



Kartierung des Anbaus von Winter-Zwischenfrüchten

Schriftenreihe 17/2025



Kartierung des Anbaus von Winter- Zwischenfrüchten in Sachsen

Prof. Dr. Claas Nendel; Dr. Gohar Ghazaryan; Cassandra Jensch; Ronja Kelch – Leibniz-Zentrum für
Agrarlandschaftsforschung (ZALF) e.V.

Inhaltsverzeichnis

1	Einleitung.....	6
2	Untersuchungsgebiet.....	8
3	Material und Methoden.....	9
3.1	Felddatenerhebung.....	9
3.2	InVeKoS-Daten	13
3.3	Fernerkundliche Datensätze.....	14
3.4	Vorverarbeitungsschritte.....	17
3.5	Zwischenfruchtklassifikation	22
3.6	Nachbearbeitung	24
3.7	Validierung und Flächenbewertung.....	25
3.8	Prozessierung in FORCE	25
4	Ergebnisse der Zwischenfruchtklassifikation.....	26
4.1	Auswirkungen der Datenverfügbarkeit	26
4.2	Phänologische Erkenntnisse aus Fernerkundungsdaten	27
4.3	Binäre Zwischenfrucht-Klassifikation	31
4.4	Flächenstatistik.....	36
5	Diskussion	37
6	Zusammenfassung	40
7	Handlungsempfehlung	41
	Anhang.....	43
	Literaturverzeichnis	46

Abbildungsverzeichnis

Abbildung 1: Karte des Freistaats Sachsen als Untersuchungsgebiet.	8
Abbildung 2: Schema der einzelnen Arbeitsschritte zur Kartierung von Winterzwischenfrüchten mittels Fernerkundung.	9
Abbildung 3: Fotos einiger Standorte zeigen die Heterogenität der Bepflanzung.	10
Abbildung 4: Räumliche Verteilung der erhobenen Felddaten im Freistaat Sachsen.	13
Abbildung 5: Anzahl der erhobenen Standorte nach Feldfrucht-Klassen in Sachsen.	14
Abbildung 6: Anzahl der Aufnahmen mit unbewölktem Himmel im Zeitraum Juni 2023 bis März 2024 (Sentinel-2).	26
Abbildung 7: Anzahl der Aufnahmen mit unbewölktem Himmel in vier verschiedenen Zeiträumen zwischen Juni 2023 und März 2024 (Sentinel-2).	27
Abbildung 8: NDVI-Zeitreihe (Median) nach Feldfrucht-Klassen an Standorten der Felddatenerhebung.	29
Abbildung 9: NDVI-Zeitreihe (Mittelwert) nach Feldfrucht-Klassen an Standorten der Felddatenerhebung.	30
Abbildung 10: Klassifizierung der landwirtschaftlich genutzten Schläge in Sachsen im Zeitraum Juni 2023 bis März 2024 auf Basis von Sentinel-1 und -2, maskiert mit InVekoS- Daten, nach Anwendung des Mehrheitsfilters.	32
Abbildung 11: Klassifikation vor (Mitte) und nach (rechts) der Anwendung des Mehrheitsfilters.	33
Abbildung 12: Die wichtigsten 25 Variablen (von insgesamt 160) für die Klassifikation von Zwischenfrüchten (Oben bei Verwendung von Sentinel-2- und Sentinel-1-Daten, unten nur mit Sentinel-2).	35
Abbildung 13: Übersicht über Anbau verschiedener Feldfrüchte im Jahr 2023.	43
Abbildung 14: Übersicht über Anbau verschiedener Feldfrüchte im Jahr 2024.	43
Abbildung 15: NDTI-Zeitreihe (Median) nach Feldfrucht-Klassen an Standorten der Felddatenerhebung.	44
Abbildung 16: MNDVI-Zeitreihe (Median) nach Feldfrucht-Klassen an Standorten der Felddatenerhebung.	45

Tabellenverzeichnis

Tabelle 1: Übersicht über im Feld erhobene Arten sowie deren Einordnung in „Zwischenfrucht“ und "Keine Zwischenfrucht".	12
Tabelle 2: Übersicht über die Zusammensetzung der Eingabefeatures.	22
Tabelle 3: Übersicht über die verschiedenen Klassifikationsansätze sowie die Klassifikations- Gesamtgenauigkeiten.	34

Tabelle 4: Konfusionsmatrix für die Zwischenfrucht-Klassifikation basierend auf Sentinel 1 und 2, nach der Anwendung des Mehrheitsfilters	34
Tabelle 5: Flächenstatistik der Klassifikation basierend auf Sentinel-1 und -2, nach Anwendung des Mehrheitsfilters	36

Abkürzungsverzeichnis

DOY	Day of Year – Julianischer Tag
LfULG	Sächsisches Landesamt für Umwelt, Landwirtschaft und Geologie
MNDVI	Modified Normalized Difference Water Index; Modifizierter normalisierter Differenz-Wasserindex
NDVI	Normalized Difference Vegetation Index; Normalisierter Differenz-Vegetationsindex
NDTI	Normalized Difference Tillage Index; Normalisierter Differenz-Bodenbearbeitungsindex
SAVI	Soil Adjusted Vegetation Index; bodenangepasster Vegetationsindex
HLS	Harmonized Landsat and Sentinel

1 Einleitung

Der vorliegende Endbericht zum Projekt „Kartierung des Anbaus von Winter-Zwischenfrüchten in Sachsen“ präsentiert die Ergebnisse der Detektion von Winterzwischenfrüchten und die dafür angewandte Methodik. Im Fokus steht die Nutzung moderner Fernerkundungstechnologien zur präzisen Erfassung und Differenzierung von Zwischenfrüchten und Nicht-Zwischenfrüchten.

Zwischenfrüchte, die zwischen zwei marktfähigen Ackerkulturen angebaut werden, erfüllen zentrale agrarökologische Funktionen (SMIT et al. 2019). Der Anbau einer Zwischenfrucht nach der Ernte der Hauptfrucht bringt insbesondere für den Bodenschutz und die Diversifizierung des Ackerlandes zahlreiche Vorteile mit sich. Die insbesondere von Landwirten gern genutzten Vorteile gliedern sich in (i) die Bodenbedeckung als Schutz vor Erosion oder vor Tiefenverlagerung von Nährstoffen durch hohe Perkolationsraten (KAYE und QUEMANDA 2017), (ii) die Aufnahme von Nährstoffen, insbesondere Nitrat, aus tieferen Bodenschichten und Zwischenspeicherung in der lebenden Biomasse bis zur folgenden Anbausaison (TONITTO et al. 2006, KAYE und QUEMANDA 2017), (iii) die Anreicherung zusätzlicher organischer Substanz im Boden als Kohlenstoffspeicher (Klimaschutz) und zur allgemeinen Verbesserung von Bodenfunktionen, insbesondere Wasserinfiltrationsfähigkeit und Nährstoff-Nachlieferung, und des Bodenlebens (SCAVO et al. 2022, SEITZ et al. 2023, Kaye und QUEMANDA 2017), (iv) die Unterbrechung von Lebenszyklen von Schadorganismen (SCAVO et al. 2022), (v) die Kontrolle von unerwünschten Beikräutern (SCAVO et al. 2022, KAYE und QUEMANDA 2017) und (vi) das Aufbrechen von Schadverdichtungen der Bodentextur (CHEN und WEIL 2011). Die Aufprallenergie von Niederschlag und der anschließende Oberflächenabfluss verringert sich durch die Vegetationsbedeckung des Bodens und die Anwesenheit einer Zwischenfrucht kann bereits auf gering geneigten Flächen das Loslösen und den Abtrag von Bodenpartikeln verringern (MEHMET et al. 2010). Gleiches gilt für die Winderosion, da die Exposition des Bodens gegenüber Wind durch Zwischenfrüchte minimiert wird (KOU DAHE et al. 2022). Gleichzeitig bildet die Vegetationsschicht einen Interzeptionspeicher für Niederschlag, der die Menge des in den Boden infiltrierenden Wassers verringert. Auf diese Weise werden an niederschlagsreichen Standorten die Perkolation und damit die Auswaschung von Nitrat ins Grundwasser reduziert (JUSTES et al. 2012). Das in der Zwischenfrucht gespeicherte Nitrat wird im Frühjahr nach Abfrieren oder Umbruch der Zwischenfrucht wieder freigesetzt und kann dann von der Folgefrucht genutzt werden (KAYE und QUEMANDA 2017). Eingebettet in eine sinnvolle Fruchtfolgeplanung werden auf diese Weise weniger Stickstoff-Düngemittel eingesetzt, was wiederum den Ausstoß von klimaschädlichen Gasen reduzieren kann (SCAVO et al. 2022). Zwischenfrüchte erhöhen die Produktivität an Biomasse pro Flächeneinheit und damit den Eintrag an organischer Substanz in den Boden. Durch die damit verbundene Erhöhung der biologischen Bodenaktivität tragen sie somit zusätzlich zur Humusbildung und damit zur Verbesserung der Bodenfruchtbarkeit bei (SCAVO et al. 2022). Verrottende Wurzeln von Zwischenfrüchten bilden Bioporen, die präferentielle Fließwege im Boden schaffen und die Wasserinfiltration erhöhen. So kann im Falle von Starkniederschlag mehr Wasser in den Boden geleitet werden,

was die Gefahr von Oberflächenabfluss verringert (SHARMA et al. 2018, JOYCE et al. 2002). Viele als Zwischenfrucht genutzte Arten haben spezifische Wirkungen auf Schadorganismen, und Krankheitsvektoren, und können als Antagonisten oder einfach als nicht geeignete Wirte die Lebenszyklen dieser Organismen unterbrechen und die jeweilige Population schwächen (SCAVO et al. 2022). Schnellwüchsige Zwischenfrüchte können außerdem unerwünschten Beikräutern Licht, Wasser und Nährstoffe vorenthalten, so dass diese im Wuchs gehemmt werden (SCAVO et al. 2022, KAYE und QUEMANDA 2017). Über die Schutzfunktionen hinaus sind Zwischenfrüchte außerdem oft zusätzliche Habitate und Nahrungsangebote für Insekten, Vögel und Kleinsäuger und erhöhen somit insgesamt die Biodiversität der Agrarlandschaft (SHARMA et al. 2018). Die Biomasse der Zwischenfrüchte wird oftmals auch als Futtermittel oder auch als Substrat für Biogasanlagen verwendet, womit sie auch ökonomisch interessant sind (KAYE und QUEMANDA 2017). Insgesamt leisten Zwischenfrüchte einen wichtigen Beitrag zur nachhaltigen Landwirtschaft, indem sie den Boden schützen, seine Fruchtbarkeit verbessern, zur Artenvielfalt beitragen und betriebswirtschaftliche Vorteile bieten (LFULG, 2010).

Die Anbaufläche von Zwischenfrüchten in Deutschland wächst kontinuierlich und erreichte 2022/2023 mit 2,2 Millionen Hektar (18 % der Ackerflächen) ihren bisherigen Höchstwert. Im Vergleich dazu lag der Anteil 2009/2010 bei nur 10 %. Winterzwischenfrüchte werden dabei auf 1,8 Mio. Hektar (82 % der Fläche) angebaut (Statistisches Bundesamt 2024, BLE 2024). Im Freistaat Sachsen wird der Anbau von Zwischenfrüchten und Untersaaten schon seit langem durch fachliche Beratung und finanzielle Förderung unterstützt. Auf über 10 % der Ackerflächen in Sachsen werden Zwischenfrüchte und Untersaaten angebaut (SMEKUL 2024).

Der vorliegende Endbericht präsentiert den Versuch, angebaute Winterzwischenfrüchte in Sachsen mittels Fernerkundung zu kartieren. Der Bericht enthält die Klassifikation der Winterzwischenfrüchte in Sachsen anhand von im Jahr 2023 erhobenen Daten und präsentiert die finalen Ergebnisse der Kartierung.

Das Projekt zur Kartierung von Zwischenfrüchten in Sachsen umfasste die folgenden vier Arbeitspakete:

- **Arbeitspaket 1:** Datenakquise. Anbauflächen wurden von geschultem Personal angefahren, Ackerkulturen bestimmt, die geographische Position eingemessen, fotografiert und die Daten in einer Datenbank abgelegt.
- **Arbeitspaket 2:** Datenstapel. Die Flächen (ca. 300 Datenpunkte) wurden mit Bildmaterial aus Landsat und Sentinel-Missionen unterlegt
- **Arbeitspaket 3:** Bildklassifikation. Die Bildklassifikation erfolgte nach den Methoden von JENSCH (2023).
- **Arbeitspaket 4:** Auswertung. Hier wurden das Klassifikationsergebnis, die Klassifikationsgüte, und die Flächenanteile analysiert und interpretiert.

2 Untersuchungsgebiet

Das Untersuchungsgebiet des Projektes umfasst die landwirtschaftlich genutzten Flächen des Landes Sachsen (Abbildung 1). Sachsen ist von einer diversen Kulturlandschaft geprägt, diese seit Jahrhunderten maßgeblich durch die Landwirtschaft beeinflusst wurde. Das Bundesland umfasst eine Fläche von circa 18.449,9 km².

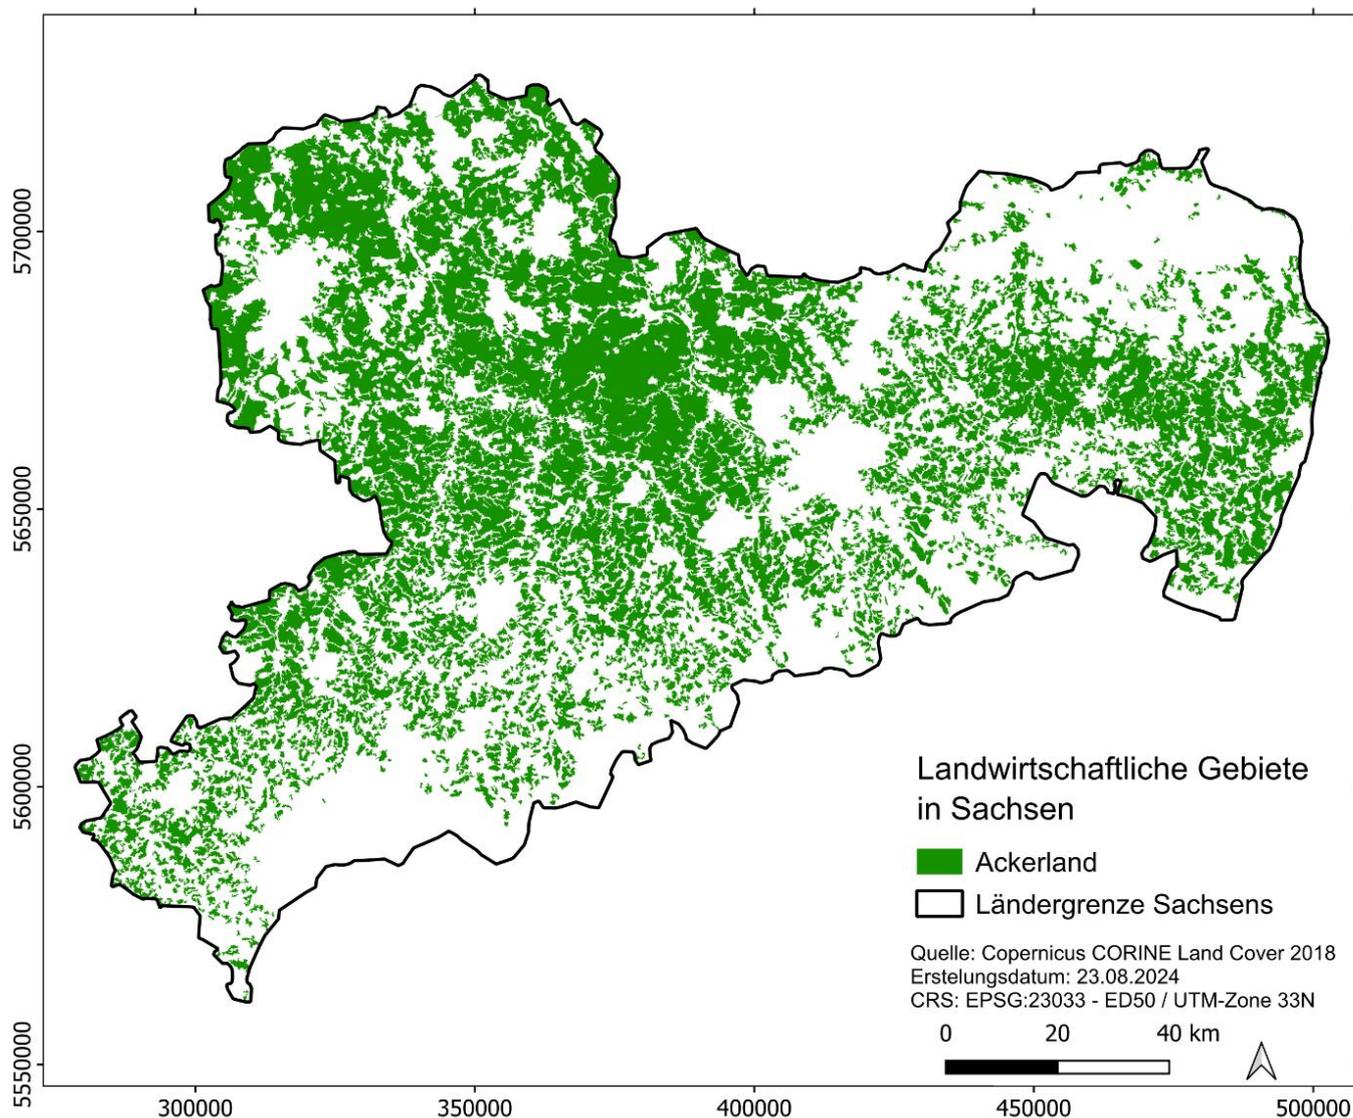


Abbildung 1: Karte des Freistaats Sachsen als Untersuchungsgebiet.

3 Material und Methoden

Die Grundlage unserer Analyse bildete eine Felddatenerhebung. Für vier Zeiträume wurden Eingabefeatures (engl. „Spectral-Temporal Metrics“, STMs) mithilfe von Satellitenaufnahmen berechnet und ein Random-Forest sowie ein Gradient Boosting-Klassifikator trainiert, um eine binäre Zwischenfrucht-Klassifikationskarte zu erhalten. Abbildung 2 zeigt die durchgeführten Arbeitsschritte.

