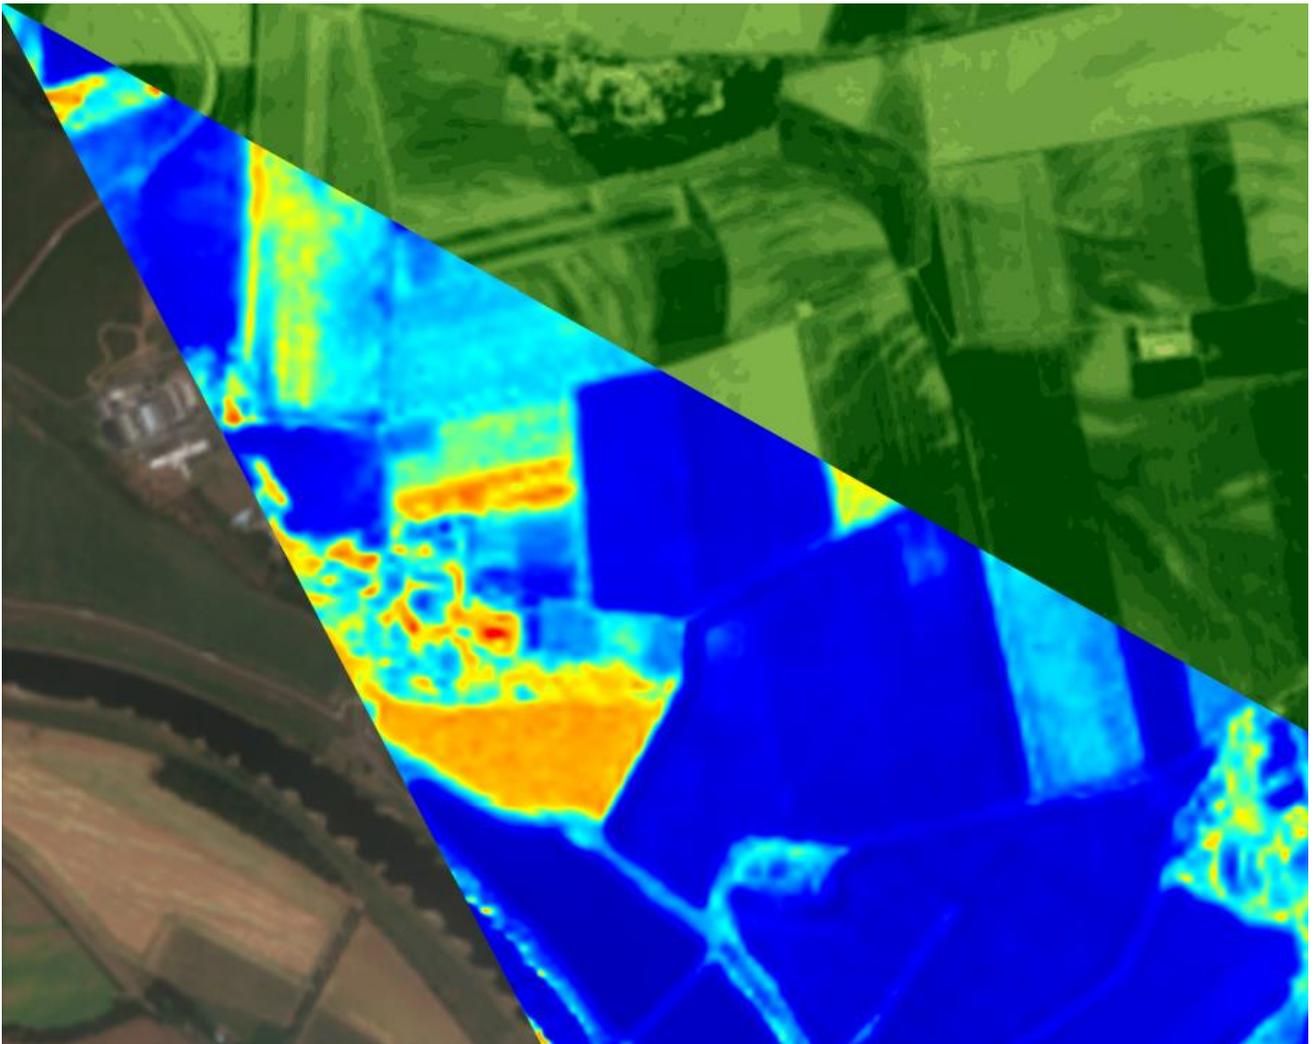


Fachinformation

Fernerkundung und Landwirtschaft



Wasserrahmenrichtlinie und Landwirtschaft – Fernerkundungsgestütztes Monitoring zum Umsetzungsstand - Machbarkeitsstudie

Dr.-Ing. Kian Pakzad, EFTAS Fernerkundung Technologietransfer GmbH, Oststraße 2, 48145 Münster;
Dr. rer. nat. Nils Wolf, EFTAS Fernerkundung Technologietransfer GmbH, Oststraße 2, 48145 Münster

Inhaltsverzeichnis

1	Aufgabenstellung	8
1.1	Zielstellung	8
1.2	Aktueller Kenntnisstand und Forschungsbedarf	8
1.3	Ausschreibungsgegenstand	8
1.4	Verwendete Zielobjekte	10
1.5	Zentrale Fragen der Machbarkeitsstudie	11
2	Datenbeschaffung und Vorprozessierung	13
2.1	Sentinel-1	13
2.2	Sentinel-2	13
2.3	Datacube	13
2.4	Referenzdaten	15
3	Stand der Technik	17
3.1	Zwischenfrüchte und Winterkulturen	17
3.2	Konservierende Bodenbearbeitung und Umbruch	17
3.3	Stoppel, Mulchauflage	18
4	Visuelle Überprüfung der Identifizierbarkeit der Zielobjekte	20
4.1	Zwischenfrüchte	20
4.2	Konservierende Bodenbearbeitung	25
4.3	Stoppel	27
4.4	Mulchauflage	28
5	Automatische Klassifikationsverfahren	30
5.1	Klassifikationsmerkmale	30
5.2	Klassifikationsalgorithmen	31
5.3	Kreuzvalidierung	32
5.4	Ergebnisse	33
5.5	Merkmalswichtigkeit	36
6	Grundsätzliche Identifizierbarkeit der Zielobjekte	38
6.1	Bezogen auf Zielobjekte	38
6.2	Einflüsse auf Identifizierbarkeit	39
6.2.1	Einfluss der Schlaggeometrie	39
6.2.2	Übertragung der Verfahren auf Gebiete mit unterschiedlichen landschaftsräumlichen Charakteristiken	41
7	Aufbau und technische Randbedingungen eines Monitoringprogramms	42
7.1	Modellaufbau	42
7.2	Systemarchitektur	43
7.3	Informationstechnische Infrastruktur zur Datenverarbeitung und notwendige Software	45
7.4	Anfallende Datenmengen	46
8	Zusammenfassung	47
	Literaturverzeichnis	48

Abbildungsverzeichnis

Abbildung 1: Prüfschema für den operationellen Ansatz (Quelle: LfULG).	11
Abbildung 2: Übersicht des Untersuchungsgebietes im Umkreis des Lehr- und Versuchsguts Köllitsch, Gemeinde Arzberg im Landkreis Nordsachsen in Sachsen. Schläge mit verfügbarer Referenzinformation bzgl. der Anwendung stoffeintragsmindernder Maßnahmen der Landbewirtschaftung sowie Bewirtschaftungscharakteristiken bedeckter Ackerflächen sind gelb umrandet.	15
Abbildung 3: Schematischer Verlauf von Sentinel-2 basiertem Normalized Difference Vegetation Index (NDVI) und Sentinel-1 basierter Kohärenz bei Mahden im Mai und Juni.	18
Abbildung 4: Vergleich der NDVI-Zeitreihen von Zwischenfrüchten (Mittelung über sämtliche Schläge des Untersuchungsgebietes; Standardabweichung in blauer Schattierung).	21
Abbildung 5: Darstellung der Entwicklung einer Zwischenfrucht (Schlag 1132-11324, Erntejahr 2018) anhand einer Zeitreihe von Sentinel-2 Echtfarbenkompositen. Sichtbar ist das mutmaßliche Abfrieren der Zwischenfrucht zwischen Januar und März 2018. Die erste Bodenbearbeitung (Saatfurche) erfolgte am 29.03.2018. Saatmischung des Zwischenfruchtanbaus: "Viterra Bodengare" (Blaue Bitterlupine, Sommerwicke, Sommerfuttererbse, Alexandrinerklee, Persischer Klee, Phazelia, Sonnenblumen).....	22
Abbildung 6: NDVI (Mittelwert und Standardabweichung) im Erntejahr 2018. In der Klasse "Winterkultur" inbegriffen sind neben Wintergetreide auch Winterraps, Feldfutter und Selbstbegrünung.	23
Abbildung 7: NDVI (Mittelwert und Standardabweichung) im Erntejahr 2019. In der Klasse "Winterkultur" inbegriffen sind neben Wintergetreide auch Winterraps, Feldfutter und Selbstbegrünung.	23
Abbildung 8: NDVI (Mittelwert und Standardabweichung) im Erntejahr 2020. In der Klasse "Winterkultur" inbegriffen sind neben Wintergetreide auch Winterraps, Feldfutter und Selbstbegrünung.	24
Abbildung 9: NDVI (Mittelwert und Standardabweichung) im Erntejahr 2021. In der Klasse "Winterkultur" inbegriffen sind neben Wintergetreide auch Winterraps, Feldfutter und Selbstbegrünung	24
Abbildung 10: Entwicklung einer Ackerfläche mit konservierender Bodenbearbeitung (Maschineneinsätze zur Bodenbearbeitung am 29.07.2019, 16.08.2019, 28.10.2019; Aussaat der Hauptkultur Erbse am 30.10.2019) und weitestgehend unbedecktem Boden (keine bis geringe Begrünung über den Herbst/Winter). Exemplarische Darstellung eines ausgewählten Schlages anhand einer Zeitreihe von Sentinel-2 Echtfarbenkompositen.	25
Abbildung 11: NDVI-Verlauf einer Ackerfläche mit konservierender Bodenbearbeitung (Maschineneinsätze zur Bodenbearbeitung am 29.07.2019, 16.08.2019, 28.10.2019; Aussaat der Hauptkultur Erbse am 30.10.2019) und weitestgehend unbedecktem Boden (keine bis geringe Begrünung über den Herbst/Winter).	26
Abbildung 12: Ackerschlag vor (links) und nach (rechts) der wendenden Bodenbearbeitung (Umbruch/Winterfurche) am 02.11.2017.	27
Abbildung 13: Entwicklung einer Stoppelbrache (Schlag 1223-1, Erntejahr 2020) über den Zeitraum 07.2019 bis 04.2020 (Bildaten: Sentinel-2 Echtfarbenkomposite).	28
Abbildung 14: Sentinel-2 basierte Indizes über die Entwicklung einer Stoppelbrache (Schlag 1223-1, Erntejahr 2020).	28
Abbildung 15: Verlauf der Sentinel-2 basierten Indexwerte Mulchen am 31.07.2018 (Maschineneinsatz Case MXM 140 TO-E 521, MC Connel SR 620)	29
Abbildung 16: Schematische Darstellung der LSTM-Netzwerkarchitektur. Input-, Zwischen- und Ausgabeschichten sind vertikal angeordnet. Die Verknüpfung der Einzelzeitpunkte der Zeitreihen ist über die horizontale Achse dargestellt.	32

Abbildung 17: Wichtigkeit ("Mean Decrease Impurity") der Klassifikationsmerkmale. Die Zeitstempel (z.B. "01. Mai JJJJ") bezeichnen die linke Bande eines halbmonatlichen Zeitintervalls; "JJJJ" = Jahr der Ernte, "JJJJ-1" = Vorjahr.....	36
Abbildung 18: Wichtigkeit ("Mean Decrease Impurity") der Klassifikationsmerkmale gruppiert nach Zeitpunkten (d.h. Aufsummierung der Merkmalswichtigkeit einzelner Kanäle/Indizes per Zeitpunkt).	37
Abbildung 19: Wichtigkeit ("Mean Decrease Impurity") der Klassifikationsmerkmale gruppiert nach Kanälen/Indizes (d.h. Aufsummierung der Merkmalswichtigkeit einzelner Zeitpunkte je Kanal/Index).	37
Abbildung 20: Sentinel-2-Szene in 20 m Rasterauflösung mit überlagerter Schlaggeometrie (weiß) sowie 10 m Innenpufferung (gelb) und 20 m Innenpufferung (pink).	40
Abbildung 21: Darstellung originaler Schläge (weißer Umriss) und der 20 m nach innen gepufferten, potenziell auswertbaren Fläche (pink). Die innengepufferten Flächengrößen je Schlag sind in Hektar angegeben.....	41
Abbildung 22: Vorschlag für die Struktur eines Monitoringprogramms	43
Abbildung 23: Systemarchitektur Anlernen des Klassifikators	44
Abbildung 24: Systemarchitektur Monitoring	45

Tabellenverzeichnis

Tabelle 1: Identifikationszeiträume und pflanzenbauliche Charakteristiken der Zielobjekte	9
Tabelle 2: Zielobjekte.....	10
Tabelle 3: Übersicht der Bänder von Sentinel-1 und Sentinel-2 sowie abgeleiteter Indizes.....	14
Tabelle 4: Anzahl der Fälle je Zielklasse und Erntejahr. *Hinweis: die Fälle der Klasse WK können gleichermaßen als Fälle der Klasse kBB betrachtet werden, da ausschließlich konservierende Bodenbearbeitung angewendet wurde und ein Umbruch ausgeschlossen werden kann.	16
Tabelle 5: Merkmalssets und zugehörige Prädiktoren (Kanäle/Indizes).	31
Tabelle 6: Pixel-basierte Klassifikationsgenauigkeit.....	34
Tabelle 7: Schlag-basierte Klassifikationsgenauigkeit.....	35
Tabelle 8: Beispielkomponenten für eine Workstation	46
Tabelle 9: Anfallende Datenmengen	46

Abkürzungsverzeichnis

BB	Bodenbearbeitung
CRC	Crop Residue Cover
FE	Fernerkundung
GRD	Ground Range Detected
IW	Interferometric Wide
kBB	Konservierende Bodenbearbeitung ohne ZF, Stoppel, Mulch, Umbruch, WK
kBB+	Konservierende Bodenbearbeitung mit Stoppel, mit Mulch, ohne ZF, Umbruch, WK
LSTM	Long Short Term Memory
NDRI	Normalized Difference Residue Index
NDTI	Normalized Difference Tillage Index
NDVI	Normalized Difference Vegetation Index
OA	Overall Accuracy
PSRI	Plant Senescence Reflectance Index
RMSE	Root Mean Square Error
RVI	Radar Vegetation Index
SAR	Synthetic Aperture Radar
SWIR	Shortwave Infrared
VH	Vertical Horizontal
VV	Vertical Vertical
WK	Winterkultur
WRRL	Wasserrahmenrichtlinie
ZF	Zwischenfrucht

1 Aufgabenstellung

1.1 Zielstellung

Ziel der Studie ist die Ermittlung von Verfahren, mit denen sich stoffeintragsmindernde Maßnahmen der Landbewirtschaftung sowie bestimmte Bewirtschaftungscharakteristiken bedeckter Ackerflächen mittels Fernerkundung identifizieren lassen. Zusätzlich sollen die Rahmenbedingungen für den Aufbau eines Monitoringprogramms zur kontinuierlichen Identifikation der landwirtschaftlichen Maßnahmen untersucht werden.

1.2 Aktueller Kenntnisstand und Forschungsbedarf

Der tatsächliche Umfang an umgesetzten stoffeintragsmindernden Bewirtschaftungsverfahren durch die Landwirtschaft lässt sich nur bedingt aus den Daten der Agrarförderung ableiten. Einerseits umfasst das Förderprogramm nur zum Teil stoffeintragsmindernde Bewirtschaftungsverfahren, andererseits ist das Förderprogramm zeitlich variabel. Darüber hinaus setzt die landwirtschaftliche Praxis Maßnahmen ohne Förderung, d. h. auf freiwilliger Basis um, was ein Spiegelbild der Nachhaltigkeit der Agrarförderung und Beratung landwirtschaftlicher Betriebe ist.

Für die Abbildung des Umsetzungsstandes der Wasserrahmenrichtlinie (WRRL) im Bereich Landwirtschaft und für die Verbesserung der Identifikation von stofflichen Belastungsquellen sowie der gebietsbezogenen Abschätzung zur Trendentwicklung von Stoffbelastungen in Einzugsgebieten von Wasserkörpern mit hoher landwirtschaftlicher Prägung werden flächendeckende Informationen über die Umsetzung bestimmter stoffeintragsmindernder Bewirtschaftungsverfahren für die Bewirtschaftungszeiträume der WRRL benötigt.

Die aus Fernerkundungsdaten abzuleitenden Charakteristiken der Landbedeckung (Zielobjekte) sind die ackerbauliche Umsetzung von Maßnahmen, die zur Minderung des diffusen Nitrataustrages aus Ackerflächen und zur Reduktion von Bodenerosion infolge von Starkniederschlag beitragen. Dazu zählen (1) der Zwischenfruchtanbau, (2) die Umsetzung von konservierender Bodenbearbeitung, (3) die überwinternde Stoppel und (4) die Mulchbedeckung.

Forschungsbedarf besteht darin, geeignete und erprobte Verfahren zur Extraktion der Zielobjekte unter Nutzung von Fernerkundungsdaten zu identifizieren. Die Datengrundlage sollen die Sentinel-1 (Radar) und Sentinel-2 (optische Sensoren) Missionen des europäischen Copernicus-Programms bilden. Eventuell können auch weitere kostenfreie Datenquellen herangezogen werden, z. B. Landsat, sollte sich dies als zielführend erweisen.

1.3 Untersuchungsgegenstand

Erstellung einer Machbarkeitsstudie zur Prüfung, ob die Zielobjekte

1. Zwischenfruchtanbau,
2. Umsetzung von konservierender Bodenbearbeitung,
3. Überwinternde Stoppel und
4. Mulchbedeckung

mit Hilfe von Fernerkundungsdaten grundsätzlich identifiziert werden können.

Für die Studie stehen siebenjährige (Zeitraum von 2014 bis 2020) Referenzdaten vom Lehr- und Versuchsgut Köllitsch (Nordsachsen) zur Verfügung. Die Referenzdaten beinhalten ca. 40 Schläge (unterschiedlich geformt und bewirtschaftet) mit einer Flächengröße von ca. 560 ha sowie detaillierte Informationen zur Bewirtschaftung (Frucht, Bodenbearbeitung). Darüber hinaus können für die Studie sächsische Ackerland-Feldblöcke (Lage, keine Bewirtschaftungsinformationen) herangezogen werden.

Die ackerbauliche Umsetzung der Zielobjekte soll differenziert nach inner- bzw. zwischenjährlichen Zeiträumen als Identifikationszeitraum betrachtet werden. Die jeweiligen Identifikationszeiträume sind in Tabelle 1 zusammen mit pflanzenbaulichen Charakteristiken zusammengestellt.

In der Machbarkeitsstudie soll untersucht werden, welche mathematischen beziehungsweise technischen Verfahren zur Identifikation der Zielobjekte geeignet sind, welche Daten für diese Verfahren benötigt werden und mit welchen Einschränkungen bei der Anwendung und Übertragung dieser Verfahren auf Gebiete mit unterschiedlichen landschaftsräumlichen Charakteristiken zu rechnen ist.

Der Fokus soll insbesondere auf der Prüfung liegen, ob und in welcher Form verfahrenstechnisch bedeckte von unbedeckten Ackerflächen unterscheidbar sind. Weiterhin ist zu evaluieren, inwieweit die Bewirtschaftungscharakteristik bedeckter Ackerflächen differenzierbar ist und welchen Einfluss Winterungen potentiell auf die Identifikation von Zwischenfrüchten nehmen.

Tabelle 1: Identifikationszeiträume und pflanzenbauliche Charakteristiken der Zielobjekte

Zielobjekt	Identifikationszeitraum/pflanzenbauliche Charakteristiken
(1) Zwischenfruchtanbau	- Zwischenfrüchte überwintert, z. B. Winterroggen, Identifikationszeitraum: Aussaat nach Ernte der Vorkultur ab Juli bis Mitte September, bis März/April auf Schlag - Zwischenfrüchte abfrierend, z. B. Phacelia, Identifikationszeitraum: Aussaat nach Ernte der Vorkultur ab Juli bis Mitte September, bis März/April auf Schlag, keine Ernte, kontinuierliche Zersetzung nach starkem Frost
(2) Umsetzung von konservierender Bodenbearbeitung	nicht wendende Bodenbearbeitung mit Grubber/Scheibenegge (ohne Schollenaufwurf), Bearbeitungstiefe des Bodens 15 bis 20 cm, 5 bis 8 cm möglich Identifikationszeitraum: Anwendung der Maßnahme (1) nach Ernte ab Juli bis September, (2) vor Aussaat März bis Mai
(3) überwinternde Stoppel	- Stoppel als Ernterest (Halm, Spross) über den Winter Identifikationszeitraum: ab Ernte im Juli bis zur Folgekultur (Sommerung) März bis Mai - Anwendung grundsätzlich bei jeder Kulturart möglich
(4) Mulchbedeckung	- Stoppel als Ernterest (Halm, Spross) in Kombination mit Mulch (abgeerntete/abgestorbene Biomasse der Vorkultur) Identifikationszeitraum: ab Ernte im Juli bis zur Folgekultur, Unterscheidung der Folgekultur: (1) Winterung und (2) Sommerung - Anwendung grundsätzlich bei jeder Kulturart möglich - Bedeckungsgrad abhängig von Bodenbearbeitungstiefe und –häufigkeit, Mulch unterliegt Abbau

Die Machbarkeitsstudie soll auch Aussagen über den Einfluss der Schlaggeometrie (Größe, Form und Komplexitätsgrad) auf die Verlässlichkeit der identifizierten ackerbaulichen Maßnahmen liefern.

