Atmosphärenkorrektur auch die Berechnung der Chlorophyll-a Konzentration beinhaltet. Zum anderen die Anwendung von unabhängigen Algorithmen, bei denen zuerst eine alleinstehende Atmosphärenkorrektur durchgeführt wird und darauf aufbauend ein Chlorophyll-a Algorithmus angewendet wird (**Algorithmus Kombinationen**).

Für **Sentinel-2 MSI** wurden die zwei Atmosphärenkorrekturen ACOLITE und C2X COMPLEX in die nähere Auswahl gezogen. Für die Berechnung des Wasserparameters Chlorophyll-a aus den atmosphärisch korrigierten Daten wurden die Algorithmen Gons und OC3 verwendet. Mit einer verwendeten räumlichen Auflösung von 20 m können alle Fallstudienseen abgedeckt werden. Zeitlich deckt Sentinel-2 den Zeitraum Juni 2015 bis heute ab.

Für **Sentinel-3 OLCI** wurde die Atmosphärenkorrektur C2RCC v.2 ausgewählt. Diese wurde in als gekoppelter und Kombination mit den Chlorophyll-a Algorithmen für die Berechnung des Wasserparameters Chlorophyll-a verwendet (Gons, Gilerson, OC4). Zusätzlich wurde der gekoppelte MPH Algorithmus verwendet. Mit einer räumlichen Auflösung von 300 m können alle mittelgroßen und großen Fallstudienseen abgedeckt werden. Die Datenreihe steht seit Februar 2016 zur Verfügung.

Ebenfalls in 300 m Auflösung stehen die Daten des **ENVISAT MERIS** Sensors für den Zeitraum Mitte 2002 bis Anfang 2012 zur Verfügung. Für MERIS wurde die Atmosphärenkorrektur C2RCC als gekoppelte Variante und als alleinstehende Atmosphärenkorrektur mit zwei darauf aufbauenden Algorithmen zu Berechnung des Wasserparameters Chlorophyll-a (Gons, Gilerson) ausgewählt. MERIS ebenfalls die mittelgroßen und großen Fallstudienseen abgedeckt werden.

**Tabelle 16: Übersicht und Referenzen zu den in den Fallstudien zur Frühjahrsalgenblüte untersuchten Algorithmen und Daten**

Name	Sensor	Quelle
<b>Atmosphärenkorrektur</b>		
ACOLITE	Sentinel-2 MSI	Vanhellemont 2019
C2RCC	Sentinel-2 MSI	Doerffer und Schiller 2007; Brockmann et al. 2016
	Sentinel-3 OLCI	Doerffer und Schiller 2007; Brockmann et al. 2016
	ENVISAT MERIS	Doerffer und Schiller 2007; Brockmann et al. 2016
<b>gekoppelte Algorithmen (AC + CHL)</b>		
C2RCC v2.0	Sentinel 3 OLCI	Doerffer und Schiller 2007; Brockmann et al. 2016
	ENVISAT MERIS	Doerffer und Schiller 2007; Brockmann et al. 2016
C2X-COMPLEX	Sentinel-2 MSI	Doerffer und Schiller 2007; Brockmann et al. 2016
MPH (BRR + CHL)	Sentinel-3 OLCI	Matthews et al. 2012; Matthews und Odermatt 2015
MPH Pitarch	Sentinel-3 OLCI	Pitarch et al. 2017
<b>Chlorophyll-a Algorithmen</b>		
OC3	Sentinel-2 MSI	O'Reilly et al. 2000
OC4	Sentinel-3 OLCI	O'Reilly et al. 2000
Gilerson	Sentinel-3 OLCI	Gilerson et al. 2010
	ENVISAT MERIS	Gilerson et al. 2010
Gons	Sentinel-2 MSI	Gons 2004
	Sentinel-3 OLCI	Gons 2004
	ENVISAT MERIS	Gons 2004

Quelle: eigene Zusammenstellung, CAU Kiel, Brockmann Consult GmbH

### Atmosphärenkorrektur ACOLITE

ACOLITE (Vanhellemont 2019) wurde für die atmosphärische Korrektur für küstennahe Gewässer und Binnengewässer entwickelt. Die zugrundeliegende Methode ist ein Ansatz zur Anpassung des Dunkelspektrums (DSF-Ansatz). Der DSF konstruiert unabhängig für jede Wellenlänge ein dunkles Spektrum unter Verwendung des Minimums des Level 1 - Reflexionsvermögens in einer Unterszene. Unter Verwendung von Nachschlagetabellen (Look up tables), die aus der Strahlungstransfermodellierung vorgeneriert wurden, wählt die Methode dann den Aerosoltyp und die optische Aerosoldicke aus, die optimal zum Dunkelspektrum passen. Interessanterweise macht ACOLITE keine Annahmen über das Wasserreflexionsspektrum und hat daher keine Schwierigkeiten mit außergewöhnlichen

Wasserbedingungen wie ungewöhnlich absorbierenden, suspendierten Sedimenten, ungewöhnlichen Phytoplanktonpigmenten, schwimmender Vegetation oder sogar Landoberflächen umzugehen. Einschränkungen von ACOLITE ergeben sich, wenn sich keine dunklen Ziele in einer Kachel befinden (dies geschieht insbesondere in homogenen Wüsten- oder Schnee- / Eisregionen, im Allgemeinen jedoch nicht in Binnengewässern). Eine weitere Einschränkung ist, dass ACOLITE in der vorliegenden Version den Nachbarschaftseffekt nicht korrigiert. Dieser ist besonders bei Seen mit bewaldeter Umgebung oder Seen in urbanen Räumen von Nachteil. Der Nachbarschaftseffekt beschreibt die Überstrahlung des Signals von benachbarten Oberflächen. In dieser Studie wurde der ACOLITE 20190326.0 Prozessor verwendet.