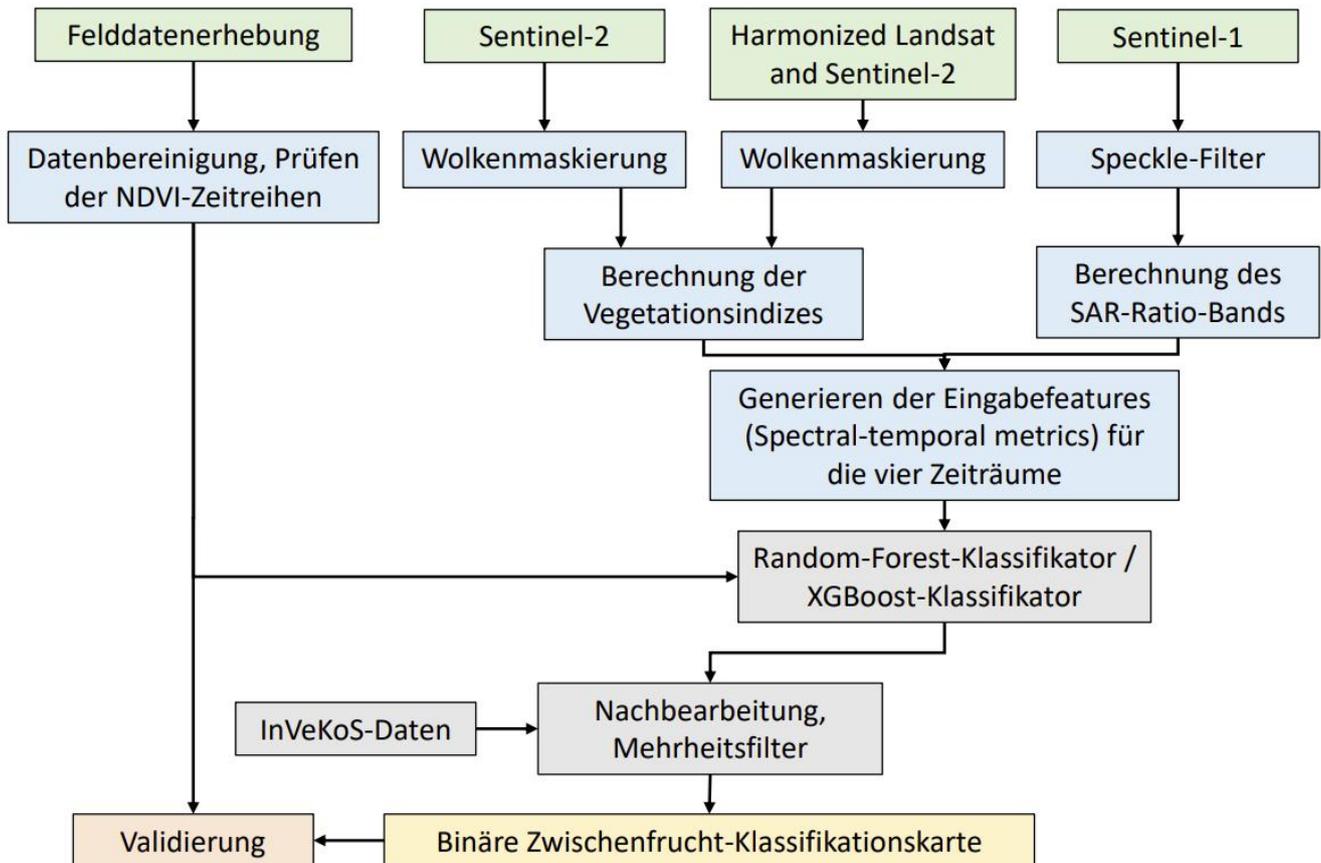
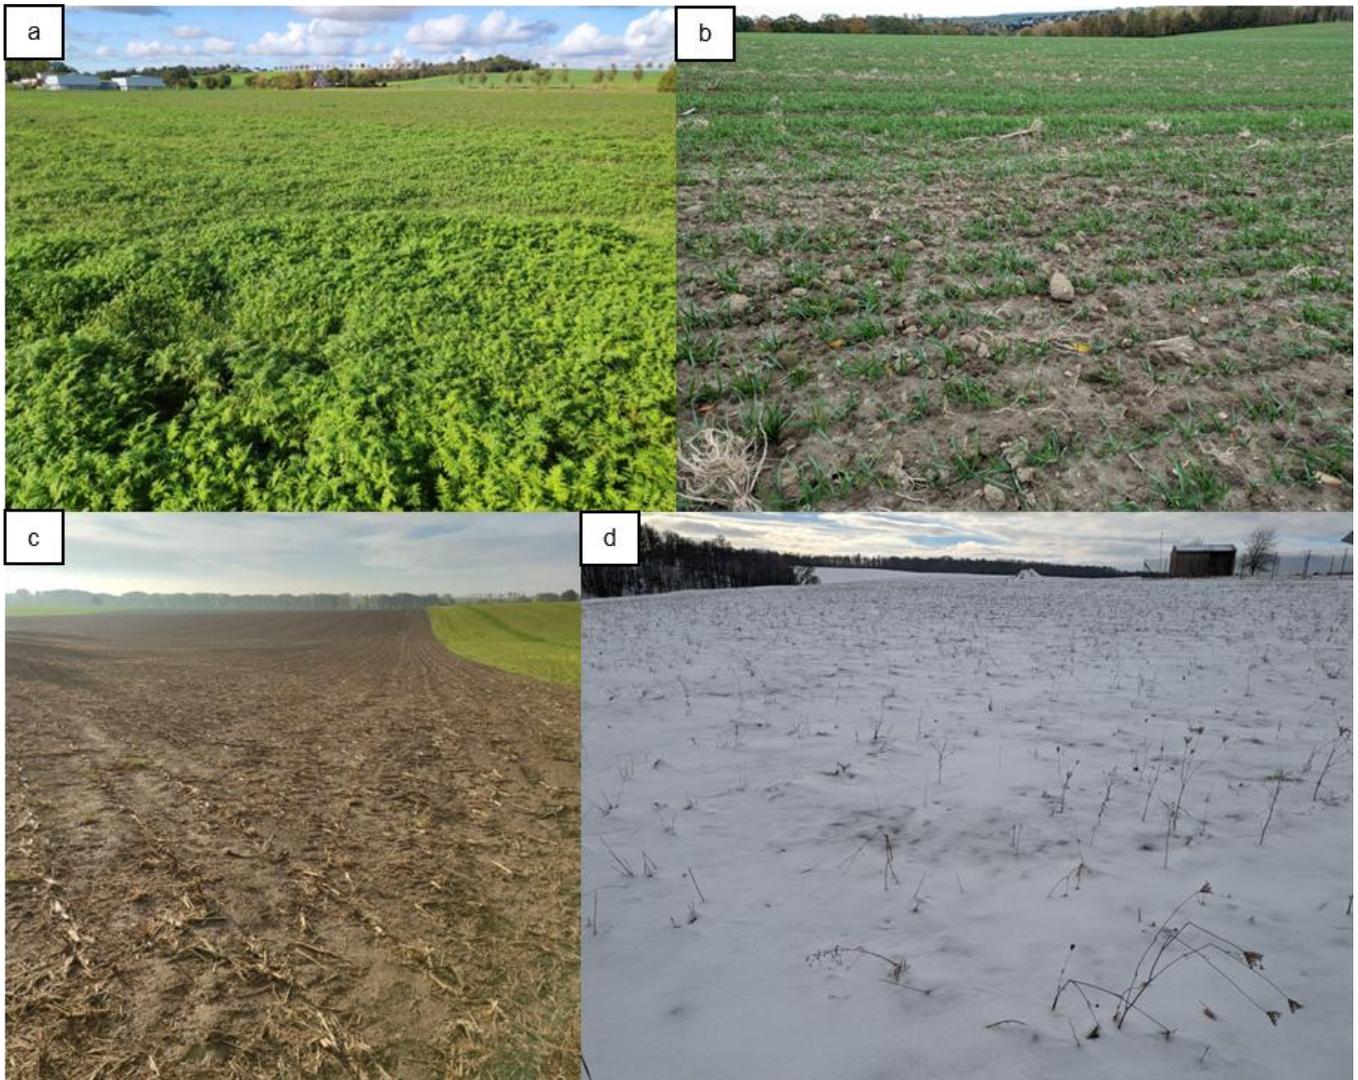


Abbildung 2: Schema der einzelnen Arbeitsschritte zur Kartierung von Winterzwischenfrüchten mittels Fernerkundung.

3.1 Felddatenerhebung

Die Felddaten zum Anbau von Zwischenfrüchten wurden im Zeitraum vom 15.07.2023 bis zum 08.12.2023 im Bundesland Sachsen durch studentische Hilfskräfte aus den Fachbereichen Biologie und Geografie, erhoben. Um eine zuverlässige Datenerhebung zu gewährleisten, erhielten alle Hilfskräfte eine Schulung, in der sie umfassend über Zwischenfrüchte informiert und zur methodisch korrekten Datenerhebung angeleitet wurden. Zu diesem Zweck wurde Bestimmungsliteratur und verlässlich arbeitende Smartphone-Apps ausgegeben, bzw. empfohlen. Mögliche Zwischenfrucht-Arten wurden gezielt angesprochen und auf Besonderheiten, insbesondere bei Mischungen, hingewiesen. Der

Großteil der Daten wurde in den Landkreisen Mittelsachsen, Meißen, Nordsachsen und Leipzig aufgenommen. In dem Datensatz sind neben den Koordinaten und dem Erhebungsdatum des jeweiligen Standortes Informationen zur Klasse und Art der Feldfrucht zu finden.



Dichter Bewuchs durch *Phacelia tanacetifolia* auf Standort a), Bewuchs durch Winterweizen auf Standort b), Brache an Standort c), Bewuchs durch Kamille, wilde Möhre, Feld mit Schneebedeckung an Standort d)

Abbildung 3: Fotos einiger Standorte zeigen die Heterogenität der Bepflanzung.

Es wurden 474 Datenpunkte erfasst. Fotos der Standorte wurden in der Datenbank gespeichert und nummeriert. In den Metadaten sind die Koordinaten der Fotos zu finden, sowie ein Link zu Google Maps, mit dem jeweiligen Erhebungsstandort des Schlages. Zudem wurden die Standorte in die Kategorien „Zwischenfrucht“ und „Keine Zwischenfrucht“ eingeteilt. 287 Standorte wurden als „Zwischenfrucht“ klassifiziert, 187 als „Keine Zwischenfrucht“. Damit wurden rund 60,6 % der Standorte als „Zwischen-

frucht“ klassifiziert (Abbildung 4). Die Klassen Beikraut, Gemenge, Klee, Reinsaat, Rüben und Weidelgras wurden der Kategorie „Zwischenfrucht“ zugeordnet (Tabelle 1). Die Klasse Reinsaat beinhaltet die Arten Ackerbohne, Buchweizen, Erbse, Gelbsenf, Hafer, Ölrettich, Phacelia, Ramtillkraut, Rettich und Rüben. Diese Zusammenfassung zur Klasse „Reinsaat“ wird aufgrund der Untrennbarkeit der Arten vorgenommen. Als „Keine Zwischenfrucht“ wurden Raps, Getreide (Wintergerste, Winterweizen) und Brache eingeordnet. Die Feldfrucht-Klassen Gemenge, Raps, Getreide, Reinsaat und Klee wurden zahlenmäßig am häufigsten aufgenommen (Abbildung 5).

Auch bei vorliegender Schneebedeckung konnten Daten zu den Feldfrüchten erhoben werden, da die jeweilige Feldfruchtart trotz Schneebedeckung in vielen Fällen erkennbar war. Teilweise wurde der Schnee beiseitegeschoben, um die Feldfrucht erkennen zu können.

Die Felddatenerhebung für das Projekt wurde ohne strenge Kriterien durchgeführt, sondern ergab sich aus der schnellen Erreichbarkeit mit dem Auto. Auf diese Weise konnten sehr viele Felder in kurzer Zeit aufgenommen werden. Der Schwerpunkt lag hier auf der Feststellung, ob Zwischenfrüchte eingesät wurden oder nicht, wobei sichergestellt wurde, dass die gesammelten Daten eine gute räumliche Abdeckung der Zielregionen bieten. Dieser Ansatz ermöglichte eine große Anzahl an Stichproben, wobei eine gute Repräsentation der untersuchten Gebiete angenommen wurde. Da für die Erhebung in Ostsachsen nicht ausreichend Personal zur Verfügung stand, wurden dort nur wenig Datenpunkte erhoben. Das hat am Ende zu einer ungenügend ausbalancierten Abdeckung des Untersuchungsgebietes geführt, deren Konsequenz für die Kartierung später diskutiert wird. 24 Standorte wurden als Brache klassifiziert. Als Brachen wurden Standorte bezeichnet, wo keine Vegetation, oder abgeerntete Felder mit Restvegetation vorhanden waren. Möglicherweise wurden Standorte zum Erhebungszeitpunkt als Brache klassifiziert, welche im späteren Jahresverlauf nicht mehr als Brache eingeordnet werden können, da beispielsweise eine Zwischenfrucht angepflanzt wurde. Dies würde das Klassifizierungsergebnis negativ beeinflussen. Um dies auszuschließen, wurden für jeden erhobenen Standort NDVI-Zeitreihen über den gesamten Studienzeitraum generiert. Damit lässt sich prüfen, ob die Standorte, die als Brache klassifiziert wurden, über den gesamten Studienzeitraum Brachen geblieben sind. Für die Bewertung der Phänologie der einzelnen Standorte wurden ausschließlich NDVI-Zeitreihen herangezogen, da diese auch zur visuellen Interpretation und zum Überprüfen der Muster bei der Unterscheidung von Zwischenfrucht- und Nicht-Zwischenfruchtklassen verwendet wurden. Andere Indizes wurden ausschließlich als Eingabefeatures für die Klassifikation genutzt.

Tabelle 1: Übersicht über im Feld erhobene Arten sowie deren Einordnung in „Zwischenfrucht“ und „Keine Zwischenfrucht“.

	Klasse	Arten
Zwischenfrucht	Reinsaat	Ackerbohne, Buchweizen, Erbse, Gelbsenf, Hafer, Ölrettich, Phacelia, Ramtillkraut, Rettich, Rübsen
	Klee	Luzerne
	Gemenge	Garten-Rettich, Phacelia, Gemeiner Lein
	Weidelgras	Wiesen-Lieschgras, Deutsches Weidelgras, Italienisches Raygras
	Beikraut	Beikräuter, Kamille, Acker-Kratzdistel, Weißer Gänsefuß, Süßgräser, Acker-Rettich etc.
	Rüben	Zuckerrübe
Keine Zwischenfrucht	Getreide	Wintergerste Winterweizen
	Raps	Raps
	Brache	
	Sonstige Hauptfrüchte	Erbsen-Gerste-Gemenge

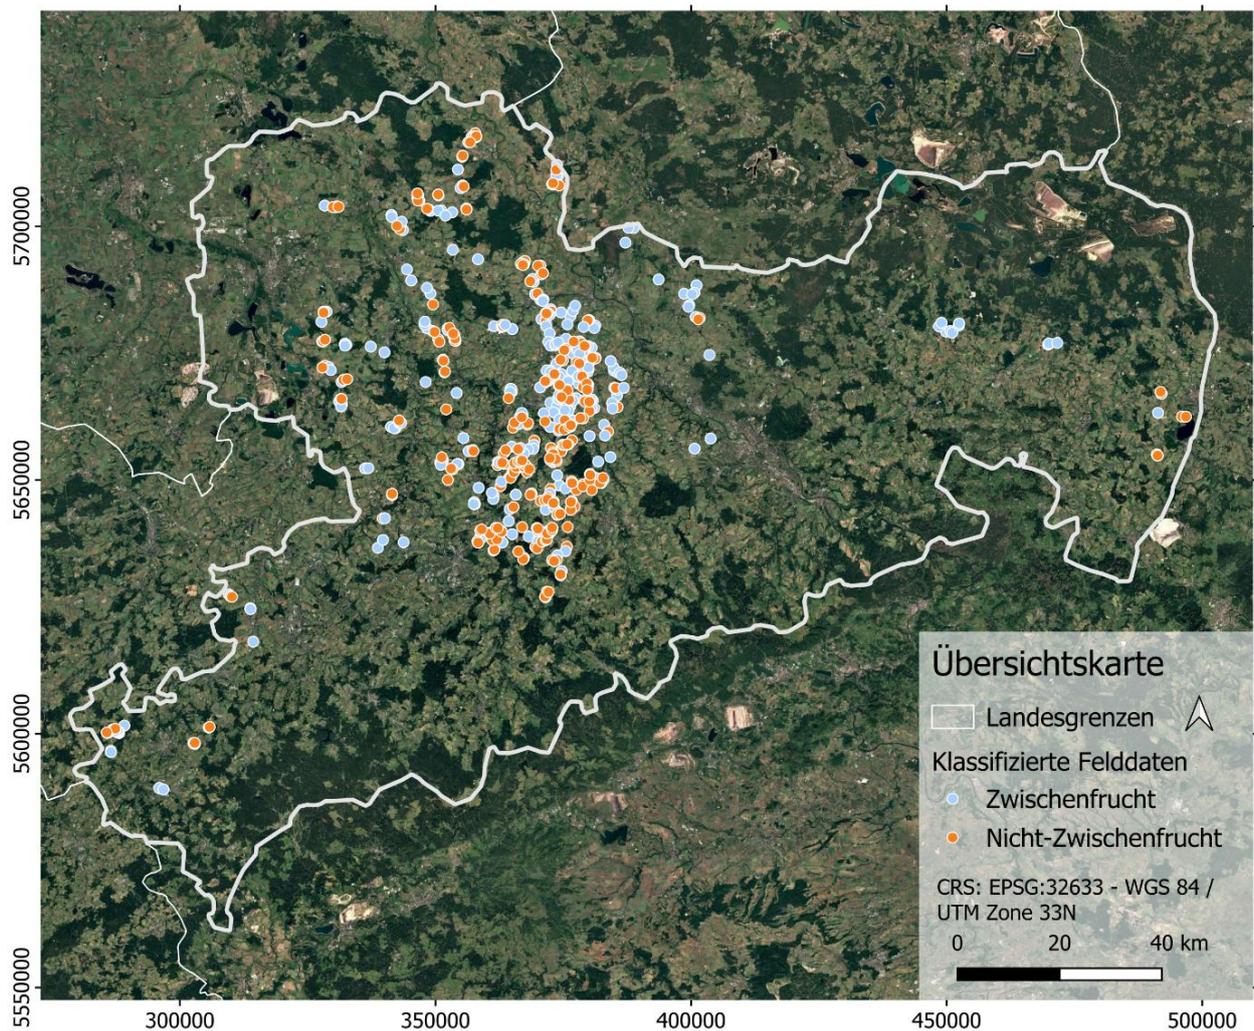


Abbildung 4: Räumliche Verteilung der erhobenen Felddaten im Freistaat Sachsen.

3.2 InVeKoS-Daten

Die InVeKoS-Daten des Landes Sachsen wurden im Laufe des Projektes zur Verfügung gestellt. Mit Hilfe dieser Daten wurde zunächst eine genauere Maske für Ackerflächen generiert. Für diese Maske wurde zuvor der CORINE-Landbedeckungs-Datensatz genutzt (COPERNICUS CORINE LAND COVER 2018), der jedoch weniger exakt ist. Die InVeKoS-Daten geben Aufschluss darüber, welche Hauptfrucht auf einem bestimmten Feld während des Frühsommers tatsächlich auf den Feldern angebaut wurde, was für die Analyse des Zwischenfruchtanbaus von Bedeutung ist. Die Hauptfrucht kann das Klassifikationsergebnis deutlich beeinflussen. Wenn beispielsweise Mais angebaut wurde und Ernterückstände auf dem Feld verblieben, könnte der Klassifizierungsalgorithmus diese Rückstände als Deckung mit einer Zwischenfrucht interpretieren. Insofern helfen die InVeKoS-Daten bei der Interpretation des Klassifikationsergebnisses und der Erfassung möglicher Auswirkungen der Hauptfrucht auf die Zwischenfrucht-klassifizierung durch z. B. Ernterückstände. Der Klassifizierungsprozess selbst verwendet keine In-

vekos-Daten, sondern stützt sich ausschließlich auf fernerkundliche Daten und die gesammelten Felddaten. Zusätzlich wurden die InVeKoS-Daten in der Nachbearbeitung der Klassifikationskarte genutzt, als Basis für einen Mehrheitsfilter.

Feldfrucht-Klassen

Anzahl der erhobenen Standorte nach Feldfrucht-Klassen in Sachsen

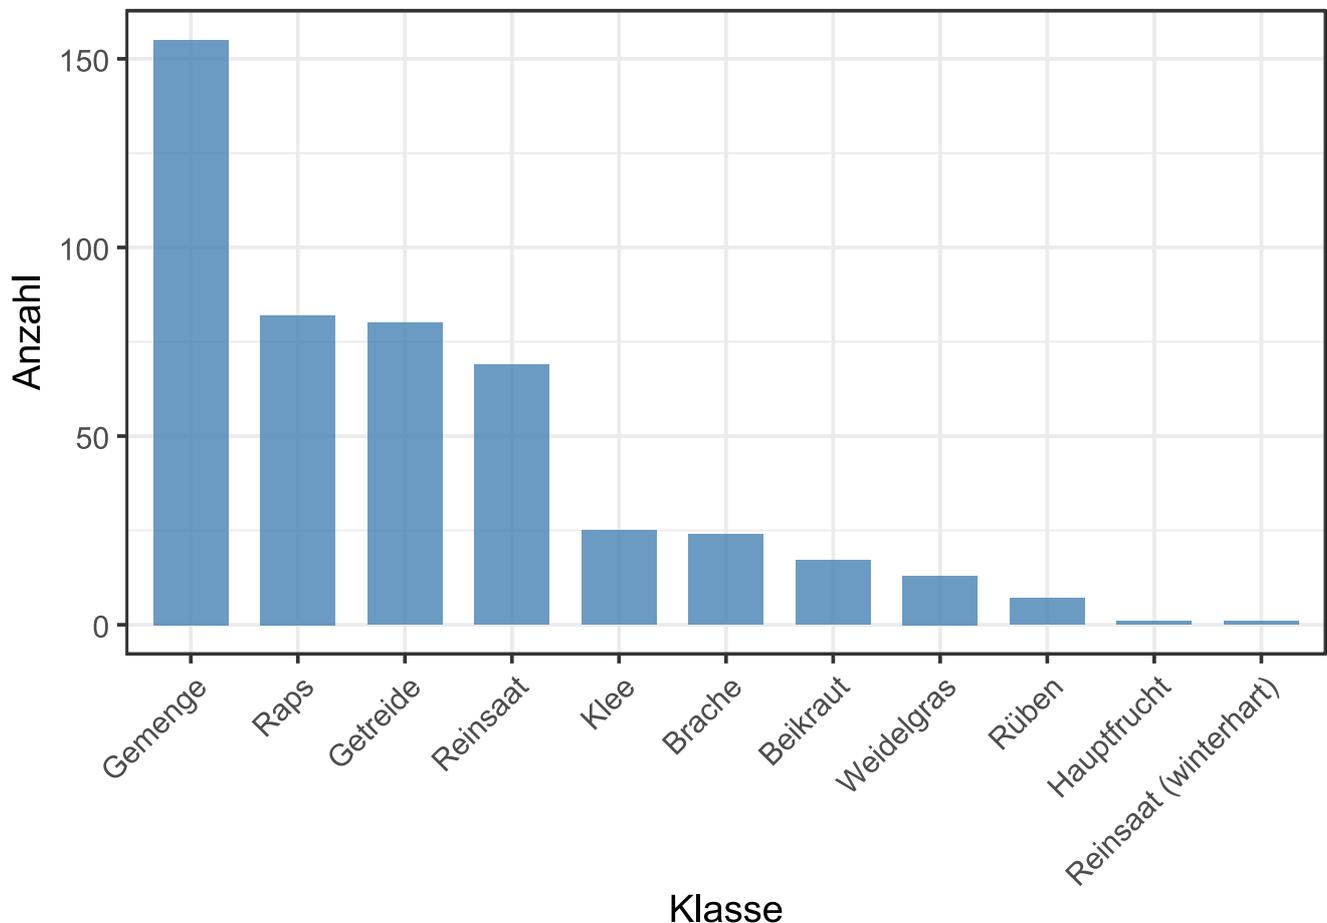


Abbildung 5: Anzahl der erhobenen Standorte nach Feldfrucht-Klassen in Sachsen

3.3 Fernerkundliche Datensätze

Sentinel-2

Das Sentinel-2-Satellitensystem ist Teil des europäischen Copernicus-Programms und liefert hochauflösende (10 - 20 m), multispektrale Weitwinkelaufnahmen der Erdoberfläche. Das Satellitensystem besteht aus den Satelliten Sentinel-2A und Sentinel-2B, welche auf der gleichen Umlaufbahn fliegen, jedoch um 180° versetzt sind. Am Äquator wird eine Wiederholungsfrequenz von fünf Tagen erreicht. Die Sentinel-Aufnahmen werden kostenlos allen Nutzern zur Verfügung gestellt und werden hauptsächlich zur Überwachung von Veränderungen der Landoberfläche genutzt (PHIRI et al. 2020). Die hohe räumliche und zeitliche Auflösung der Sentinel-2 Satelliten ermöglicht eine großräumige und regelmäßige Überwachung von landwirtschaftlich genutzten Flächen (Du et al. 2024).