Werden geeignete Verfahren für die Problemstellung ermittelt, schließt die Studie mit einer Einschätzung dazu, welche Schritte für den Aufbau eines Monitoringprogramms nötig sind und welche Zielobjekte kontinuierlich in der Fläche identifiziert werden können.

Eingegangen werden soll dabei insbesondere auf die notwendigen technischen Rahmenbedingungen, d. h. Modellaufbau, informationstechnische Infrastruktur zur Datenverarbeitung, Bausteine der Prozessierungsumgebung, notwendige Software sowie die Abschätzung der anfallenden Datenmengen (Mengengerüst), gegliedert nach Rohdaten, Zwischenprodukten und Ergebnisdaten. Daneben sind die finanziellen Rahmenbedingungen zu schätzen, d. h. plausible und aufgeschlüsselte Kostenschätzung für die nötigen Schritte zum Aufbau des Monitoringprogramms im Falle einer praktischen Umsetzung.

1.4 Verwendete Zielobjekte

Ausgehend von der Liste der Zielobjekte aus der Leistungsbeschreibung wurde im Projektverlauf der in Tabelle 2 dargestellte Klassenkatalog definiert. Die dort gelisteten Zielklassen sind in Bezug auf die im Identifikationszeitraum (Herbst, Winter) vorzunehmende Einschätzung eindeutig und vollständig. Zum besseren Verständnis sind in Abbildung 1 die Begrifflichkeiten im Rahmen eines operationellen Prüfschemas dargestellt.

Tabelle 2: Zielobjekte.

Zielklasse (Abkürzung)	Beschreibung	Entsprechung der Benennung im Prüfschema (siehe Abbildung 1)
Konservierende Bodenbearbeitung (kBB)	Konservierende Bodenbearbeitung ohne ZF, Stoppel, Mulch, Umbruch, WK	Konserv. BB
Zwischenfrucht (ZF)	Zwischenfrucht	Zwischenfrucht
Stoppel	Stehende oder gestürzte Stoppel (kein Umbruch)	Überwinternde Stoppel
Mulch	Mulchauflage (kein Umbruch)	Pflanzenreste
Umbruch	Umbruch/Winterfurche (wendende Bodenbearbeitung)	Winterfurche, wendende BB
Winterkultur (WK)	Winterkulturen (bzw. Winterung); umfasst sämtliche Begrünungen über den Winter, inkl. Wintergetreide, Winterraps, Selbstbegrünung, Feldfutter, exkl. Zwischenfrucht	Wintergetreide, Winterraps, Selbstbegrünung, Feldfutter

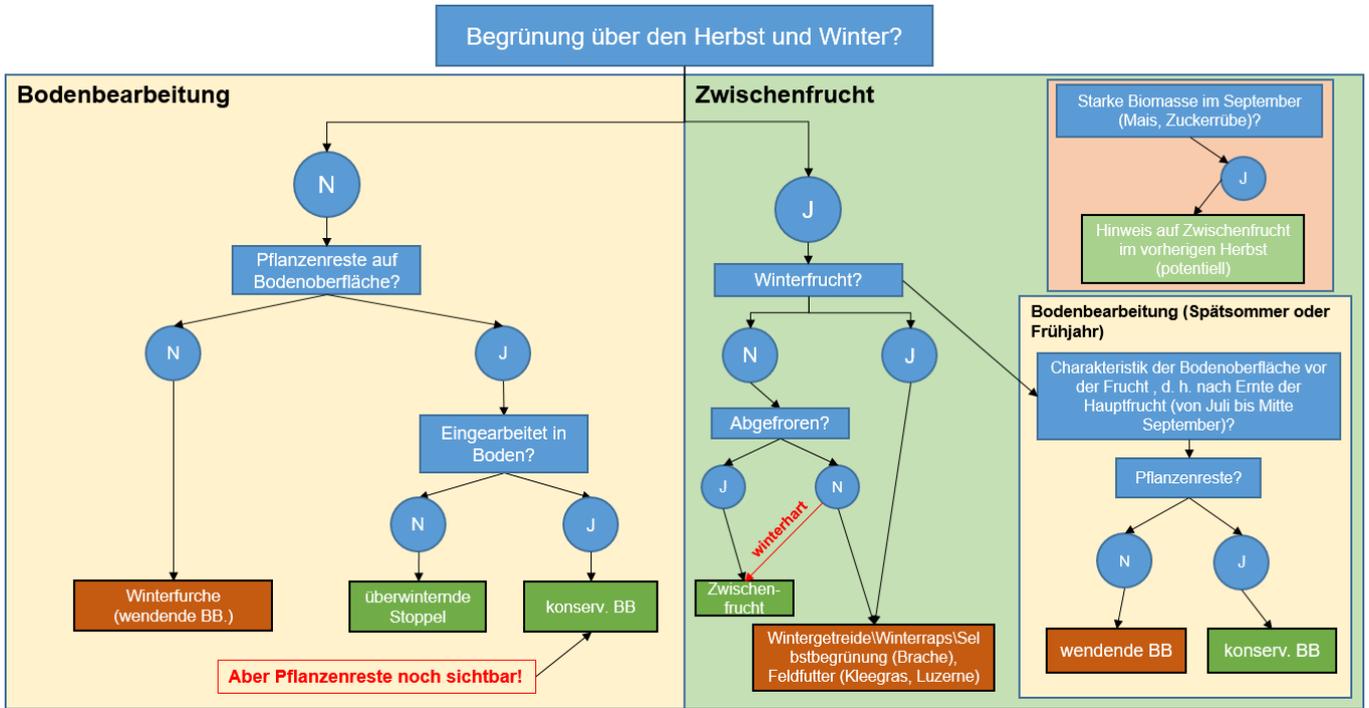


Abbildung 1: Prüfschema für den operationellen Ansatz (Quelle: LfULG).

1.5 Zentrale Fragen der Machbarkeitsstudie

Im Verlauf des Projektes wurden acht zentrale Fragen definiert, die es im Verlauf des Projektes zu beantworten galt. Diese Fragen sind im Folgenden dargestellt und sollen als roter Faden für diesen Bericht dienen. Daher ist zu jeder Frage beschrieben, wo im Bericht dieses Thema behandelt wird und wo die Antworten darauf zu finden sind.

1. Sind die Zielobjekte (1) Zwischenfruchtanbau, (2) Umsetzung von konservierender Bodenbearbeitung, (3) überwinternde Stoppel und (4) Mulchbedeckung anhand von FE-Daten grundsätzlich identifizierbar?
Dazu wurden verschiedene Untersuchungen in den Kapiteln 0, 0 und 0 durchgeführt. Zusammenfassend wird diese Frage in Abschnitt 6.1 beantwortet.
2. Welche Verfahren eignen sich zur Identifikation der Zielobjekte?
Diese Frage wird im Abschnitt 6.1 und im Kapitel 5 beleuchtet.
3. Welche Datenanforderungen stellen die Verfahren?
Näheres hierzu findet sich in Kapitel 5.
4. Gibt es Einschränkungen bei der Anwendung der Verfahren auf Gebiete mit unterschiedlichen naturräumlichen Charakteristiken?
Dieser Punkt wird in Abschnitt 6.2.2 besprochen.
5. Sind verfahrenstechnisch bedeckte von unbedeckten Ackerflächen unterscheidbar?
Dies ist im Abschnitt 6.1 dargestellt.
6. Inwieweit ist die Bewirtschaftungscharakteristik bedeckter Ackerflächen differenzierbar? Winterung vs. Zwischenfrucht?
Dies ist in Abschnitt 6.1 dargestellt.
7. Welchen Einfluss hat die Schlaggeometrie (Form und Komplexität) auf die Verlässlichkeit der identifizierten Merkmale?
Dies wird in Abschnitt 6.2.1 untersucht
8. Welche Schritte (technische Rahmenbedingungen, finanzielle Aufwände) sind erforderlich, um die Zielobjekte kontinuierlich in der Fläche identifizieren zu können (Monitoringprogramm)?
Dies wird in Kapitel 7 dargestellt.

2 Datenbeschaffung und Vorprozessierung

2.1 Sentinel-1

Sentinel-1 ist der erste Satellit der Satellitenkonstellation des Copernicus-Programms der Europäischen Raumfahrtagentur. Diese Mission besteht aus einer Konstellation von zwei Satelliten, Sentinel-1A und Sentinel-1B, die sich dieselbe Bahnebene teilen. Sie tragen ein C-Band-Radarinstrument mit synthetischer Apertur, das bei jedem Wetter, bei Tag und bei Nacht Daten sammelt. Dieses Instrument hat eine räumliche Auflösung von bis zu 5 m und generiert Daten mit einer Ausdehnung von bis zu 400 km. Die Konstellation befindet sich auf einer sonnensynchronen, nahezu polaren (98,18°) Umlaufbahn. Die Umlaufbahn hat einen Wiederholungszyklus von 12 Tagen. Der erste Satellit, Sentinel-1A, startete am 3. April 2014, Sentinel-1B wurde am 25. April 2016 gestartet.

Im Rahmen der vorliegenden Studie wurden Sentinel-1 SAR Interferometric Wide (IW) swath Daten, in der Prozessierungsstufe Ground Range Detected (GRD), mit den Polarisierungen VV (Single co-polarization, vertical transmit/vertical receive) und VH (Dual-band cross-polarization, vertical transmit/horizontal receive) verwendet. Weitere Vorprozessierungsschritte (durchgeführt mit der Sentinel-1 Toolbox) umfassen die Entfernung des Wärmerauschens, die Radiometrische Kalibrierung, die Geländekorrektur (SRTM-30) und die Logskalierung (Konvertierung zu Dezibel).

2.2 Sentinel-2

Die Raumfahrtmission Sentinel-2, bestehend aus Sentinel-2A und Sentinel-2B, ist ein Paar optischer Erdbeobachtungssatelliten in einem sonnensynchronen Erdorbit. Sie gehören wie die Satellitenpaare Sentinel-1 und Sentinel-3 zum Copernicus-Programm der Europäischen Kommission und Europäischen Weltraum Organisation ESA für Global Monitoring for Environment and Security und sind Teil der Sentinel-Satellitenreihe. Sentinel-2 soll Daten für den Klimaschutz, zur Landüberwachung sowie zum Katastrophen- und Krisenmanagement auf der Erde liefern. Die Bilder werden in räumlichen Auflösungen von 10 m oder 20 m pro Pixel in zehn Spektralkanälen im Wellenlängenbereich von 490 bis 2200 nm aufgenommen. Zusätzlich gibt es drei Spektralkanäle mit 60 m räumlicher Auflösung zur Messung der atmosphärischen Eigenschaften (aus <https://de.wikipedia.org/wiki/Sentinel-2>). Sentinel-2A nahm Mitte 2015 seine Arbeit auf, Sentinel-2B Mitte 2017. Das Satellitenpaar liefert jedoch erst seit Mitte 2017 hochfrequent Bilder der Erdoberfläche.

Im Rahmen dieses Projektes wurden alle Sentinel-2-Bänder mit der Auflösung $\leq 20\text{m}$ genutzt, wobei die höher aufgelösten Bänder für eine einheitliche Bearbeitung auf 20m herunterskaliert wurden. Zudem wurden die Produkte der Stufe Level 2A verwendet: Bei den Sentinel-2 Level 2A Produkten handelt es sich um kartographisch entzerrte atmosphärenkorrigierte Sentinel-2 Daten (bottom-of-atmosphere reflectance). Hierbei handelt es sich um Ausgangsdaten für einen Großteil der geowissenschaftlichen Analysen. Die von der ESA berechneten Produkte sind über den ständig aktualisierten Datenkatalog von CODE-DE nach Raum, Zeit und weiteren Suchkriterien auffindbar und können vom Nutzer über die Katalog-Anwendung und von Online-Serverplattformen heruntergeladen werden. Sentinel-2 Level 2A Produkte können aber auch dediziert vom Nutzer selbst aus Sentinel-2 Daten beispielsweise mit dem auf CODE-DE bereitgestellten Sen2Cor-Prozessor generiert werden (aus <https://www.d-copernicus.de>).

2.3 Datacube

Zur weiteren Aufbereitung und synergetischen Auswertung wurden die Sentinel-1 und Sentinel-2-Daten in einen Datacube (Datenwürfel) überführt. Der Datacube ist eine mehrdimensionale ("n-D") Anordnung von Werten in Arrays

und unterstützt datenintensive Anwendungskontexte, wie die Verarbeitung räumlich und zeitlich hochauflösender Zeitreihen von Erdbeobachtungssatelliten, in denen die Arrays oftmals deutlich größer sind als der Hauptspeicher des Host-Computers.

Der aufgesetzte Datacube erfüllt darüber hinaus spezifische Funktionen zur Verarbeitung und Auswertung multisensoraler Fernerkundungsdaten, wie das Einlesen der in Bezug auf die Datenformate und Metadaten verschiedenen strukturierten Sensordaten. Zudem ist ein Algorithmus zur optimierten Maskierung von Wolken, Wolkenschatten, Schneebedeckung und sonstigen unerwünschten Artefakten implementiert, um die optischen Sentinel-2-Daten für nachfolgende Analysen aufzubereiten. Eine weitere Funktion ist die Generierung von synthetischen Zeitscheibenmosaiken (z.B. 6-tägige oder halbmonatliche Intervalle) durch Mittelung vorliegender Sensorwerte je Zeitintervall sowie die (lineare) Interpolation im Falle fehlender Werte (zumeist bedingt durch Bewölkung). Dies dient einerseits der weiteren Unterdrückung szenenspezifischer Artefakte sowie Fehlern der Atmosphärenkorrektur und Wolkenmaskierung. Andererseits können auf diese Weise irregulär bzw. verschieden getaktete Zeitreihen (bedingt durch unterschiedliche Orbits und Wiederkehrzeiten) von Sentinel-1 und Sentinel-2 in ein reguläres, zeitliches Grid überführt werden. Eine weitere Aufgabe des Datacubes ist die räumliche Projektion sämtlicher Eingangsdaten (Satellitendaten, Vektor-Referenzdaten) auf ein einheitliches Koordinatenreferenzsystem und Rastergitter.

Tabelle 3: Übersicht der Bänder von Sentinel-1 und Sentinel-2 sowie abgeleiteter Indizes.

Sensor	Band/Index	Beschreibung
Sentinel-2	B02	Band 02 (Wellenlänge 496 nm)
Sentinel-2	B03	Band 03 (Wellenlänge 560 nm)
Sentinel-2	B04	Band 04 (Wellenlänge 664 nm)
Sentinel-2	B05	Band 05 (Wellenlänge 703 nm)
Sentinel-2	B06	Band 06 (Wellenlänge 740 nm)
Sentinel-2	B07	Band 07 (Wellenlänge 782 nm)
Sentinel-2	B8A	Band 8A (Wellenlänge 864 nm)
Sentinel-2	B11	Band 11 (Wellenlänge 1613 nm)
Sentinel-2	B12	Band 12 (Wellenlänge 2202 nm)
Sentinel-1	VV	C-Band Polarisation vertikal-vertikal (Send./Empf.)
Sentinel-1	VH	C-Band Polarisation vertikal-horizont. (Send./Empf.)
Sentinel-2	NDVI	Normalized Difference Vegetation Index: $(B8A - B04) / (B8A + B04)$
Sentinel-2	NDWI	Normalized Difference Water Index: $(B8A - B11) / (B8A + B11)$
Sentinel-2	PSRI	Plant Senescence Reflectance Index: $(B04 - B02) / B06$
Sentinel-2	3BI2	3-Band Index II: $(B02 - B04) / (B02 - B12)$
Sentinel-2	NDTI	Normalized Difference Tillage Index: $(B11 - B12) / (B11 + B12)$
Sentinel-2	NDRI	Normalized Difference Residue Index: $(B04 - B12) / (B04 + B12)$
Sentinel-1	VH-VV	Polarisation Difference: $VH - VV$
Sentinel-1	RVI	Radar Vegetation Index: $(4 * VH) / (VH + VV)$

Sentinel-1 und Sentinel-2 decken das Untersuchungsgebiet mit jeweils mehreren Orbits ab. Unterschiedliche Orbits haben verschiedene Blickwinkel des Sensors auf das Untersuchungsgebiet zur Folge, was insbesondere im Falle von SAR-Daten (hier: Sentinel-1) einen großen Einfluss auf das rückgestreute Signal haben kann. Um diesbezüglich eine Varianz in den Daten auszuschließen, wurde lediglich ein einzelner Orbit (Relative Orbitnummer: 44) für weitere Analysen berücksichtigt. Im Falle der kurzwelligeren (optischen) Sentinel-2-Daten lassen sich solche Effekte der sog. bidirektionalen Reflektanzverteilungsfunktion in Bezug auf die vorliegende Fragestellung vernachlässigen; dementsprechend wurde in diesem Fall keine Selektion der Orbits vorgenommen.

Neben den originären Bändern der Satelliten Sentinel-1 und Sentinel-2 wurde der Datacube um verschiedene Indizes (arithmetische Kombination ausgewählter Bänder) ergänzt. Die Indizes heben im Kontext der Fragestellung spektrale Eigenschaften hervor, indem Bänder - beispielsweise im Bereich kennzeichnender Absorptionsbanden von Chlorophyll, Cellulose oder Wasser - arithmetisch kombiniert werden.

2.4 Referenzdaten

Abbildung 2 zeigt eine Übersicht des Untersuchungsgebietes im Umkreis des Lehr- und Versuchsguts Köllitsch in der Gemeinde Arzberg im Landkreis Nordsachsen in Sachsen. Die Schläge der Erntejahre 2015 bis 2021 sind bzgl. der Zuordnung zu den definierten Zielobjekten und weiterer Information zur Bewirtschaftung (Frucht, Bodenbearbeitung) annotiert.

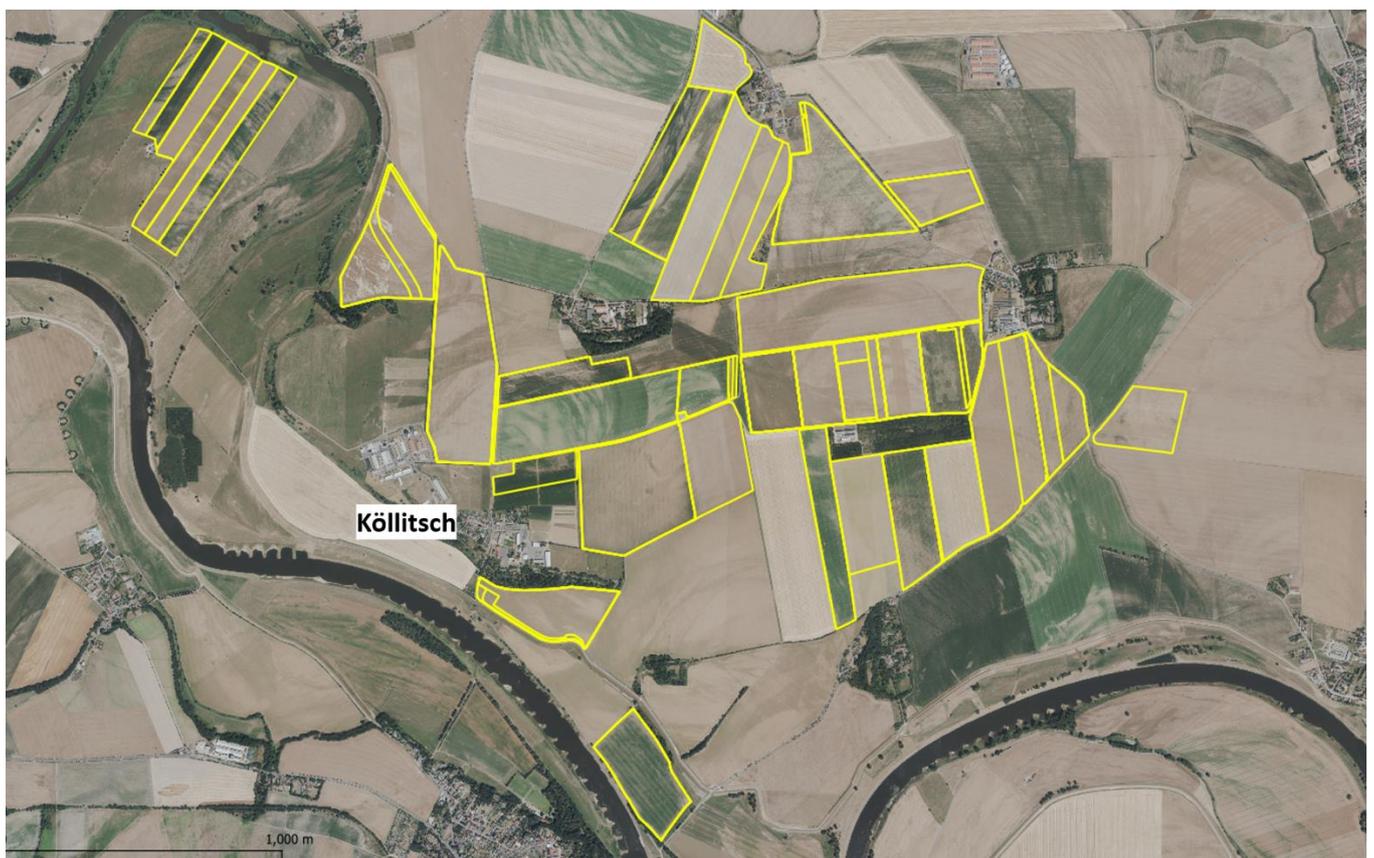


Abbildung 2: Übersicht des Untersuchungsgebietes im Umkreis des Lehr- und Versuchsguts Köllitsch, Gemeinde Arzberg im Landkreis Nordsachsen in Sachsen. Schläge mit verfügbarer Referenzinformation bzgl. der Anwendung stoffeintragsmindernder Maßnahmen der Landwirtschaft sowie Bewirtschaftungscharakteristiken bedeckter Ackerflächen sind gelb umrandet.