### **Atmosphärenkorrektur C2RCC**

Der C2RCC Algorithmus (Doerffer und Schiller 2007; Brockmann et al. 2016) hat sich aus dem ursprünglich für MERIS entwickelten Algorithmus „Case 2“ entwickelt. Er basiert auf einer Suite von Neuronalen Netzen. Ein Modell für wasserinhärente optische Eigenschaften und ein gekoppeltes Wasser-Atmosphäre-Strahlungstransfermodell werden verwendet, um eine sehr große Anzahl von Wasserreflexions- und TOA-Reflexionsspektren aus verschiedenen Kombinationen von Konzentrationen der Wasserinhaltsstoffe und unterschiedliche atmosphärischen Bedingungen zu erzeugen. Diese simulierten TOA-Reflexionsspektren werden verwendet, um ein neuronales Netz zu trainieren, das dann jedes eingegebene TOA-Reflexionsspektrum schnell invertieren kann, um optimale Schätzungen von Wasserreflexion und den Konzentrationen der Wasserinhaltsstoffe darzustellen. Der C2RCC Algorithmus zeigt robuste Leistung unter einer Reihe von Wasser- und Atmosphärenbedingungen, einschließlich extrem absorbierendem und extrem streuendem Wasser. Eine Einschränkung von C2RCC besteht darin, dass das Wasserreflexionsvermögen den Wertebereichen der Spektren entsprechen muss, die im Trainingssatz für neuronale Netze vorhanden waren. Wenn ein ungewöhnliches Wasserreflexionsspektrum auftritt, ist die Ausgabe des Algorithmus möglicherweise fehlerhaft. Diese Fälle werden mit "Out-of-Scope" oder „Out-of-Range“ gekennzeichnet. C2RCC ist ein gekoppelter Algorithmus, da er sowohl atmosphärisch korrigierte Wasserreflexionen als auch die Wasserinhaltsstoffe berechnet. Im Zusammenhang mit DASIF wird C2RCC als eigenständige Atmosphärenkorrektur und als gekoppelter Algorithmus verwendet. Für ENVISAT MERIS und für Sentinel-3 OLCI werden die Standardnetze in Version 2.0 verwendet und für Sentinel-2 MSI werden die C2X-COMPLEX Netze verwendet.

### **Gekoppelter Algorithmus C2X-COMPLEX (Atmosphärenkorrektur + Chlorophyll-a)**

Für Sentinel-2 MSI wurden für den gekoppelten C2RCC Algorithmus neuronale Netze trainiert, deren Trainingsdatensatz optische Modelle komplexer Gewässer repräsentieren. Das heißt, dass diese trainierten Netze die Eigenschaften besonders von Binnengewässern und deren Konzentrationsbereiche für die Chlorophyll-a Konzentration und die Trübung abdecken.

### **Gekoppelter Algorithmus MPH (Atmosphärenkorrektur + Chlorophyll-a)**

Der MPH Algorithmus ist bereits in Kapitel 3.3 genauer beschrieben. Eine neu kalibrierte Variante des MPH nach Pitarch et al. (2017) wird für die Chlorophyll-a Berechnung verwendet.

### **Gekoppelter Algorithmus MPH Pitarch (Atmosphärenkorrektur + Chlorophyll-a)**

Der MPH Pitarch Algorithmus (Pitarch et al. 2017) beinhaltet eine Neukalibrierung mit einer Kalibrierungskurve dritten Grades und eine Modifikation des originalen MPH Ansatzes durch die Berücksichtigung eines Phycocyanin Indexes. Die neukalibrierte Version zeigt eine deutliche Verbesserung der Chlorophyll-a Konzentrationen bei gemischten Phytoplanktonpopulationen und bei dominantem Cyanobakterienvorkommen.

### Chlorophyll-a Algorithmen OC3 und OC4

Die Chlorophyll-a Algorithmen OC3 und OC4 (O'Reilly et al. 2000; O'Reilly und Werdell 2019) gehören zu den Algorithmen, die das Blau / Grün Verhältnis in einem Gewässer nutzen. Diese wurde für ozeanische „Case 1“ Gewässer entwickelt und sind ziemlich zuverlässig, sofern die Bedingungen von „Case 1“ Gewässern erfüllt sind. Das heißt, dass die optischen Eigenschaften des Wassers primär auf den Eigenschaften von Phytoplankton beruhen. Diese Algorithmen schlagen fehl oder liefern fehlerhafte Ergebnisse, wenn diese Bedingungen nicht erfüllt sind, z. B. wenn sich signifikante Mineralpartikel in Suspension befinden und / oder wenn gelöstes organisches Material (Gelbstoffe) nicht-marinen Ursprungs vorhanden ist, wie in Flussmündungen und Flussfahnen oder huminstoffreichen Seen. Diese Algorithmen wurden ausgewählt, um die Chlorophyll-a Konzentration in klaren Seen zu bestimmen.

### Chlorophyll-a Algorithmus Gilerson und Gons

Die Chlorophyll-a Algorithmen Gilerson (Gilerson et al. 2010) und Gons (Gons 2004) basieren auf der Absorption von Chlorophyll-a bei 665 nm. Diese Algorithmen funktionieren am besten unter Bedingungen mit hohem Reflexionsvermögen (trübe Gewässer) und hohen Chlorophyll-a Konzentrationen, da das Reflexionsvermögen bei 665 nm großen relativen Fehlern in klarem Wasser unterliegt und der Einfluss der Chlorophyll-a Absorption in diesem Wellenlängenbereich möglicherweise nicht nachweisbar ist. Diese Algorithmen wurden ursprünglich basierend auf ENVISAT MERIS und Sentinel-3 OLCI entwickelt und konnten für Sentinel-2 MSI angepasst werden (Vanhellemont und Ruddick 2016).

## B.2.2 Ergebnisse der Validierung


Die Repräsentativität der aus den Satellitendaten berechneten Chlorophyll-a-Konzentration hängt stark von der Klarheit des Gewässers ab. Bei eutrophen Zuständen ist die Eindringtiefe des Lichts geringer als bei klaren Gewässern. Es wird davon ausgegangen, dass diese Eindringtiefe für Seen zwischen 0 - 5 m liegt, weswegen die verfügbaren in-situ Daten entsprechend auf die Oberflächenmessungen reduziert wurden.