Sentinel-1

Zusätzlich zu den Sentinel-2-Daten werden auch Sentinel-1-Aufnahmen verwendet. Sentinel-1 basiert auf einem Radarsystem mit synthetischer Apertur (Abkürzung SAR, engl. „Synthetic Aperture Radar“) mit einem C-Band-SAR mit einer Wellenlänge von 6 cm. Als Eingangsdaten wurden Sentinel-1-GRD (engl. „Ground Range Detected“)-Daten aus dem Interferometric Wide-Swath-Modus verwendet. Sentinel-1 kann mehrere verschiedene Bilder aus derselben Impulsserie sammeln, indem es seine Antenne verwendet, um bestimmte Polarisierungen gleichzeitig zu empfangen. Copernicus Sentinel-1 ist ein phasenerhaltendes SAR-System mit doppelter Polarisierung. Es kann ein Signal entweder in horizontaler (H) oder vertikaler (V) Polarisierung senden und dann sowohl in H- als auch in V-Polarisation empfangen (COPERNICUS SENTINEL-1 MISSION, n. d.). In den Wintermonaten ist die Wolkenbedeckung in Europa hoch und der optische Erdbeobachtungssatellit Sentinel-2 kann nur eine begrenzte Anzahl an wolkenfreien Aufnahmen bereitstellen. Diese Lücken können geschlossen werden, da die Radartechnik des Sentinel-1-Satelliten unabhängig vom Tageslicht und der Wolkenbedeckung Aufnahmen liefert (NAJEM et al. 2023). Die Dichte und geometrische Struktur der Vegetation beeinflusst das rückgestreute SAR-Signal, weswegen ein Zusammenhang zwischen der SAR-Rückstreuung und den Vegetationseigenschaften besteht (NAJEM et al. 2023, VREUGDENHIL et al. 2018). Die Studie von SELVARAJ et al. (2024) zeigt, wie Winterzwischenfrüchte mithilfe von Radar-Zeitreihen von Sentinel-1 trotz schlechter Wetterbedingungen effektiv detektiert werden können. NAJEM et al. (2023) nutzten Sentinel-1-Daten und einen Entscheidungsbaum-Algorithmus. Dafür wurden spezifische Filter integriert, um Überschneidungen mit anderen temporär ähnlichen Signaturen, wie die von Winterweizen und Raps, zu eliminieren. Der vorgeschlagene Entscheidungsbaum erwies sich als effektiv zur Detektion von Zwischenfruchtflächen, was sich in Recall-Werten zwischen 83,5 % und 95,0 % sowie hohen Präzisionswerten zwischen 81,5 % und 89,2 % zeigte. Diese Methodik demonstrierte das Potenzial von Sentinel-1-Daten zur robusten Klassifikation von Zwischenfrüchten auch bei komplexen Landnutzungsmustern.

Harmonized Landsat and Sentinel

Für die Klassifikation von Winter-Zwischenfrüchten in Sachsen wurden Satellitendaten des HLS-Projekts (engl. „Harmonized Landsat and Sentinel-2“) der NASA (CLAVERIE et al. 2018) genutzt. Dabei werden Informationen der Landsat-Satelliten 8 und 9 mit denen von Sentinel-2A und Sentinel-2B kombiniert, um ein einheitliches, analysefähiges Produkt von Oberflächenreflexionsdaten zu erzeugen. Sentinel-2 bietet eine höhere räumliche Auflösung (10 m) und kürzere Wiederholungsintervalle (5 Tage), während Landsat durch seine thermischen Infrarotbänder und jahrzehntelange Beobachtungszeitreihen zusätzliche spektrale und historische Perspektiven liefert. Dieses Produkt liefert alle zwei bis drei Tage aktualisierte Aufnahmen, die durch die hohe zeitliche und räumliche Auflösung besonders für die Überwachung landwirtschaftlicher Flächen geeignet sind. Die harmonisierten Daten erlauben die Erkennung

schneller Veränderungen und ermöglichen selbst in bewölkten Regionen die Analyse phänologischer Phasen.

Harmonisierung bedeutet in diesem Zusammenhang, dass Daten der beiden Satellitensysteme so abgestimmt werden, dass sie in räumlicher, zeitlicher und spektraler Hinsicht vergleichbar sind. Unterschiede in Sensoren, Auflösungen und Beobachtungszeitpunkten werden durch angepasste Algorithmen ausgeglichen, wodurch ein konsistentes Datenprodukt entsteht. Dies erleichtert nahtlose Analysen und verbessert die Präzision bei der Ableitung von Informationen zu Landnutzung und Landbedeckung.

Klassifikationsansätze

Die beschriebenen Datensätze können grundsätzlich als einzelne Datensätze für die Klassifikation genutzt werden oder auch kombiniert werden. In der vorliegenden Analyse wurde die Klassifikation mit den einzelnen Datensätzen sowie deren Kombinationen durchgeführt, um zu testen, welche Klassifikation die höchste Genauigkeit erreicht und welcher Datensatz sich dementsprechend am besten für die Analyse in Sachsen über den Untersuchungszeitraum eignet.

Auf die jeweiligen Satellitendaten wurde auf unterschiedliche Weise zugegriffen: Die Sentinel-1 und Sentinel-2-Daten sowie das HLS-Produkt der NASA wurden in der Google Earth Engine (GEE) vorverarbeitet und anschließend exportiert. Die Google Earth Engine ist eine cloudbasierte Plattform, die umfassende fernerkundliche Daten und leistungsstarke Analysewerkzeuge bietet, um großflächige Umwelt- und Erdbeobachtungsdaten zu verarbeiten, zu analysieren und darzustellen. Sie wird häufig für die Fernerkundung und Analyse von Satellitenbildern sowie für geowissenschaftliche Forschung eingesetzt (ZHAO et al. 2021).

Zusätzlich wurde FORCE (engl. „Framework for Operational Radiometric Correction for Environmental Monitoring“, FRANTZ 2019) verwendet, um auf die harmonisierten Level 2 Sentinel- und Landsat-Daten mit einer räumlichen Auflösung von 30 m zuzugreifen. Die Gesamtgröße der verarbeiteten Daten überstieg dabei 150 GB. Die verschiedenen Analyseansätze mit jeweils unterschiedlichen Datensätzen sind:

1. Google Earth Engine:

- Sentinel-2
- Sentinel-1
- Kombination aus Sentinel-1 und Sentinel-2
- HLS Produkt der NASA (Sentinel-2 und Landsat 8/9)

2. FORCE

- L2 Bottom of Atmosphere (BOA). Auf der Grundlage der FORCE-Verarbeitung wurden SEN2B_BOA (Level 2 Bottom-of-Atmosphere data) getestet.

3.4 Vorverarbeitungsschritte

Die zuvor getesteten Methoden wurden anschließend auf der Grundlage der zeitlichen Aggregation über vier verschiedene Zeiträume während der Hauptwachstumsperiode der Zwischenfrüchte verwendet (JENSCH 2023). Folgende Datenverarbeitungsschritte wurden durchgeführt:

Datenaufbereitung

Die Felddaten wurden zufällig in einen Trainingsatz (80 %) und einen Testatz (20 %) aufgeteilt, um einen robusten Modelltrainings- und Evaluierungsprozess zu gewährleisten.

Aufgrund des anfänglichen Ungleichgewichts zwischen den Klassen – die Klasse 0 (keine Zwischenfrucht) hatte deutlich weniger Daten als die Klasse 1 (Zwischenfrucht) – wurde der Datensatz durch eine Stichprobe aus der Klasse 1 ausgeglichen (Verhältnis 180/280). Dies wurde erreicht, indem die Größe der Klasse 1 auf die Größe der Klasse 0 begrenzt wurde, wodurch eine Verzerrung des Modells in Richtung der dominierenden Klasse abgeschwächt wurde. Weitere Verbesserungen der Klasse 0 wurden auf der Grundlage der visuellen Interpretation der zeitlichen Profile der Vegetationsindizes und der Generierung von mehr Daten mit genauen Feldinformationen vorgenommen.

Als Alternative zu der beschriebenen Methode zum Ausgleich des Ungleichgewichts der Klassengrößen haben wir in QGIS die Stichprobengröße der Klasse „Nicht-Zwischenfrucht“ erhöht, indem wir manuell einen zweiten Datenpunkt in die Felder gesetzt haben. Dabei haben wir einen gewissen Abstand zu dem benachbarten Trainingspunkt der gleichen Parzelle eingehalten. So konnten wir die Klassengrößen angleichen.

Eine weitere Möglichkeit zur Gewinnung von mehr Trainingsdaten bestand darin, den Felddatensatz mit den InVeKoS-Schlagdaten von 2023 in QGIS zu verschneiden, sodass die jeweiligen Polygone des InVeKoS-Datensatzes, welche sich mit den Felddatenstandorten überlagern, mit den Informationen des Felddatensatzes kombiniert wurden. Diese Polygone konnten dann als Referenzdatensatz genutzt werden. Um die Rechenzeit zu verkürzen, haben wir in jedem Polygon fünf Punkte nach dem Zufallsprinzip ausgewählt und den Datensatz als Referenzdatensatz genutzt.

Auf der Grundlage der Klassifizierungstests und der erreichten Klassifizierungsgenauigkeiten wurde der erste Ansatz für die Aufbereitung der Referenzdaten ausgewählt.

Tabelle 2: Vegetationsindizes und deren Berechnung.

Vegetationsindex	Abkürzung	Formel	Referenz
Normalized Difference Vegetation Index	NDVI	$NDVI = (NIR - RED) / (NIR + RED)$	ROUSE et al. 1974
Modified Normalized Difference Vegetation Index	MNDVI	$MNDVI = (Green - SWIR) / (Green + SWIR)$	JURGENS 1997
Normalized Difference Tillage Index	NDTI	$NDTI = (NIR - SWIR) / (NIR + SWIR)$	VAN DEVENTER et al. 1997
Soil Adjusted Vegetation Index	SAVI	$SAVI = [(NIR - RED) / (NIR + RED + L)] \times 1 + L$	HUETE 1988
Tassled Cap Brightness	Brightness	$Brightness = Blue \times 0.3037 + Green \times 0.2793 + Red \times 0.4743 + Red\ Edge\ 1 \times 0.5585 + Red\ Edge\ 2 \times 0.5082 + Red\ Edge\ 3 \times 0.1863 + SWIR \times 0.2626$	KAUTH et al. 1976
Tassled Cap Wetness	Wetness	$Wetness = Blue \times 0.1509 + Green \times 0.1973 + Red \times 0.3279 + Red\ Edge\ 1 \times 0.3406 + Red\ Edge\ 2 \times -0.7112 + Red\ Edge\ 3 \times -0.4572 + SWIR \times 0.5678$	KAUTH et al. 1976
Tassled Cap Greenness	Greenness	$Greenness = Blue \times -0.2848 + Green \times -0.2435 + Red \times -0.5436 + Red\ Edge\ 1 \times -0.7243 + Red\ Edge\ 2 \times -0.0840 + Red\ Edge\ 3 \times -0.1800 + SWIR \times 0.4256$	KAUTH et al. 1976

Vorverarbeitung der optischen Daten:

Berechnung der Vegetationsindizes

Um die Vorhersagefähigkeit und die Generalisierung des Modells zu verbessern, wurden verschiedene Vegetations- und Feuchteindizes wie NDVI (Normalized Difference Vegetation Index; Normalisierter Differenz-Vegetationsindex), MNDVI (Modified Normalized Difference Vegetation Index; Modifizierter normalisierter Differenz-Vegetationsindex), NDTI (Normalized Difference Tillage Index; Normalisierter Differenz-Bodenbearbeitungsindex), SAVI (Soil Adjusted Vegetation Index; bodenangepasster Vegetationsindex) und Tasseled Cap-Indizes (TC Brightness, TC Wetness, TC Greenness) auf der Basis von Sentinel-2 sowie des HLS-Produktes berechnet. Die Verwendung vieler verschiedener Vegetations- und Feuchteindizes verbessert die Vorhersagefähigkeit und Generalisierung des Klassifikationsmodells, da

jeder Index unterschiedliche Landschaftsmerkmale wie Vegetation, Feuchtigkeit und Bodenbeschaffenheit betont. Sie helfen, Störungen zu reduzieren und ermöglichen eine genauere Unterscheidung von Landnutzungstypen. Die Berechnung verschiedener Vegetations- und Feuchteindizes, wie NDVI, MNDVI, NDTI, SAVI und Tasseled Cap-Indizes (Brightness, Wetness, Greenness), verbessert die Vorhersagefähigkeit und Generalisierung des Klassifikationsmodells für die Kartierung von Zwischenfrüchten. Jeder Index betont unterschiedliche Landschaftsmerkmale wie Vegetation, Feuchtigkeit oder Bodenbeschaffenheit und trägt dazu bei, Störungen zu reduzieren und spektrale sowie strukturelle Unterschiede zwischen Zwischenfrüchten und Nicht-Zwischenfrüchten hervorzuheben. Beispielsweise erfasst der NDVI die Vitalität der Vegetation, während der SAVI Bodeneffekte minimiert und der NDTI Hinweise auf Bodenbearbeitung liefert. Durch die Kombination dieser Indizes wird die Modellgenauigkeit erhöht und eine robustere Klassifikation erzielt, die besser an verschiedene Umweltbedingungen angepasst ist (XUE und SU 2017). Tabelle 1 gibt die Formeln für die Berechnung der Indizes wieder.

Wolken- und Schneemaskierung

Für die Maskierung von Wolken, Wolkenschatten und Schneeflächen wurden Sentinel-2-Oberflächenreflexionsdaten verwendet, die den Zeitraum von Juni 2023 bis März 2024 abdecken und auf das Untersuchungsgebiet beschränkt sind. Jedes Bild wurde einer Maskierung unterzogen, um bewölkte, beschattete oder schneebedeckte Pixel zu entfernen und sicherzustellen, dass nur Beobachtungen mit unbeeinträchtigtem Signal der Geländeoberfläche für die weitere Analyse verwendet wurden.

Die Wolkenmaskierung in FORCE basiert auf einer modifizierten Version des Fmask-Codes (COPERNICUS DATA SPACE ECOSYSTEM, 2024). Bei der Klassifizierung wurden die Bottom-of-Atmosphäre-Reflexionsdaten getestet und die Wolken-/Wolkenschatten-/Schneedistanzmaske verwendet. Die Daten wurden außerdem zusätzlich mit dem Produkt Haze-Optimized Transformation (HOT) untersucht, das eine optionale Ausgabe aus FORCE ist. Es enthält den HOT-Index, der auf der Top-of-Atmosphäre-Reflexion (TOA) basiert und daher nicht auf Level-2-ARD berechnet werden kann. Der HOT-Index ermöglicht die Eliminierung von Beeinträchtigungen der Reflexionssignale durch Dunst und Restwolken.

TOA (engl. „Top of Atmosphere“) bezeichnet die Strahlungswerte, die an der Obergrenze der Atmosphäre gemessen werden. Diese Rohdaten beinhalten Effekte der Atmosphäre, wie Streuung und Absorption, und eignen sich für Analysen, bei denen atmosphärische Einflüsse berücksichtigt werden sollen. BOA (engl. „Bottom of Atmosphere“) hingegen repräsentiert die Reflexion, die die Erdoberfläche erreicht oder von ihr zurückgeworfen wird, nachdem atmosphärische Störungen korrigiert wurden. BOA-Daten sind besser geeignet für die Analyse von Boden- und Vegetationsmerkmalen, da sie die direkten Oberflächenbedingungen widerspiegeln.

Die SCL-Masken (engl. „Scene Classification Map“, Klasse 11 - Snow / Ice, COPERNICUS DATA SPACE ECOSYSTEM, 2024) wurden getestet, insbesondere die Schneebedeckungsklasse, um schneebedeckte Flächen aus den Satellitenbildern herauszufiltern. Diese Maskierung stellt sicher, dass die Schneebedeckung keinen Einfluss auf die Analyse hat. Zusätzlich wurde der Einfluss des Schnees durch die Komposite weiter minimiert, indem nur schneefreie Zeitpunkte in die Analyse einbezogen wurden. Schneebedeckung kann die Klassifikation von Winterzwischenfrüchten beeinflussen, da sie die spektralen Signaturen der Vegetation überdeckt. In der Analyse wurden schneebedeckte Flächen aus den Sentinel-2-Daten maskiert, um Fehlklassifikationen zu minimieren. Dennoch können Ernterückstände oder Restvegetation unter Schnee fälschlicherweise als Zwischenfrüchte erkannt werden. Radardaten wie Sentinel-1 bieten hier Vorteile, da sie unabhängig von Schnee Textur- und Feuchtigkeitsinformationen liefern, die eine robustere Differenzierung ermöglichen. Eine gezielte Prüfung der Ergebnisse in schneebedeckten Gebieten ist daher sinnvoll.

Vorverarbeitung der Radardaten (Sentinel-1):

Die folgenden Vorverarbeitungsschritte wurden bereits auf die Sentinel-1-Daten in GEE angewendet: Aktualisierung der Orbitdaten, Entfernung des thermischen Rauschens, Kalibrierung auf sinnvolle Rückstreuungswerte sowie die Entfernung radiometrischer und geometrischer Verzerrungen. Zusätzlich wurde ein Speckle-Filter angewendet, um das Speckle-Rauschen zu reduzieren.

Speckle-Rauschen ist ein häufig auftretendes Problem bei der Analyse von Radardaten, da die Bildklarheit beeinträchtigt wird. Durch den Speckle-Filter wird dieses Rauschen reduziert. Dabei wurde ein 3x3-Kernel verwendet, um den Mittelwert und die Varianz in jeder Nachbarschaft von Pixeln zu berechnen und Bereiche auf der Grundlage von berechneten Schwellenwerten zu filtern.

Für die Berechnung des SAR-Ratio-Bandes wird die VV-Polarisation (vertikale Sende- und Empfangspolarisation) von der VH-Polarisation (vertikale Sende- und horizontale Empfangspolarisation) subtrahiert, um Unterschiede in den Oberflächeneigenschaften hervorzuheben und die Merkmalsextraktion für die Analyse zu verbessern.

Zeitliche Aggregation

Um zeitliche Veränderungen zu erfassen und die Dimensionalität der Daten zu reduzieren, wurden statistische Reduktionen (Mittelwert, Median, Maximum und 25. und 75. Perzentil) für jedes Band und jeden Vegetationsindex auf verschiedene vordefinierte Zeiträume innerhalb des Untersuchungszeitraums angewendet. Die Aggregationszeiträume, ausgedrückt als julianischer Tag (day of the year; DOY), sind:

■ 2023-06-01 bis 2023-08-14: DOY 152–226

- 2023-08-15 bis 2023-09-30: DOY 227–273
- 2023-10-01 bis 2023-12-31: DOY 274–365
- 2024-01-01 bis 2024-03-31: DOY 1–91

Die vordefinierten Zeiträume basieren auf der Phänologie von Winterzwischenfrüchten, die spezifische Wachstums- und Entwicklungsphasen durchlaufen. Diese Zeiträume wurden so gewählt, dass sie die relevanten phänologischen Stadien der Zwischenfrüchte abdecken, wie die Aussaat im Spätsommer, das aktive Wachstum im Herbst, die Winterruhe und das erneute Wachstum im Frühjahr. Zudem stützt sich die Wahl der Zeiträume auf erfolgreiche Tests von JENSCH (2023) in Brandenburg, die gezeigt haben, dass eine zeitliche Segmentierung in ähnliche Wachstumsphasen die Modellleistung signifikant verbessern kann. Ergänzend dazu wurden multitemporale Bildkomposite verwendet, um jahreszeitliche Veränderungen der Vegetation präzise zu erfassen und die Analyse robuster gegen kurzzeitige Störungen, wie Wolkenbedeckung, zu machen. Diese Kombination ermöglicht eine optimale Auswertung der saisonalen Dynamik von Zwischenfrüchten.

Die zwei späteren Zeiträume (DOY 274–365 und DOY 1–91) erstrecken sich jeweils über 91 Tage und sind damit länger als die ersten beiden Zeiträume. Dies ist damit zu erklären, dass aufgrund des hohen Wolkenbedeckungsgrades während des Winters weniger wolkenfreie Satellitenaufnahmen zur Verfügung standen und die Zeiträume daher erweitert wurden. Die zwei ersten Zeiträume wurden so gewählt, dass sich verschiedene phänologische Stadien durch die Sentinel-2-Komposite charakterisieren ließen. Diese spezifischen phänologischen Stadien sollten das Ende der Hauptfruchtsaison als auch die Entwicklung der Zwischenfrüchte charakterisieren. Der erste Zeitraum entspricht dem Spätsommer und frühen Herbst, in dem die Hauptfrüchte geerntet und Zwischenfrüchte ausgesät werden. Der zweite Zeitraum erfasst die Phase des aktiven Wachstums der Zwischenfrüchte im Herbst. Diese Zeiträume ermöglichen eine klare Differenzierung zwischen Ernterückständen der Hauptfrüchte und den neu angelegten Zwischenfrüchten, wie sie durch die Sentinel-2-Komposite dargestellt werden.