Die zahlenmäßige Verfügbarkeit der Zielobjekte je Erntejahr ist in Tabelle 4 dargestellt. Des Weiteren wurden Wetterdaten des Agrarmeteorologischen Messnetzes Sachsen (LfULG-Wetterstation "Köllitsch") bezogen¹, um Temperatur und Niederschlag als Einflussfaktoren auf ackerbauliche Maßnahmen sowie spektrale Eigenschaften der Satellitenbilddaten zu berücksichtigen.

Tabelle 4: Anzahl der Fälle je Zielklasse und Erntejahr. *Hinweis: die Fälle der Klasse WK können gleichermaßen als Fälle der Klasse kBB betrachtet werden, da ausschließlich konservierende Bodenbearbeitung angewendet wurde und ein Umbruch ausgeschlossen werden kann.

Zielklassen	2015	2016	2017	2018	2019	2020	2021	Gesamt
konservierende Bodenbearbeitung (kBB) *						1		1
Mulch	1							1
Stoppel	3	2	3	1		1	1	11
Umbruch			1	1				2
Winterkulturen (WK) *	6	5	6	6	7	6	8	44
Zwischenfrucht (ZF)	4	4	6	8	5	10	8	45
Gesamt	14	11	16	16	12	18	17	104

¹ Quelle: <https://www.landwirtschaft.sachsen.de/Wetter09/asp/inhalt.asp?seite=uebersicht>

3 Stand der Technik

3.1 Zwischenfrüchte und Winterkulturen

Denize et al. (2019) untersuchten den Einsatz von Sentinel-1 und Sentinel-2 Zeitreihen zur Erfassung der ackerbaulichen Nutzung über den Winter. Sie verwendeten überwachte Klassifikationsverfahren (Random Forest, Support Vector Machines) und unterscheiden Winterkultur, Grünland, Zwischenfrucht (z.B. Phaceliae, Senfgras), Pflanzenreste (z.B. Maisstoppel) und offenen Boden. Zwischenfrüchte wurden mit einer Produzentengenauigkeit von 89 % und einer Nutzergenauigkeit von 68 % erfasst. Fehlklassifikationen waren dabei größtenteils auf die Konfusion mit den Klassen Winterkultur und Grünland zurückzuführen.

Ochsenbauer et al. (2019) nutzten Sentinel-2-Daten, um die Möglichkeiten einer fernerkundungsgestützten Erfassung von Intensität und Dauer der Winterbegrünung in Bayern über die Berechnung des Blattflächenindex zu erörtern. Sie schlussfolgerten, dass auf Basis von Sentinel-2 derartige Informationen grundsätzlich abgeleitet werden können. Eine besondere Herausforderung bestand jedoch in der Bewertung einzelner Schläge, da unterschiedliche Kulturarten durch ihr spezifisches Reflexionsverhalten Einfluss auf die Ergebnisse nehmen. Des Weiteren nannten sie die in den Wintermonaten ungünstigen Wolken- und Beleuchtungsverhältnisse (tiefer Sonnenstand, Schattenwurf) sowie Schnee-/Frostereignisse als limitierende Faktoren.

Neben dem Blattflächenindex sind zur Abschätzung der von Bedeckungsgrad und Zustand der Vegetation eine Vielzahl weiterer Vegetationsindizes etabliert, wie beispielsweise der Normalized Difference Vegetation Index (NDVI), der Normalized Difference Water Index (NDWI) oder der Plant Senescence Reflectance Index (PSRI) (Holtgrave et al., 2020). In Projekten der EFTAS finden fernerkundlich ermittelte biophysikalische Parameter wie der Blattflächenindex (Visús et al., 2018) sowie verschiedene Vegetationsindizes in verschiedenen Bereichen des Umweltmonitorings regelmäßige Anwendung.

Zur Klassifizierung von Kulturarten sind neben konventionellen Verfahren wie Random Forest und Support Vector Machines zuletzt vermehrt Deep Learning-Verfahren, im Speziellen Rekurrente Neuronale Netze (RNN) eingesetzt worden, da sich diese Ansätze besonders zur Erkennung von zeitlichen Abhängigkeiten in dichten Zeitreihen eignen (Rußwurm and Korner, 2017). Während unterschiedliche Kulturarten sowie Zwischenfrüchte bei der Auswertung einzelner Szenen/Zeitpunkte ähnliche spektrale Merkmale aufweisen und eine Trennung erschweren, erkennen RNN-Ansätze die aufgrund kulturartenspezifischer Phänologie oder ackerbaulicher Maßnahmen spektral-temporalen Datenmuster. Mit einem sog. Long-Short-Term-Memory-Netzwerk (LSTM) wurde eine Variante eines solchen RNNs bereits im Rahmen von Projektarbeiten bei der EFTAS erfolgreich eingesetzt (Woditsch, 2019). In Anwendung eines Random Forest-Verfahrens werden zudem in laufenden Projekten der EFTAS die Kulturarten (Sommerungen, Winterungen, Zwischenfrüchte) in synergetischer Nutzung von Sentinel-1 und Sentinel-2-Zeitreihen klassifiziert.

3.2 Konservierende Bodenbearbeitung und Umbruch

Zhou et al. (2021) nutzten Sentinel-2-Zeitreihen, um im Kontext des Reis- und Weizenanbaus der nordindischen Flussebene konventionelle Bodenbearbeitung („conventional-tillage“) von schonender Anbaupraxis ohne Bodenbearbeitung („zero-tillage“) zu unterscheiden. Auf Basis eines trainierten Random Forest-Modells konnten die beiden Kategorien mit einer Gesamtgenauigkeit von 75% (Nutzer- und Produzentengenauigkeiten zwischen 74 und 77%) unterschieden werden.

Azzari et al. (2019) untersuchten die Intensität der Bodenbearbeitung im mittleren Norden der USA auf der Basis von Landsat-5/7/8-Daten. Sie setzen ebenfalls ein Random Forest-Verfahren ein und erzielten eine zu oben genannter

Studie vergleichbare Klassifikationsgenauigkeit von 75-79%. Verwendung fanden in dieser Studie auch Sentinel-1-Daten, deren Informationszugewinn jedoch als eher gering eingeschätzt wurde.

Im Rahmen bisheriger Projekte der EFTAS wurden bereits Prüfungen hinsichtlich landwirtschaftlicher Tätigkeit auf Dauergrünland sowie Mindesttätigkeit auf Brachen umgesetzt. Die dort eingesetzten Algorithmen werden als Mahd- bzw. Umbruchprüfung bezeichnet, bei denen die Entfernung des oberirdischen Aufwuchses (z.B. durch Mähen, Mulchen, Fräsen oder Pflügen) geprüft wird. Zwischen Grubber/Fräsen und einem Schwarzumbruch per Pflug kann dabei nicht unterschieden werden. Als Datengrundlage kommen Sentinel-1 basierte Kohärenzen, Sentinel-2 basierte Vegetationsindizes und Niederschlagsdaten zum Einsatz (siehe Abbildung 3).

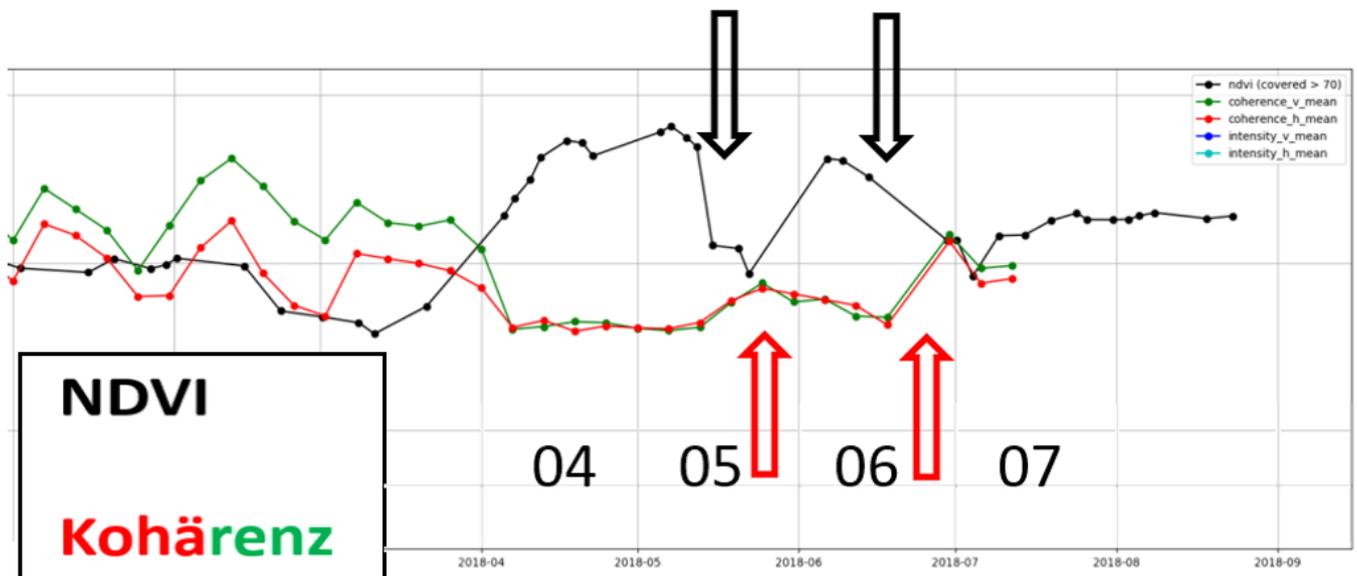


Abbildung 3: Schematischer Verlauf von Sentinel-2 basierem Normalized Difference Vegetation Index (NDVI) und Sentinel-1 basierter Kohärenz bei Mahden im Mai und Juni.

3.3 Stoppel, Mulchauflage

In der bereits genannten Studie von Denize et al. (2019) wurden Pflanzenreste ("Crop residues") per überwachter Klassifikation erfasst. Die Klasse "crop residues" setzt sich dabei aus Stoppeln verschiedener Getreide, insbesondere Mais, zusammen. Sie erreichten für diese Klasse eine Produzentengenauigkeit von 100% und eine Nutzergenauigkeit von 85%. Ding et al. (2020) verwendeten Sentinel-2-Daten zur Abschätzung des Bedeckungsgrades mit Pflanzenresten. Sie verglichen dabei einerseits lineare, univariate Regressionsmodelle mit Verfahren des Maschinellen Lernens (u.a. Random Forest und Support Vector Machines), andererseits die Verwendung unterschiedlicher Spektralbänder und -indizes bzw. (multivariater) Merkmalsstapel. Per univariater Regressionsmodelle erreichten sie einen R^2 -Wert von 0.63 und einen RMSE von 6.509 %. Mittels Maschinellen Lernen wurden geringfügig höhere Genauigkeiten erzielt (R^2 0.69, RMSE 6.149 %).

In Bezug auf bestehende Arbeiten zur Erfassung von Mulchauflage als konservierende Maßnahme lässt sich ebenso auf die o.g. Studie von Denize et al. (2019) und die dort erfasste Klasse der Pflanzenreste ("Crop residues") verweisen. Eine explizite Unterscheidung von Stoppeln und Mulchauflage erscheint nach Recherche der aktuellen Fachliteratur nicht untersucht. Dagegen ist aber auf verschiedene Studien zu verweisen, deren Verfahren die Bedeckung mit Pflanzenresten als kontinuierliche Variable (CRC = "Crop Residue Cover") erfassen und diese ggf. auch in Bedeckungsgrade (relativer Anteil der mit Pflanzenresten überdeckten Fläche zur Bezugsfläche) überführen (Quemada and Daughtry, 2016). Während sich Reflexionsspektren von trockenem Boden und trockenen Ernterückständen im sichtbaren und nahen Infrarot teilweise kaum unterscheiden, bestehen signifikante

Absorptionsmerkmale (von Lignin und Zellulose) im kurzwelligen Infrarot (SWIR) (Daughtry, 2001). Im Bereich von 2100 Nanometer des elektromagnetischen Spektrums verfügen Pflanzenreste über charakteristische Absorptionseigenschaften, welche auf C-O- und O-H-Bindungen von Lignin und Zellulose und anderen Sacchariden in der Außenwand der Ernterückstände zurückzuführen sind. Entsprechende Spektralindizes sind beispielsweise der Normalized Difference Tillage Index (NDTI) oder der Normalized Difference Residue Index (NDRI) (Cai et al., 2019; Yue and Tian, 2020). Allerdings ist die Auswirkung der Absorption von Bodenfeuchtigkeit auf breitbandige Spektralkanäle (wie z.B. im Falle der Erdbeobachtungssatelliten Sentinel-2 oder Landsat-8) größer als die von Lignin und Zellulose, was zu Fehlern in den Schätzungen von Pflanzenresten mit relativ hohem Feuchtigkeitsgehalt führt (Daughtry, 2001; Quemada und Daughtry, 2016; Yue et al., 2019a). Somit bestehen bei der Anwendung in mittleren Breiten -- im Gegensatz zu ariden und semi-ariden Gebieten -- besondere Herausforderungen (Quemada and Daughtry, 2016). Hinsichtlich der satellitengestützten Detektion von Pflanzenresten (Stoppel, Mulch) und der Abschätzung von entsprechenden Graden der Bodenbedeckung sind seitens EFTAS bisher keine Projekte durchgeführt worden.

Zusammenfassend lässt sich auf Grundlage genannter Fachliteratur und eigener Vorarbeiten die Ackerfläche als System aus relativen Flächenanteilen der drei Komponenten (1) Vegetation, (2) Ernterückstände/Mulch und (3) Offenboden beschreiben und deren Status mit Blick auf die Verfügbarkeit zeitlich und räumlich hochauflösender Erdbeobachtungssatelliten wie Sentinel-2 im Sinne eines kontinuierlichen (z.B. monatlichen) Monitorings fortschreiben. Diese Informationsebenen lassen sich mit Klassifikationen der Landbedeckung bzw. Kulturarten verschneiden. In der Fachliteratur wird zudem auf den Nutzen von (weitestgehend) wetterunabhängigen SAR-Daten wie Sentinel-1 verwiesen. SAR-Daten korrelieren unter gewissen Voraussetzungen mit landwirtschaftlich relevanten Parametern wie der Biomasse und der Bodenfeuchte, sowie mit Spektralindizes optischer Daten (Holtgrave et al., 2020). Zusammenhänge bestehen dabei allerdings oft nur partiell, z.B. innerhalb bestimmter Landbedeckungsklassen oder beschränkter Zeiträume bzw. Wachstumsphasen. Die wechselseitigen Einflüsse von Aufnahmegeometrie, Oberflächenrauigkeit und Bodenfeuchte auf das empfangene SAR-Signal müssen bei der Abschätzung von Pflanzenparametern über Modelle oder Annahmen einbezogen werden.

4 Visuelle Überprüfung der Identifizierbarkeit der Zielobjekte

Im Folgenden werden Auszüge der Sentinel-1 und Sentinel-2-Daten in Form von Echtfarbenkompositen und Zeitreihendiagrammen visuell ausgewertet. Zu prüfen ist dabei, inwiefern sich die Zielobjekte, beispielsweise über markante Zeitreihenprofile, abgrenzen lassen. Hieraus soll ein besseres Verständnis der Zielklassen bzw. ihrer Abbildung in den Satellitendaten über charakteristische spektrale, temporale und räumliche/strukturelle Merkmale entstehen.

4.1 Zwischenfrüchte

Die Bedeckung des Bodens mit (photosynthetisch aktiver) Vegetation lässt sich mit Vegetationsindizes, wie dem NDVI, oder abgeleiteter biophysikalischer Parameter, wie dem Blattflächenindex, zuverlässig detektieren und von offenem Boden, Pflanzenresten (z.B. Mulch, Stoppel) oder spärlichem Bewuchs abgrenzen. In der Auswertung von entsprechenden Zeitreihen lassen sich dabei Rückschlüsse sowohl auf die Dichte des Bewuchses als auch auf die Dauer der Begrünung vom Aufgang der Begrünung bis zur Degeneration bzw. Mahd/Umbruch ableiten.

In Abbildung 4 werden die NDVI-Verläufe von Zwischenfrüchten der Erntejahre 2018 bis 2021 verglichen. Die NDVI-Werte der einzelnen Schläge sind dabei je Erntejahr und Aufnahmezeitpunkt über den Mittelwert zusammengefasst. Zu erkennen ist die Wachstumsphase der Zwischenfrüchte mit dem Aufwuchs im Herbst und der Degeneration oder der Ernte im Frühjahr. Im Vergleich der Erntejahre zeigen sich dabei unterschiedliche Verläufe. Im Erntejahr 2018 wachsen Zwischenfrüchte früh (ca. August 2017), im Erntejahr 2019 spät (ca. Oktober 2018) auf. Im Erntejahr 2020 ist ab ca. November ein Maximum an NDVI-Werten erreicht, welches sich in einem plateauähnlichen Verlauf bis März/April hält und dann abrupt (Umbruch/Ernte) abfällt. Bezüglich dieses Verlaufs können die Witterungsverhältnisse als Erklärung herangezogen werden. Der Winter 2019/20 gilt in Deutschland mit +4,1 °C über dem langjährigen Mittel (im Bereich des Untersuchungsgebietes ca. +4,4 °C) als zweitwärmster seit Beginn der Wetteraufzeichnungen. Die Lufttemperaturen lagen nur selten und unwesentlich unterhalb der Frostgrenze (siehe Abbildung 8).