### Sentinel-2 MSI

Für die Validierung wurden die Chlorophyll-a Messungen aus der DASIF-Datenbank ausgewählt, die am nächsten zu Oberfläche durchgeführt wurden und die Tiefe von 5 m nicht überschreiten. Eine weitere Bedingung für die Auswahl von Messdaten ist die zeitliche Messung innerhalb von einem Tag vor oder nach der Satellitenaufnahme. Bei den manuell erfassten in-situ Chlorophyll-a Messungen wurden nicht immer die Information der Aufnahmezeit mitgeliefert. Es wird davon ausgegangen, dass die Beprobung während der Tageszeit durchgeführt wurde. Bei Datenloggern wurde der Chlorophyll-a Tagesmittelwert verwendet. Für die Validierung wurden die Satellitenmessungen eines Pixelbereiches von 5 x 5 Pixeln um die Koordinaten der Messstellen extrahiert. Die verwendete räumliche Auflösung beträgt bei Sentinel-2 MSI 20 m. Bedingungen für eine gültige Aufnahme sind, dass mindestens 8 von 25 Pixeln gültig sind und der Z-Score des Pixelbereiches maximal 1,5 beträgt. Dadurch werden Ausreißer identifiziert und aus der Mittelwertbildung herausgenommen. Aus den gültigen Aufnahmen wurde der Median und das arithmetische Mittel des 5 x 5 Pixelbereich berechnet. Abbildung 32 zeigt die Streudiagramme der Validierung für die ausgewählten Algorithmen für den Sentinel-2 MSI Sensor. Der **gekoppelte Algorithmus C2X-COMPLEX** weist die geringste Abweichung auf, streut bei hohen Konzentrationen jedoch stärker (oben rechts). Die **Algorithmus Kombinationen** weisen je nach Kombination unterschiedliche Ergebnisse auf. Der Chlorophyll-a Algorithmus Gons überschätzt geringe Konzentrationen für beide Atmosphärenkorrekturen (linke Seite). Der OC3

Algorithmus wurde mit Gons als Chlorophyll-a Algorithmus kombiniert. Basierend auf C2RCC Atmosphärenkorrektur unterschätzt OC3\Gons hingegen hohe Konzentrationen (rechts unten). Die Ergebnisse spiegeln die Wertebereiche, für welche die Algorithmen konzipiert sind, sehr gut wider. So liefert OC3 für die klaren Gewässer bessere Ergebnisse, während Gons in eutrophen Gewässern besser mit den in-situ Daten übereinstimmt.


**Abbildung 32: Streudiagramme zur Validierung der Chlorophyll-a Konzentration – Sentinel-2 MSI**



Quelle: eigene Darstellung, CAU Kiel, Brockmann Consult GmbH

### Sentinel-3 OLCI

Für die Validierung der Sentinel-3 OLCI Satellitendaten wurde dasselbe Verfahren wie bei Sentinel-2 MSI angewandt. Für die Satellitendaten wurde bei einer räumlichen Auflösung von 300 m ein Pixelbereich von 3 x 3 Pixeln ausgewählt und die Bedingung von mindestens 3 von 9 gültigen Pixeln musste erfüllt sein. Abbildung 33 zeigt die Streudiagramme der Validierung für die ausgewählten Algorithmen. Der **gekoppelte Algorithmus** MPH Pitarch zeigte eine starke Überschätzung der Werte. Daher wurde er mit dem C2RCC kombiniert, sodass man für eutrophe Seen den MPH Pitarch und für oligotrophe Seen den gekoppelten C2RCC verwendet. Im weiteren Verlauf wird diese Kombination MPH Pitarch merged genannt. Der MPH Pitarch merged zeigt einen guten Zusammenhang zwischen den Messmethoden, weist aber einen hohen Bias und RMSE auf (oben links). Zusätzlich zeigt sich, dass MPH Pitarch merged mit  $n = 579$  die meisten Validierungspunkte aufweist. Dies lässt sich durch strengeres Ausmaskieren in den anderen Algorithmen erklären. Die **Algorithmus Kombinationen** streuen ebenfalls stark. C2RCC in Kombination mit Chlorophyll-a Algorithmen wie Gons, Gilerson und OC4\Gons unterschätzen hohe Konzentrationen. Der OC4 Algorithmus wurde mit Gons als Chlorophyll-a Algorithmus kombiniert.


**Abbildung 33: Streudiagramme zur Validierung der Chlorophyll-a Konzentration – Sentinel-3 OLCI**

Quelle: eigene Darstellung, CAU Kiel, Brockmann Consult GmbH

### ENVISAT MERIS

Für die Validierung der ENVISAT MERIS Satellitendaten wurde dasselbe Verfahren, wie bei Sentinel-3 OLCI angewendet. In Abbildung 34 sind die Streudiagramme der Validierung für MERIS abgebildet. Der **gekoppelte Algorithmus** zeigt die besten Ergebnisse mit dem geringsten Bias und dem geringsten RMSE (Tabelle 17). Die **Algorithmus Kombinationen** zeigen, dass alle Algorithmen stark streuen und die Werte überschätzen.

**Abbildung 34: Streudiagramme zur Validierung der Chlorophyll-a Konzentration – ENVISAT MERIS**



Quelle: eigene Darstellung, CAU Kiel, Brockmann Consult GmbH

Auf Basis der Streudiagramme wurden die in Kapitel 3.2 beschriebenen Gütemaße berechnet. Tabelle 17 fasst die absoluten Werte der berechneten Gütemaße zusammen.

**Tabelle 17: Tabellarische Darstellung der berechneten Gütemaße über alle Messpunkte pro Sensor und Algorithmus – Chlorophyll-a Konzentration**


R <sup>2</sup>	Steigung	y-Achse [µg/l]	RMSE [µg/l]	Mean AE [µg/l]	Median AE [µg/l]	Bias [µg/l]	MAPD [%]	n	Set
Sentinel 2 MSI									
0.69	0.61	17.86	18.81	10.34	14.36	13.2	618	302	ACOLITE Gons
0.69	0.71	7.35	15.86	2.37	9.45	4.94	321	298	C2X COMPLEX
0.70	0.91	10.41	19.90	8.86	11.86	7.06	391	298	C2RCC Gons
0.51	0.25	3.18	19.56	10.08	11.95	5.73	132	298	C2RCC OC3\Gons
Sentinel 3 OLCI									
0.65	1.08	4.14	25.49	5.48	11.89	4.09	202	579	MPH Pitarch merged
0.68	0.43	8.25	15.40	3.91	10.06	6.37	104	285	C2RCC Gons
0.58	0.57	11.49	19.25	0.64	12.78	7.38	99	217	C2RCC Gilerson
0.51	0.36	8.12	22.71	8.47	14.76	8.09	94	257	C2RCC OC4\Gons
ENVISAT MERIS									
0.70	1.04	3.05	21.32	3.64	11.09	3.35	133	783	C2RCC
0.67	1.23	6.91	34.65	11.91	20.03	8.81	194	490	C2RCC Gons
0.57	1.23	24.33	53.96	30.50	35.97	18.4	356	352	C2RCC Gilerson