Mit diesem Ansatz wurden jahreszeitliche und phänologische Veränderungen der Vegetation und des Feuchtigkeitsgehalts der Feldfruchtclassen hervorgehoben, die für eine genaue Klassifizierung wichtig sind. Die Eingabefeatures setzen sich aus den Vegetationsindizes für jeden Zeitraum zusammen, sowie den statistischen Metriken (engl. „Spectral-Temporal Metrics“). Mit diesem Ansatz wurden jahreszeitliche und phänologische Veränderungen der Vegetation und des Feuchtigkeitsgehalts hervorgehoben, die für eine genaue Klassifizierung wichtig sind. Dabei wird der Feuchtigkeitsgehalt sowohl im Boden als auch in der Vegetation berücksichtigt. Indizes wie TC Wetness und SAR-Daten (VV, VH) erfassen Bodenfeuchtigkeit und pflanzliche Wassergehalte, während NDVI die Vitalität und den Zustand der Vegetation misst, jedoch nicht direkt die Feuchtigkeit. In Kombination mit den spektral-zeitlichen ermöglichen diese Eingabefeatures eine differenzierte Analyse von Pflanzen- und Bodenprozessen sowie deren

saisonalen Veränderungen, was für die Klassifikation entscheidend ist. Die Eingabefeatures sind bandweise deskriptive Statistiken, die die Reflektanz, oder einen daraus abgeleiteten Index, aller verfügbaren Aufnahmen innerhalb eines definierten Zeitraums zusammenfassen.

Tabelle 3: Übersicht über die Zusammensetzung der Eingabefeatures

Datensatz	Vegetationsindex	Statistische Metrik	Zeitraum	Gesamtzahl der Eingabefeatures
Sentinel-2	NDVI MNDVI NDTI SAVI TC Brightness TC Greenness TC Wetness	Mittelwert Median Maximalwert 25%-Quantil 75%-Quantil	DOY 152–226 DOY 227–273 DOY 274–365 DOY 1–91	
Anzahl Features	7	5	4	$7 \times 5 \times 4 = 140$
Sentinel-1	VV VH Ratio	Mittelwert Median Maximalwert 25%-Quantil 75%-Quantil	DOY 152–226 DOY 227–273 DOY 274–365 DOY 1–91	
Anzahl Features	3	5	4	$3 \times 5 \times 4 = 60$

3.5 Zwischenfruchtklassifikation

Random-Forest-Klassifikator

Ein Random-Forest-Klassifikator (BREIMANN 2001; BELGIU et al., 2016) wurde zunächst genutzt, um das Klassifikationsmodell zu generieren. Random Forest ist ein häufig eingesetzter Algorithmus, der auf maschinellem Lernen basiert und für seine Robustheit und Genauigkeit bekannt ist. Der Algorithmus kann für Klassifizierungen und Regressionen genutzt werden und ist nicht-linear sowie nicht-parametrisch. Zudem kann er mit hochdimensionalen, numerischen und kategorialen Variablen umgehen. Random Forest ist eine „Ensemble-Learning“-Methode, wobei für die Berechnung eines Random Forests eine große Anzahl von Entscheidungsbäumen generiert werden. Der Output mehrerer Entscheidungsbäume (engl. „Decision Trees“) wird zu einem Ergebnis kombiniert.

Das Modell wurde mit dem ausgewogenen Felddatensatz (siehe Kapitel 3.4 Vorverarbeitungsschritte) trainiert, wobei die Parameter zur Optimierung an die Heterogenität und Komplexität der Daten angepasst wurden. Alle berechneten Eingabefeatures wurden dabei als Prädiktorvariablen verwendet. Das Klassifikationsmodell, welches auf Sentinel-1 und Sentinel-2-Daten für die vier Zeiträume basiert,

wurde mit 197 Eingabefeatures trainiert. Zur Optimierung der Leistung des Random-Forest-Klassifikators wurden die Hyperparameter angepasst. Zu den wichtigsten angepassten Hyperparametern gehören die Anzahl der Bäume (`n_estimators`), die maximale Baumtiefe (`max_depth`) und die minimalen Stichproben pro Blatt (`min_samples_leaf`).

Der Random-Forest-Klassifikator basierte auf 500 Entscheidungsbäumen und zwölf zufällig ausgewählten Merkmalen bei jedem Split. Wir haben 500 Entscheidungsbäume gewählt, um eine optimale Balance zwischen Klassifikationsgenauigkeit und Rechenzeit zu erreichen. Eine hohe Anzahl an Entscheidungsbäumen führt generell zu höheren Genauigkeiten, da mit mehr Entscheidungsbäumen die Modellvarianz reduziert werden kann. In vielen fernerkundlichen Analysen werden 500 Entscheidungsbäume genutzt, da so eine hohe Genauigkeit für komplexe Daten wie Satellitenbildern ohne übermäßig lange Rechenzeiten erreicht werden kann. Die Anzahl an Entscheidungsbäumen sollte nicht zu hoch gewählt sein, da die Genauigkeit ab einem bestimmten Punkt nicht mehr verbessert werden kann, es jedoch so höheren Rechenzeiten kommen kann.

Ein Split in einem Entscheidungsbaum bezieht sich auf den Punkt, an dem der Baum die Daten in zwei Gruppen unterteilt, basierend auf einem Merkmal, das die beste Trennung der Klassen ermöglicht. Bei jedem Split wird ein Merkmal ausgewählt, das die höchste Informationsgewinnung bietet, um die Daten effektiv zu teilen. Die Anzahl der Merkmale, die bei jedem Split zufällig ausgewählt werden, wurde auf zwölf festgelegt. Diese Anzahl ermöglicht es dem Klassifikator, eine Vielzahl von Informationen aus den verschiedenen Bändern und Indizes zu nutzen, ohne dass der Baum zu stark an den Trainingsdaten angepasst wird. Zu viele Merkmale könnten jedoch die Zufälligkeit zwischen den Bäumen verringern und zu Überanpassung (engl. „Overfitting“) führen, bei der das Modell zu genau auf die Trainingsdaten zugeschnitten ist und bei neuen Daten schlechtere Vorhersagen liefert. Anschließend wurden die beiden Zielklassen (Zwischenfrucht und Nicht-Zwischenfrucht) für das gesamte Untersuchungsgebiet prognostiziert.

XGBoost-Klassifikator

Gradient-Boosting-Algorithmen wie der XGBoost-Algorithmus (engl. „extreme gradient boosting“) eignen sich aufgrund ihrer hohen Genauigkeit und schnellen Berechnungsgeschwindigkeit für viele fernerkundliche Analysen und für Regressions- und Klassifizierungsaufgaben (MIAO et al. 2022). XGBoost und Random Forest sind beides Ensemble-Methoden, die auf Entscheidungsbäumen basieren, aber sie unterscheiden sich in der Art und Weise, wie die Bäume gebildet werden. Während Random Forest mehrere Bäume parallel trainiert, wobei jeder Baum unabhängig von den anderen lernt und durch Zufall Daten und Merkmale auswählt, baut XGBoost seine Bäume sequenziell auf, wobei jeder neue Baum die Fehler des vorherigen korrigiert (CHEN et al. 2016). XGBoost nutzt Boosting und bietet eingebaute Regu-

larisierung, um Überanpassung zu vermeiden, was zu einer besseren Leistung führt, aber auch zu höheren Rechenkosten. Im Gegensatz dazu verwendet Random Forest die Aggregation von Bäumen zur Fehlerreduktion und ist schneller im Training, bietet jedoch in komplexeren Szenarien oft geringere Genauigkeit als XGBoost. Beide Methoden kombinieren mehrere Bäume, um robuste Modelle zu erstellen, wobei XGBoost durch die sequentielle Fehlerkorrektur und Regularisierung oft präziser ist.

XGBoost wurde zusätzlich zu dem Random-Forest-Klassifikator für die Klassifizierung von Zwischenfrüchten eingesetzt und die Ergebnisse und deren Genauigkeiten wurden verglichen. Um die Leistung des XGBoost-Klassifikators zu optimieren, wurden die Hyperparameter angepasst. Zu den wichtigsten angepassten Hyperparametern gehören die Anzahl der Boosting-Runden (n_{rounds}), die maximale Baumtiefe (max_depth), die Lernrate (η), der Regularisierungsparameter γ , der Anteil der Spaltenstichprobe bei jedem Baum (colsample_bytree), das minimale Gewicht eines Blattes (min_child_weight) und das Verhältnis der Unterstichproben (subsample). Zur systematischen Bewertung von Kombinationen dieser Hyperparameter wurde ein Gittersuchansatz (engl. „Grid Search“) verwendet, während die Kreuzvalidierung die Robustheit bei der Auswahl der optimalen Einstellungen sicherstellte. Mit einem Gittersuchansatz ist eine systematische Methode zur Optimierung der Hyperparameter eines Modells gemeint. Dabei werden verschiedene Kombinationen von Hyperparametern ausprobiert, um die beste Kombination für das Modell zu finden. In diesem Fall wurde der Gittersuchansatz verwendet, um die Hyperparameter des XGBoost-Klassifikators zu optimieren. Darauf basierend wurde ein Klassifikator trainiert, der beispielsweise 500 Boosting-Runden, eine Lernrate von 0,005 und eine maximale Tiefe von 10 umfasst. Für beide Algorithmen wurde die Wichtigkeit der Variablen (engl. „Variable Importance“) berechnet.

3.6 Nachbearbeitung

Das Klassifikationsergebnis wurde in RStudio nachbearbeitet. Zunächst wurde die Klassifikationskarte mithilfe der InVeKoS-Daten zugeschnitten und maskiert, um ausschließlich die landwirtschaftlich genutzten Flächen zu extrahieren. Mithilfe dieser Maske für Ackerflächen konnten dann Flächen herausgeschnitten werden, die keine Ackerflächen sind, wie zum Beispiel Wälder, urbane Gebiete, Straßen oder Naturschutzgebiete. Anschließend wurde ein Mehrheitsfilter generiert, um die Genauigkeit und Interpretierbarkeit der klassifizierten Karte zu verbessern. Dazu wurde die kleinste Kartiereinheit (engl. „Minimum Mapping Unit“) von einzelnen Pixeln auf die landwirtschaftlichen Polygone des InVeKoS-Datensatzes umgestellt. Für jedes Polygon wurde dabei eine Mehrheitsabstimmung durchgeführt, wobei die häufigste Klasse innerhalb der Polygongrenze als repräsentative Klasse für das gesamte Polygon ausgewählt wurde. Damit konnten falsch klassifizierte Pixel entfernt werden. Die Mehrheitszuweisung in der Nachbearbeitung führt dazu, dass die Klasse mit dem höchsten Flächenanteil innerhalb eines Polygons die gesamte Fläche repräsentiert. Dies ist insbesondere bei stark fragmentierten Flächen relevant, wo einzelne falsch klassifizierte Pixel durch die Mehrheitsfilterung eliminiert werden. Zwar wird

dadurch das „Rauschen“ reduziert und die Kohärenz der Klassifikation verbessert, jedoch besteht das Risiko, dass kleinere, korrekt klassifizierte Teilflächen umgewidmet werden. Die Klassifizierungsgenauigkeit wird für die pixelbasierte Klassifizierung (vor der Anwendung des Mehrheitsfilters) gezeigt.

3.7 Validierung und Flächenbewertung

Die statistische Genauigkeit des Klassifikationsergebnisses wurde durch den Vergleich des Validierungsdatensatzes mit der Kartenklassifizierung bewertet. Die sich daraus ergebende Konfusionsmatrix wurde zur Berechnung verschiedener Koeffizienten verwendet, darunter die Gesamtgenauigkeit, die Herstellergenauigkeit und die Benutzergenauigkeit. Flächenschätzungen wurden für die beiden Zielklassen berechnet und diese mit verfügbaren agronomischen Statistiken verglichen, um die Plausibilität unseres Klassifikationsergebnisses zu bewerten.

3.8 Prozessierung in FORCE

Zusätzlich zu der Analyse in GEE haben wir die Klassifikationsanalyse in FORCE (engl. „Framework for Operational Radiometric Correction for Environmental Monitoring“, FRANTZ 2019) durchgeführt. Während es sich bei der GEE um eine benutzerfreundliche Cloud-basierte Plattform handelt, die eine schnelle Geodatenanalyse mit vorgeladenen Datensätzen ermöglicht, handelt sich bei FORCE um eine lokale, hochleistungsfähige Verarbeitungssoftware, welche sich auf eine hochwertige Vorverarbeitung von Satellitendaten konzentriert und Nutzern mehr Kontrolle über die Einstellung radiometrischer Korrekturen gibt. GEE ist vergleichsweise einfach zu bedienen, bietet jedoch nur begrenzte Anpassungsmöglichkeiten, während FORCE mehr Einrichtungsaufwand, technische Vorkenntnisse und hohe lokale Rechenressourcen benötigt, aber eine erweiterte Kontrolle über die Datenqualität bietet. Wir haben die Klassifikationsergebnisse aus FORCE mit den Klassifikationsergebnissen aus GEE verglichen.

4 Ergebnisse der Zwischenfruchtklassifikation

4.1 Auswirkungen der Datenverfügbarkeit

Abbildung 6 und Abbildung 7 zeigen die Anzahl der wolkenfreien Sentinel-2-Beobachtungen pro Pixel für den gesamten Zeitraum sowie für spezifische Wachstumszeiträume. Es sind sowohl räumliche als auch zeitliche Unterschiede in der Anzahl der wolkenfreien Aufnahmen erkennbar. In Gebieten, in denen sich die Satellitenumlaufbahnen überschneiden, ist die Anzahl der wolkenfreien Aufnahmen höher. Besonders auffällig ist ein nord-südlich verlaufender Streifen mit wenigen wolkenfreien Aufnahmen, der dort liegt, wo sich die Satellitenbahnen nicht überschneiden. Saisonale Unterschiede verschärfen dieses Muster, wie Abbildung 7 zeigt. Insbesondere die Wintermonate bieten aufgrund der hohen Wolkenbedeckung ungünstige Bedingungen für Fernerkundungsaufnahmen. Zusätzlich wird die Datenverfügbarkeit durch die geometrische Wiederholungsfrequenz und die Überlappung benachbarter Satelliten-Tracks beeinflusst (COPERNICUS SENTINEL-2 MISSION 2024).

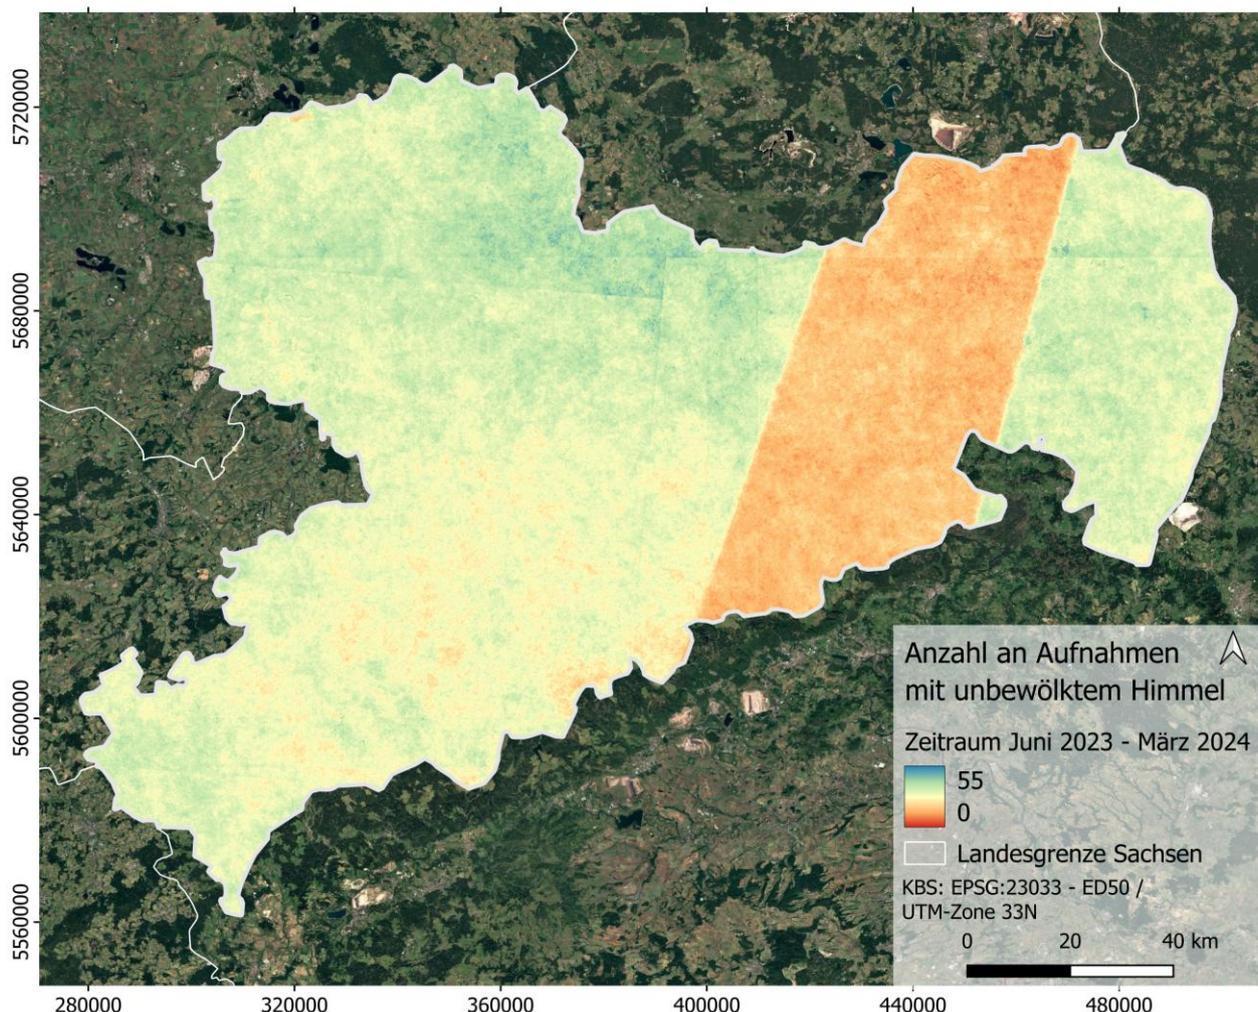


Abbildung 6: Anzahl der Aufnahmen mit unbewölktem Himmel im Zeitraum Juni 2023 bis März 2024 (Sentinel-2).

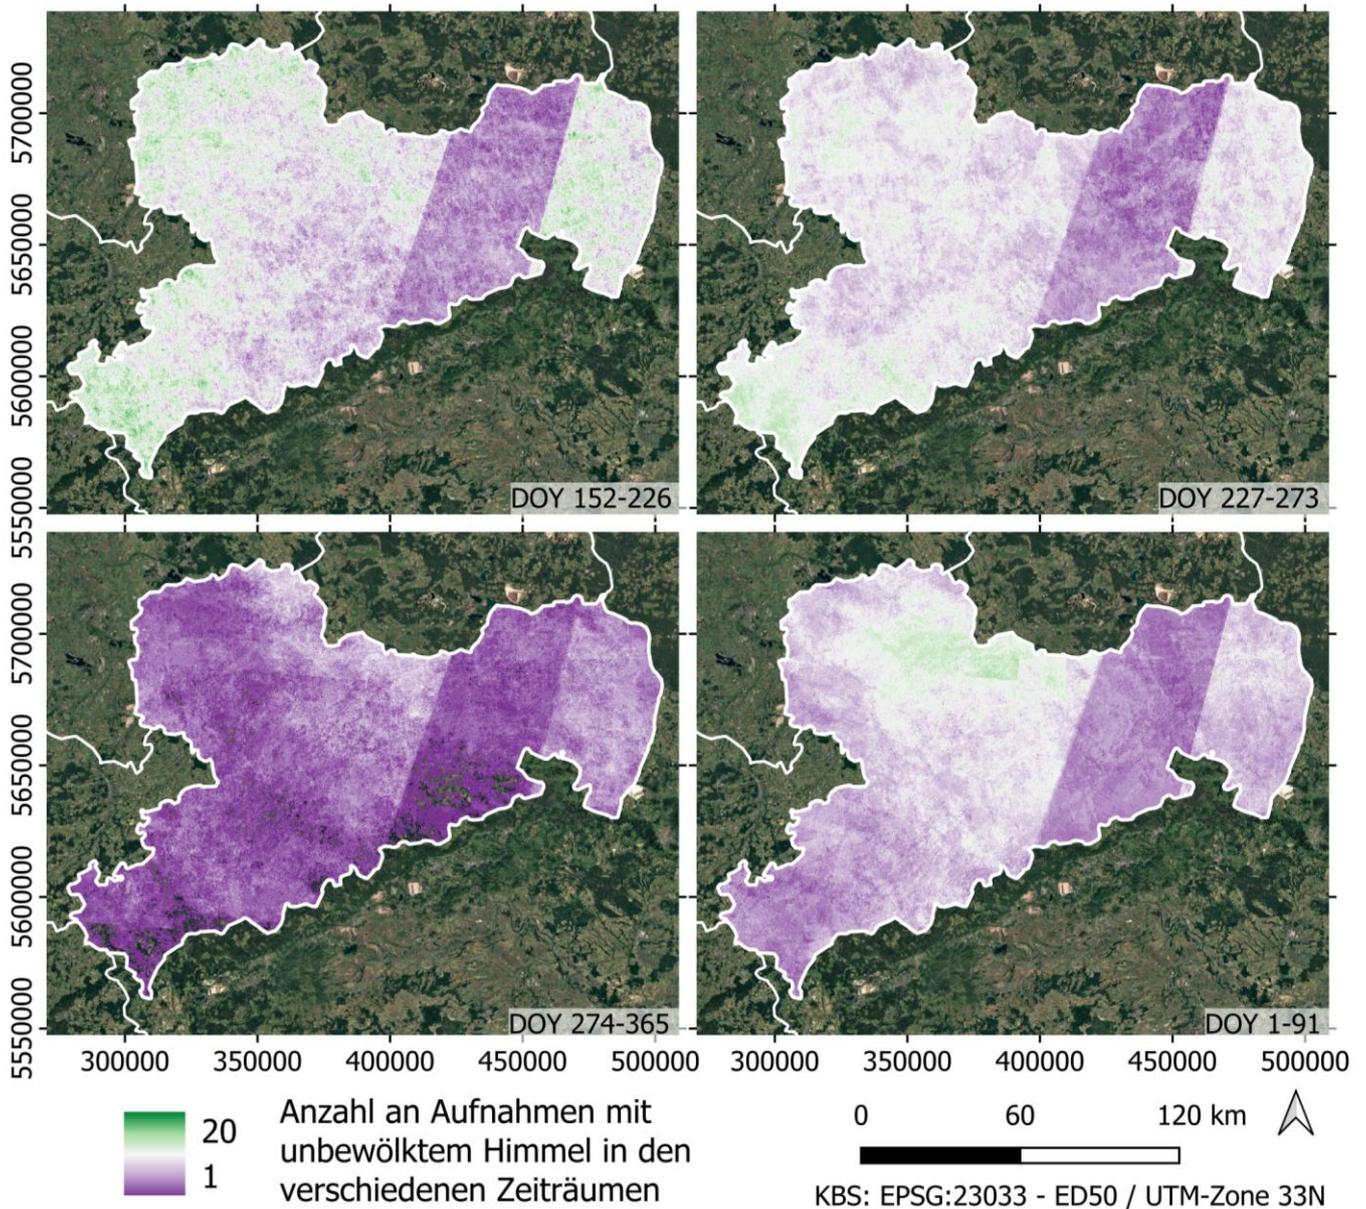


Abbildung 7: Anzahl der Aufnahmen mit unbewölktem Himmel in vier verschiedenen Zeiträumen zwischen Juni 2023 und März 2024 (Sentinel-2).