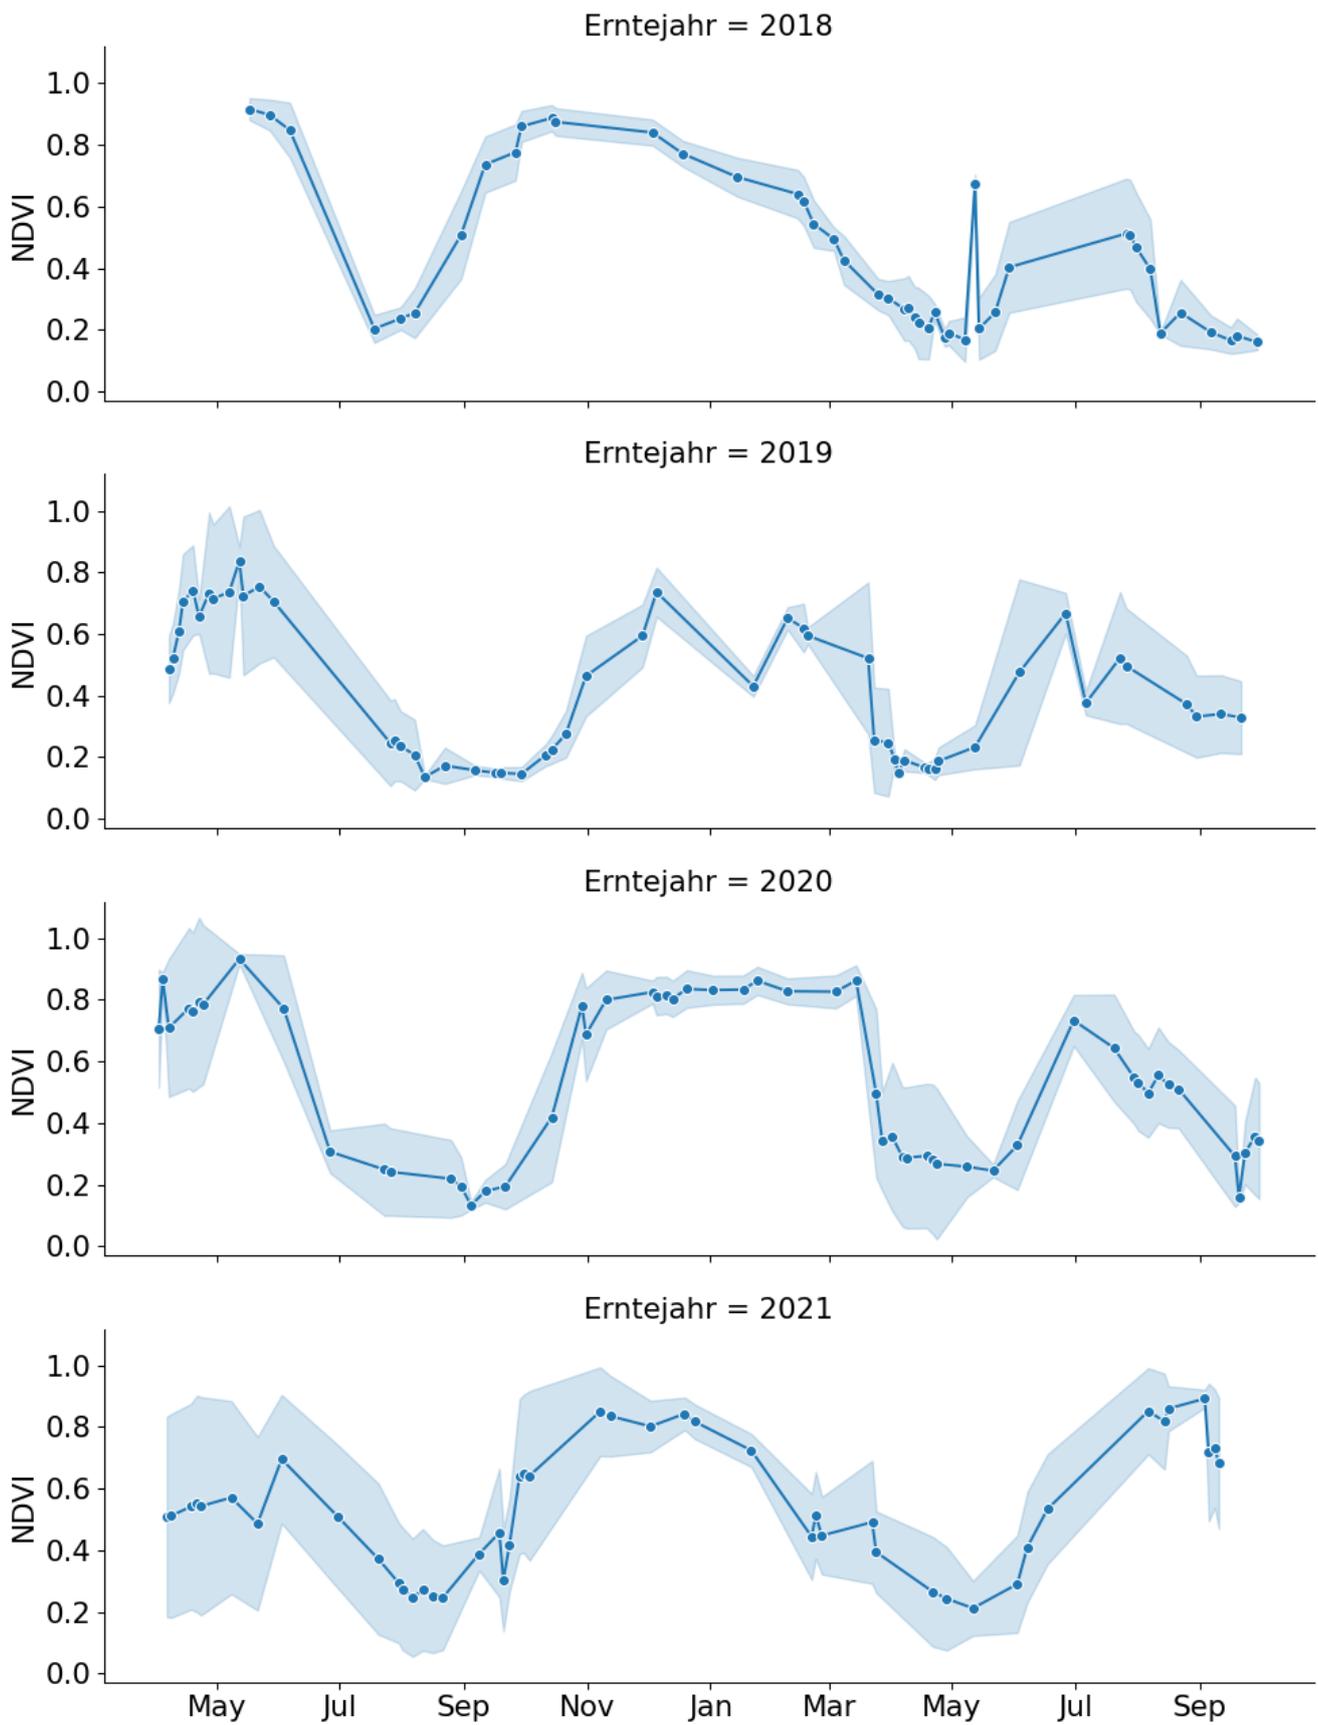


Abbildung 4: Vergleich der NDVI-Zeitreihen von Zwischenfrüchten (Mittelung über sämtliche Schläge des Untersuchungsgebietes; Standardabweichung in blauer Schattierung).

Dem entgegengesetzt sind für die Erntejahre 2018 und 2021 nach einem anfänglichen Maximum im Herbst im weiteren Verlauf bis zum Frühjahr tendenziell kontinuierlich fallende NDVI-Werte zu verzeichnen, was mutmaßlich auf die vergleichsweise kälteren, frostreichereren Wetterbedingungen in diesen Wintern zurückzuführen ist.² Ein exemplarisches Verlaufsmuster mit über den Winter und das Frühjahr sichtbar rückläufiger Bodenbedeckung durch Zwischenfrüchte ist anhand einer Zeitreihe von Echtfarbendarstellungen der Sentinel-2-Daten in Abbildung 5 dargestellt. Am 25.03.2018, unmittelbar vor der ersten Bodenbearbeitung (Saatfurche) am 29.03.2018, erscheint der Boden bereits größtenteils unbedeckt. Die angebaute Saatmischung "Viterra Bodengare" (Blaue Bitterlupine, Sommerwicke, Sommerfuttererbse, Alexandrinerklee, Persischer Klee, Phazelia, Sonnenblumen) gilt als abfrierend. Nicht gänzlich auszuschließen sind darüber hinaus Schädlingsbefall, Staunässe und sonstige Schadereignisse als Ursache eines Rückgangs an Vitalität bzw. der Bedeckung durch die Zwischenfrucht.

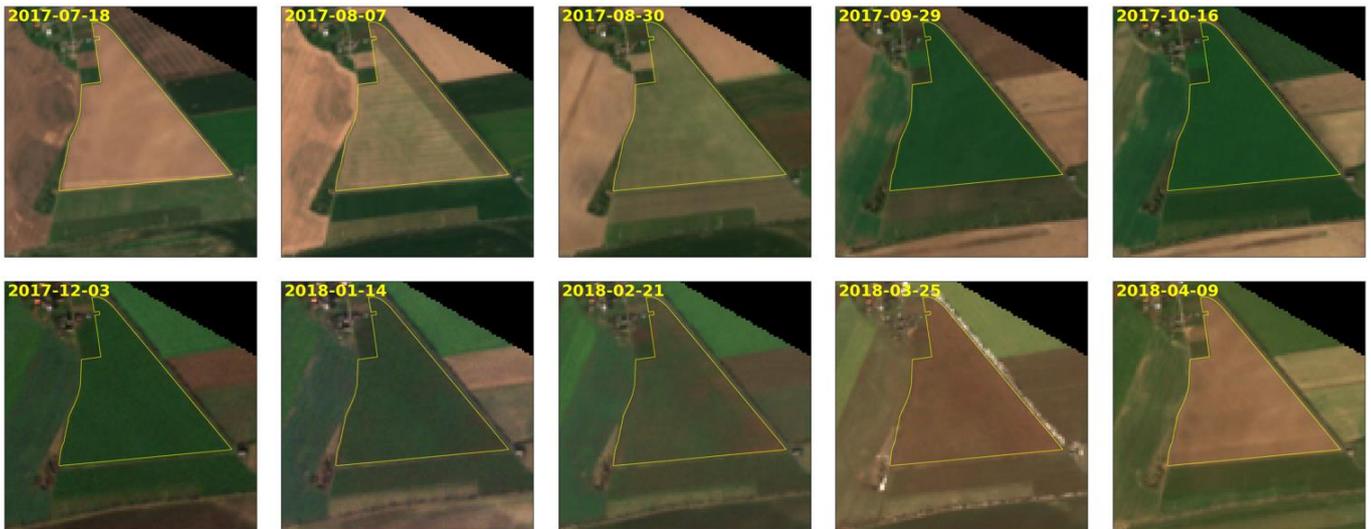


Abbildung 5: Darstellung der Entwicklung einer Zwischenfrucht (Schlag 1132-11324, Erntejahr 2018) anhand einer Zeitreihe von Sentinel-2 Echtfarbenkompositen. Sichtbar ist das mutmaßliche Abfrieren der Zwischenfrucht zwischen Januar und März 2018. Die erste Bodenbearbeitung (Saatfurche) erfolgte am 29.03.2018. Saatmischung des Zwischenfruchtanbaus: "Viterra Bodengare" (Blaue Bitterlupine, Sommerwicke, Sommerfuttererbse, Alexandrinerklee, Persischer Klee, Phazelia, Sonnenblumen).

Ein weiterer Untersuchungsgegenstand der vorliegenden Studie ist die Abgrenzung der Zwischenfrüchte von Winterkulturen (inkl. jeglicher sonstiger winterlichen Begrünung, d. h. Wintergetreide, Winterraps, Feldfutter und Selbstbegrünung). Diesbezüglich zeigt sich beim Vergleich der NDVI-Verläufe über den Zeitraum September bis April, dass Zwischenfrüchte in der Tendenz höhere Werte aufweisen. Eine Differenzierung erscheint weitestgehend möglich. Unsicherheiten verbleiben durch zeitweise Überlappung der Wertebereiche und ggf. die Frage nach optimalen Identifikationszeitfenstern. Ursache hierfür ist die Varianz der NDVI-Verläufe, welche auf verschiedenartigen Saatgutzusammensetzungen, Fruchtarten, ggf. Brachen, sowie den Einfluss der Witterung und

² Bzgl. Lufttemperaturen (2 m über Grund) und Niederschlagsmengen gemessen an der LfULG-Wetterstation "Köllitsch" siehe

Abbildung 6, Abbildung 7, Abbildung 8 und Abbildung 9.

Bewirtschaftung zurückgeführt werden kann. Nach Ende der Vegetationsphase der Zwischenfrüchte divergieren die Verläufe beider Klassen letztlich deutlich, da hier Winterkulturen typischerweise noch fortbestehen.

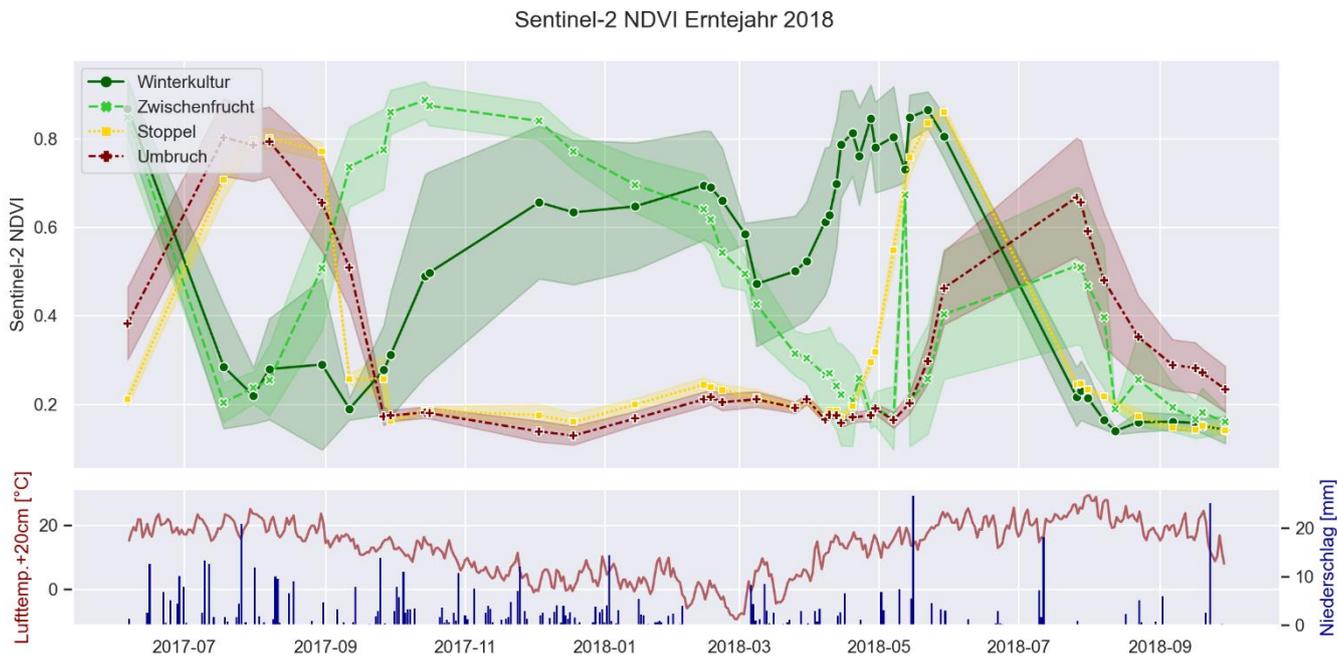


Abbildung 6: NDVI (Mittelwert und Standardabweichung) im Erntejahr 2018. In der Klasse "Winterkultur" inbegriffen sind neben Wintergetreide auch Wintereraps, Feldfutter und Selbstbegrünung.

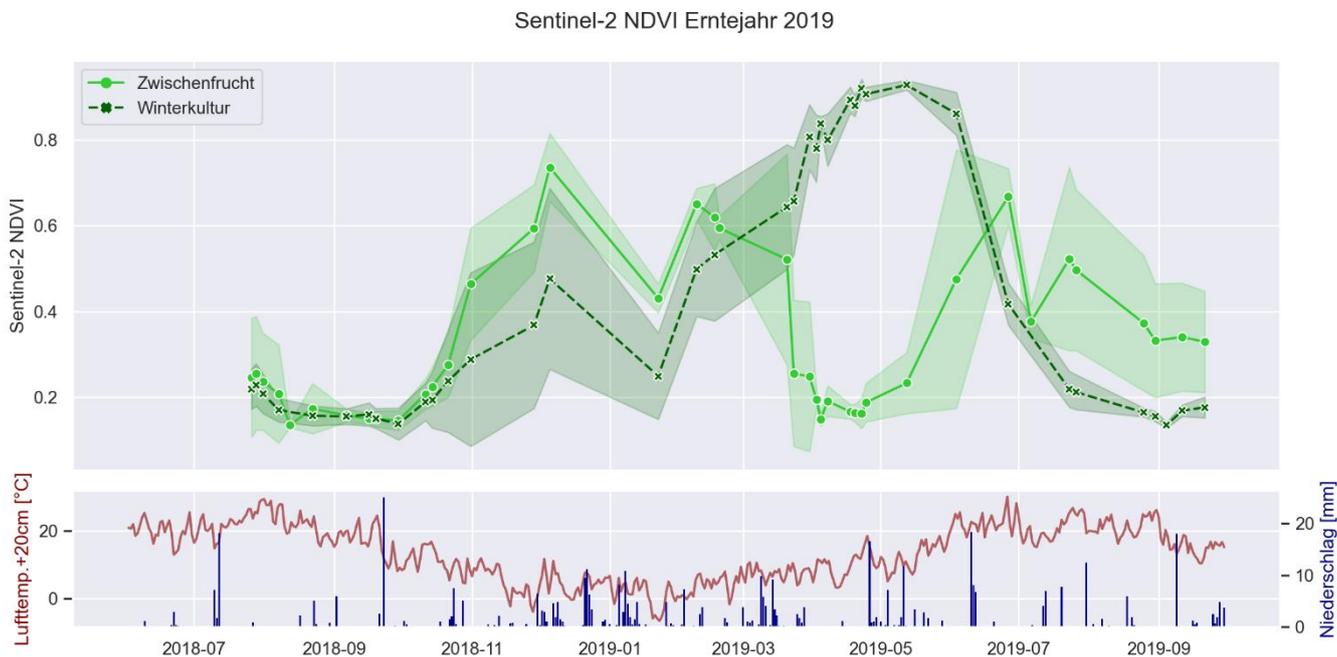


Abbildung 7: NDVI (Mittelwert und Standardabweichung) im Erntejahr 2019. In der Klasse "Winterkultur" inbegriffen sind neben Wintergetreide auch Wintereraps, Feldfutter und Selbstbegrünung.

Sentinel-2 NDVI Erntejahr 2020

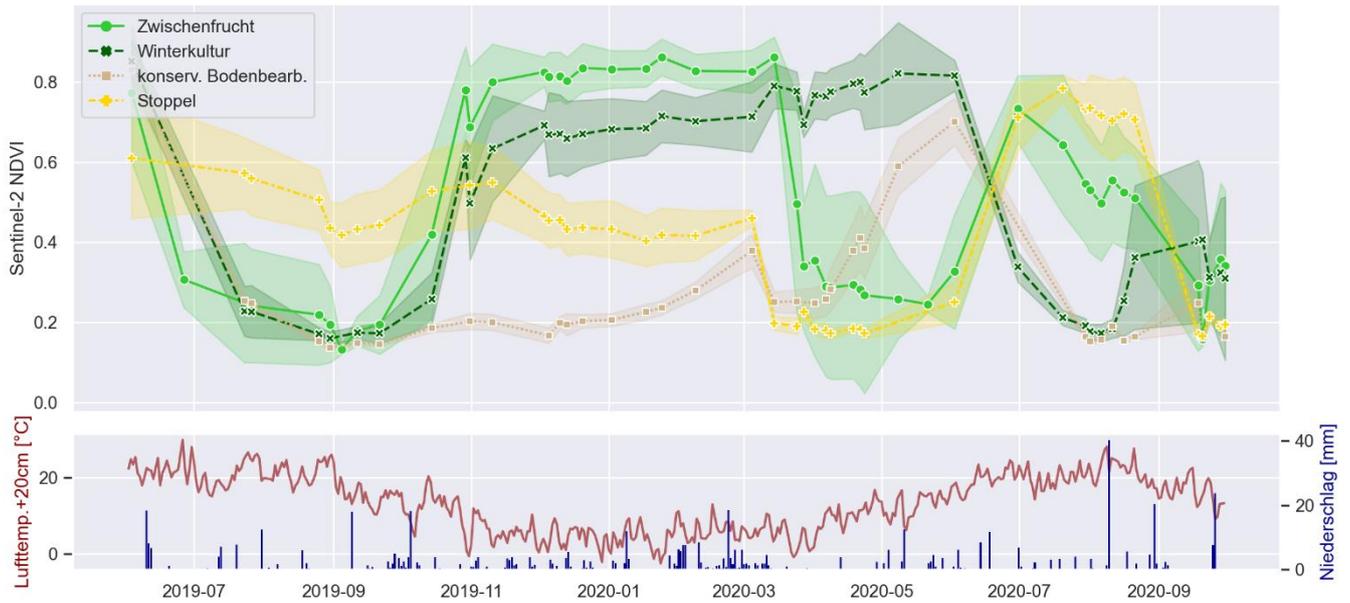


Abbildung 8: NDVI (Mittelwert und Standardabweichung) im Erntejahr 2020. In der Klasse "Winterkultur" inbegriffen sind neben Wintergetreide auch Winterraps, Feldfutter und Selbstbegrünung.

Sentinel-2 NDVI Erntejahr 2021

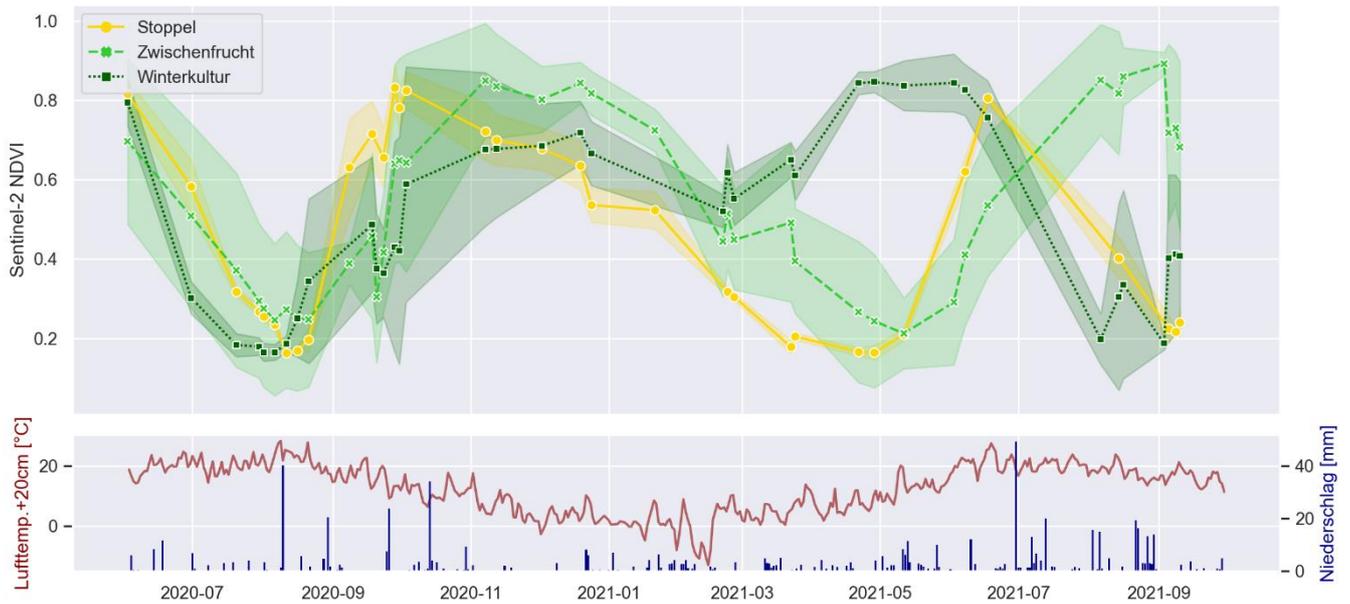


Abbildung 9: NDVI (Mittelwert und Standardabweichung) im Erntejahr 2021. In der Klasse "Winterkultur" inbegriffen sind neben Wintergetreide auch Winterraps, Feldfutter und Selbstbegrünung

4.2 Konservierende Bodenbearbeitung

Die konservierende Bodenbearbeitung zeichnet sich im Gegensatz zur konventionellen, wendenden Bodenbearbeitung (Umbruch) durch reduzierte Bearbeitungstiefen (< 20 cm) aus. Im Vergleich zur wendenden Bodenbearbeitung ist im Anschluss an die Bearbeitung von einer größeren Bedeckung an Pflanzenresten auszugehen (ca. 15-30%). In Relation zu den Zielobjekten "Stoppel" und "Mulch" ist bei flachen bis nicht wendenden Bodenbearbeitungstiefen ein geringerer Bedeckungsgrad zu erwarten.