Quelle: eigene Zusammenstellung, CAU Kiel, Brockmann Consult GmbH

Um einzuschätzen, bei welchem Algorithmus in-situ Messwerte und Satellitenmessungen am besten übereinstimmen, normalisierten wir ausgewählte Gütemaße auf einen vergleichbaren Bereich von 0 - 100 %. Abbildung 35 zeigt die Ergebnisse der Algorithmen für Sentinel-2 MSI. Für Sentinel-2 MSI scheidet der C2X-COMPLEX bei fast allen Gütemaßen am besten ab. Für Sentinel-3 OLCI sind die Gütemaße sehr ausgeglichen (Quelle: eigene Darstellung, CAU Kiel, Brockmann Consult GmbH


Abbildung 36). Es gibt hier keinen Algorithmus, der in allen Gütemaßen das beste Ergebnis erzielt. Obwohl MPH Pitarch merged nicht alle Gütemaße optimal erfüllt, hat dieser Algorithmus den Vorteil mehr Datenpunkte zu liefern als die anderen Algorithmen. Für ENVISAT MERIS ist eindeutig der gekoppelte C2RCC der beste Algorithmus, da er in allen Gütemaßen das beste Ergebnis erzielt (Abbildung 37).

**Abbildung 35: Normalisierte Gütemaße der Algorithmus-Sets über alle Seen für Sentinel-2 MSI**




Quelle: eigene Darstellung, CAU Kiel, Brockmann Consult GmbH

**Abbildung 36: Normalisierte Gütemaße der Algorithmus-Sets über alle Seen für Sentinel-3 OLCI**



Quelle: eigene Darstellung, CAU Kiel, Brockmann Consult GmbH

**Abbildung 37: Normalisierte Gütemaße der Algorithmus-Sets über alle Seen für ENVISAT MERIS**

Quelle: eigene Darstellung, CAU Kiel, Brockmann Consult GmbH

## B.3 Wassertemperatur in Seen

### B.3.1 Ausgewählte Algorithmen

Anhand der Bewertungsmatrix zur Algorithmenauswahl (Kapitel 2.6) entschied das Projektteam, in den Fallstudien zwei Mono-Window-Algorithmen zu untersuchen, die für die Thermalsensoren von Landsat 5 TM, 7 ETM+ und 8 TIRS anwendbar sind (vgl. Tabelle 18). Landsat-Daten reichen bis in die 1980er Jahre zurück und ermöglichen so eine konsistente Zeitreihe. Die räumliche Auflösung der Thermalsensoren von ca. 100 m – 120 m kann die vielen kleinen bis mittelgroßen See in Deutschland erfassen. Für die Fallstudien wurden Level 1C Daten der Collection 1, die zu Beginn der Fallstudienentwicklung verfügbar waren, genutzt. Die Collection 2 wurde erst später im Verlauf des Projekts vom USGS veröffentlicht.

Um einzuschätzen, wie stark die Atmosphäre einen Datensatz beeinflusst, benötigen die beiden ausgewählten Mono-Window-Algorithmen zusätzliche meteorologische Daten zum Zeitpunkt der Aufnahme. Dafür wurden Daten von Wetterstationen des DWD (Deutscher Wetterdienst) sowie ERA5 und ERA5-Land Klima Re-Analyse Daten des Copernicus Climate Change Service verglichen. Darüber hinaus analysierte das Projektteam die Variable LSWT des CCI Lakes Projekts.

**Tabelle 18: Übersicht und Referenzen zu den in den Fallstudien zur Wassertemperatur untersuchten Algorithmen und Daten**

Name	Sensor	Quelle
IMWA Qin	Landsat 5	Qin et al. 2001
	Landsat 7	Wang et al. 2015, mit angepassten Koeffizienten
	Landsat 8	Wang et al. 2015
SC Sobrino	Landsat 5	Sobrino et al. 2004
	Landsat 7	Jimenez-Munoz et al. 2009
	Landsat 8	Jimenez-Munoz et al. 2014
CCI Lakes 'Lake surface water temperature'	AVHRR, ATSR	Crétau et al. 2020
<b>Meteorologische Daten</b>		
DWD Wetterstationen stündlich (Lufttemperatur, Luftfeuchte, Luftdruck)		CDC 2018, Bezug über Climate Data Center
ERA5 stündlich (Lufttemperatur, Wasserdampfgehalt)		Copernicus Climate Change Service 2018, Bezug über Copernicus Climate Data Store
ERA5-Land stündlich (Lufttemperatur, Luftfeuchte, Luftdruck)		Copernicus Climate Change Service 2018, Bezug über Copernicus Climate Data Store

Quelle: eigene Zusammenstellung, CAU Kiel, Brockmann Consult GmbH

### Improved Mono-Window Algorithmus von Qin

Qin et al. (2001) entwickelte den IMWA (Improved Mono-Window Algorithmus) ursprünglich für den Landsat 5 TM Sensor mit einem thermalen Band im Wellenlängenbereich 10,4 - 12,50  $\mu\text{m}$ . Da der Landsat 7 ETM+ Sensor im gleichen Wellenlängenbereich thermale Strahlung misst, ist der Algorithmus auch auf diesen Sensor anwendbar. Landsat 8 TIRS besitzt zwei thermale Bänder (10,6 - 11,19  $\mu\text{m}$  und 11,5 - 12,51  $\mu\text{m}$ ). Allerdings beeinflusst Streulicht die Messungen des ersten thermalen Bands. Daher wird die Verwendung von Mono-Window Algorithmen auch für Landsat 8 TIRS empfohlen. Wang et al. (2015) entwickelte den ursprünglichen Qin-Algorithmus für Band 11 von Landsat 8 TIRS weiter.