4.2 Phänologische Erkenntnisse aus Fernerkundungsdaten

Abbildung 8 und Abbildung 9 zeigen den Mittelwert und den Median des zeitlichen Verlaufs des NDVIs für die verschiedenen Feldfruchtklassen an den Erhebungsstandorten für die Klassen „Zwischenfrucht“ und „Nicht-Zwischenfrucht“. Weitere Zeitreihen anderer Vegetationsindizes befinden sich im Anhang. In beiden Abbildungen sinkt der NDVI über die Sommermonate hinweg (Juni bis Oktober), was auf den Rückgang der Vegetationsaktivität nach der Hauptwachstumsperiode hinweist. Ab November bleibt der NDVI auf niedrigem Niveau stabil und steigt ab Februar/März 2024 deutlich an, was auf erneutes Wachstum hindeutet. Die Median-Zeitreihen zeigen gleichmäßigere Kurven und robustere Trends, da diese weniger empfindlich gegenüber Ausreißern sind. Die Mittelwert-Zeitreihen sind dagegen etwas

variabler, da einige NDVI-Werte möglicherweise durch eine heterogene Vegetationsbedeckung innerhalb bestimmter Klassen stark vom Durchschnitt abweichen. Die gewonnenen Erkenntnisse helfen dabei, die Entwicklung der Kulturpflanzen besser zu verstehen, potenzielle Herausforderungen zu identifizieren und geeignete Aggregationszeiträume zu bestimmen.

Der NDVI wurde gewählt, da dieser einer der am weitesten verbreiteten Vegetationsindizes ist und sich bewährt hat, um die Vegetationsaktivität und -vitalität effizient zu bewerten. Zudem wurde er in der Studie von JENSCH (2023) erfolgreich eingesetzt, um die Felddaten zu überprüfen und potenziell falsch erhobene Daten zu identifizieren. Der Fokus auf den NDVI ermöglicht eine einfache und schnelle visuelle Interpretation der phänologischen Muster, die für die Unterscheidung von Zwischenfrüchten und Nicht-Zwischenfrüchten relevant sind. Im Anhang des Berichts finden sich jedoch auch Zeitreihen anderer Indizes, wie MNDVI und NDTI. Diese wurden nicht primär zur visuellen Interpretation genutzt, sondern später in die Klassifikationsmodelle integriert, um eine differenziertere Analyse und eine höhere Klassifikationsgenauigkeit zu erreichen. Die ergänzenden Indizes tragen dazu bei, weitere Landschaftsmerkmale und Variationen in der Vegetation hervorzuheben, die der NDVI allein nicht vollständig abdecken kann.

Median-NDVI-Zeitreihen nach Feldfrucht-Klassen

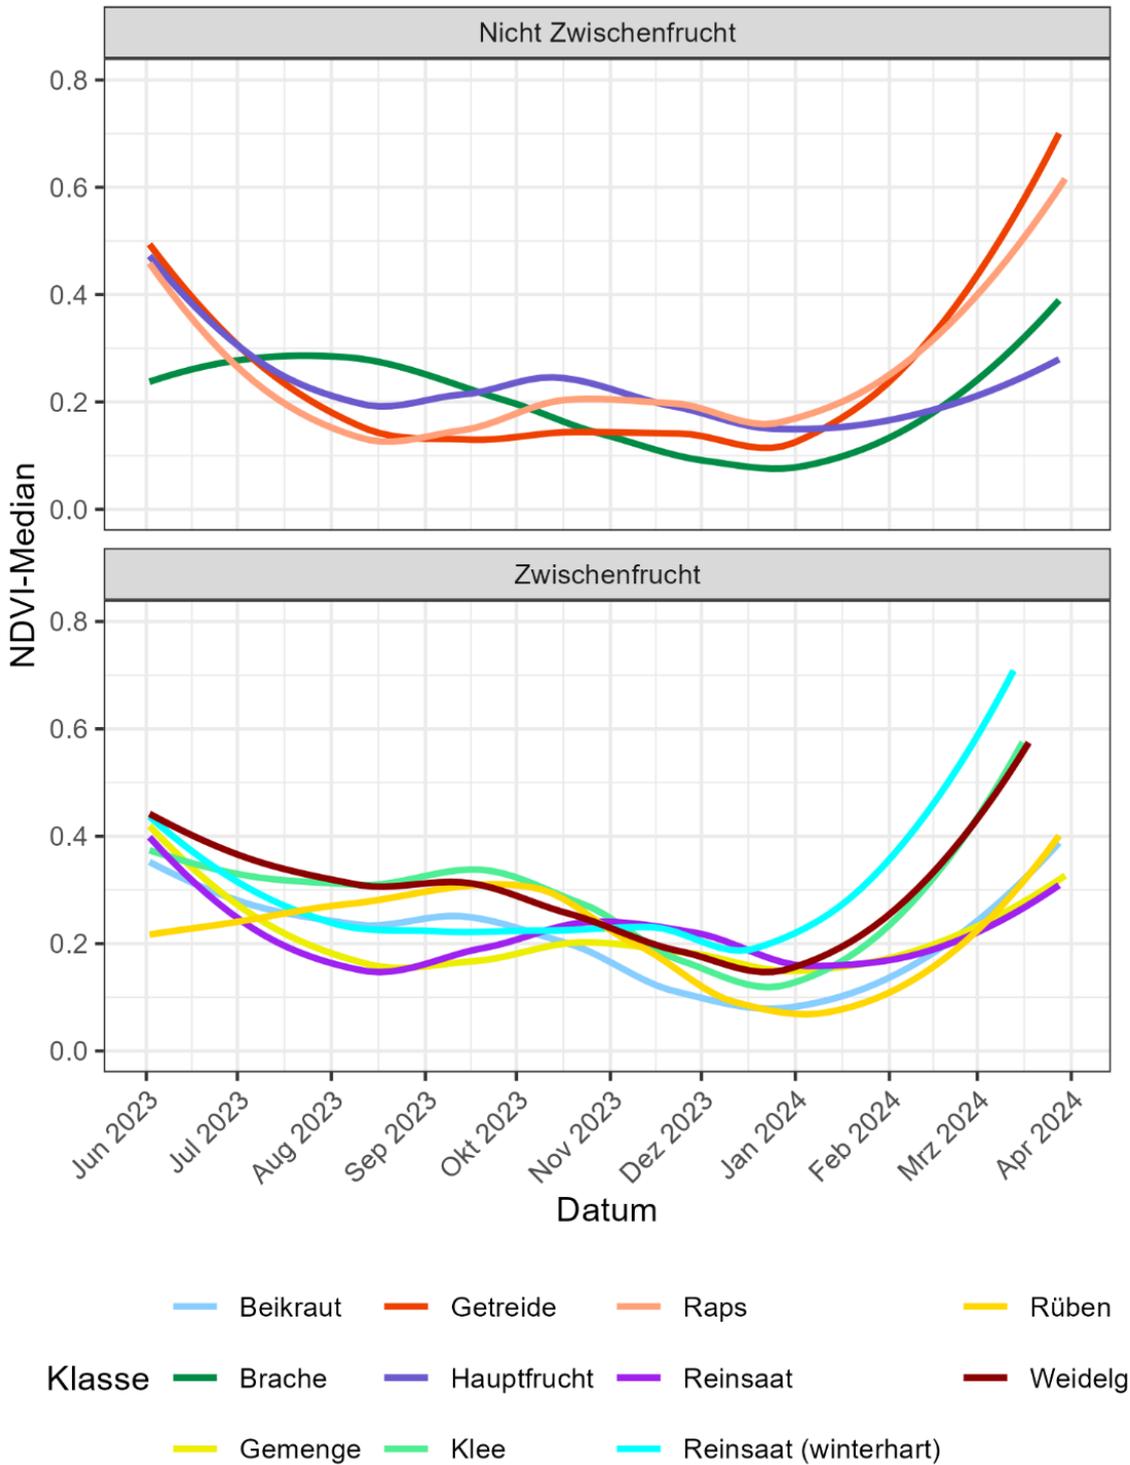


Abbildung 8: NDVI-Zeitreihe (Median) nach Feldfrucht-Klassen an Standorten der Felddatenerhebung

Mittelwert-NDVI-Zeitreihen nach Feldfrucht-Klassen

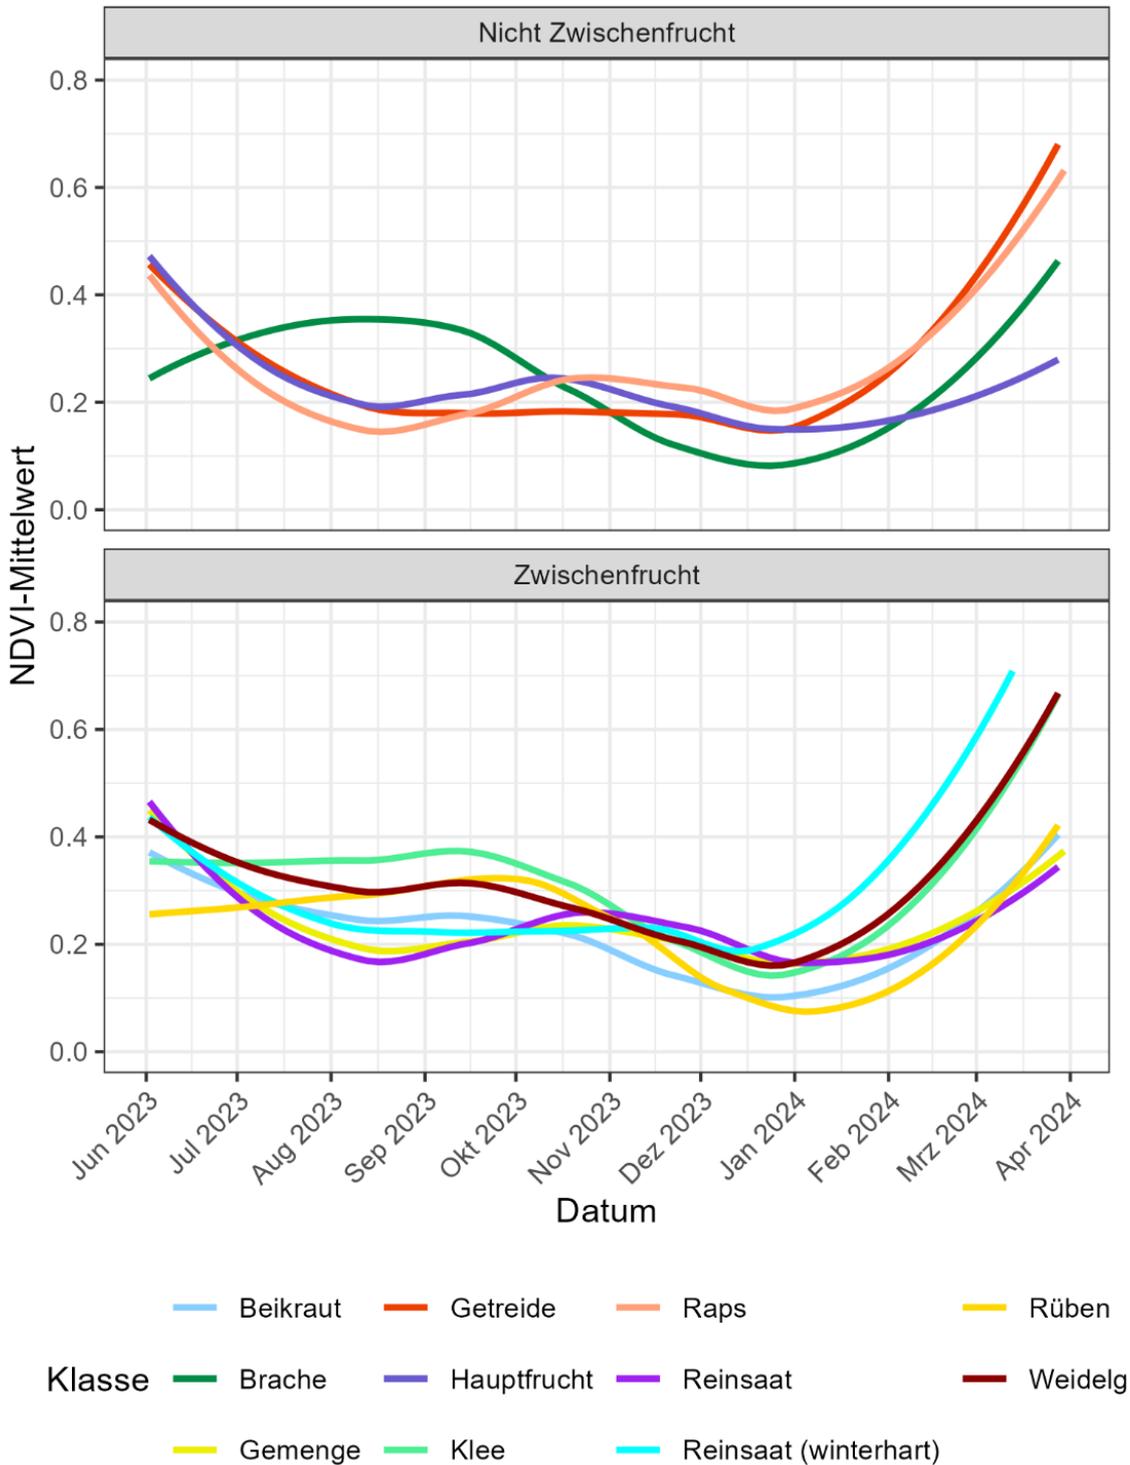


Abbildung 9: NDVI-Zeitreihe (Mittelwert) nach Feldfrucht-Klassen an Standorten der Felddatenerhebung

4.3 Binäre Zwischenfrucht-Klassifikation

Abbildung 12 zeigt das Ergebnis der Zwischenfruchtklassifikation auf Basis der Kombination von Sentinel-1 und Sentinel-2-Daten von Juni 2023 bis März 2024. Die Ergebnisse beruhen ausschließlich auf den erhobenen Felddaten (Punktdatensatz) sowie auf den Sentinel-1 und Sentinel-2-Aufnahmen bzw. den generierten Input-Features für die verschiedenen Zeiträume. Die Karte unterscheidet Zwischenfrüchte von anderen Feldfrüchten.

Anhand der Ergebniskarte wird deutlich, dass die Verteilung des Zwischenfruchtanbaus in Sachsen nicht einheitlich ist. Es gibt deutliche Konzentrationen in bestimmten Regionen wie dem Vogtland und der Oberlausitz, wo neben Zwischenfruchtflächen auch Flächen ohne Zwischenfruchtanbau dominieren. Diese Muster deuten auf lokale landwirtschaftliche Praktiken oder Umweltbedingungen hin, die die Verteilung von Zwischenfrüchten beeinflussen. Darüber hinaus können die Klassifizierungsergebnisse auf eine mögliche Verwechslung von Zwischenfrüchten mit anderen Fruchtarten hinweisen (Anhang Abbildung 13 und Abbildung 14), insbesondere in Regionen mit komplexer Landnutzung. Die möglichen Verwechslungen von Zwischenfrüchten mit anderen Fruchtarten können auf spektrale Ähnlichkeiten und phänologische Überschneidungen zurückzuführen sein. Beispielsweise können Ernterückstände oder winterfeste Hauptfrüchte wie Winterraps in bestimmten Wachstumsphasen ähnliche spektrale Signaturen wie Zwischenfrüchte aufweisen. Darüber hinaus können Umweltbedingungen, wie etwa unterschiedliche Bodenbearbeitungsmethoden oder Restvegetation nach der Ernte, die Reflexionseigenschaften beeinflussen und so die Abgrenzung erschweren. Auch regionale Unterschiede in landwirtschaftlichen Praktiken, wie die späte Aussaat oder Mischkulturen, können zu spektralen Variationen führen, die fälschlicherweise als Zwischenfrüchte interpretiert werden. Solche Verwechslungen unterstreichen die Bedeutung einer präzisen Auswahl von Trainingsdaten und der Integration zusätzlicher Indizes, um eine klare Differenzierung zu gewährleisten.

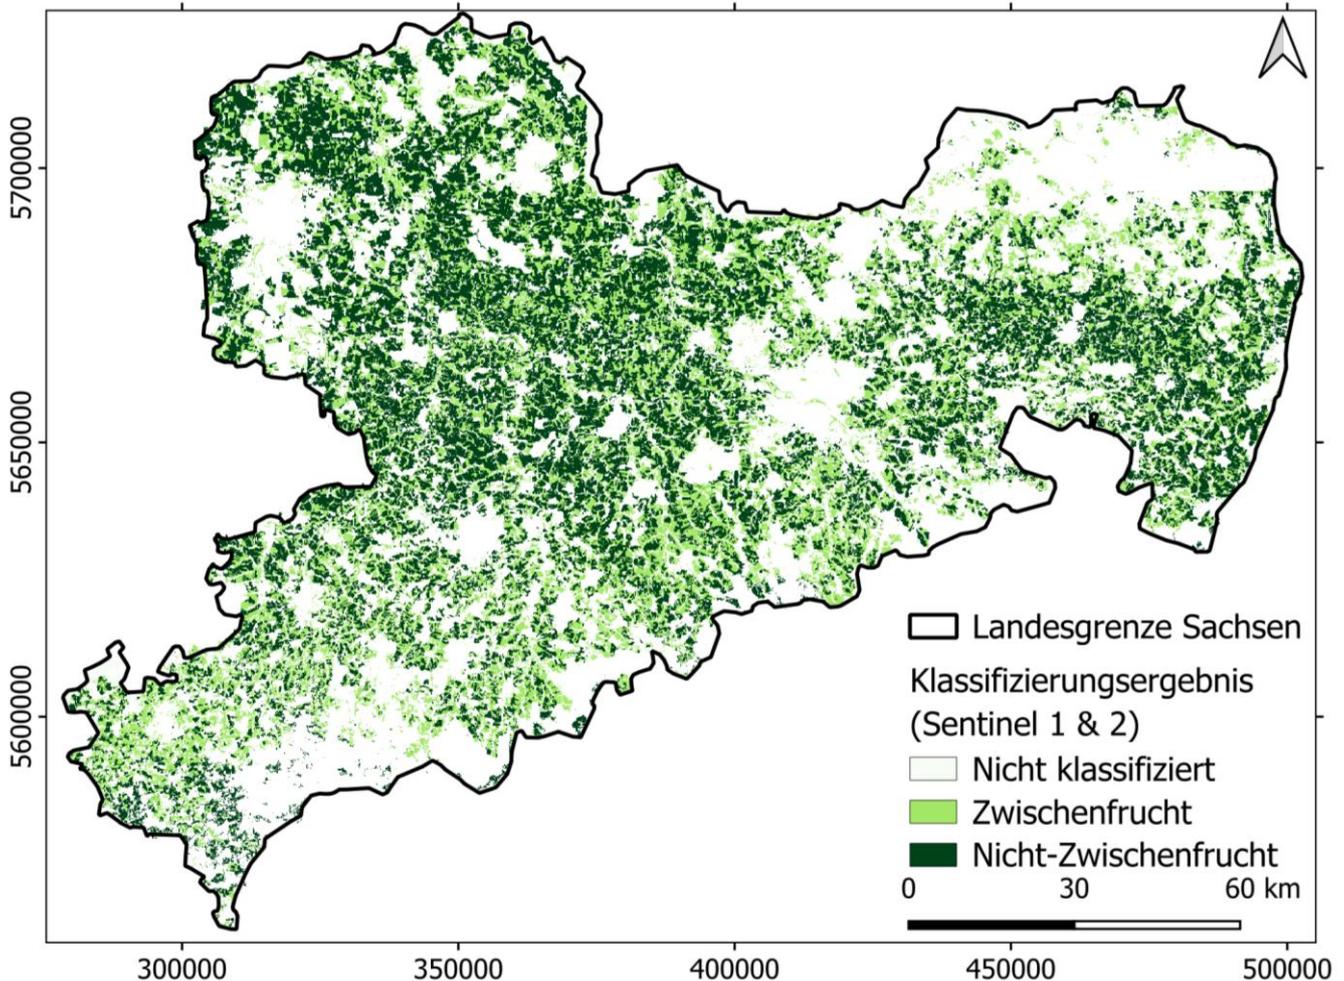


Abbildung 10: Klassifizierung der landwirtschaftlich genutzten Schläge in Sachsen im Zeitraum Juni 2023 bis März 2024 auf Basis von Sentinel-1 und -2, maskiert mit InVeKoS-Daten, nach Anwendung des Mehrheitsfilters

Abbildung 11 zeigt die Ergebnisse der Klassifikation von Zwischenfrucht- und Nicht-Zwischenfruchtflächen anhand von Sentinel-Daten sowie deren Vergleich mit den InVeKoS-Schlagdaten 2023. Karte a) stellt die landwirtschaftlichen Parzellen basierend auf den InVeKoS-Daten dar, während Karte b) das ungeglättete Klassifikationsergebnis zeigt, das Fragmentierungen an Feldrändern und innerhalb von Schlägen aufweist. In der Karte c) wurde der Mehrheitsfilter angewendet, wodurch die Ergebnisse deutlich geglättet und besser an die tatsächliche Feldstruktur angepasst wurden. Die Glättung reduziert die Fragmentierung und verbessert die Kohärenz der Klassifikation, wodurch kleine Fehlklassifikationen minimiert werden. Dennoch zeigen die Unterschiede zwischen den InVeKoS-Daten und den klassifizierten Flächen Herausforderungen bei der Abgrenzung von Zwischenfruchtflächen, insbesondere durch spektrale Ähnlichkeiten mit Nicht-Zwischenfrüchten oder durch Restvegetation der Hauptfrüchte. Insgesamt verdeutlichen die Ergebnisse das Potenzial der Fernerkundungsdaten, weisen jedoch auf Optimierungsbedarf bei der Klassifikation und Validierung hin.