Abbildung 10 zeigt -- anhand einer Serie exemplarisch ausgewählter Sentinel-2 Echtfarbenkomposite -- die Entwicklung eines Schlages mit konservierender Bodenbearbeitung. Beginnend mit der Ernte der Vorkultur im Juni/Juli 2019 folgt eine Phase mit weitestgehend unbedecktem Boden bis ins Frühjahr. Ab April 2020 ist schließlich der Aufgang der am 30.10.2019 ausgesäten Hauptkultur (Erbse) visuell deutlich erkennbar.

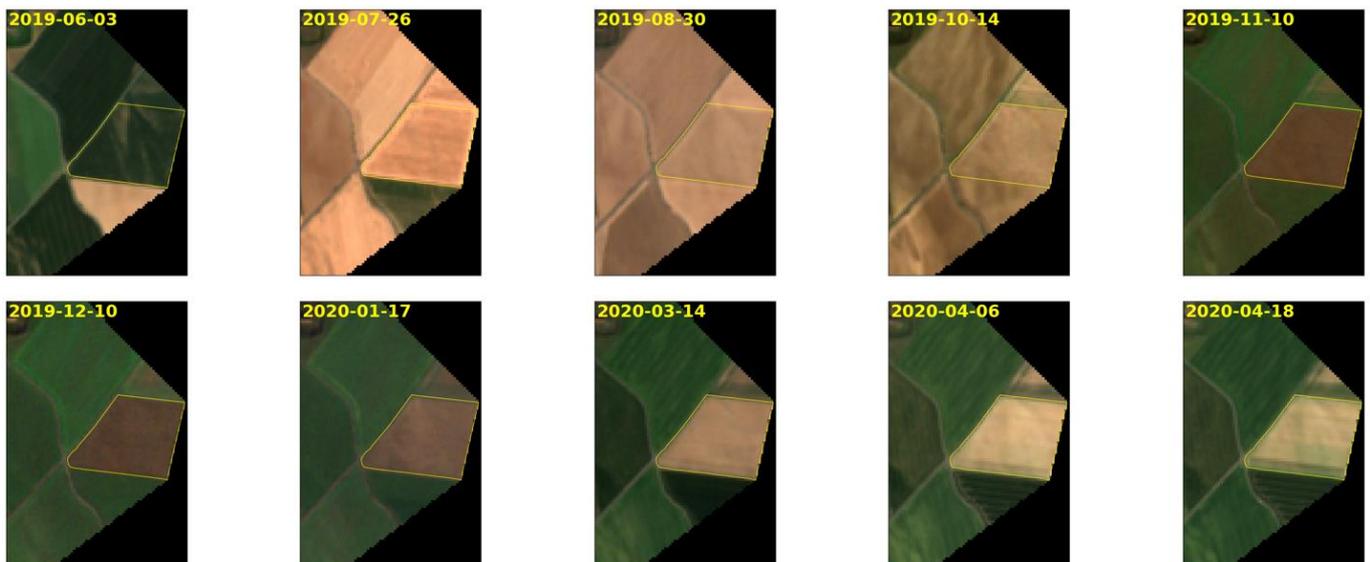


Abbildung 10: Entwicklung einer Ackerfläche mit konservierender Bodenbearbeitung (Maschineneinsätze zur Bodenbearbeitung am 29.07.2019, 16.08.2019, 28.10.2019; Aussaat der Hauptkultur Erbse am 30.10.2019) und weitestgehend unbedecktem Boden (keine bis geringe Begrünung über den Herbst/Winter). Exemplarische Darstellung eines ausgewählten Schlages anhand einer Zeitreihe von Sentinel-2 Echtfarbenkompositen.

Im Verlauf des NDVI zeigt sich der Aufgang der Hauptkultur mutmaßlich bereits durch einen geringfügigen Anstieg der Werte zunächst im Oktober/November 2019, später im Februar 2020 (siehe Abbildung 11). Neben den dargestellten charakteristischen Verläufen mit über den Herbst/Winter geringen NDVI-Werten definiert sich die konservierende Bodenbearbeitung im Wesentlichen über die Abstinenz wendender Bodenbearbeitung. Indizien für eine wendende Bodenbearbeitung können geringere Reflektanzen im Bereich des sichtbaren Lichts sein, bedingt durch eine höhere Oberflächenrauigkeit und entsprechendem Schattenwurf sowie ggf. einer höheren Bodenfeuchte und geringeren Bedeckung durch Pflanzenreste.



Abbildung 11: NDVI-Verlauf einer Ackerfläche mit konservierender Bodenbearbeitung (Maschineneinsätze zur Bodenbearbeitung am 29.07.2019, 16.08.2019, 28.10.2019; Aussaat der Hauptkultur Erbse am 30.10.2019) und weitestgehend unbedecktem Boden (keine bis geringe Begrünung über den Herbst/Winter).

Abbildung 12 zeigt einen Schlag vor und nach Anwendung wendender Bodenbearbeitung. Eine zuverlässige Abgrenzung konservierender von wendender Bodenbearbeitung erscheint jedoch auf Basis einer visuellen Auswertung von Sentinel-2-Bilddaten oder Zeitreihendiagrammen mit zu großer Unsicherheit behaftet, da Oberflächenreflektanzen in Abhängigkeit von den Witterungsbedingungen bzw. von der Bodenfeuchte einer Varianz unterliegen. Des Weiteren kann aufgrund der Wetterabhängigkeit von Sentinel-2 die Verfügbarkeit von Daten mit einer zum Maschineneinsatz zeitlichen Entsprechung nicht gewährleistet werden. Hinsichtlich der Interpretation der (nahezu wetterunabhängigen) Sentinel-1-Daten sind aufgrund komplexer Abhängigkeiten von u.a. Oberflächenrauigkeit, Bodenfeuchte und Eindringtiefe keine unmittelbar visuell interpretierbaren Muster in den Zeitreihen zu erwarten.

2017-10-14 (Sentinel-2)
Schlag-ID 2018_1213-12134



2017-12-03 (Sentinel-2)
Schlag-ID 2018_1213-12134



Abbildung 12: Ackerschlag vor (links) und nach (rechts) der wendenden Bodenbearbeitung (Umbruch/Winterfurche) am 02.11.2017.

4.3 Stoppel

Abbildung 13 zeigt in einer Serie ausgewählter Sentinel-2-Szenen die Entwicklung einer Stoppelbrache über den Zeitraum Juli 2019 bis April 2020. In den Bilddaten erkennbar ist der Übergang von einer bedingt durch stellenweise Selbstbegrünung inhomogenen zu einer homogenen Struktur zwischen den Szenen vom 08.02.2020 und 14.03.2020. Zurückzuführen ist dies auf eine Bodenbearbeitung (Saatfurche 20-25 cm) vom 13.03.2020.

Der Verlauf des NDVI mit Werten zwischen ca. 0,4 und 0,5 über den Herbst und Winter und einem Abfall nach der Bodenbearbeitung auf ca. 0,2 bestätigt den o.g. Eindruck (siehe Abbildung 14). Hinsichtlich des Grades an Bedeckung mit Pflanzenresten lassen die Verläufe des NDTI und NDRI keine unmittelbaren Rückschlüsse zu. Der NDTI erfordert nahezu vegetationsfreie Bedingungen und steht durch seine Korrelation mit dem NDVI sichtbar unter Beeinflussung der (photosynthetisch aktiven) Vegetation. Der NDRI gilt gegenüber der Vegetationsbedeckung als unempfindlicher, zeigt jedoch als Folge der o.g. Bodenbearbeitung nicht den bedingt durch die Abnahme oberflächlicher Pflanzenreste entsprechenden Abfall der NDRI-Werte (hohe Werte stehen für einen hohen Grad an Bedeckung mit Pflanzenresten).

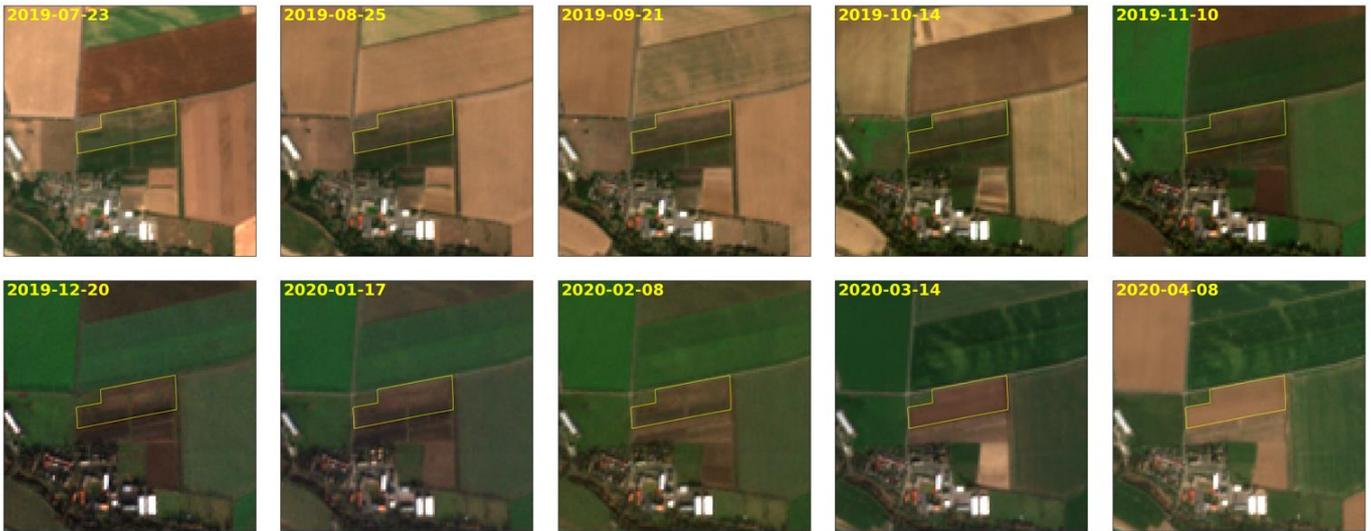


Abbildung 13: Entwicklung einer Stoppelbrache (Schlag 1223-1, Erntejahr 2020) über den Zeitraum 07.2019 bis 04.2020 (Bildraten: Sentinel-2 Echtfarbenkomposite).

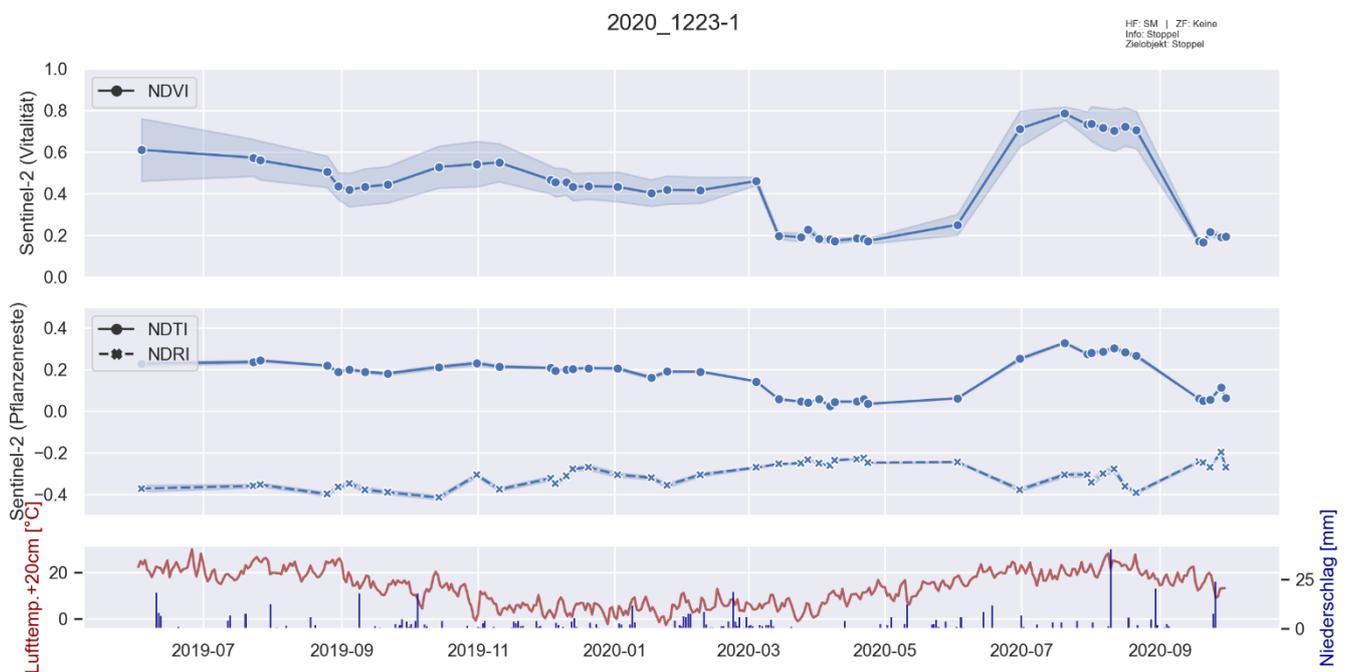


Abbildung 14: Sentinel-2 basierte Indizes über die Entwicklung einer Stoppelbrache (Schlag 1223-1, Erntejahr 2020).

4.4 Mulchaufgabe

Das Aufbringen von Mulch auf unbedeckten (vegetationsfreien) Boden spiegelt sich nach theoretischer Betrachtung über erhöhte Werte in den Sentinel-2 basierten Indizes NDTI und NDRI wider. Abbildung 15 zeigt den Verlauf beider Indizes vor und nach dem Aufbringen einer Mulchaufgabe Ende Juli 2018. Ein entsprechender, jedoch geringfügiger Anstieg beider Indizes ist für den Zeitraum Ende Juli bis Anfang August 2018 zu verzeichnen. Voraussetzung für die Aussagekraft der Indexwerte ist hierbei die Abstinenz einer (photosynthetisch aktiven) Vegetationsdecke sowie möglichst trockene, v.a. stabile Bodenfeuchteverhältnisse. Beide Bedingungen scheinen mit Blick auf die ebenfalls dargestellten Werte von NDVI, Lufttemperatur und Niederschlag gegeben. Im weiteren Verlauf über den Sommer

nehmen die Indexwerte wieder leicht ab, was möglicherweise auf eine Verrottung der Mulchauflage zurückgeführt werden kann. Ähnliche Verläufe sind auch auf anderen Schlägen mit Mulchauflage zu beobachten; in einigen anderen Fällen spiegeln sich die Mulchtermine wiederum nicht in den Index-Verläufen wider. Vor diesem Hintergrund sind in Bezug auf die vorliegende Datenbasis Aussagen hinsichtlich der Machbarkeit einer quantitativen Schätzung des Bedeckungsgrades von Mulch über die Korrelation mit entsprechenden Indizes entsprechend einzuordnen.

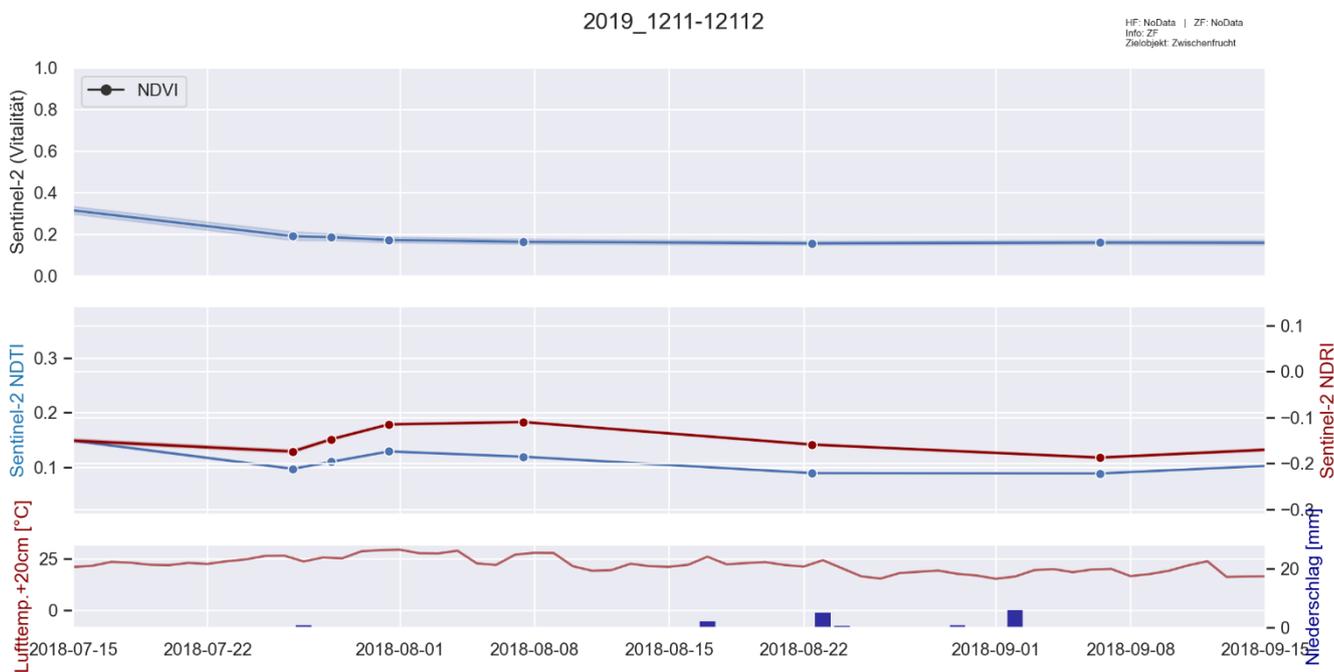


Abbildung 15: Verlauf der Sentinel-2 basierten Indexwerte Mulchen am 31.07.2018 (Maschineneinsatz Case MXM 140 TO-E 521, MC Connel SR 620)

5 Automatische Klassifikationsverfahren

Im Rahmen der vorliegenden Studie werden Verfahren der überwachten Klassifizierung getestet, um aus den Satellitenzeitreihen die Zielklassen bzw. die Anwendung bodenkonservierender Maßnahmen automatisiert abzuleiten.

Hierzu werden die Satellitenzeitreihen auf Basis der bereitgestellten Referenzdaten in annotierte Datenstapel überführt, welche im Anschluss zum Trainieren eines Klassifikationsmodells genutzt werden. Der trainierte Klassifikator kann im Anschluss auf neue Fälle (d.h. Pixel oder Polygone mit entsprechend hinterlegten Grauwerten der Bänder der Satelliten bzw. deren arithmetische Kombination in Indizes) angewendet werden, um eine Zielklasse vorherzusagen. Die Vorhersage kann anschließend mit der gemäß Referenz tatsächlich vorliegenden Zielklasse auf Übereinstimmung bzw. Konfusion abgeglichen werden. Der Grad der Übereinstimmung über die Gesamtheit der Fälle dient als Maß der Klassifikationsgüte.

Der Aufbau eines Systems zur Datenklassifizierung erfordert in der Regel verschiedene Design-Entscheidungen, welche einen wesentlichen Einfluss auf Klassifikationsgüte, Datenanforderungen und Rechenperformanz haben. Im Rahmen dieser Studie wird der Einfluss der verwendeten Merkmale (Spektralkanäle der Satelliten bzw. abgeleitete Kanalkombinationen/Indizes), verschiedener Zeitfenster zur Definition der Satellitenzeitreihen sowie die Wahl aus zwei verschiedenartigen Klassifikationsalgorithmen (Long-Short-Term-Memory Neuronales Netzwerk und Random Forest Entscheidungsbaum Ensemble) untersucht. Die einzelnen Konfigurationen werden im Folgenden vorgestellt. Abschließend werden das Validierungsschema und die erzielten Ergebnisse beschrieben.