Grundlage für den IMWA sind Level 1C Daten des jeweiligen thermalen Bands als Strahldichten in  $\text{W}/(\text{m}^2 \cdot \mu\text{m} \cdot \text{sr})$ . Diese werden in Strahlungstemperatur [K] am Sensor mit empirisch festgelegten Koeffizienten vom USGS bzw. aus den Metadaten umgerechnet. Im nächsten Schritt muss der Einfluss der Atmosphäre korrigiert werden, um die Strahlungstemperatur am Boden zu erhalten. Dafür ermittelten Qin et al. (2001) und Wang et al. (2015) Korrekturfaktoren basierend auf empirischen linearen Zusammenhängen zwischen Transmissivität der Atmosphäre und Wasserdampfgehalt sowie bodennaher Lufttemperatur und mittlerer atmosphärischer Temperatur. Um die einfache Inversion der Strahlungstransfergleichung zu lösen (Bestimmung der Strahlungstemperatur am Boden) benötigt der IMWA Informationen zur Art der Atmosphäre (bspw. mittlere Breiten im Sommer/ Winter, Tropen), zum Wasserdampfgehalt der Atmosphäre und zur bodennahen Lufttemperatur. Als Sommer betrachten wir die Monate April bis Oktober, als Winter die Monate November bis März. Aus drei verschiedenen meteorologischen Datenquellen erhalten wir die bodennahe Lufttemperatur

und bestimmen den Wasserdampfgehalt der Atmosphäre (siehe übernächster Abschnitt und Tabelle 18).

Darüber hinaus geht die Emissivität der betrachteten Oberfläche in die Rechnung mit ein. Da wir ausschließlich Wasserflächen betrachten und die Wellenlängenbereiche der Sensoren vergleichbar sind, nehmen wir einen sensor-übergreifenden konstanten Emissivitätswert für Wasser von 0,991 an (Wang et al. 2015).

### Single-Channel Algorithmus von Sobrino

Der Single-Channel (SC) Algorithmus von Sobrino ist anwendbar auf eine Vielzahl von thermalen Sensoren. Sobrino et al. (2004) zeigte die Anwendbarkeit für Landsat 5 TM, Jimenez-Munoz et al. (2009) für Landsat 7 ETM+ und Jimenez-Munoz et al. (2014) für Landsat 8 TIRS. Wie der IMWA, berechnet der SC die Strahlungstemperatur am Boden über eine einfache Inversion der Strahlungstransfergleichung. Als Zusatzdaten benötigt der SC ausschließlich den Wasserdampfgehalt der Atmosphäre und die Emissivität der Landoberfläche (hier bei Wasser: 0,991). Um den Einfluss der Atmosphäre abzuschätzen, nutzt der SC drei Koeffizienten, die auf empirischen Zusammenhängen zwischen Wasserdampfgehalt der Atmosphäre und atmosphärischen Funktionen (einfallende und rückgestreute Strahlung, Transmissivität) basieren. Die Koeffizienten sind in den referenzierten Publikationen verfügbar und wurden über Simulationen mithilfe von Datenbanken atmosphärischer Profile bestimmt.

### Meteorologische Datenquellen

SC und IMWA benötigen den Wasserdampfgehalt der Atmosphäre zum Aufnahmezeitpunkt, der IMWA zusätzlich noch die bodennahe Lufttemperatur. Lufttemperatur wird als Klimaelement an vielen DWD Wetterstation gemessen. Für die Fallstudien wurden die am nächsten gelegene Messstation zum Mittelpunkt eines Sees ausgewählt. Das dichte Stationsnetz in Deutschland reduzierte sich, da nur Stationen verwendet wurden, deren Messdaten das gesamte Landsat-Archiv seit etwa 1984 umfassen. Daher schwankte die Distanz der Stationen zum See zwischen wenigen km bis max. 50 km.

Der Wasserdampfgehalt wird nicht direkt an den DWD Stationen gemessen. Er kann aber über die relative Luftfeuchte, Lufttemperatur und den Luftdruck berechnet werden (Häckel 2021):

- ▶ Sättigungsdampfdruck  $e_s = 6.112 \cdot e^{((17.62 \cdot \text{Lufttemperatur}) / (243.12 + \text{Lufttemperatur}))}$
- ▶ Sättigungsmischungsverhältnis  $E = 621.97 \cdot (e_s / \text{Luftdruck} - e_s)$
- ▶ Luftdichte  $A = \text{Luftdruck} / (287.05 \cdot \text{Lufttemperatur})$
- ▶ Bodennaher Wasserdampfgehalt  $w_0 = (\text{relative Luftfeuchte} \cdot E \cdot A) / 1000$

ERA5-Daten sind re-analyisierte Klimadaten. Um einen global vollständigen und vergleichbaren Datensatz zu generieren, wurden Messdaten aus unterschiedliche Datenquellen (Messstationen, Satelliten, Flugzeug etc.) mit aktuellen Wettermodellen verknüpft. Durch verschiedene Techniken der Datenassimilation entsteht ein zeitlich und räumlich konsistenter und lückenloser Wetterdatensatz. ERA-5 Daten liegen grid-basiert in  $0,25^\circ \times 0,25^\circ$  räumlicher Auflösung vor. Die in den Fallstudien verwendeten Daten liegen stündlich vor (10:00 UTC, Zeitpunkt der Landsataufnahme) und beginnen im Jahr 1979. Die benötigten Parameter Lufttemperatur (2 m) und atmosphärischer Wasserdampfgehalt sind direkt verfügbar und wurden aus dem Pixel, in dem der Mittelpunkt des jeweiligen Sees liegt, extrahiert.

ERA5-Land Daten sind ebenfalls re-analyisierte Klimadaten, allerdings sind die Ozeane ausgeschlossen und nur die Landoberfläche wird modelliert. Die Daten liegen in einer höheren räumlichen Auflösung vor ( $9 \text{ km} \times 9 \text{ km}$ ) und wurden aus dem Pixel, in dem der Mittelpunkt des

jeweiligen Sees liegt, extrahiert. Die Lufttemperatur (2 m) ist direkt verfügbar. Der atmosphärische Wasserdampfgehalt wurde wie bei den DWD Daten aus Luftfeuchte, Lufttemperatur und Luftdruck berechnet.