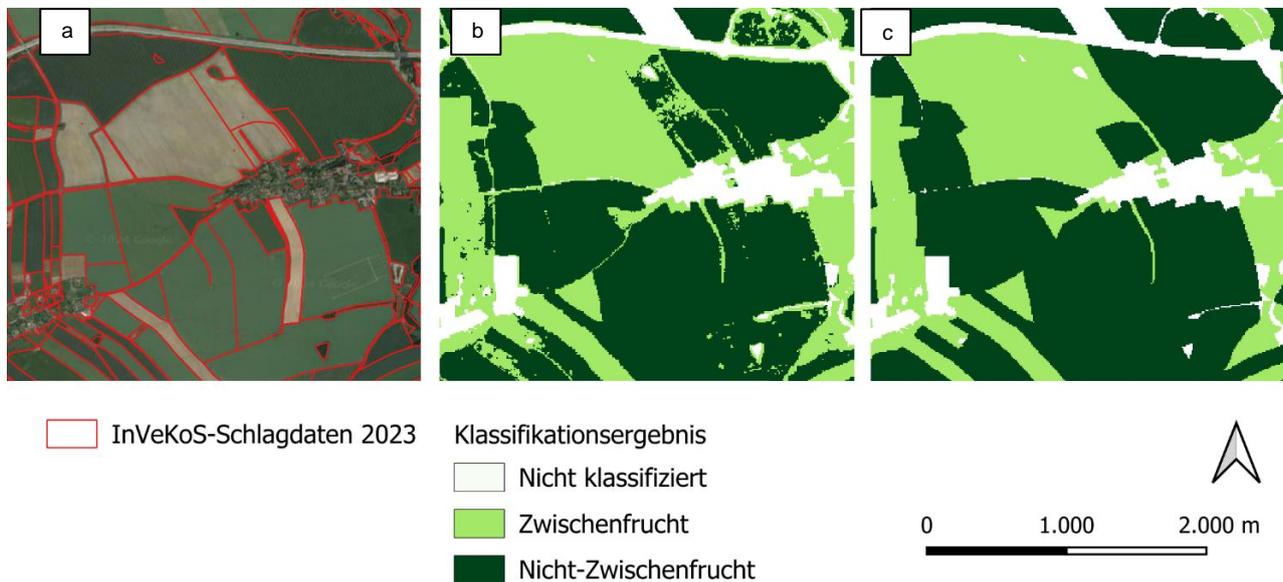


Abbildung 11: Klassifikation vor (Mitte) und nach (rechts) der Anwendung des Mehrheitsfilters

Tabelle 4 zeigt die Ergebnisse verschiedener Klassifikationsansätze zur Unterscheidung von Zwischenfrucht- und Nicht-Zwischenfruchtflächen anhand von Satellitendaten. Die Ansätze nutzen unterschiedliche Datensätze (Sentinel-1, Sentinel-2, HLS und Kombinationen dieser) sowie verschiedene zeitliche Auflösungen (periodisch und monatlich). Die Gesamtgenauigkeit beschreibt, wie gut die jeweiligen Klassifikationen die Referenzdaten widerspiegeln, wobei die Bewertung auf einer pixelgenauen Analyse basiert.

Die alleinige Nutzung von Sentinel-1-Daten führte zu der geringsten Genauigkeit. Dies könnte auf die Limitierungen der Radardaten in Bezug auf die Differenzierung von Vegetationsarten zurückzuführen sein. Optische Daten von Sentinel-2 zeigen eine deutliche Verbesserung im Vergleich zu Sentinel-1, da diese Daten spezifischere spektrale Informationen über die Vegetation bieten. Die höchste Genauigkeit (0,86) wurde bei der Kombination von Sentinel-1- und Sentinel-2-Daten mit monatlicher zeitlicher Auflösung erzielt. Dies verdeutlicht, dass die Integration von Radar- und optischen Daten sowie die Berücksichtigung der zeitlichen Dynamik entscheidend für die Verbesserung der Klassifikation ist. Interessanterweise erreichte die Kombination von S1 und S2 (für die periodischen Komposite) mit 0,85 eine nahezu gleich hohe Genauigkeit und zeigt, dass selbst bei leicht reduzierter zeitlicher Auflösung eine robuste Klassifikation möglich ist. Die Ergebnisse wurden pixelgenau verglichen, was bedeutet, dass jede Klassifikation direkt mit den Referenzdaten auf Pixelebene abgeglichen wurde. Die Ergebnisse zeigen zudem, dass auch FORCE mit einer Gesamtgenauigkeit von 0,86 eine vergleichbare Leistung erzielen konnte und als Alternative betrachtet werden kann.

Tabelle 4: Übersicht über die verschiedenen Klassifikationsansätze sowie die Klassifikations-Gesamtgenauigkeiten.

Datensatz	Komposit	Gesamtgenauigkeit Random Forest	Gesamtgenauigkeit XGBoost
Sentinel-1	Periode	0,73	0,74
Sentinel-2	Periode	0,84	0,82
Sentinel-1 und 2	Periode	0,85	0,86
Sentinel-1 und 2	Monatlich	0,86	0,85
HLS	Periode	0,87	
FORCE	Periode	0,86	
HLS und Sentinel-1	Periode	0,83	

Die Gesamtgenauigkeit (Tabelle 4) der mehrheitsgefilterten Klassifikation, die auf Sentinel-1 und 2 basiert, liegt bei **90,7 %**. Die Produzenten-Genauigkeit (Producer's Accuracy) liegt bei 91,5 % für die Klasse Zwischenfrucht und bei 90,0 % für die Klasse Nicht-Zwischenfrucht. Die Nutzer-Genauigkeit (User's Accuracy) liegt währenddessen bei 89,6 % für die Klasse Zwischenfrucht und bei 91,8 % für die Klasse Nicht-Zwischenfrucht. Die Validierungsergebnisse deuten auf eine hohe Klassifikationsgenauigkeit hin. Die Klassen Zwischenfrucht und Nicht-Zwischenfrucht können zuverlässig unterschieden werden.

Tabelle 5: Konfusionsmatrix für die Zwischenfrucht-Klassifikation basierend auf Sentinel 1 und 2, nach der Anwendung des Mehrheitsfilters

		Referenzdaten		
		Zwischenfrucht	Nicht-Zwischenfrucht	Summe
Klassifikation	Zwischenfrucht	43	5	48
	Nicht-Zwischenfrucht	4	45	49
	Summe	47	50	97

Die Variable Wichtigkeit (Abbildung 14) zeigt, dass die wichtigsten Eingaben für die Klassifikation zwischen Periode 3 (2023-10-01 bis 2023-12-31) und Periode 4 (2024-01-01 bis 2024-03-31) liegen. Gleichzeitig ist jedoch erkennbar, dass einige Indizes, wie z. B. wetness-mean-1-91, auch in Periode 4 eine hohe Bedeutung haben. Dies könnte darauf hinweisen, dass der Feuchtigkeitsgehalt während der Wintermonate, insbesondere in Periode 4, entscheidend für die Differenzierung zwischen Zwischenfrucht- und Nicht-Zwischenfruchtflächen ist. Es zeigt, dass neben phänologischen Mustern auch spezifische Umweltmerkmale in der Klassifikation eine wichtige Rolle spielen.

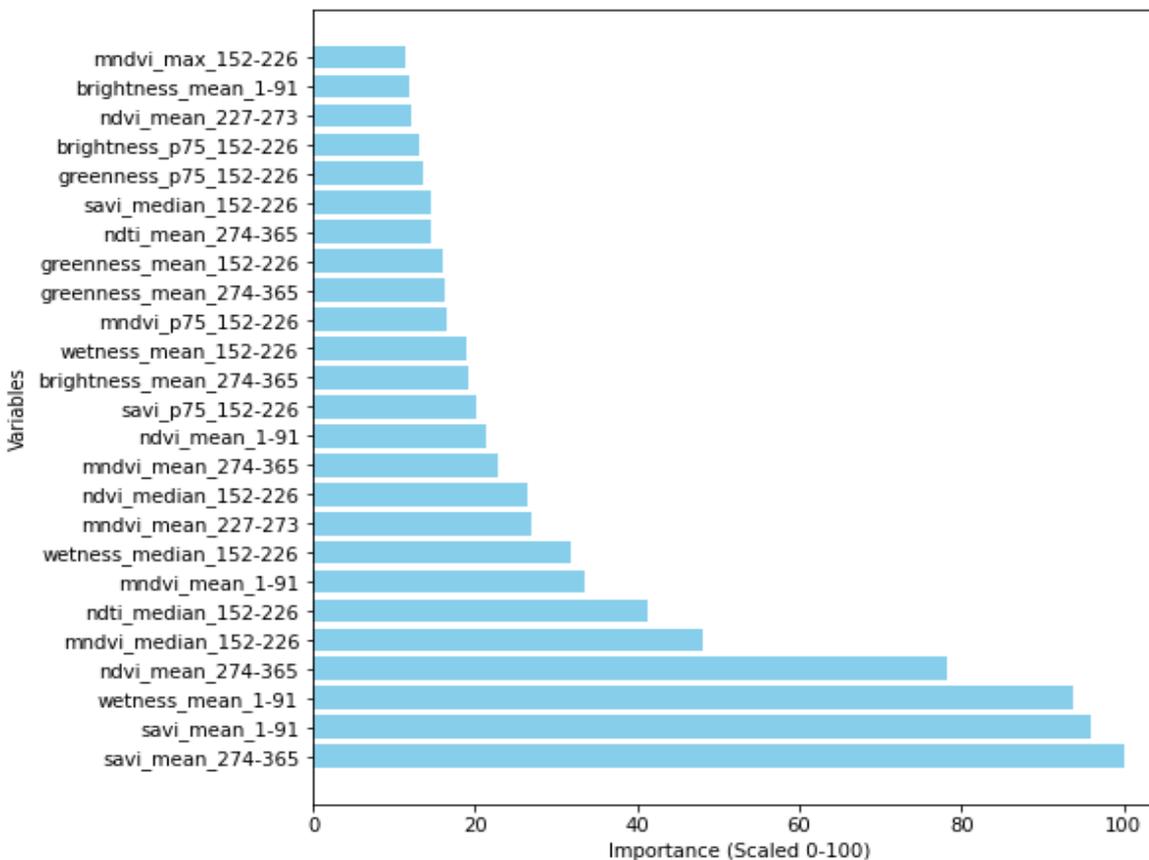
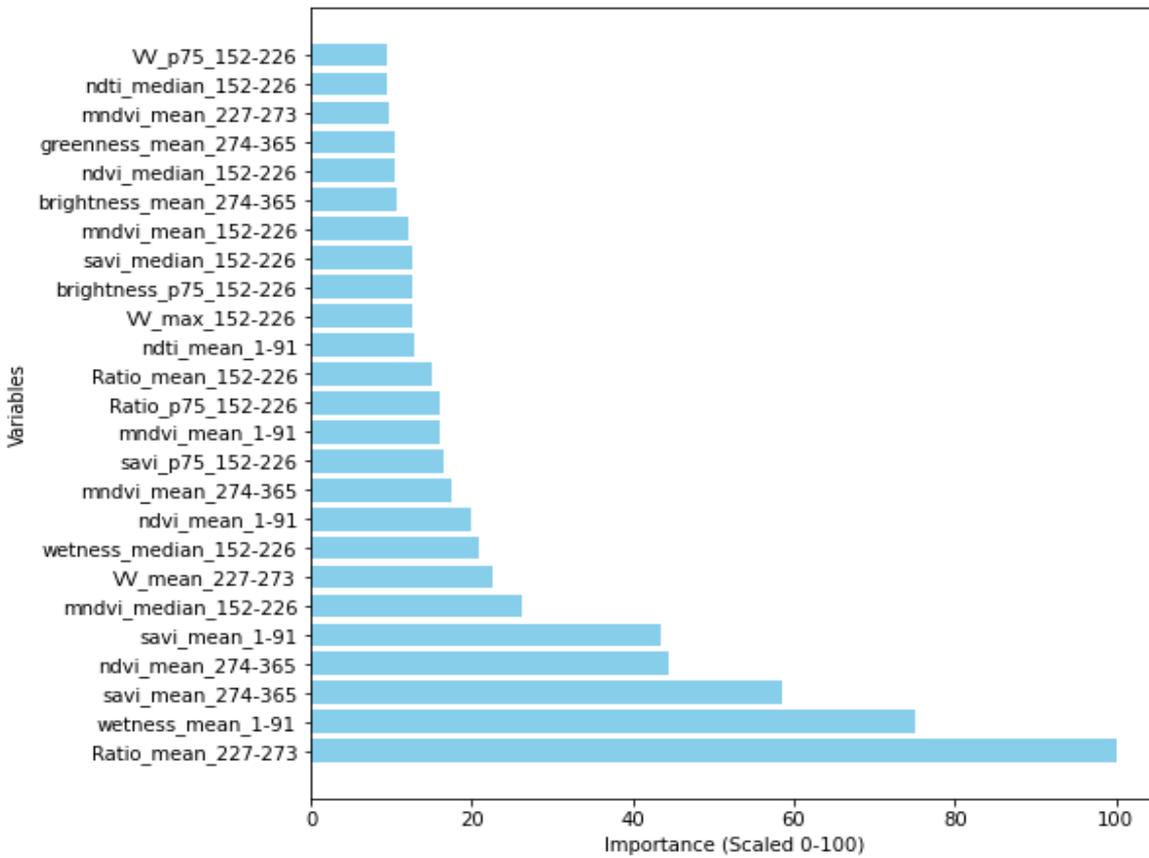


Abbildung 12: Die wichtigsten 25 Variablen (von insgesamt 160) für die Klassifikation von Zwischenfrüchten (Oben bei Verwendung von Sentinel-2- und Sentinel-1-Daten, unten nur mit Sentinel-2).

4.4 Flächenstatistik

Die Flächenschätzung basierend auf der Klassifikation unter Verwendung von Sentinel-1- und Sentinel-2-Daten zeigt eine Aufteilung der landwirtschaftlichen Flächen in die Kategorien „Zwischenfrucht“ und „Nicht-Zwischenfrucht“. Der Großteil der Schläge, 56,2 %, wurde als „Nicht-Zwischenfrucht“ klassifiziert. Etwa 43,8 % wurden als „Zwischenfrucht“ eingeordnet. Amtliche Statistiken ordnen 10 % der Ackerflächen in Sachsen als Zwischenfruchtanbau ein (SMEKUL 2024). Der Anteil an Zwischenfrüchten an Ackerflächen in Deutschland beträgt circa 18 % (STATISTISCHES BUNDESAMT 2024).

Tabelle 6: Flächenstatistik der Klassifikation basierend auf Sentinel-1 und -2, nach Anwendung des Mehrheitsfilters

Klasse	Fläche (in ha)	Prozentualer Anteil
Zwischenfrucht	412.097	43,8 %
Nicht-Zwischenfrucht	529.043	56,2 %

5 Diskussion

Die vorliegende Studie zeigt, dass die erhobenen Felddaten eine verlässliche Grundlage für die Erstellung einer Zwischenfrucht-Klassifikationskarte bieten, die eine Vielfalt verschiedener Zwischenfruchtarten abdeckt. Unsere Daten ermöglichen einen räumlichen Überblick über den Anbau von Zwischenfrüchten in Sachsen. Die Klassifikation erzielte eine hohe Genauigkeit.

Der Klassifikationsansatz, der auf der Kombination von Sentinel-1 und Sentinel-2-Daten beruht, erreichte die höchsten Klassifikationsgenauigkeiten. Die Kombination von Sentinel-1 (SAR-Daten) und Sentinel-2 (optischen Daten) führt zu höheren Klassifikationsgenauigkeiten, da sie sich in ihren jeweiligen Vorteilen ergänzen (SNEVAJS et al. 2022). Sentinel-1 liefert robuste Informationen zu Texturen und Bodenfeuchtigkeit, die weniger anfällig für Wolken oder Nachtbedingungen sind (SELVARAJ et al. 2024, NAJEM et al. 2023), während Sentinel-2 detaillierte spektrale Daten für die Unterscheidung von Vegetationstypen und Bodenbedeckung bietet (SCHULZ et al. 2021). Diese Synergie ermöglicht eine genauere Analyse von Landnutzung und Vegetation, da beide Datensätze unterschiedliche Aspekte der Oberfläche abdecken, die einzeln möglicherweise nicht ausreichend sind. Dadurch wird die Klassifikation stabiler und robuster, besonders bei schwierigen Umweltbedingungen.

Ein Defizit in dieser Studie war der Mangel an unabhängigen Validierungsdaten. Die Felddaten mussten in einen Trainings- und einen Validierungsdatensatz aufgeteilt werden, wodurch die Stichprobengröße für das Training des Klassifikationsmodells reduziert wurde. Dies könnte die Robustheit des Modells beeinflusst haben, da es keine Möglichkeit gab, die Ergebnisse unabhängig zu prüfen.

Die erhobenen Felddaten wurden räumlich nicht gleichmäßig verteilt über das gesamte Untersuchungsgebiet erhoben. Dies kann die Leistung des Klassifikationsmodells beeinflussen. Der Großteil der Daten wurde im Mittelsächsischen Hügelland und in der Lommatzcher Pflege kartiert. Die ungleichmäßige Verteilung von Felddaten kann zu Verzerrungen bei der Klassifizierung führen, wobei die Bodenbedeckungsarten in dicht beprobten Regionen überrepräsentiert und in spärlich beprobten Gebieten unterrepräsentiert oder falsch klassifiziert werden. Dies kann die Verallgemeinerbarkeit des Klassifikators über das gesamte Untersuchungsgebiet hinweg verringern und zu irreführenden Genauigkeitsmetriken führen.

Die räumlich uneinheitliche Verteilung des Zwischenfruchtanbaus in Sachsen lässt darauf schließen, dass regionale Faktoren – etwa unterschiedliche Bodenverhältnisse, klimatische Bedingungen oder betriebliche Managementansätze – einen erheblichen Einfluss auf die Ausprägung dieser Praxis haben. Um die beobachteten Muster zu verstehen und Fehlklassifikationen zu minimieren, ist eine weiterführende Analyse erforderlich, bei der insbesondere Bodendaten und betriebsbezogene Informationen in die Bewertung einbezogen werden. Auf dieser Basis lassen sich Schlussfolgerungen über mögliche

Hemmnisse und Potenziale für den Zwischenfruchtanbau in den betroffenen Regionen ableiten und gezielte Empfehlungen oder Förderinstrumente entwickeln.