Der den nachfolgenden Experimenten zu Grunde gelegte Klassenkatalog (Zielvariablen) umfasst die Kategorien Zwischenfrucht (ZF) und Winterkultur (WK), da hierfür aus den Referenzdaten eine ausreichende Menge an Trainingsdaten generiert werden konnte. Prinzipiell anwendbar ist ein überwachtes Verfahren zur Klassifizierung jedoch auch auf die anderen in dieser Studie behandelten Zielklassen, sofern ausreichend Trainingsdaten verfügbar gemacht werden können.

5.1 Klassifikationsmerkmale

Zur Beantwortung der Frage nach dem Mehrwert einzelner Satellitensensoren bzw. deren Spektralkanäle und abgeleiteten Indizes wurden verschiedene Merkmalssets definiert. Das Merkmalsset "S1" umfasst lediglich die beiden Polarisierungen von Sentinel-1, Merkmalsset "S2" die 10 und 20 Meter auflösenden Spektralkanäle von Sentinel-2, Merkmalsset "S1S2" die Kombination der beiden zuvor genannten Sets, Merkmalsset "Indizes" umfasst lediglich aus den originären Kanälen beider Sensoren abgeleitete Kanalkombinationen und Merkmalsset "Alle" umfasst die Menge sämtlicher o.g. Kanäle und Indizes. Tabelle 5 bietet hierzu eine entsprechende Übersicht und auf Tabelle 3 sei bzgl. der Aufschlüsselung der Bezeichnung von Kanälen und Indizes verwiesen.

Tabelle 5: Merkmalssets und zugehörige Prädiktoren (Kanäle/Indizes).

Bezeichnung Merkmalsset	Kanäle/Indizes (Prädiktoren)
S1	VV, VH
S2	B02, B03, B04, B05, B06, B07, B8A, B11, B12
S1S2	VV, VH, B02, B03, B04, B05, B06, B07, B8A, B11, B12
Indizes	NDVI, NDWI, PSRI, 3BI2, NDTI, NDRI, VH-VV, RVI
Alle	B02, B03, B04, B05, B06, B07, B8A, B11, B12, VV, VH, NDVI, NDWI, PSRI, 3BI2, NDTI, NDRI, VH-VV, RVI

Die einzelnen Kanäle bzw. Indizes liegen als Zeitreihe (aggregiert und interpoliert auf halbmonatliche Intervalle) vor. Um den Einfluss der Wahl von Start- und Enddatum zur Definition des Zeitfensters zu testen, wurden folgende beiden Zeiträume definiert und hinsichtlich der erzielten Klassifikationsergebnisse verglichen: 1) April d. Vorjahres bis einschl. September im Jahr der Ernte und 2) Oktober d. Vorjahres bis einschl. März im Jahr der Ernte. Der erstgenannte Zeitraum liefert den Klassifikatoren umfassenden zeitlichen Kontext, einschließlich der Entwicklung vor und nach dem Kern-Identifikationszeitraum (Herbst, Winter). Der zweitgenannte, verkürzte Zeitraum fokussiert dagegen auf den Zeitraum der eigentlichen Anwendung von konservierenden Maßnahmen.

5.2 Klassifikationsalgorithmen

Im Rahmen der vorliegenden Studie werden mit dem Random Forest und dem Long Short Term Memory (LSTM) zwei verschiedene Verfahren zur Datenklassifizierung verglichen.

Random Forests gehören -- ähnlich wie Support Vector Machines oder Gradient Boosting (Hastie et al., 2009) -- zu den Verfahren, welche sich bis in die 2000er Jahre als Stand der Technik im Bereich datengetriebener Prognosemodelle etabliert und breite Anwendung in einer Vielzahl von Anwendungsfeldern gefunden hatten. Zuletzt sind jedoch sog. Deep Learning-Verfahren in den Fokus gerückt, da sie in datenintensivem Umfeld und bei gegebenen Rechenkapazitäten im Vergleich zu o.g. konventionellen Verfahren bessere Ergebnisse erzielen. Zudem hängen sie weniger von einer per Expertenwissen vordefinierten Merkmalsextraktion (Aufbereitung und Auswahl "roher" Eingangsdaten) ab, sondern leiten Merkmale als Teil der Optimierungsaufgabe zur Maximierung Klassifikationsgenauigkeit (bzw. Minimierung der Kostenfunktion) inhärent ab. Die hier verwendete LSTM Netzwerkarchitektur gehört zu den Deep Learning-Verfahren, die sich explizit für die Verarbeitung von Zeitreihen eignen.

Random Forest

Das Random Forest-Verfahren besteht aus einer großen Anzahl von einzelnen Entscheidungsbäumen, die als Ensemble arbeiten. Jeder einzelne Baum im Random Forest gibt eine Klassenvorhersage aus. Per Mehrheitsentscheid wird über die Gesamtheit der Einzelbäume eine finale Klassenvorhersage für einen Fall/Datenpunkt abgeleitet. Einzelne Entscheidungsbäume sind dabei unkorreliert zueinander, da sie jeweils auf Basis einer zufällig ausgewählten Untermenge der Trainingsdaten generiert werden. Dieser Mechanismus verhindert ein Überanpassen einzelner Bäume (letztlich auch des Ensembles) an die Trainingsdaten. Der durch die geringere Stichprobe verursachte höhere Fehler einzelner Bäume wird über die Gesamtheit der Bäume nivelliert. Der hier angewendete Random Forest-Algorithmus wurde mit 200 Bäumen je Modell induziert. Es wurden keine

Abbruchkriterien beim Verzweigen einzelner Entscheidungsbäume des Random Forest-Ensembles definiert (d.h. kein "Pruning").

Long Short Term Memory (LSTM)

Die verwendete LSTM-Basisarchitektur (siehe Abbildung 16) ist Netzwerk, das die Inputs (Pixelwerte der aufbereiteten Sentinel-1 und Sentinel-2-Zeitreihe) über drei Zwischenschichten in eine Ausgabeschicht überführt. Die Ausgabeschicht enthält je Zielklasse einen Wahrscheinlichkeitslayer. Die Klasse mit der höchsten Ausgabewahrscheinlichkeit erhält den Zuschlag. Die dargestellte Netzarchitektur verfügt über 11.841.795 trainierbare Parameter und ist damit für komplexe Mustererkennung und größere Trainingsstichproben ausgelegt. Im Rahmen dieser Studie wurde die Kapazität der o.g. Architektur durch Reduzierung der sog. "hidden nodes" auf 12.453 Parameter reduziert und somit an den gegebenen Stichprobenumfang angepasst.

Hinsichtlich der grundlegenden Funktionsmechanismen der LSTM-Netzwerktopologien sei auf Hochreiter & Schmidhuber (1997) verwiesen.

Architecture and Hyperparameters of the developed LSTM Network

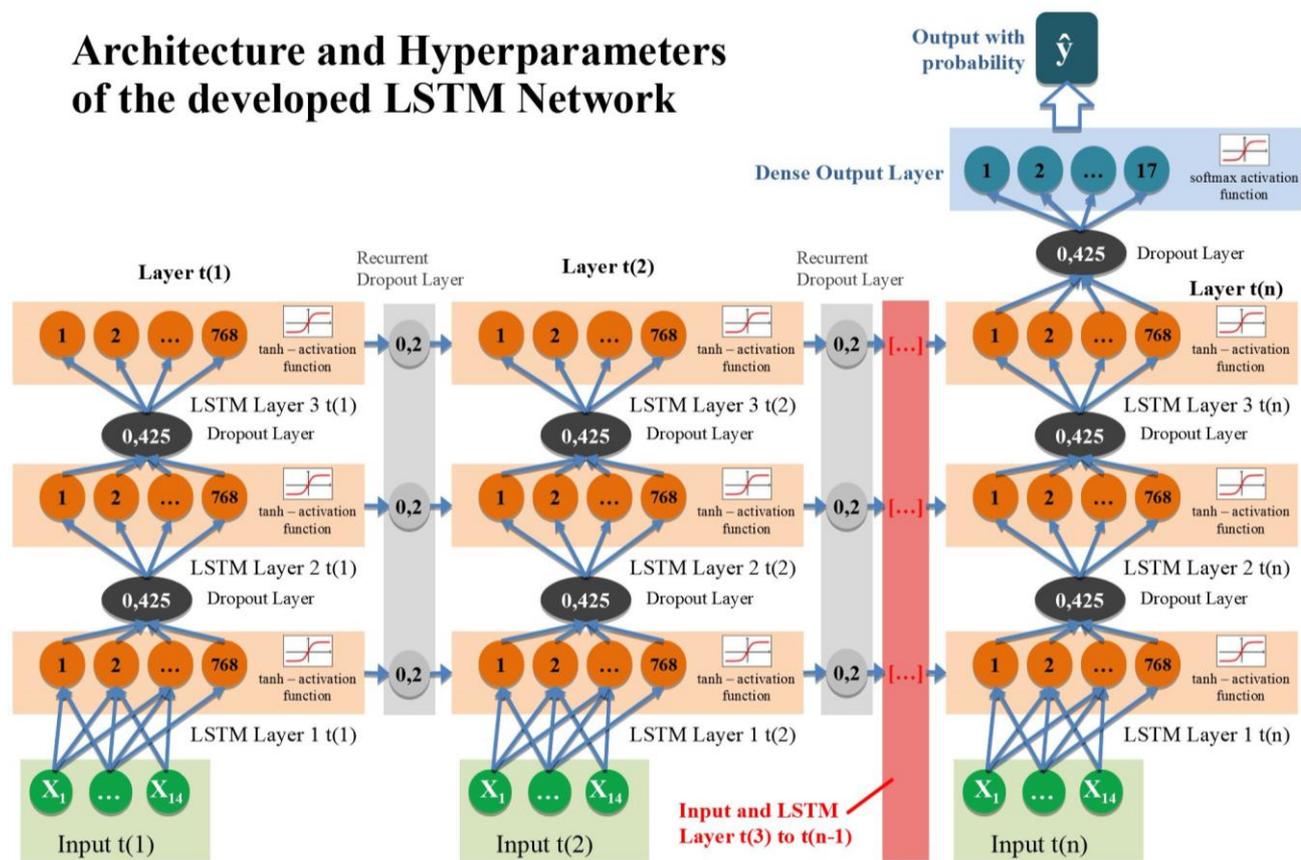


Abbildung 16: Schematische Darstellung der LSTM-Netzwerkarchitektur. Input-, Zwischen- und Ausgabeschichten sind vertikal angeordnet. Die Verknüpfung der Einzelzeitpunkte der Zeitreihen ist über die horizontale Achse dargestellt.

5.3 Kreuzvalidierung

Der Auswertung zu Grunde gelegt werden 58 Schläge der Erntejahre 2018, 2019, 2020 und 2021. Frühere Erntejahre sind dagegen nicht berücksichtigt, da Sentinel-2B erst seit Sommer 2017 operativ im Einsatz ist und so in der Konstellation mit dem Zwillingssatelliten Sentinel-2A ausreichend dichte Zeitreihen ermöglicht. Die Schlaggeometrien werden mit 20 m nach innen gepuffert, um Randeffekte bedingt einerseits durch Lagefehler in den

Sentinel-2-Daten sowie den Schlaggeometrien selbst, andererseits durch die begrenzte Auflösung von 10 bzw. 20 m der Sentinel-1 und Sentinel-2 Spektralbänder, auszuschließen. Schließlich werden die multitemporalen Rasterwerte (je Kanal/Index) aus dem Schnittbereich der innengepufferten Schlaggeometrien als Input für die Klassifizierung verwendet. Es handelt sich demnach um einen pixelbasierten Ansatz mit insgesamt 9346 Datenpunkten der Klasse "Zwischenfrucht" (zugehörig zu 31 Schlägen) und 7299 Datenpunkten der Klasse "Winterkultur" (zugehörig zu 27 Schlägen).

Das Prinzip der sog. "Leave-One-Out"-Kreuzvalidierung sieht vor, dass jeder der 58 Schläge separat getestet wird. Die 58 Tests erfolgen somit über die Anwendung eines Klassifikationsmodells, welches auf den jeweils verbleibenden 57 Schlägen antrainiert wurde.

Als Qualitätsmetriken werden die Gesamtgenauigkeit (OA, von "Overall Accuracy") sowie klassenweise berechnete Werte zu Precision, Recall und F1-Score berücksichtigt. Der "Recall" gibt den Anteil der bei einer Vorhersage gefundenen relevanten Fälle und damit die Vollständigkeit einer Vorhersage an. "Precision" beschreibt den Anteil relevanter Fälle an der Ergebnismenge und damit die Genauigkeit einer Vorhersage. Der "F1-Score" ist das harmonische Mittel aus Precision und Recall.

Neben der pixelweisen Berechnung der Qualitätsmetriken erfolgt auch die Berechnung in per Mehrheitsentscheid auf Schlagebene aggregierte Werte, da ggf. eine einheitliche Frucht und Bewirtschaftung per Schlag vorausgesetzt werden kann.

5.4 Ergebnisse

Im Folgenden sind die Ergebnisse der Kreuzvalidierungen, differenziert nach den betrachteten Design-Aspekten (Merkmalssets, Zeitfenster, Algorithmus) und ermittelten Qualitätsmetriken aufgeführt. Nach pixelbasierter Bewertung (siehe Tabelle 6) wird die höchste Gesamtgenauigkeit (0.9988) in der Konstellation des längeren Zeitfensters (April des Vorjahres bis September des Jahres der Ernte) unter Verwendung sämtlicher Merkmale (Merkmalsset "Alle") und des Random Forest-Algorithmus erzielt. In Bezug auf die Testläufe innerhalb des verkürzten Zeitfensters (Oktober des Vorjahres bis März des Jahres der Ernte) wird mit dem Merkmalsset "S2" in Kombination mit dem LSTM-Verfahren die höchste Gesamtgenauigkeit (0.9094) erzielt. Insgesamt erzielen Random Forest und LSTM sehr vergleichbare Genauigkeiten.

Im Vergleich der Zeitfenster bestehen deutliche Unterschiede. Die Verkürzung des Zeitfensters führte zu einer erheblichen Reduzierung der Gesamtgenauigkeit im Mittel um 0.1409. In Bezug auf die Auswahl von Satellitensensoren und jeweiligen Kanälen und Indizes lässt sich insbesondere der Mehrwert der Sentinel-2-Daten feststellen. Die Ergänzung der Sentinel-2 um Sentinel-1-Daten bringt in der Anwendung des LSTM und des längeren Zeitfensters sowie des Random Forest-Verfahren mit dem kürzeren Zeitfenster eine weitere Verbesserung, in den anderen - nicht genannten - Konfigurationen jedoch eine Verschlechterung. Die Verwendung von ausschließlich Indizes erscheint aufgrund der Ergebnisse in der Regel nicht ausreichend, was auf einen zu erheblichen Informationsverlust durch in den Indizes nicht (ausreichend) repräsentierten Kanälen zurückzuführen sein könnte.

Ergänzend sind in Tabelle 7 die auf Schlagebene aggregierten Genauigkeiten zusammengefasst. Die Ergebnisse spiegeln größtenteils o.g. Tendenzen wider. In Abweichung fällt jedoch die hohe Gesamtgenauigkeit des Merkmalssets "S1" in Kombination mit dem längeren Zeitfenster und dem LSTM-Verfahren auf. Demnach fallen einzelne, fehlerhafte Pixel bei der Aggregation aller Pixel eines Schlages nicht mehr ins Gewicht, da die Anzahl der korrekt klassifizierten Pixel jeweils den Anteil fehlerhaft klassifizierter Pixel übertrifft (Mehrheitsentscheid). Als Ursache für die größere Streuung in den Ergebnisdaten auf Pixelebene können die komplexen Abhängigkeiten der SAR-Daten von der Aufnahmegeometrie, Oberflächenrauigkeit und Bodenfeuchte sowie spezifisches Rauschen (sog. "Speckle"-Effekt) vermutet werden.

Tabelle 6: Pixel-basierte Klassifikationsgenauigkeit.

Merkmale	Algor.	OA	Zwischenf rucht (ZF) Precision	Zwischenf rucht (ZF) Recall	Zwischenf rucht (ZF) F1-Score	Winterkult ur WK Precision	Winterkult ur WK Rcall	Winterkult ur WK F1- Score
Zeitreihe Apr. (Vorjahr) bis Sep. (Jahr d. Ernte)								
S1	LSTM	0,977	0,988	0,971	0,979	0,963	0,985	0,974
S2	LSTM	0,994	0,999	0,991	0,995	0,989	0,998	0,993
S1S2	LSTM	0,998	1,000	0,997	0,998	0,996	0,999	0,998
Indizes	LSTM	0,962	0,998	0,934	0,965	0,922	0,998	0,959
Alle	LSTM	0,994	1,000	0,989	0,995	0,986	1,000	0,993
S1	RF	0,974	0,974	0,980	0,977	0,974	0,967	0,970
S2	RF	0,998	0,996	1,000	0,998	1,000	0,995	0,998
S1S2	RF	0,996	0,993	0,999	0,996	0,999	0,991	0,995
Indizes	RF	0,973	0,996	0,957	0,976	0,947	0,995	0,970
Alle	RF	0,999	0,999	0,999	0,999	0,999	0,999	0,999
Zeitreihe Okt (Vorjahr) bis Mrz. (Jahr d. Ernte)								
S1	LSTM	0,746	0,774	0,775	0,774	0,711	0,709	0,710
S2	LSTM	0,909	0,906	0,936	0,921	0,914	0,876	0,895
S1S2	LSTM	0,853	0,875	0,861	0,868	0,825	0,842	0,834
Indizes	LSTM	0,856	0,866	0,880	0,873	0,843	0,826	0,834
Alle	LSTM	0,877	0,879	0,906	0,893	0,875	0,840	0,857
S1	RF	0,783	0,811	0,801	0,806	0,749	0,761	0,755
S2	RF	0,849	0,871	0,859	0,865	0,822	0,837	0,829
S1S2	RF	0,850	0,872	0,859	0,866	0,823	0,839	0,831
Indizes	RF	0,871	0,882	0,889	0,885	0,856	0,847	0,852
Alle	RF	0,861	0,888	0,862	0,875	0,830	0,860	0,845
			Anzahl ZF 9346			Anzahl WK 7299		

Tabelle 7: Schlag-basierte Klassifikationsgenauigkeit.

Merkmale	Algor.	OA	Zwischenf rucht (ZF) Precision	Zwischenf rucht (ZF) Recall	Zwischenf rucht (ZF) F1-Score	Winterkult ur (WK) Precision	Winterkult ur (WK) Recall	Winterkult ur (WK) F1-Score
Zeitreihe Apr. (Vorjahr) bis Sep. (Jahr d. Ernte)								
S1	LSTM	1,00	1,00	1,00	1,00	1,00	1,00	1,00
S2	LSTM	1,00	1,00	1,00	1,00	1,00	1,00	1,00
S1S2	LSTM	1,00	1,00	1,00	1,00	1,00	1,00	1,00
Indizes	LSTM	0,97	1,00	0,94	0,97	0,93	1,00	0,96
Alle	LSTM	1,00	1,00	1,00	1,00	1,00	1,00	1,00
S1	RF	0,98	0,97	1,00	0,98	1,00	0,96	0,98
S2	RF	1,00	1,00	1,00	1,00	1,00	1,00	1,00
S1S2	RF	0,98	0,97	1,00	0,98	1,00	0,96	0,98
Indizes	RF	0,98	1,00	0,97	0,98	0,96	1,00	0,98
Alle	RF	1,00	1,00	1,00	1,00	1,00	1,00	1,00
Zeitreihe Okt (Vorjahr) bis Mrz. (Jahr d. Ernte)								
S1	LSTM	0,83	0,84	0,84	0,84	0,81	0,81	0,81
S2	LSTM	0,91	0,93	0,90	0,92	0,89	0,93	0,91
S1S2	LSTM	0,86	0,90	0,84	0,87	0,83	0,89	0,86
Indizes	LSTM	0,86	0,90	0,84	0,87	0,83	0,89	0,86
Alle	LSTM	0,86	0,87	0,87	0,87	0,85	0,85	0,85
S1	RF	0,79	0,81	0,81	0,81	0,78	0,78	0,78
S2	RF	0,86	0,87	0,87	0,87	0,85	0,85	0,85
S1S2	RF	0,88	0,90	0,87	0,89	0,86	0,89	0,87
Indizes	RF	0,86	0,87	0,87	0,87	0,85	0,85	0,85
Alle	RF	0,88	0,90	0,87	0,89	0,86	0,89	0,87
						Anzahl ZF 31		Anzahl WK 27

5.5 Merkmalswichtigkeit

Auf Basis eines trainierten Random Forest-Modells lässt sich über das "Mean Decrease Impurity"-Verfahren die Bedeutung der im Modell verwendeten Klassifikationsmerkmale bewerten (Hastie et al., 2009). Hierbei wird per Klassifikationsmerkmal die gewichtete Abnahme eines Maßes zur Ungleichverteilung (hier: Gini-Koeffizient) durch entsprechende Knotenpunkte der Entscheidungsbäume (gemittelt über sämtliche Entscheidungsbäume des Random Forest Ensembles) addiert.