### **CCI Lakes ‚Lake surface water temperature‘**

Das Lakes Projekt (<https://climate.esa.int/en/projects/lakes/about/>) der ESA CCI entwickelt als ein globales Seenprodukt die essentielle Klimavariablen ‚Lake surface water temperature‘. In das Produkt gehen Daten der Sensoren AVHRR und ATSR ein. Die LSWT wird über ein physikalisch basiertes Strahlungstransfermodell abgeleitet. Das Strahlungstransfermodell modelliert das gemessene Signal am Sensor und vergleicht es mit den gemessenen Werten. Die endgültige LSWT ist das Ergebnis der besten Übereinstimmung zwischen modelliertem und gemessenem Wert. Atmosphärische Profile stammen aus den ERA5-Daten. Die berechneten LSWT Werte der unterschiedlichen Sensoren werden mit AVHRR als Basis harmonisiert. Darüber hinaus liefert das Produkt Qualitäts-Flags. In den Fallstudien wurden, wie empfohlen, nur Pixel verwendet, die der Qualitätsstufe 4 (akzeptabel) oder 5 (beste Qualität) entsprechen. Für Deutschland ist aktuell nur der Bodensee im Produkt verfügbar. Allerdings werden in der nächsten Version weitere Seen für Deutschland enthalten sein. Die nächste Version wird für September 2021 erwartet. Die Zeitspanne des Produkts umfasst Januar 2000 bis September 2019 (Simis et al. 2020a).

### **B.3.2 Ergebnisse der Validierung**

Es gibt methodische Unterschiede zwischen der satellitenbasierten Strahlungstemperatur und in-situ gemessener Wassertemperatur (vgl. Kapitel 0). Die Unterschiede müssen bedacht werden, wenn in-situ gemessene und satellitenbasierte Wasseroberflächentemperaturen verglichen werden. Die Auswahl der match-ups unterscheidet sich zwischen den Fallstudien und validierten 50 operationellen Seen v.a. in der tolerierten Zeitspanne.


#### **SC und IMWA Landsat-Sensoren**

Für die Validierung wurden die Wassertemperaturmessungen aus der DASIF-Datenbank ausgewählt, die am nächsten zu Oberfläche durchgeführt wurden (zumeist 0 m oder 0,5 m) und innerhalb von vier Tagen vor oder nach der Satellitenaufnahme stattfanden. Bei Datenloggern wurden die nächstgelegene Messung zur Satellitenaufnahme (~10 Uhr UTC) verwendet. Die Aufnahmezeiten bei manueller Beprobung sind nur teilweise bekannt und variierten zwischen ca. 7 Uhr und 14 Uhr. Temperaturlogger an Pegelstandorten liegen teilweise zu nah am Uferbereich. Aus den Satellitenergebnissen wurde die LSWT Werte in einem Umkreis von 120 m (ca. 3 x 3 thermale Pixel) um das Pixel mit den Koordinaten der Messstelle extrahiert. Um Satelliten- und in-situ-Werte gegenüberzustellen, wurde der Median aus der Pixelumgebung gewählt. Mindestens 45 % der Pixel in der Pixelumgebung mussten valide sein, um in die Validierungsstatistik einzugehen. Am Rottachspeicher und dem Flussee Dahme liegen die Messstellen zu nahe am Ufer, sodass die LSWT in diesen beiden Seen nicht validiert werden konnten.

Abbildung 38 zeigt Streudiagramme zwischen in-situ Wassertemperaturen und Landsat LSWT aufgetrennt nach Sensoren (farbige Punkte) und Algorithmen (Zeile) und meteorologische Datenquellen (Spalte). Insgesamt streuen alle drei Sensoren und alle sechs Algorithmus-Sets nahe der 1:1 Linie, wobei die Ergebnisse des IMWA deutlich niedriger als die in-situ Werte sind im Vergleich zu den LSWT Werten des SC. Der in-situ Wertebereich reicht von 0,2 °C bis 29,0 °C. Der Wertebereich der Landsat LSWT ist breiter und reicht von -18,3 °C bis 31,6 °C. Die Streudiagramme verdeutlichen, dass v.a. bei Landsat 5 TM und vereinzelt Landsat 7 ETM+ die

LSWT kleiner  $0^{\circ}\text{C}$  ist, während die in-situ Messungen zwischen  $0$  und  $12^{\circ}\text{C}$  liegen. In-situ Messungen unter einer Eiskecke könnten diese Ergebnisse erklären. Andernfalls kann die Validierung darauf hindeuten, dass die vom Level 1C Produkt verwendete Wolkenmaske nicht immer alle Wolken, bspw. Zirren, zuverlässig ausmaskiert.

**Abbildung 38: Streudiagramme zur Validierung der Landsat LSWT Werte aufgetrennt nach Sensoren (farbige Punkte) und Algorithmen (Zeile) und meteorologische Datenquellen (Spalte)**



Quelle: eigene Darstellung, CAU Kiel, Brockmann Consult GmbH

Auf Basis der Streudiagramme wurden die in Kapitel 3.2 beschriebenen Gütemaße berechnet. Tabelle 19 fasst die absoluten Werte der berechneten Gütemaße zusammen. Die Gütemaße verdeutlichen den starken linearen Zusammenhang zwischen den in-situ Messwerten und der Landsat LSWT. Je nach Algorithmus-Set und Sensor sind relativen Unterschiede (MAPD) kleiner (bspw. Landsat 8, SC mit ERA5-Land  $< 10\%$ ) oder größer (bspw. Landsat 5 TM, IMWA mit ERA5 fast  $20\%$ ). Insgesamt schneiden Landsat 8 TIRS und Landsat 7 ETM+ deutlich besser ab als Landsat 5 TM.


Um einzuschätzen, bei welchem Algorithmus-Set in-situ Messwerte und Satelliten LSWT am besten übereinstimmen, wurden ausgewählte Gütemaße auf einen vergleichbaren Bereich von  $0$  -  $100\%$  normalisiert. Quelle: eigene Zusammenstellung, CAU Kiel, Brockmann Consult GmbH

Abbildung 39 zeigt die Ergebnisse der sechs Algorithmus-Sets über alle drei Sensoren kombiniert. Der SC von Sobrinho erbringt deutlich bessere Ergebnisse als der IMWA von Qin. Innerhalb des Sobrinho Algorithmus unterscheiden sich die meteorologische Datenquellen DWD und ERA5-Land kaum voneinander und sind deutlich besser als ERA5. Die Sobrinho-ERA5-Land Ergebnisse sind minimal besser. Darüber hinaus sind die ERA5-Land Daten ohne zeitliche Messlücken konsistent im Mittelpunkt eines Sees verfügbar. Die DWD-Daten weisen durchaus Fehlwerte auf und ihre Entfernung variiert zwischen den Seen stark. Um die Landsat-Zeitreihe weiter zu analysieren, konzentrieren wir uns daher auf das Algorithmus-Set SC mit ERA5-Land.