Die Klassifikation zeigte eine Überklassifizierung von Zwischenfrüchten. Es wurden mehr Flächen als „Zwischenfrucht“ identifiziert, als in landwirtschaftlichen Statistiken (SMEKUL 2024) berichtet wird. Die Diskrepanz zwischen den offiziellen Statistiken und den Ergebnissen der Klassifikation könnte durch verschiedene Faktoren bedingt sein, darunter die Differenzierung der Datenerhebungsmethoden und die zeitliche Variation des Anbaus. Während die amtlichen Statistiken meist auf Erhebungen zu einem spezifischen Zeitpunkt basieren, spiegelt die Fernerkundung eine dynamische Perspektive wider, die saisonale Veränderungen und regionale Unterschiede in der Landnutzung aufzeigt. Diese Differenzen könnten auch durch die zeitliche Auflösung der Sentinel-Daten und die Klassifikationsgenauigkeit beeinflusst werden. Ausfallkulturen und Beikräuter, die nicht gezielt angebaut werden, können in der Klassifikation mit Zwischenfrüchten verwechselt werden. Solche Pflanzen entwickeln sich auf jedem Feld unterschiedlich, wodurch ihre spektralen Eigenschaften entweder einzigartig sind oder denen anderer Kulturpflanzen ähneln. Unkontrolliert wachsende Pflanzenarten sowie die Vielfalt an Hauptfrüchten, die nach der Ernte als Zwischenfruchtflächen eingestuft werden, weisen eine große Variabilität in ihrer Entwicklung und Phänologie auf. Dies erschwert eine klare Abgrenzung gegenüber Zwischenfrüchten. Im Gegensatz dazu folgen die meisten Zwischenfruchtarten und -mischungen klaren Wachstumsmustern, die sich nur geringfügig durch Aussaatzeitpunkt, Frostresistenz und Wachstumsperiode unterscheiden.

Einige Zwischenfruchtarten weisen große Gemeinsamkeiten zu in den spektralen Eigenschaften mit Hauptfrüchten auf, was eine Differenzierung schwierig macht. Zwischenfrüchte umfassen eine breite Bandbreite an Pflanzenarten, die jeweils unterschiedliche Wachstums- und Entwicklungsphasen aufweisen. Zudem werden Zwischenfrüchte zu unterschiedlichen Zeitpunkten ausgesät, was die spektralen Eigenschaften der Felder über die Zeit hinweg heterogen macht.

Des Weiteren wurden mehrere Felder, die zuvor mit Mais bepflanzt waren, anschließend als „Zwischenfrucht“ klassifiziert, was möglicherweise eine Fehlklassifikation war. Mais hinterlässt nach der Ernte oft Rückstände auf dem Feld, die fälschlicherweise als Zwischenfrucht interpretiert werden (NAJEM et al. 2023). Dies unterstreicht die Notwendigkeit einer präzisen Erkennung von Ernterückständen in zukünftigen Modellen. Auch eine anschließende Plausibilisierung der Ergebnisse mit verfügbaren weiteren Datenquellen, wie den Schlagdaten, kann zur Verbesserung der Ergebnisse beitragen.

Darüber hinaus kann die erhöhte Bodenrauhigkeit nach dem Pflügen dazu beitragen, dass die Reflexion der SAR-Signale verstärkt werden und zu einer Überklassifizierung führen kann (NAJEM et al. 2023). Zudem könnten schwach entwickelte Rapskulturen dazu führen, dass Raps aufgrund der niedrigen NDVI-Werte Zwischenfrüchten ähneln und daher schwer unterscheidbar sind (NAJEM et al. 2023).

In zukünftigen Studien zur Detektion von Winterzwischenfrüchten sollte darauf geachtet werden, einen umfangreichen Felddatensatz zu erheben. Die Erhebung von multitemporalen Felddaten könnte die Einordnung der Feldfrucht und damit die Klassifikationsgenauigkeit verbessern. Zudem sollte die Felddatenerhebung räumlich möglichst gleichmäßig über das Untersuchungsgebiet verteilt durchgeführt werden. Des Weiteren könnten fernerkundliche Daten mit einer höheren zeitlichen und räumlichen Auflösung, wie z. B. PlanetScope (kostenpflichtig), oder Hyperspektraldaten, wie z. B. EnMAP (kostenfrei), in die Analyse mitaufgenommen werden.

6 Zusammenfassung

Im Projekt zur Detektion von Winterzwischenfrüchten in Sachsen während des Winters 2023/2024 wurden sowohl Felddaten als auch fernerkundliche Daten von Sentinel-1 und Sentinel-2 zur Klassifikation von Zwischenfrüchten und anderen Feldfrüchten eingesetzt. Zusammenfassend liefert die Zwischenfrucht-Klassifikation unserer Analyse eine hohe Genauigkeit, jedoch sind bestimmte Einschränkungen zu berücksichtigen. Der Mangel an unabhängigen Validierungsdaten und die Überklassifizierung von Zwischenfrüchten stellen wesentliche Limitationen dar. Darüber hinaus erfordern die Variabilität von Pflanzenarten, deren Phänologie und das Vorhandensein von Unkräutern sowie Ernterückständen weitere methodische Anpassungen. Die Ergebnisse dieser Studie zeigen dennoch, dass die entwickelte Klassifikationskarte eine wertvolle Grundlage für die Analyse und das Monitoring des Zwischenfruchtanbaus darstellt.

7 Handlungsempfehlung

Die beschriebene Analyse zeigt das Potenzial der Fernerkundungsmethoden zur zuverlässigen Klassifikation von Zwischenfrüchten in Sachsen. Trotz hoher Genauigkeit und einer guten Grundlage für zukünftige Anwendungen gibt es einige Aspekte, die weiter optimiert werden können, um die Ergebnisse noch robuster und präziser zu gestalten. Hier sind konkrete Handlungsempfehlungen:

1. Erhebung zusätzlicher Referenzdaten mit gleichmäßiger räumlicher Abdeckung

Eine der wesentlichen Einschränkungen der vorliegenden Studie ist die ungleichmäßige räumliche Verteilung der Felddaten, insbesondere in Gebieten wie Ostsachsen, die nur spärlich erfasst wurden. Um die Klassifikationsgenauigkeit zu verbessern, sollte die Datenerhebung zukünftiger Studien auf eine gleichmäßigere Abdeckung des gesamten Untersuchungsgebietes abzielen. Dies könnte durch eine strategische Planung der Stichprobenorte und den Einsatz zusätzlicher Erhebungsteams erreicht werden, um die Repräsentativität und Verallgemeinerbarkeit der Ergebnisse zu erhöhen.

2. Integration von hochauflösenden und hyperspektralen Fernerkundungsdaten

Die Ergänzung der verwendeten Sentinel-1 und Sentinel-2-Daten durch hochauflösende Datenquellen wie PlanetScope oder hyperspektrale Sensoren wie EnMAP könnte die Differenzierung von Zwischenfrüchten und anderen Feldfrüchten weiter verbessern. Hyperspektraldaten bieten spezifischere spektrale Signaturen, die zur besseren Trennung von Fruchtarten beitragen können, während hochauflösende Daten lokale Variationen besser erfassen. Dies würde auch helfen, die spektrale Ähnlichkeit von Zwischenfrüchten mit Ernterückständen oder Beikräutern zu minimieren.

3. Post-Processing mit Vektordaten zur Verbesserung der visuellen Darstellung

Die Anwendung von Post-Processing-Schritten, wie z. B. das Glätten der Klassifikationsergebnisse mithilfe von Vektordaten und Mehrheitsfiltern, hat bereits in der vorliegenden Analyse gezeigt, dass dadurch die visuelle Darstellung und Interpretierbarkeit der Ergebnisse deutlich verbessert werden kann. Zukünftig sollte die Nutzung von vektorbasierten Daten für Post-Processing und Darstellung weiter ausgebaut werden, um kleinräumige Fehlklassifikationen zu minimieren und die Ergebnisse für landwirtschaftliche Entscheidungsträger zugänglicher zu gestalten.

4. Erprobung alternativer Klassifikationsverfahren

Neben den eingesetzten Random-Forest- und XGBoost-Klassifikatoren könnten andere moderne Ansätze, wie neuronale Netze (z. B. Convolutional Neural Networks, CNNs) oder hybride Modelle, getestet werden. Diese Methoden könnten von der Integration von räumlich-zeitlichen Mustern und tiefen Lern-

strukturen profitieren, insbesondere bei der Analyse komplexer Daten wie hyperspektraler oder hochauflösender Fernerkundungsdaten. Ein besonderes Augenmerk könnte auf Modelle gelegt werden, die für kleine, unausgeglichene Datensätze geeignet sind, oder transferbasierte Lernmethoden.

5. Optimierung der zeitlichen Dynamik in der Klassifikation

Die Nutzung monatlicher oder sogar dekadischer Komposite anstelle periodischer Daten könnte die zeitliche Dynamik besser erfassen und somit die Klassifikationsgenauigkeit weiter erhöhen. Insbesondere bei Zwischenfrüchten, die unterschiedliche Phänologien aufweisen, kann eine präzisere zeitliche Granularität dabei helfen, Fehlklassifikationen aufgrund von Entwicklungsphasen zu reduzieren. Dies könnte auch durch den Einsatz von Recurrent Neural Networks (RNNs) oder Long Short-Term Memory Networks (LSTMs) ergänzt werden, die speziell für zeitabhängige Daten entwickelt wurden.

6. Zeitreihenanalyse für Datenqualität und Zeitaggregation

Die Extraktion von Zeitreihen ist wichtig, um die Qualität der zugrundeliegenden Daten zu beurteilen und potenziell fehlerhafte Daten frühzeitig zu erkennen und auszusortieren. Darüber hinaus geben die zeitlichen Muster zusätzliche Einblicke in die Wachstumsphasen und die Entwicklungsdynamik von Zwischenfrüchten und ermöglichen so eine fundierte Auswahl geeigneter Erfassungszeitfenster sowie eine genauere Ableitung geeigneter Vegetationsindikatoren.

Anhang

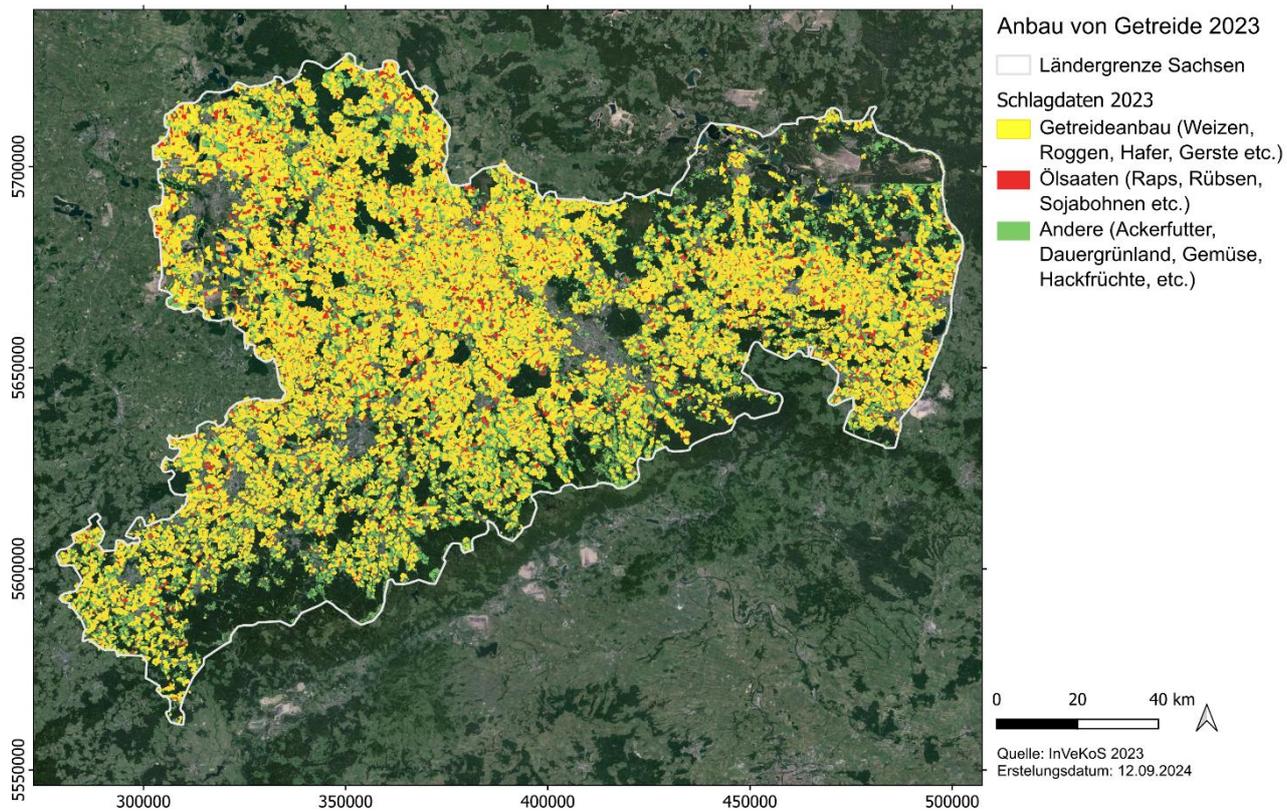


Abbildung 13: Übersicht über Anbau verschiedener Feldfrüchte im Jahr 2023

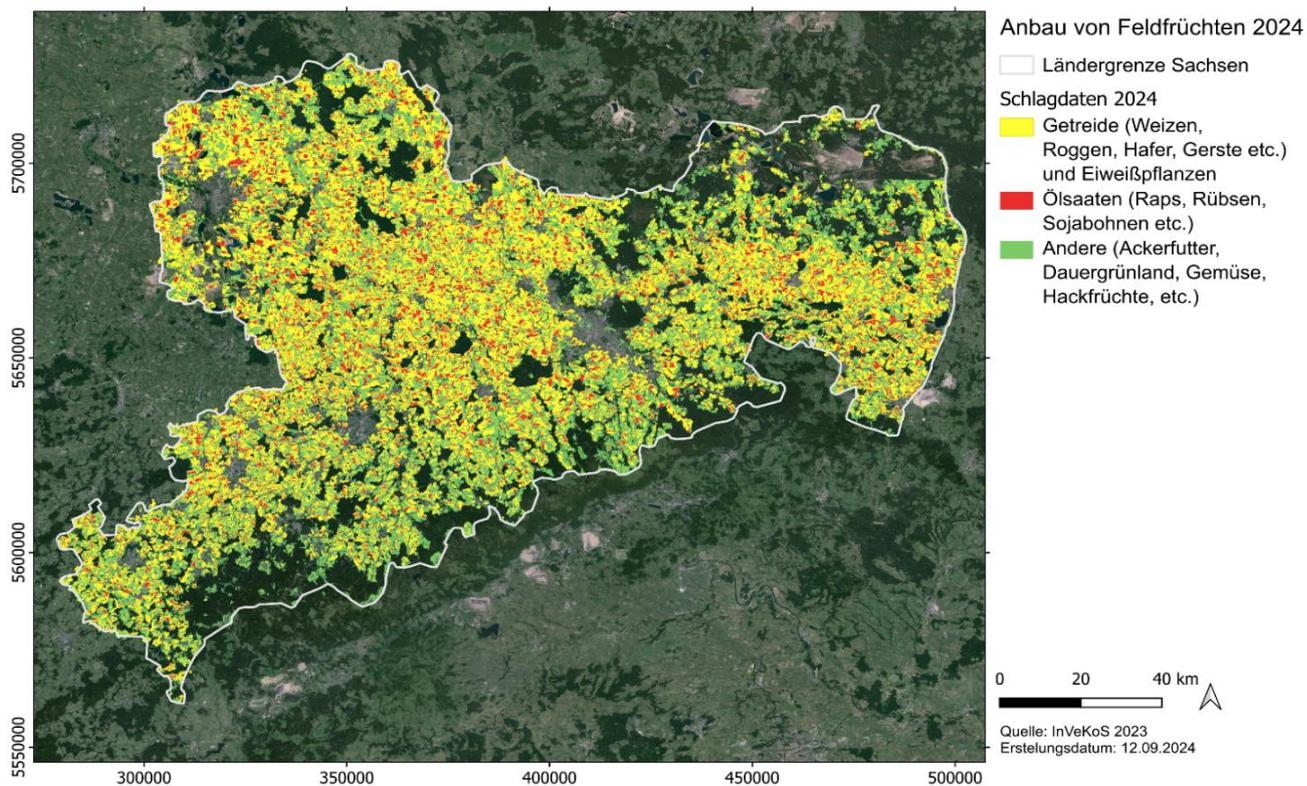


Abbildung 14: Übersicht über Anbau verschiedener Feldfrüchte im Jahr 2024

Median-NDTI-Zeitreihen nach Feldfrucht-Klassen

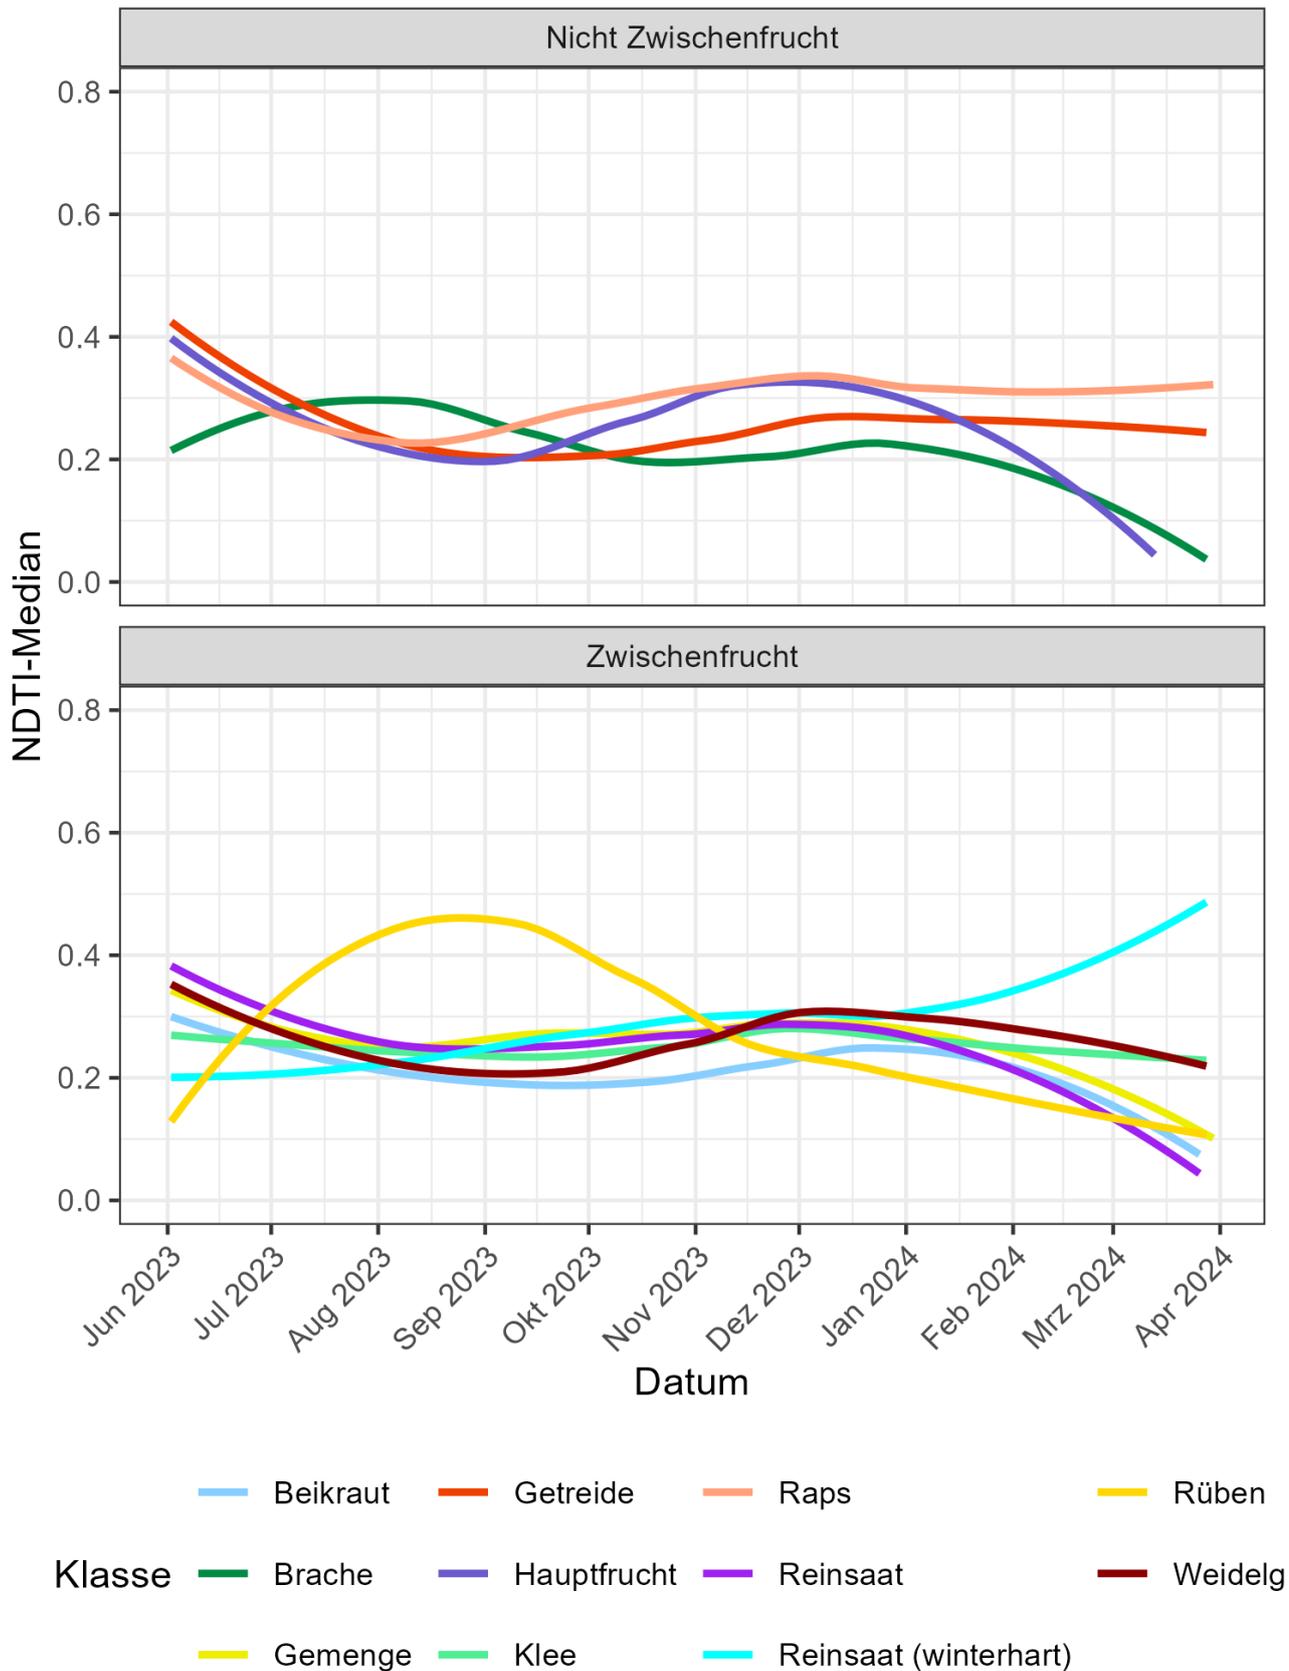


Abbildung 15: NDTI-Zeitreihe (Median) nach Feldfrucht-Klassen an Standorten der Felddatenerhebung