Abbildung 17 listet die die 30 wichtigsten (der insgesamt 684) Klassifikationsmerkmale auf. Das wichtigste Merkmal ist der "NDVI 1. Mai JJJJ" (Intervall erste Monathälfte Mai), gefolgt von Band 6 und 12 des gleichen Zeitpunktes ("B06 1. Mai JJJJ", "B12 1. Mai JJJJ"). Bei der Betrachtung der Merkmalswichtigkeiten fällt die große Anzahl von Merkmalen aus der ersten und zweiten Maihälfte auf, was aufgrund der unterschiedlichen Anbau-/Vegetationsphasen von Zwischenfrüchten und Winterkulturen sowie der in Kapitel 4.1 dargestellten Verläufe des NDVI plausibel erscheint.

Der Eindruck bestätigt sich bei Betrachtung der Merkmalswichtigkeit gruppiert nach Zeitpunkten bzw. halbmonatlichen Intervallen (Abbildung 18). Es zeigt sich, dass diskriminierende Merkmale vor allem aus Satellitenszenen vom Mai, Juni und August des Jahres der Ernte abgeleitet sind. Abbildung 19 listet die Merkmalswichtigkeit gruppiert nach Kanälen/Indizes -- d.h. über die Zeitachse aggregiert -- auf. Die größte Wichtigkeit fällt auf Sentinel-2 basierte Indizes (NDVI, NDWI, NDTI, PSRI), gefolgt von Sentinel-2 basierten Kanälen. Der Beitrag von Sentinel-1 erscheint demnach eher untergeordnet.

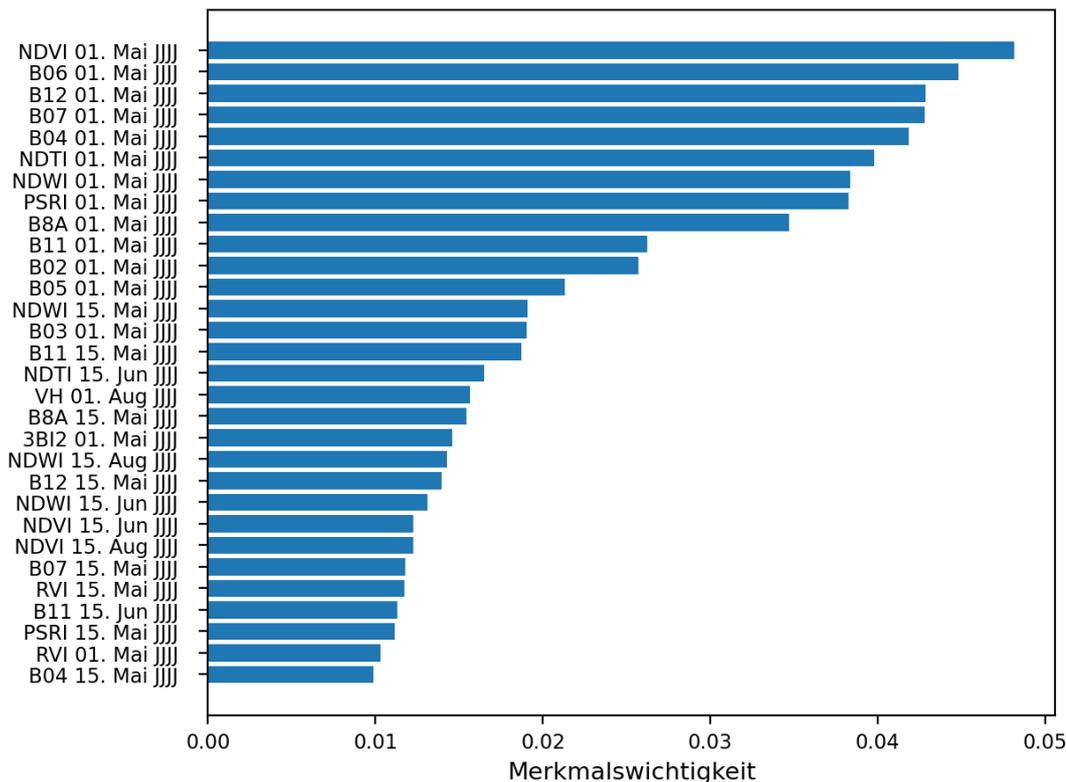


Abbildung 17: Wichtigkeit ("Mean Decrease Impurity") der Klassifikationsmerkmale. Die Zeitstempel (z.B. "01. Mai JJJJ") bezeichnen die linke Bande eines halbmonatlichen Zeitintervalls; "JJJJ" = Jahr der Ernte, "JJJJ-1" = Vorjahr

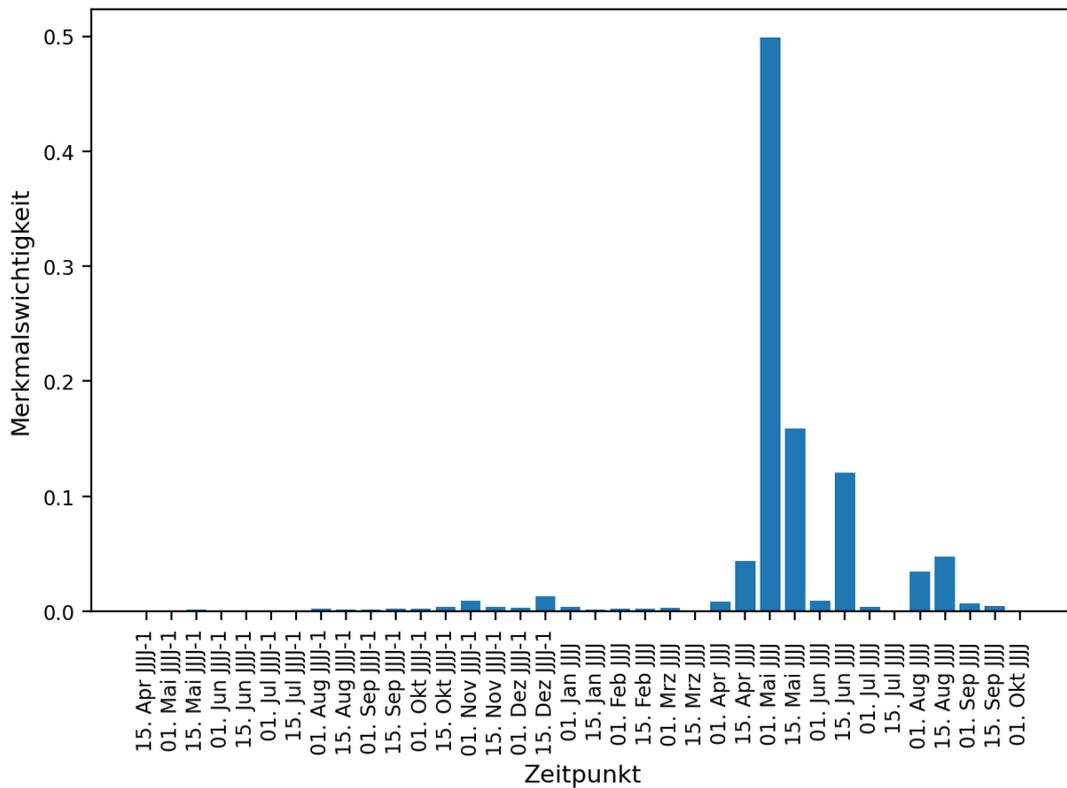


Abbildung 18: Wichtigkeit ("Mean Decrease Impurity") der Klassifikationsmerkmale gruppiert nach Zeitpunkten (d.h. Aufsummierung der Merkmalswichtigkeit einzelner Kanäle/Indizes per Zeitpunkt).

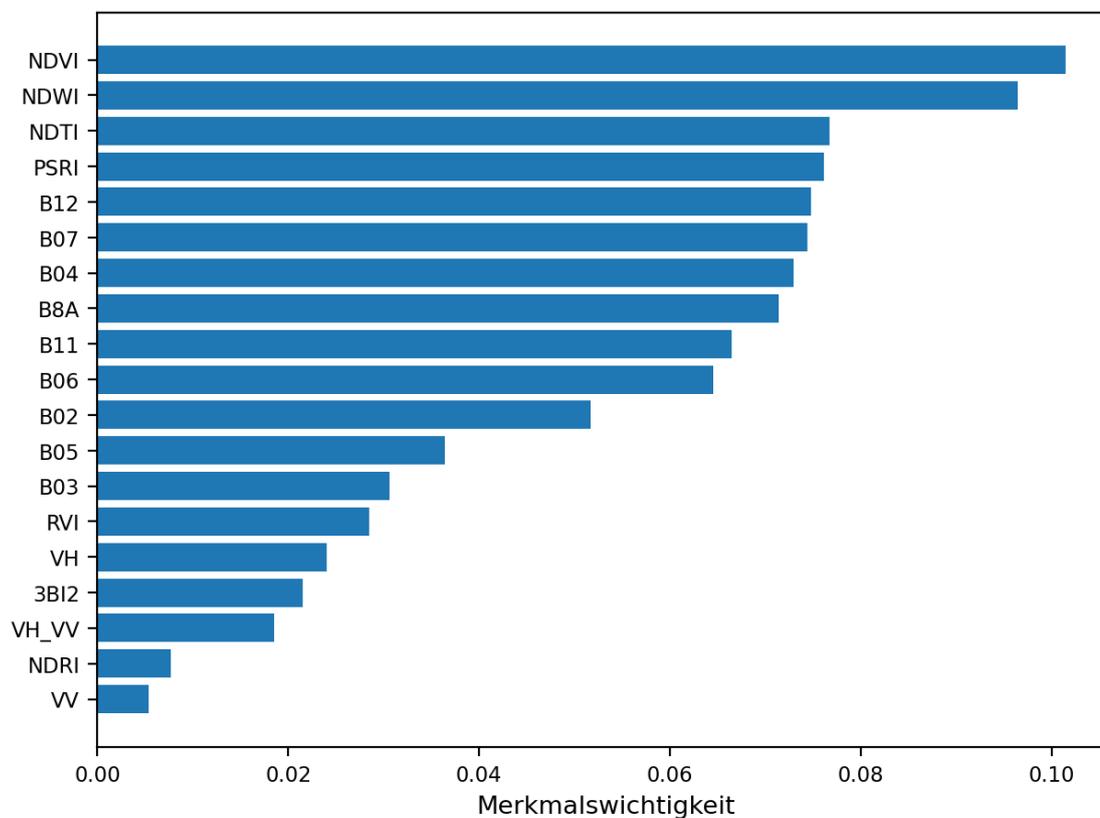


Abbildung 19: Wichtigkeit ("Mean Decrease Impurity") der Klassifikationsmerkmale gruppiert nach Kanälen/Indizes (d.h. Aufsummierung der Merkmalswichtigkeit einzelner Zeitpunkte je Kanal/Index).

6 Grundsätzliche Identifizierbarkeit der Zielobjekte

6.1 Bezogen auf Zielobjekte

Basierend auf den Ergebnissen der vorherigen Untersuchungen wird eine Einschätzung der grundsätzlichen Identifizierbarkeit der Zielobjekte aus den Fernerkundungsdaten durchgeführt. Dabei fließen die Ergebnisse aus den Untersuchungen zur automatischen Identifizierbarkeit der Zielobjekte mit Hilfe der herkömmlichen Klassifikationsverfahren genauso ein wie mit Hilfe der Deep Learning Methoden. Zudem werden die Untersuchungen der visuellen Identifizierbarkeit der Zielobjekte herangezogen, genauso wie die Literaturrecherche.

Aus den automatischen Klassifikationsverfahren (siehe Kapitel 5) ergab sich, dass eine sehr gute Trennung zwischen Zwischenfrüchten (ZF) und Winterkulturen (WK) möglich ist. Dies lässt sich auf Basis der anteilmäßig hohen Zahl von Referenzdaten feststellen. Dabei hat sich hier keine der verwendeten automatischen Klassifikationsverfahren als signifikant besser erwiesen. Dies ist jedoch auch nicht verwunderlich, da die Deep Learning Verfahren ihre Stärke erst bei einer großen Zahl an Stichproben für die Lernregionen (Referenzflächen) ausspielen. Dies ist in dieser Studie nicht gegeben und war auch nicht geplant. Aus diesem Grunde war dieses Ergebnis so zu erwarten. Als Verfahren können sowohl das Random Forest Verfahren, als auch das Deep Learning Verfahren empfohlen werden, wobei mit einer zunehmenden Menge an Referenzdaten die Deep Learning Verfahren ihre Vorteile zeigen. Bei einer geringen Menge an Referenzdaten kann das Anlernen der Deep Learning Verfahren gar nicht durchgeführt werden.

Aus der Literaturrecherche in Abschnitt 0 hat sich ergeben, dass eine Trennung zwischen konventioneller Bodenbearbeitung („conventional-tillage“) und schonender Anbaupraxis ohne Bodenbearbeitung („zero-tillage“) möglich ist. Hieraus interpretieren wir, dass eine Unterscheidung zwischen konservierender Bodenbearbeitung (kBB+) und Umbruch möglich sein sollte. Zudem hat die visuelle Überprüfung der Identifizierbarkeit der Zielobjekte in Abschnitt 4.2 bestätigt, dass sich voraussichtlich die Fälle mit konservierender Bodenbearbeitung (kBB+) aus den Fernerkundungsdaten identifizieren lassen. Aus diesem Grunde wird hier ebenfalls die Nutzung einer automatischen Klassifikation für die Identifizierung der Klassen kBB+ und Umbruch empfohlen, wobei diese Empfehlung sich auf die Literatur und die visuelle Überprüfung einer geringen Menge an Flächen stützt und somit mit einer gewissen Unsicherheit verbunden ist.

Zur Unterscheidbarkeit zwischen den Zielobjekten der konservierenden Bodenbearbeitung und der gemeinsamen Klasse Stoppel/Mulch ist auf Basis der Literaturrecherche die Einschätzung, dass hier eine Unterscheidung möglich sein sollte, indem der Anteil der Totaufgaben (Crop Residue Cover, CRC) dafür verwendet wird. Dazu wurde in Abschnitt 3.3 ein Verfahren dargestellt, mit dem sich der Anteil des CRCs ermitteln lässt. Aus der Literaturrecherche hat sich nicht gezeigt, dass eine direkte Unterscheidung zwischen Stoppel und Mulch möglich ist. Jedoch könnte nach unserer Einschätzung zur weiteren Unterscheidung die Vorinformation verwendet werden, welche Fruchtart vorher angebaut worden ist.

6.2 Einflüsse auf Identifizierbarkeit

6.2.1 Einfluss der Schlaggeometrie

In diesem Abschnitt soll dargestellt werden, inwieweit die Schlaggeometrie einen Einfluss auf die grundsätzliche Identifizierbarkeit der Zielobjekte haben kann. Hierbei sind die Größe, die Form und die Komplexität der Schläge zu berücksichtigen. Die Schläge, die im Rahmen dieser Untersuchung als Referenzen zur Verfügung standen, haben aufgrund ihrer Geometrie keinen Einfluss auf die Identifizierbarkeit gezeigt. Allerdings lagen bei den Geometrien auch keine Extremfälle vor, die einen Einfluss auf die Identifizierbarkeit erwarten ließen. Daher soll der Einfluss an dieser Stelle auf Basis der Theorie und der Erfahrung dargestellt werden.

Es gibt einen Einfluss der Schlaggröße auf die Identifizierbarkeit. Grundsätzlich ist bereits ein Pixel ausreichend, um eine Klassifikation durchzuführen. Jedoch nimmt mit zunehmender Anzahl der Pixel eines Schlages die Sicherheit der Klassifikation zu, da innerhalb eines Schlages eine Mehrheitsentscheidung getroffen wird, welches Objekt vorliegt.

Zudem besteht ein Einfluss auf die Identifizierbarkeit bei sehr schmalen Objekten, wenn sich die Objektbreite im Bereich der Bodenpixelgröße des Sensors befindet. Grundsätzlich möchte man den Einfluss der Randpixel der Schläge verringern. Aus diesem Grunde wird eine Innenpufferung durchgeführt.

Dabei ist zu berücksichtigen, mit welchen Fernerkundungsdaten gearbeitet wird. Die primären Fernerkundungsdaten, die dieser Studie zugrunde liegen, sind Sentinel-2-Daten. Die wesentlichen der Auswertung zu Grunde liegenden Spektralbänder von Sentinel-2 (z.B. in den sog. "Rededge"- und kurzwelligen Infrarotbereichen des elektromagnetischen Spektrums) liegen in einer Auflösung von 20 m vor. Bei Sentinel-1 ist die Auflösung besser. Des weiteren zu berücksichtigen sind die Positionsfehler der Satellitendaten (i.d.R. bis zu 8 m bei Sentinel-2 (Clerc, 2021) sowie der Schlagdaten selbst. Wie in Abbildung 20 zu erkennen ist eine Innenpufferung von mind. 20 m empfehlenswert, um Randeffekte/Mischpixel auszuschließen.

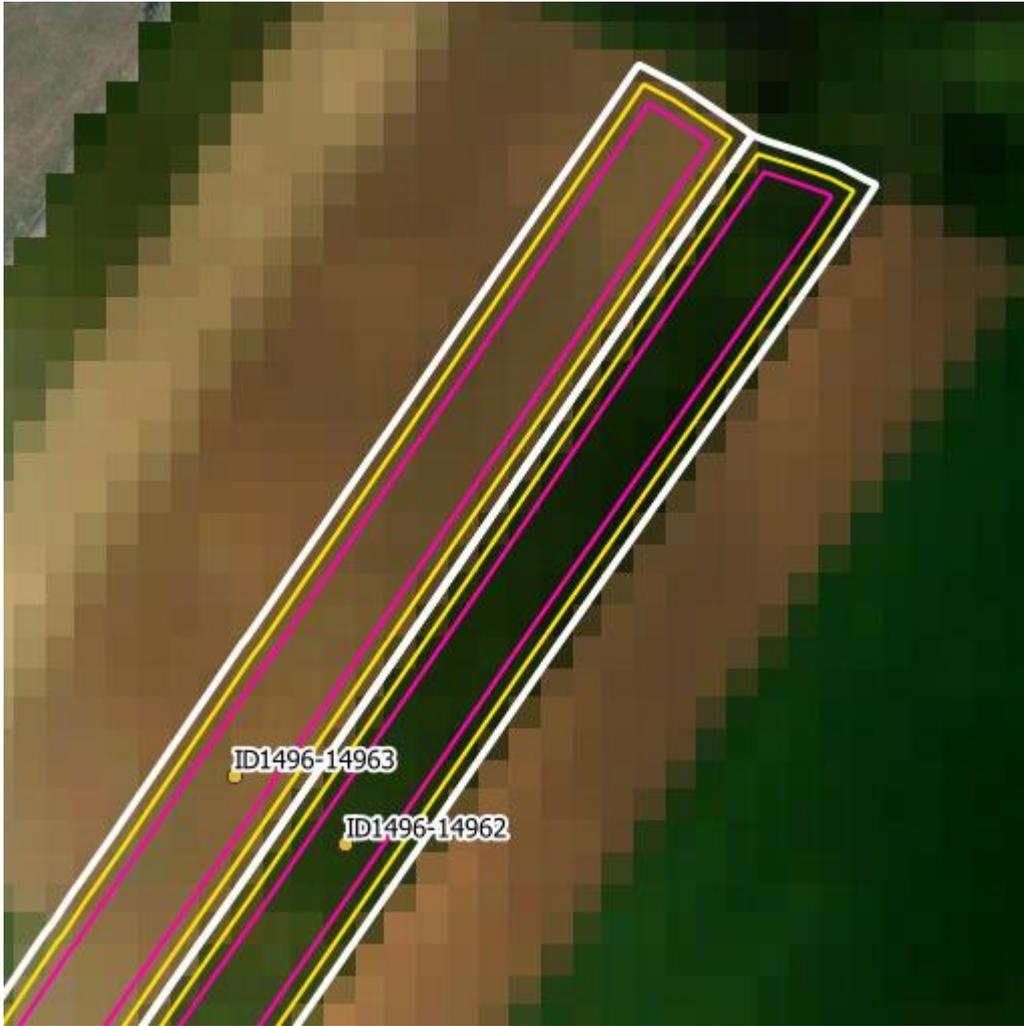


Abbildung 20: Sentinel-2-Szene in 20 m Rasterauflösung mit überlagerter Schlaggeometrie (weiß) sowie 10 m Innenpufferung (gelb) und 20 m Innenpufferung (pink).

Bezogen auf die gesamte landwirtschaftliche Ackerfläche Sachsens ergibt sich bei einer definierten Mindest erfassungsgröße von 0,5 Hektar (der innengepufferten Schlaggeometrien) eine auswertbare Fläche von 707.195,89 Hektar. Dem gegenüber steht eine Fläche von 4.776,48 Hektar, die sich aus Schlägen unterhalb der Mindest erfassungsgröße zusammensetzt. Bei einer konservativeren Festsetzung der Mindest erfassungsgröße von einem Hektar verblieben 702.020,96 Hektar auswertbare und 9951,41 Hektar nicht auswertbare Fläche. Bei der Innenpufferung werden komplexe Geometrien etwas geglättet.

Durch die Innenpufferung wird der Einfluss der Randpixel verringert bzw. eliminiert. Auf diese Art und Weise spielt die Länglichkeit der Objekte keine weitere Rolle. Demgegenüber wirkt sich die Komplexität der Form erst dann auf die Identifizierbarkeit aus, wenn sie dazu führt, dass der Schlag uneinheitlich bearbeitet wird.