**Tabelle 19: Tabellarische Darstellung der berechneten Gütemaße über alle Messpunkte pro Sensor und Algorithmus-Set**

R2	Steigung	y-Achse [°C]	RMSE [°C]	Mean AE [°C]	Median AE [°C]	Bias [°C]	MAPD [%]	n	Set
0.9271	1.068	-2.94	3.35	2.51	1.97	1.9	12.49	624	SC ERA5L L5
0.9363	1.021	-1.3	2.77	1.84	1.33	1	9.26	651	SC ERA5L L7
0.9332	0.964	-0.45	2.7	1.91	1.36	1.01	9.89	394	SC ERA5L L8
0.9244	1.097	-3.26	3.39	2.54	2.05	1.78	13.25	603	SC ERA5 L5
0.9244	1.057	-1.71	3.09	1.98	1.42	0.89	9.66	662	SC ERA5 L7
0.9168	0.972	-1.07	3.23	2.33	1.7	1.5	12.24	393	SC ERA5 L8
0.9268	1.057	-2.84	3.36	2.54	2.04	1.97	12.82	620	SC DWD L5
0.9373	1.007	-1.2	2.76	1.86	1.35	1.1	9.49	651	SC DWD L7
0.9356	0.965	-0.42	2.65	1.85	1.31	0.95	9.56	388	SC DWD L8
0.9106	0.927	-1.79	3.95	3.17	2.68	2.9	18.17	623	IMWA ERA5L L5
0.9189	0.891	-0.66	3.5	2.55	2.06	2.24	14.56	651	IMWA ERA5L L7
0.9233	0.895	0.49	2.84	1.94	1.3	1.11	10.03	396	IMWA ERA5L L8
0.8854	0.892	-1.57	4.42	3.5	2.88	3.22	19.87	625	IMWA ERA5 L5
0.891	0.866	-0.46	3.92	2.75	2.11	2.4	14.93	660	IMWA ERA5 L7
0.9051	0.88	0.66	3.13	2.1	1.41	1.17	10.09	394	IMWA ERA5 L8
0.9191	0.931	-1.79	3.82	3.08	2.66	2.84	17.35	619	IMWA DWD L5
0.9268	0.889	-0.53	3.33	2.44	2.02	2.15	13.81	650	IMWA DWD L
0.9302	0.9	0.52	2.68	1.77	1.24	1.01	8.2	387	IMW DWD L8

Quelle: eigene Zusammenstellung, CAU Kiel, Brockmann Consult GmbH


**Abbildung 39: Normalisierte Gütemaße der Algorithmus-Sets über alle Seen und Landsat-Sensoren**

Quelle: eigene Darstellung, CAU Kiel, Brockmann Consult GmbH

### CCI Lakes LSWT - Bodensee

Beim CCI Lakes LSWT Datensatz wurden nur Pixel verwendet, die mindestens die Qualitätsklasse 4 aufweisen. Da das Produkt in Deutschland nur für den Bodensee verfügbar ist, wurden für die Validierung ausschließlich in-situ Messdaten vom Bodensee (Obersee) verwendet, die maximal 4 Tage von der Satellitenmessung entfernt waren. Die CCI Lakes LSWT Werte wurden um die Koordinaten der Messstelle in einer 3 x 3 Pixelumgebung extrahiert und der Median gebildet. Es mussten mindestens 5 von 9 Pixel in der Pixelumgebung valide sein, um in die Validierungsstatistik einzugehen. Wie bei der Landsat-Analyse wurde ein Streudiagramm (Abbildung 40) erstellt und die Gütemaße (Tabelle 20) berechnet. Das Streudiagramm und die tabellarisch zusammengefassten Gütemaße zeigen, dass das CCI Lakes LSWT Produkt sehr gute Ergebnisse am Bodensee aufweist. In-situ Messwerten und LSWT Werte korrelieren sehr stark linear. Absolut weichen die Daten weniger als 1 °C (Median AE = 0,8 °C) voneinander ab. Die Genauigkeiten zeigen, dass sich das CCI Lakes LSWT Produkt sehr gut eignet, um Effekte des Klimawandels in Seen zu indizieren. Allerdings ist das Produkt aktuell nur für den Bodensee in Deutschland verfügbar. Aufgrund der groben Pixelauflösung (~ 1000 m) lässt es sich auch nur auf wenige sehr große Seen anwenden (bspw. Müritzt). Im Gegensatz zum Landsatarchiv reicht das Produkt nur bis in das Jahr 2000 zurück. Daher wurde für die Indikatorentwicklung auf das Landsatarchiv zurückgegriffen.

**Abbildung 40: Streudiagramm zwischen in-situ Messwerten und CCI Lakes LSWT Werten am Bodensee**



Quelle: eigene Darstellung, CAU Kiel, Brockmann Consult GmbH

**Tabelle 20: Gütemaße des CCI Lakes LSWT Produkt am Bodensee**

R2	Steigung	y-Achse [°C]	RMSE [°C]	Mean AE [°C]	Median AE [°C]	Bias [°C]	MAPD [%]	n
0.9769	0.993	0.39	2.09	1.09	0.8	0.28	6.3	116

Quelle: eigene Zusammenstellung, CAU Kiel, Brockmann Consult GmbH

## B.4 Eisbedeckung von Seen

Unter den Algorithmen zur Detektion von Eis, hat es nur die Klassifikation über maschinelle Lernverfahren in die Fallstudien geschafft. Aufgrund der nicht verfügbaren in-situ Datengrundlage und den Eigenschaften des Webcam-Vergleichsdatensatzes wurden nur die entwickelten Random Forest Klassifikationsmodelle an den sieben ausgewählten Fallstudienseen validiert. Diese sind in Kapitel 3.6 beschrieben.

## B.5 Gründächer in Großstädten

### B.5.1 Ausgewählte Algorithmen und Daten

Um festzustellen, ob ein Dach begrünt ist, wurde in der Fallstudie zu den Gründächern Schwellwertverfahren mit Vegetationsindizes untersucht. Zunächst orientierte sich das Projektteam an dem Verfahren des BuGG e.V. und der EFTAS (vgl. Ansel et al. 2016), die den NDVI basierend auf CIR-Orthofotos nutzen. CIR-Orthofotos wurden vom UBA über das Bundesamt für Kartographie und Geodäsie (BKG) bereitgestellt. Da die Bilddaten in den meisten

Städten außerhalb der Vegetationsperiode aufgenommen und bis zur vollständigen Abdeckung einer Stadt zum Teil über mehrere Monate oder mehr als ein Jahr auseinander liegen (bspw. Hamburg), entschieden wir uns das Verfahren auf Satellitendaten zu übertragen. Im Fokus standen PlanetScope Daten, die über einen RESA-Antrag beschafft wurden. Diese haben eine räumliche Auflösung von 3,5 m und besitzen vier Bänder im sichtbaren und nahinfraroten Wellenlängenbereich. Für die Analyse wurden ortho-rektifizierte und atmosphärisch korrigierte Level 3B Daten verwendet.