Median-MNDVI-Zeitreihen nach Feldfrucht-Klassen

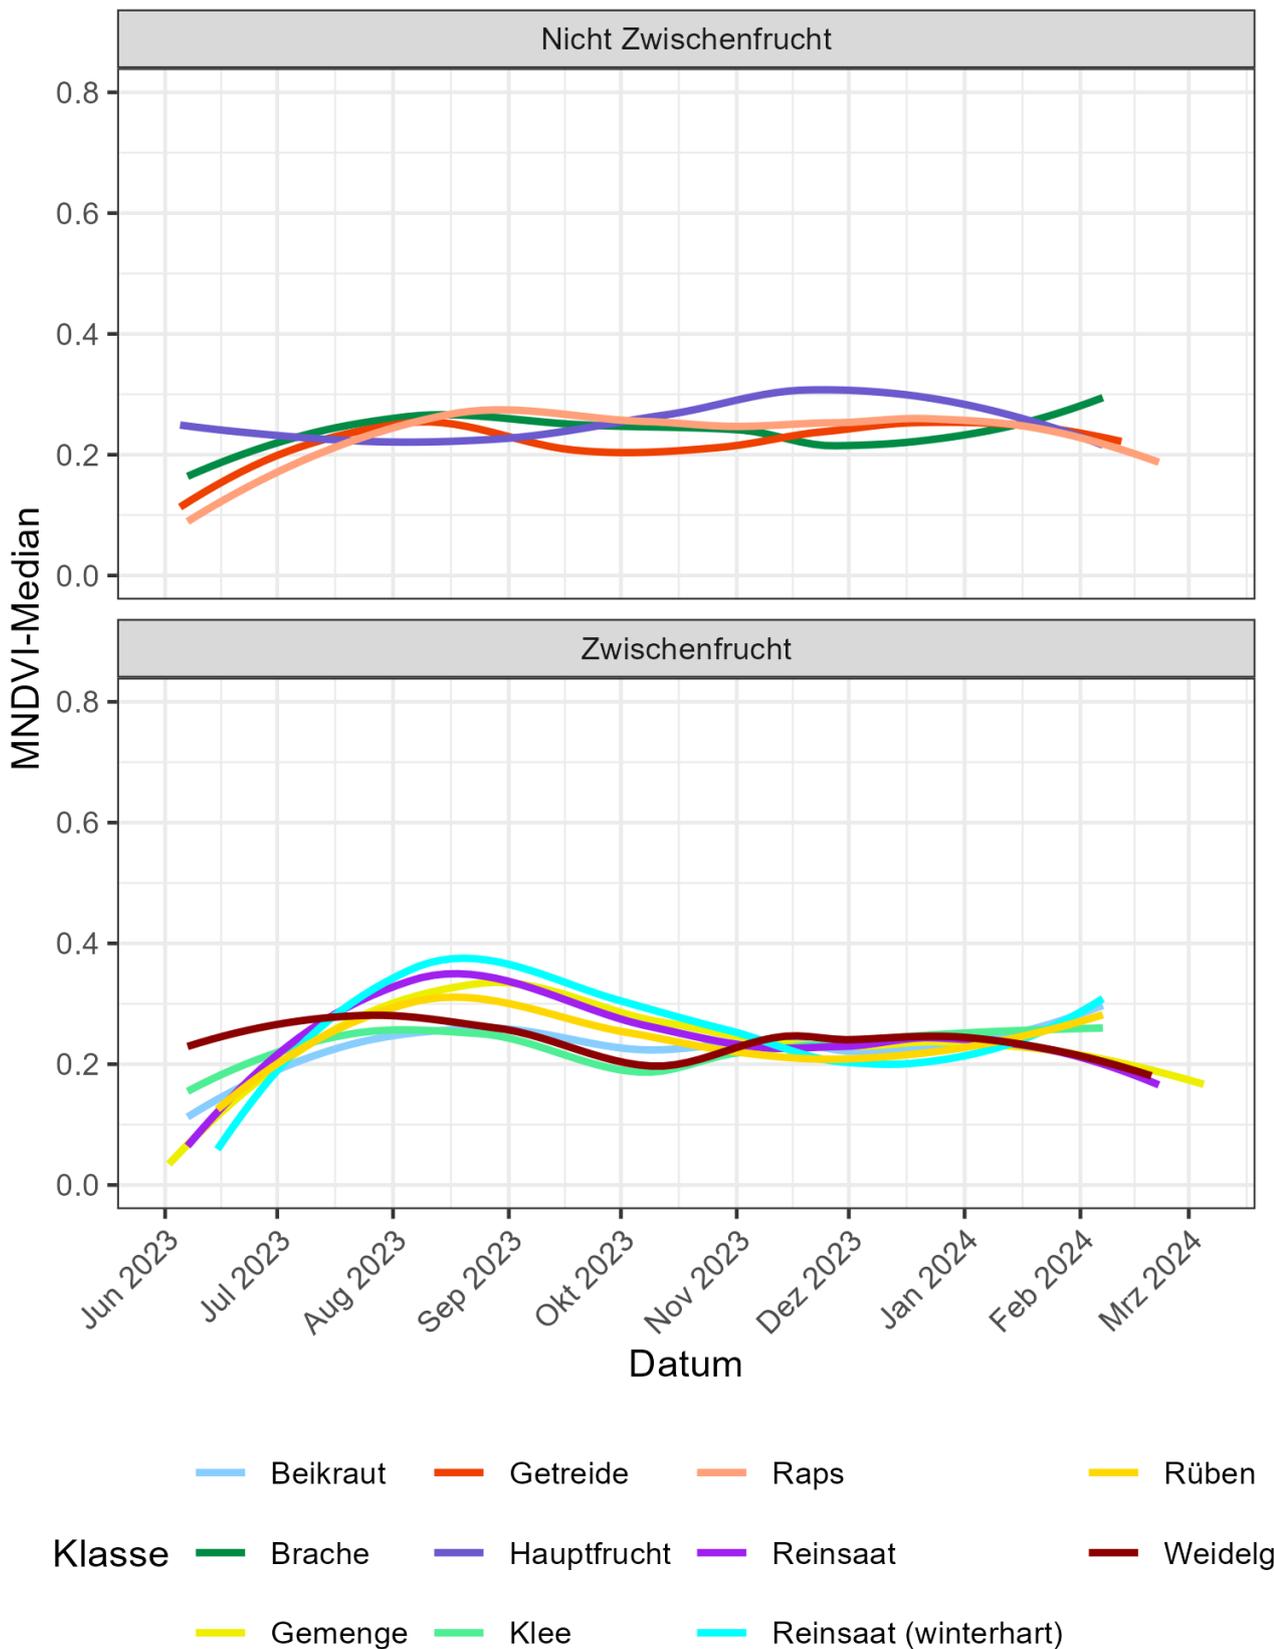


Abbildung 16: MNDVI-Zeitreihe (Median) nach Feldfrucht-Klassen an Standorten der Felddatenerhebung

Literaturverzeichnis

- BELGIU, M., DRĂGUȚ, L. (2016): Random forest in remote sensing: A review of applications and future directions. In: ISPRS Journal of Photogrammetry and Remote Sensing, 114, 24–31. <https://doi.org/10.1016/j.isprsjprs.2016.01.011>.
- BREIMAN, L. (2001): Random Forests. In: Machine Learning, Heft 45(1), 5–32. <https://doi.org/10.1023/A:1010933404324>.
- Bundesanstalt für Landwirtschaft und Ernährung (BLE) (2024): Zwischenfruchtanbau – Infografik. Zugriff am 09.12.2024, von <https://www.praxis-agrar.de/service/infografiken/zwischenfruchtanbau>.
- CHEN G., WEIL R. R. (2011): Root growth and yield of maize as affected by soil compaction and cover crops. Soil tillage Res 117:17–27. <https://doi.org/10.1016/j.still.2011.08.001>.
- CHEN, T., GUESTRIN, C. (2016): XGBoost: A Scalable Tree Boosting System. In Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining (KDD '16). Association for Computing Machinery, New York, NY, USA, 785–794. <https://doi.org/10.1145/2939672.2939785>.
- CLAVERIE, M., JU, J., MASEK, J. G., DUNGAN, J. L., VERMOTE, E. F., ROGER, J.-C., SHAKUN, S., JUSTICE, C. (2018): The Harmonized Landsat and Sentinel-2 surface reflectance data set. In: Remote Sensing of Environment, 219, 145–161. <https://doi.org/10.1016/j.rse.2018.09.002>.
- Copernicus Data Space Ecosystem (2025): Sentinel-2 Level 2A Data API Documentation. Zugriff am 09.01.2025. <https://documentation.dataspace.copernicus.eu/APIs/SentinelHub/Data/S2L2A.html>.
- Copernicus Sentinel-1 Mission (2025): Sentinel-1 Mission - Polarimetry. Zugriff am 09.01.2025, von <https://sentiwiki.copernicus.eu/web/s1-mission#S1Mission-PolarimetryS1-Mission-Polarimetry>.
- Copernicus Sentinel-2 Mission (2024): Sentinel-2 mission overview. Copernicus. Zugriff am 09. Dezember 2024, von <https://sentiwiki.copernicus.eu/web/s2-mission>.
- DEVENTER, V., WARD, A., GOWDA, P., LYON, J. (1997): Using Thematic Mapper Data to Identify Contrasting Soil Plains and Tillage Practices. Photogrammetric Engineering and Remote Sensing. 63. 87–93.
- DU, J., JACINTHE, P.A., SONG, K., ZHANG, L., ZHAO, B., LIU, H., WANG, Y., ZHANG, W., ZHENG, Z., YU, W., ZHANG, Y., JIANG, D. (2024): Maize crop residue cover mapping using Sentinel-2 MSI data and random forest algorithms. International Soil and Water Conservation Research. <https://doi.org/10.1016/j.iswcr.2024.09.004>.
- European Union's Copernicus Land Monitoring Service information: CORINE Land Cover 2018 (vector/raster 100 m) (2018): Europe, 6-yearly, <https://doi.org/10.2909/71c95a07-e296-44fc-b22b-415f42acdf0>.
- FRANTZ D. (2019): FORCE - Landsat + Sentinel-2 Analysis Ready Data and Beyond. In: Remote Sensing; 11(9):1124. <https://doi.org/10.3390/rs11091124>.

- HUETE, A. R. (1988): A soil-adjusted vegetation index (SAVI). In: *Remote Sensing of Environment*, 25, 3, 295-309. [https://doi.org/10.1016/0034-4257\(88\)90106-X](https://doi.org/10.1016/0034-4257(88)90106-X).
- JENSCH, K. (2023): Mapping intermediate crops in Brandenburg using Landsat and Sentinel-2 time series. Bachelorarbeit, Geographisches Institut der Humboldt-Universität zu Berlin, 42 S.
- JOYCE, B.A., WALLENDER, W.W., MITCHELL, J.P., HUYCK, L.M., TEMPLE, S.R., BROSTROM, P., HSIAO, T.C. (2002): Infiltration and Soil Water Storage under Winter Cover Cropping in California's Sacramento Valley. *Transactions of the ASAE*, 45, 315-326. <https://doi.org/10.13031/2013.8526>.
- JURGENS, C. (1997): The modified normalized difference vegetation index (mNDVI) a new index to determine frost damages in agriculture based on Landsat TM data. In: *International Journal of Remote Sensing*, 18:17, 3583-3594. <https://doi.org/10.1080/014311697216810>.
- JUSTES E., BEAUDOIN N., BERTUZZI P., CHARLES R., CONSTANTIN J., DÜRR C., HERMON C., JOANNON A., LE BAS C., MARY B., MIGNOLET C., MONTFORT F., RUIZ L., SARTHOU J.P., SOUCHÈRE V., TOURNEBIZE J., SAVINI I., RÉCHAUCHÈRE O. (2012): The use of cover crops to reduce nitrate leaching: Effect on the water and nitrogen balance and other ecosystem services. Synopsis of the study report INRA (France), 68 S.
- KAUTH R. J., G. S. THOMAS (1976): The tasseled Cap - A Graphic Description of the Spectral-Temporal Development of Agricultural Crops as Seen by LANDSAT. *Proceedings of the Symposium on Machine Processing of Remotely Sensed Data*.
- KAYE, J.P., QUEMADA, M. (2017): Using cover crops to mitigate and adapt to climate change. A review. *Agron. Sustain. Dev.* 37, 4. <https://doi.org/10.1007/s13593-016-0410-x>.
- KOUDAHE, K., ALLEN, S.C., DJAMAN, K. (2022): Critical review of the impact of cover crops on soil properties. *Int. Soil Water Conserv. Res.* 10, 343-354. <https://doi.org/10.1016/j.iswcr.2022.03.003>.
- Landesamt für Umwelt, Landwirtschaft und Geologie (2010): Zwischenfrüchte. Schriftenreihe des LfULG, Heft 13/2010, Sächsisches Landesamt für Umwelt, Landwirtschaft und Geologie. <https://publikationen.sachsen.de/bdb/artikel/24664>.
- MIAO, J., ZHEN, J., WANG, J., ZHAO, D., JIANG, X., SHEN, Z., GAO, C., WU, G. (2022): Mapping Seasonal Leaf Nutrients of Mangrove with Sentinel-2 Images and XGBoost Method. *Remote Sensing*; 14(15):3679. <https://doi.org/10.3390/rs14153679>.
- NAJEM, S., BAGHDADI, N., BAZZI, H., LALANDE, N., BOUCHET, L. (2024): Detection and mapping of cover crops using Sentinel-1 SAR remote sensing data. In: *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 17, 1446-1461. <https://doi.org/10.1109/JSTARS.2023.3337989>.
- PARLAK, M., ÖZASLAN PARLAK, A. (2010): Measurement of splash erosion in different cover crops. *Turkish Journal of Field Crops*. 15.
- PHIRI, D., SIMWANDA, M., SALEKIN, S., NYIRENDA, V.R., MURAYAMA, Y., RANAGALAGE, M. (2020): Sentinel-2 Data for Land Cover/Use Mapping: A Review. *Remote Sens.* 12, 2291. <https://doi.org/10.3390/rs12142291>.

- ROUSE JR. J., HAAS, R.H., SCHELL J.A., DEERING, D.W. (1974): Monitoring vegetation systems in the Great Plains with ERTS. In: Proceedings of the Third Earth Resources Technology Satellite — 1 Symposium; NASA SP-351.
- Sächsisches Staatsministerium für Energie, Klimaschutz, Umwelt und Landwirtschaft (SMEKUL) (2024): „Anbau von Zwischenfrüchten und Untersaaten.“ Landwirtschaft Sachsen. Abgerufen am 25. November 2024. <https://www.landwirtschaft.sachsen.de/anbau-von-zwischenfruechten-und-untersaaten-37212.html>.
- Sächsisches Staatsministerium für Energie, Klimaschutz, Umwelt und Landwirtschaft (SMEKUL) (2024): Anbau von Zwischenfrüchten und Untersaaten. Abgerufen am 09.12.2024, von <https://www.landwirtschaft.sachsen.de/anbau-von-zwischenfruechten-und-untersaaten-37212.html>.
- SCAVO, A., FONTANAZZA, S., RESTUCCIA, A. (2022): The role of cover crops in improving soil fertility and plant nutritional status in temperate climates. A review. *Agron. Sustain. Dev.* 42, 93. <https://doi.org/10.1007/s13593-022-00825-0>.
- SCHULZ, C., HOLTGRAVE, A.-K., KLEINSCHMIT, B. (2021): Large-scale winter catch crop monitoring with Sentinel-2 time series and machine learning—An alternative to on-site controls? In: *Computers and Electronics in Agriculture*, 186. <https://doi.org/10.1016/j.compag.2021.106173>.
- SEITZ, D., FISCHER, L.M., DECHOW, R. (2023): The potential of cover crops to increase soil organic carbon storage in German croplands. *Plant Soil*, 488, 157–173. <https://doi.org/10.1007/s11104-022-05438-w>.
- SELVARAJ, S., BARGIEL, D., HTITIOU, A., & GERIGHAUSEN, H. (2024): Analyzing Temporal Characteristics of Winter Catch Crops Using Sentinel-1 Time Series. *Remote Sensing*, 16(19), 3737. <https://doi.org/10.3390/rs16193737>.
- SMIT, B., JANSSENS, B., HAAGSMA, W., HENNEN, W., ADRADOS, J. L., KATHAGE, J., DOMÍNGUEZ, I. P. (2019): Adoption of cover crops for climate change mitigation in the EU, EUR 29863 EN, Publications Office of the European Union, Luxembourg, ISBN 978-92-76-11312-6. <https://doi.org/10.2760/638382, JRC116730>.
- SNEVAJS, H., CHARVAT, K., ONCKELET, V., KVAPIL, J., ZADRAZIL, F., KUBICKOVA, H., SEIDLOVA, J., BATRLOVA, I. (2022): Crop Detection Using Time Series of Sentinel-2 and Sentinel-1 and Existing Land Parcel Information Systems. *Remote Sensing*, 14(5), 1095. <https://doi.org/10.3390/rs14051095>.
- Statistisches Bundesamt (DeStatis) (2024): Anbaufläche von Zwischenfrüchten. Abgerufen am 09.12.2024, von <https://www.destatis.de/DE/Themen/Branchen-Unternehmen/Landwirtschaft-Forstwirtschaft-Fischerei/Feldfruechte-Gruenland/Tabellen/zwischenfruechte.html>.
- TONITTO C., DAVID M. B., DRINKWATER L. E. (2006): Replacing bare fallows with cover crops in fertilizer-intensive cropping systems: a meta-analysis of crop yield and N dynamics. *Agric Ecosyst Environ* 112:58–72. <https://doi.org/10.1016/j.agee.2005.07.003>.

- VREUGDENHIL M, WAGNER W, BAUER-MARSCHALLINGER B, PFEIL I, TEUBNER I, RÜDIGER C, STRAUSS P. (2018): Sensitivity of Sentinel-1 Backscatter to Vegetation Dynamics: An Austrian Case Study. *Remote Sensing*, 10(9):1396. <https://doi.org/10.3390/rs10091396>.
- XUE, J., SU, B. (2017): Significant Remote Sensing Vegetation Indices: A Review of Developments and Applications, *Journal of Sensors*, 1353691, 17 pages. <https://doi.org/10.1155/2017/1353691>.
- ZHAO, Q., YU, L., LI, X., PENG, D., ZHANG, Y., & GONG, P. (2021): Progress and Trends in the Application of Google Earth and Google Earth Engine. *Remote Sensing*, 13(18), 3778. <https://doi.org/10.3390/rs13183778>.

Herausgeber

Sächsisches Landesamt für Umwelt, Landwirtschaft und Geologie (LfULG)
Pillnitzer Platz 3, 01326 Dresden
Telefon: + 49 351 2612-0; Telefax: + 49 351 2612-1099
E- Mail: Poststelle@lfulg.sachsen.de
www.lfulg.sachsen.de

Autor

Prof. Dr. Claas Nendel, Dr. Gohar Ghazaryan, Kassandra Jensch, Ronja Kelch
Leibniz-Zentrum für Agrarlandschaftsforschung (ZALF) e.V.

Redaktion

Sebastian Goihl
Abteilung 2, Referat 22
Pillnitzer Platz 3, 01326 Dresden Pillnitz
Telefon: + 49 351 2612-2202
E-Mail: sebastian.goihl@lfulg.sachsen.de

Bildnachweis

Leibniz-Zentrum für Agrarlandschaftsforschung (ZALF) e.V..

Redaktionsschluss

07.08.2025

ISSN

1867-2868

Bestellservice

Die Broschüre steht nicht als Printmedium zur Verfügung, kann aber als PDF-Datei heruntergeladen werden aus der Publikationsdatenbank des Freistaates Sachsen (<https://publikationen.sachsen.de>).

Hinweis

Diese Publikation wird im Rahmen der Öffentlichkeitsarbeit vom LfULG (Geschäftsbereich des SMUL) kostenlos herausgegeben. Sie ist nicht zum Verkauf bestimmt und darf nicht zur Wahlwerbung politischer Parteien oder Gruppen eingesetzt werden.

Diese Maßnahme wird mitfinanziert durch Steuermittel auf der Grundlage des vom Sächsischen Landtag beschlossenen Haushaltes.

Täglich für ein gutes Leben.

www.lfulg.sachsen.de