Um die Begrünung zu erkennen, wurden drei verschiedene Vegetationsindizes berechnet:

- ▶ Normalised Difference Vegetation Index (NDVI) =  $(\text{NIR}-\text{ROT}) / (\text{NIR}+\text{ROT})$ . Er variiert zwischen  $-1$  und  $+1$ . Werte kleiner  $0$  entsprechen meist Wasserflächen, Werte zwischen  $0$  und  $0,2$  offenem Boden. Ab  $0,3$  steigt der Anteil der Vegetation in einem Pixel (Rondeaux et al. 1996).
- ▶ Soil Adjusted Vegetation Index (SAVI) =  $((\text{NIR}-\text{ROT})/(\text{NIR}+\text{ROT}+L)) * (1+L)$ , mit  $L=0,5$ . Durch den Korrekturfaktor  $L$  berücksichtigt der SAVI anteilig die Reflexion vom Boden (Huete 1988).
- ▶ Transformed Soil Adjusted Vegetation Index (TSAVI) =  $(a*(\text{NIR}-a*\text{RED}-b))/(\text{RED}+a-(\text{NIR}-b) + 0,08*(1+a^2))$ , mit  $a = 1,086$  und  $b = 0,0243$  für mineralischen Boden. Die Konstanten  $a$  und  $b$  sind empirisch bestimmte Regressionskoeffizienten, die die Sensitivität des Index gegenüber vorhandener Bodenreflexion minimieren sollen (Baret und Guyot 1991).

## B.5.2 Ergebnisse der Validierung

Neben dem NDVI, wurden TSAVI und SAVI ausgewählt, da Gründächer je nach Bedeckungsgrad unterschiedlich stark von Bodenreflexion beeinflusst sein können, auf die der NDVI sensitiv reagiert (Rondeaux et al. 1996). Abbildung 41 zeigt basierend auf den Trainingsdaten von Dresden (70 % des Datensatzes), wie die Vegetationsindexwerte zwischen den beiden Klassen Gründach und Nicht-Gründach verteilt sind. Grundsätzlich lassen sie sich gut trennen, es gibt aber in allen Indizes einen kleinen Überlappungsbereich. Um Gründächer zu klassifizieren, entschieden wir uns für das 25 % Perzentil der Gründach-Trainingsdaten als Schwellwert (Tabelle 21).

**Abbildung 41: Histogramme der Vegetationsindizes basierend auf den Trainingsdaten und PlanetScope-Daten von Dresden der Klassen Gründach und Nicht-Gründach**



Quelle: eigene Darstellung, CAU Kiel, Brockmann Consult GmbH

**Tabelle 21: Schwellwerte (25 % Perzentil) für die Klassifikation von Gründächern**

	NDVI	SAVI	TSAVI
PlanetScope	0,32	0,48	0,30
Sentinel-2	0,37	0,21	0,18

Quelle: eigene Zusammenstellung, CAU Kiel, Brockmann Consult GmbH

Tabelle 22 fasst die Gütemaße der Schwellwertklassifikationen basierend auf den drei ausgewählten Vegetationsindizes für PlanetScope und Sentinel-2 zusammen. Die Genauigkeiten sind bei allen Indizes sehr hoch, die Ergebnisse des NDVIs waren bei PlanetScope etwas besser, bei Sentinel-2 schnitt TSAVI minimal besser ab.


**Tabelle 22: Gütemaße des Schwellwertverfahrens mit drei Vegetationsindizes basierend auf dem Testdatensatz von Dresden mit PlanetScope (PS) und Sentinel-2 (S2)**

Gütemaß	NDVI_PS	SAVI_PS	TSAVI_PS	NDVI_S2	SAVI_S2	TSAVI_S2
OA	0,9367	0,9339	0,9343	0,9212	0,9212	0,9261
Precision	0,9275	0,9222	0,923	0,9415	0,9332	0,9366
Recall	0,9251	0,9248	0,9247	0,8627	0,8682	0,8771
F1-Score	0,9251	0,9248	0,9247	0,8924	0,8939	0,9012
balanced OA	0,9367	0,9339	0,9343	0,8627	0,8682	0,8771

Quelle: eigene Zusammenstellung, CAU Kiel, Brockmann Consult GmbH

Die Klassifikationen zwischen den drei Fernerkundungsdatenquellen unterschieden sich visuell kaum. Mit Sentinel-2 MSI konnten die Gründächer auf den Wohngebäuden am unteren Bildrand nicht detektiert werden (Abbildung 42). Neben den großen Dachflächen in der Mitte wurden aber auch kleinere am unteren und linken Bildrand erkannt. Mit PlanetScope konnten Dächer ab 70 m<sup>2</sup> Fläche detektiert werden. Damit können sie einen Kompromiss zwischen Ortho-Fotos und Sentinel-2 MSI Daten darstellen. Sie bieten Potential für die Fortschreibung des Indikators, mit dem Vorteil, auch kleinere Dachflächen analysieren zu können. Zum Zeitpunkt der DASIF-Analyse stand aber kein deutschlandweiter, harmonisierter Datensatz kostenfrei für das UBA zur Verfügung. CIR-Luftbilder wurden nicht verwendet, da es nicht gelang, eine vergleichbare deutschlandweite Grundlage während der Vegetationsperiode zusammenzustellen.

**Abbildung 42: Ausschnitt aus Dresden, der das Klassifikationsergebnis auf Dachebene darstellt basierend auf CIR-Orthofotos (a), PlanetScope (b), Sentinel-2 MSI (c) und vergleichend eine CIR-Falschfarbendarstellung des Orthofotos (d)**



Quelle: Geobasisdaten: © GeoBasis DE / BKG 2022, Darstellung: CAU Kiel, Brockmann Consult GmbH