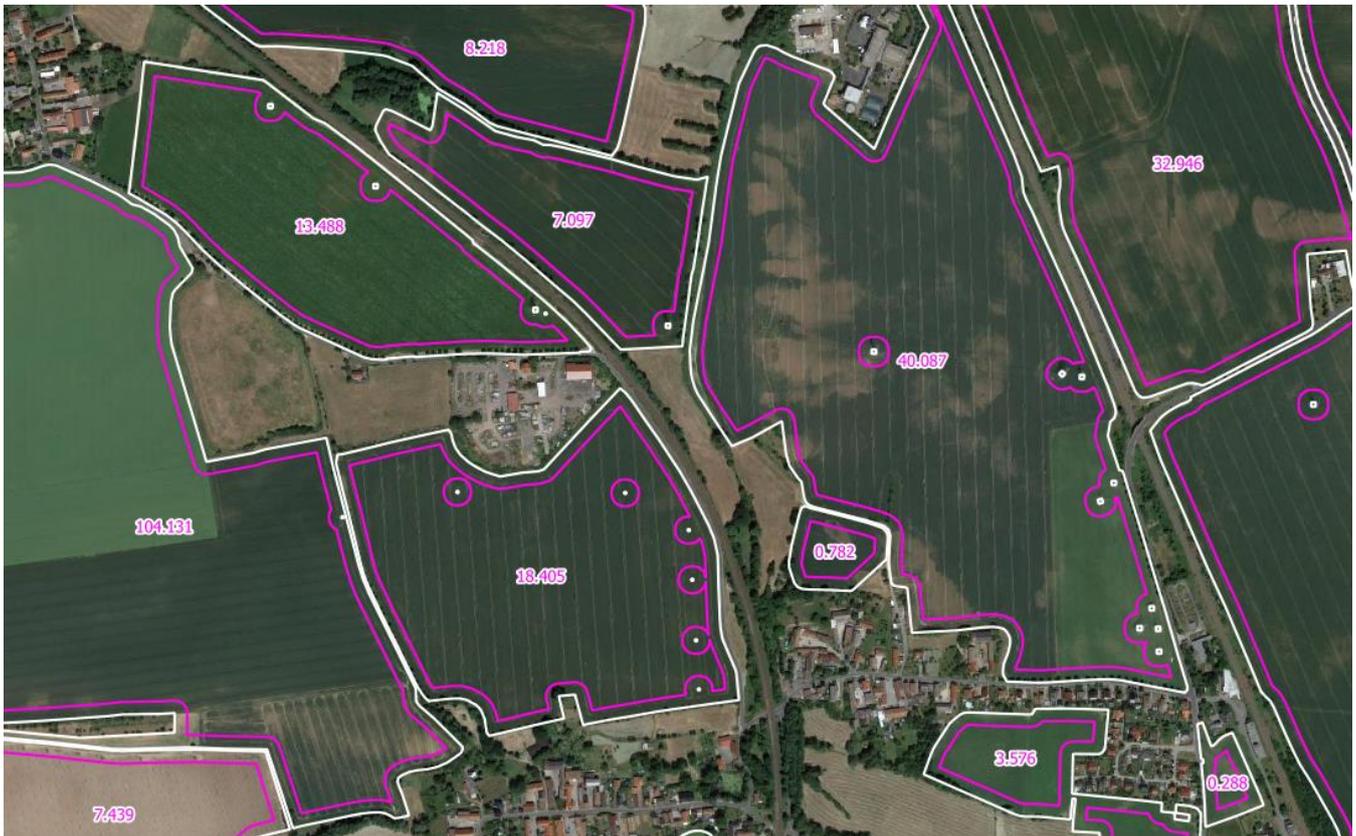


Abbildung 21: Darstellung originaler Schläge (weißer Umriss) und der 20 m nach innen gepufferten, potenziell auswertbaren Fläche (pink). Die innengepufferten Flächengrößen je Schlag sind in Hektar angegeben.

6.2.2 Übertragung der Verfahren auf Gebiete mit unterschiedlichen landschaftsräumlichen Charakteristiken

Im Rahmen dieser Untersuchung werden Verfahren vorgeschlagen, die verschiedene Schläge zu Zielobjekten klassifizieren. Um die Klassifikation durchführen zu können, wird der Klassifikator zuvor angelernt. Dazu werden Referenzflächen verwendet, zu denen die Zuordnung zu den Zielobjekten bekannt ist. Der Anlernvorgang betrifft sowohl die spektralen Eigenschaften der Flächen als auch den zeitlichen Verlauf. Wenn das Gebiet mit den zum Anlernen genutzten Referenzflächen andere landwirtschaftliche Bearbeitungszeiten hat als die Flächen, die schließlich klassifiziert werden, kann dies zu Fehlern führen.

Das bedeutet, dass es zu Fehlklassifikationen kommen kann, wenn sich die für das Anlernen verwendeten Referenzen in einem Gebiet mit anderen landschaftsräumlichen Charakteristiken befinden (insbesondere andere Bearbeitungszeiten der Flächen) als die Flächen, die es zu klassifizieren gilt. In diesem Fall sollte bei der Auswahl der Referenzflächen darauf geachtet werden, möglichst alle landschaftsräumlichen Charakteristiken zu inkludieren. Sind die Unterschiede jedoch zu groß, kann dies dazu führen, dass die Klassifikatoren nicht gut angelernt werden können. Es wird erwartet, dass die Deep Learning Methoden besser mit derartigen Inhomogenitäten umgehen können als die klassischen Klassifikationsverfahren, wie z.B. Random Forest.

7 Aufbau und technische Randbedingungen eines Monitoringprogramms

7.1 Modellaufbau

In diesem Abschnitt soll eine Einschätzung vorgenommen werden, wie ein Monitoringprogramm aufgebaut werden kann und welche Schritte notwendig sind, um die Zielobjekte in einem kontinuierlichen Verfahren zu identifizieren.

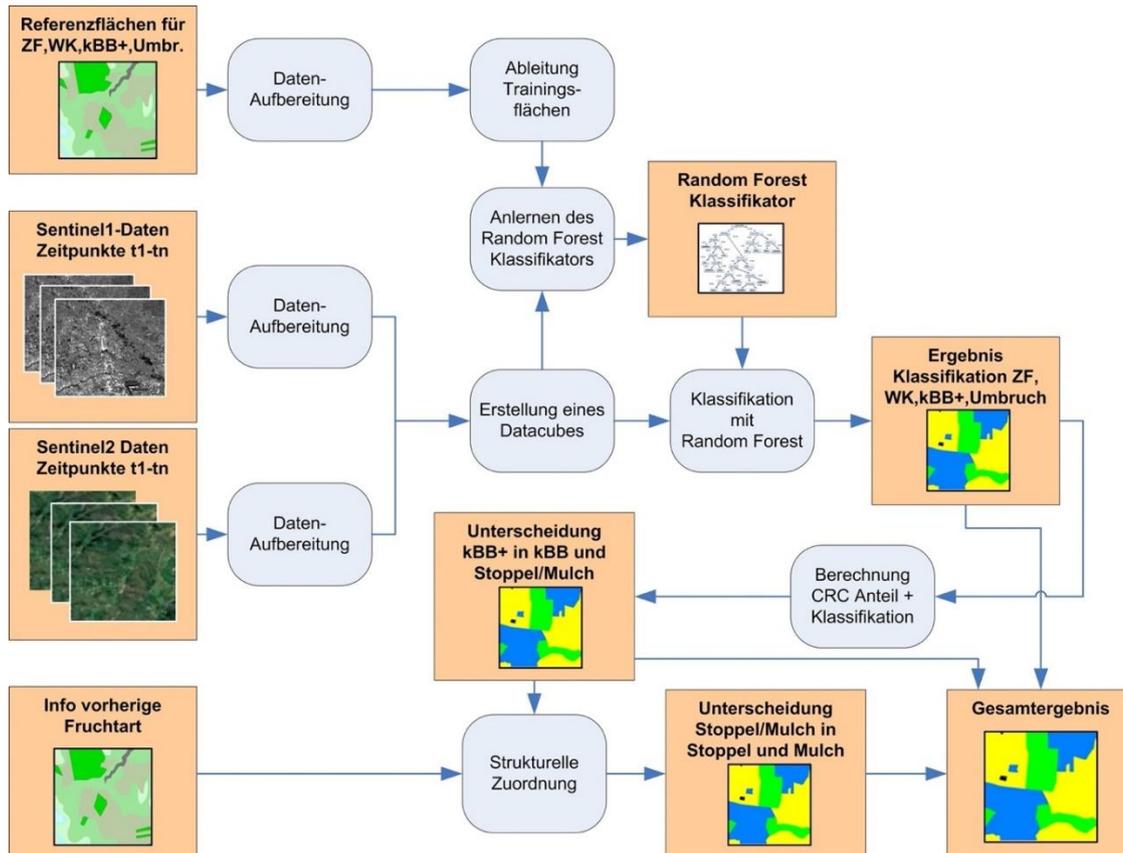


Abbildung 22 enthält ein Vorschlag für den Modellaufbau eines Monitoringprogramms. Basis des Monitoringprogramms ist, ausgehend von den Beschreibungen im vorhergehenden Kapitel, eine Random Forest Klassifikation (oder alternativ eine Deep Learning Klassifikation) in die vier Klassen ZF, WK, Umbruch und kBB+.

Hierzu werden Referenzdaten benötigt, die als Eingang zum Anlernen des Klassifikators verwendet werden. Dieser Klassifikator wird dann genutzt, um die Klassifikation nach dem Anlernvorgang über die Fläche in diese vier Klassen durchzuführen. Damit sind ZF, WK und Umbruch klassifiziert, die Klasse kBB+ besteht jedoch noch aus den Klassen kBB, Mulch und Stoppel. In einem nächsten Schritt kann eine Trennung zwischen kBB und einer gemeinsamen Klasse Mulch/Stoppel durchgeführt werden, indem der CRC-Anteil berechnet wird und über die Information, ob Totmaterial auf der jeweiligen Fläche liegt oder nicht, diese Zuordnung getroffen werden kann. In einem abschließenden Schritt könnte zur Unterscheidung, ob auf der jeweiligen Fläche Stoppel oder Mulch liegt, die Vorinformation verwendet werden, welche Fruchtart auf der Fläche vorher angebaut wurde. Auf diese Art können

die verschiedenen Klassen über die verschiedenen Stufen identifiziert werden.

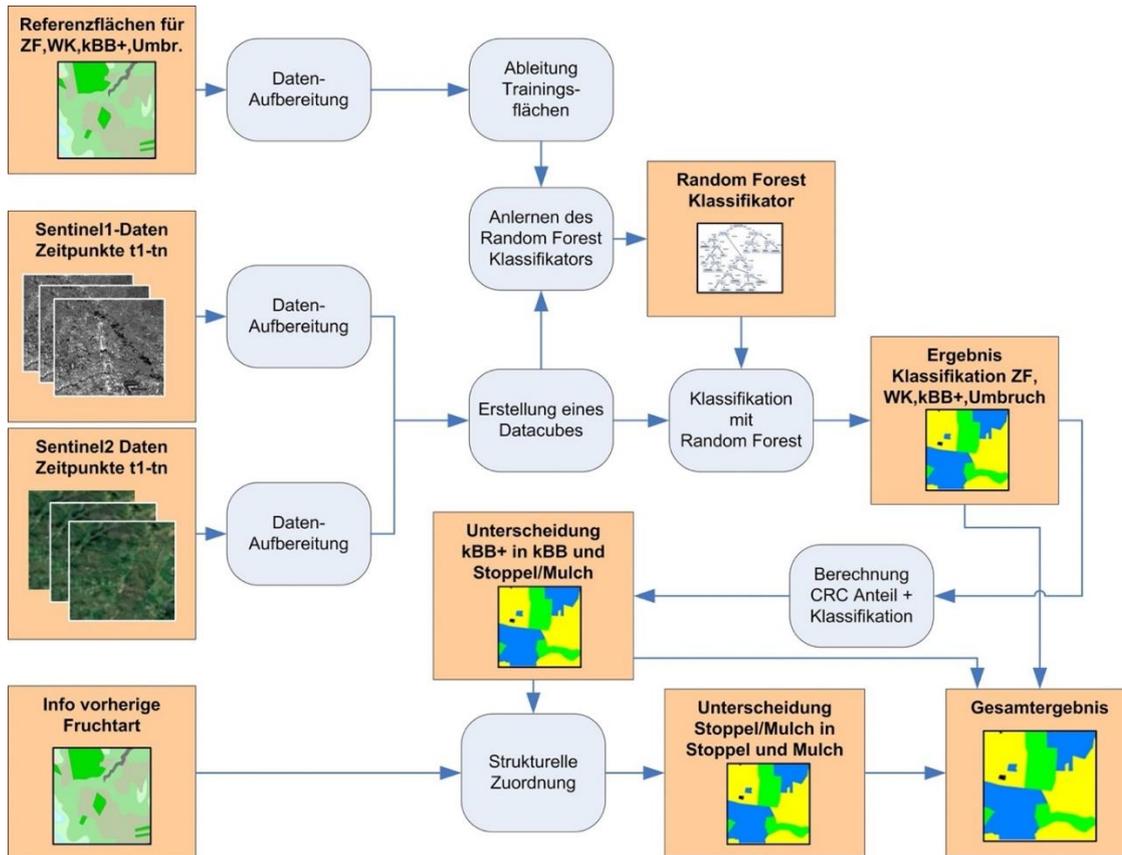


Abbildung 22: Vorschlag für die Struktur eines Monitoringprogramms

7.2 Systemarchitektur

In Abbildung 23 und Abbildung 24 sind ein Vorschlag für die Systemarchitektur des Monitoringprogramms dargestellt. Hier wurden die Teile "Anlernen des Klassifikators" und "Monitoring" bewusst getrennt, weil es verschiedene Verknüpfungsmöglichkeiten dazu gibt.

In Abbildung 23 ist dargestellt, wie die Systemarchitektur für das Anlernen des Klassifikators aufgebaut ist. Das Anlernen des Klassifikators ist eine Voraussetzung, um später eine Klassifikation im Rahmen des Monitorings auf Basis der Fernerkundungsdaten durchführen zu können. Dazu muss der Klassifikator lernen, wie sich die verschiedenen Zielklassen zeitlich und spektral verhalten. Daher werden die Fernerkundungsdaten vom ESA Hub automatisiert mittels eines Sentinel Loaders heruntergeladen und aufbereitet. Dabei wurden in dieser Machbarkeitsstudie zwei Zeiträume untersucht, die für die Klassifikation verwendet werden können: 17 Monate und 6 Monate. Die Ergebnisse bei Nutzung von 17 Monaten waren besser als die bei Nutzung von 6 Monaten. Aus diesem Grunde wird dieser Zeitraum favorisiert. Aus den heruntergeladenen und aufbereiteten Sentinel-1 und Sentinel-2 Bildern werden daraufhin Databubes erstellt, die für den Anlernvorgang des Klassifikators genutzt werden. Auf der anderen Seite sind für das Anlernen Referenzen notwendig. Dazu werden die Schlaggrenzen mit Informationen, wie deren Zuordnung zu den Zielobjekten ist, benötigt. Diese werden als Trainings- und als Validierungsdaten verwendet. Mit den Trainingsdaten und den Fernerkundungsdaten erfolgt ein Anlernen des Klassifikators, die Validierungsdaten werden verwendet um herauszufinden, wie gut der Klassifikator angelernt wurde. Das Ergebnis dieses Vorgangs ist der angelernte Klassifikator.

Die Frage, welcher Klassifikator hier verwendet werden soll, ist von zwei Komponenten abhängig: Zum einen von dem Gesamtsystemaufbau und der Strategie (dazu weiter unten mehr) und zum anderen von der Menge an Referenzdaten. Wenn man beispielsweise den Random Forest Klassifikator als ein gutes Beispiel für die klassischen Klassifikationsverfahren nimmt und auf der anderen Seite Neuronale Netze als Deep Learning Verfahren als Repräsentant der "modernen" Verfahren (beides wurde in dieser Studie untersucht), kann man sagen, dass die Neuronale Netze sehr viel mehr Trainingsdaten benötigen als der Random Forest Klassifikator. Bei Neuronale Netze sollte man sinnvollerweise von einer Größenordnung von tausenden von Trainingsflächen pro Zielklasse ausgehen, beim Random Forest Klassifikator deutlich weniger.

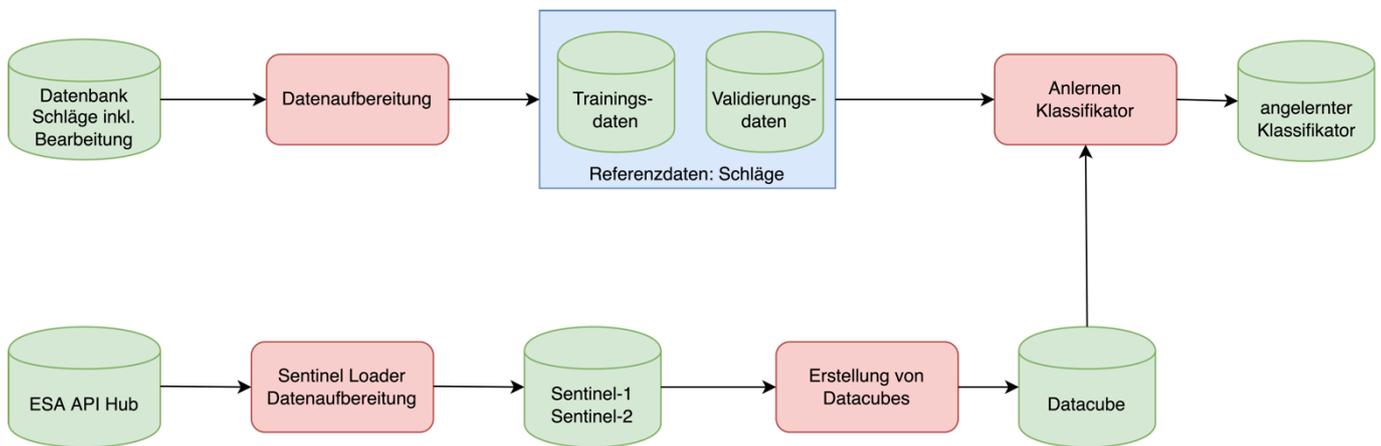


Abbildung 23: Systemarchitektur Anlernen des Klassifikators

Eine wichtige Fragestellung bei der Entscheidung, welcher Klassifikator verwendet werden soll, ist die Strategie des Gesamtsystems. Bei den meisten heute operationell genutzten fernerkundungsbasierten Klassifikationssystemen wird für jedes neue Monitoring-Jahr ein Anlernen des Klassifikators mit den neuen Fernerkundungsdaten durchgeführt, die auch für die Klassifikation verwendet werden sollen. Das bedeutet, dass der Klassifikator an die zu verwendenden Fernerkundungsdaten direkt angepasst werden. Das hieße aber auch, dass für jedes neue Monitoring-Jahr aktuelle Referenzdaten benötigt werden. So aufgebaute Systeme befinden sich im operationellen Einsatz und sie funktionieren.

Wenn das System jedoch so aufgebaut werden soll, dass nicht jedes Jahr neue Referenzen notwendig sein sollen, besteht die Möglichkeit zu versuchen, den Klassifikator vorab mit einer großen Menge an Trainingsdaten anzulernen und diesen dann für die Klassifikation der neuen Zeitpunkte zu nutzen. Hierzu würde sich am ehesten ein Ansatz mit Neuronale Netze eignen, da diese mit größeren Variationen innerhalb der Klassen besser umgehen können. Derartige Systeme, die vorab angelern werden und dann ohne erneutes Anlernen zur Klassifikation verwendet werden, sind aktuell noch Gegenstand von Forschung und Entwicklung. Es besteht jedoch die Einschätzung, dass ein derartiges System funktionieren könnte, wenn zum Anlernen ausreichend Referenzen genutzt werden. Dies müsste in einer weiteren Studie untersucht werden.

In Abbildung 24 ist die Systemarchitektur für das Monitoring dargestellt. Der angelernete Klassifikator wird entweder jedes Jahr neu angelern oder nur ein mal vorab, wie oben beschrieben. Für das Monitoring liegen i.d.R. immer die Feldblöcke vor. Diese sind als Eingangsdaten dargestellt. Was jedoch benötigt wird, sind die Schläge, die einheitlich bewirtschaftet werden. Daher ist eine Resegmentierung notwendig. Für die Resegmentierung werden die Fernerkundungsdaten des Beobachtungszeitraums verwendet und geprüft, welche Teilflächen innerhalb der Feldblöcke einheitlich sind. So zerfallen die Feldblöcke im Rahmen der Resegmentierung in einheitliche Teilflächen. Diese Teilflächen stellen für das System die Schläge dar, die es nun zu identifizieren gilt. Diese Schläge gehen

zusammen mit den aus den Sentinel-Daten erstellten Datacubes in die multispektrale, multitemporale Klassifikation hinein. Das Ergebnis ist die Zuordnung der Schläge zu den Zielklassen der Stufe 1. Im Ergebnis der Stufe 1 sind alle Klassen, die direkt mit der Klassifikation identifiziert werden können, enthalten.

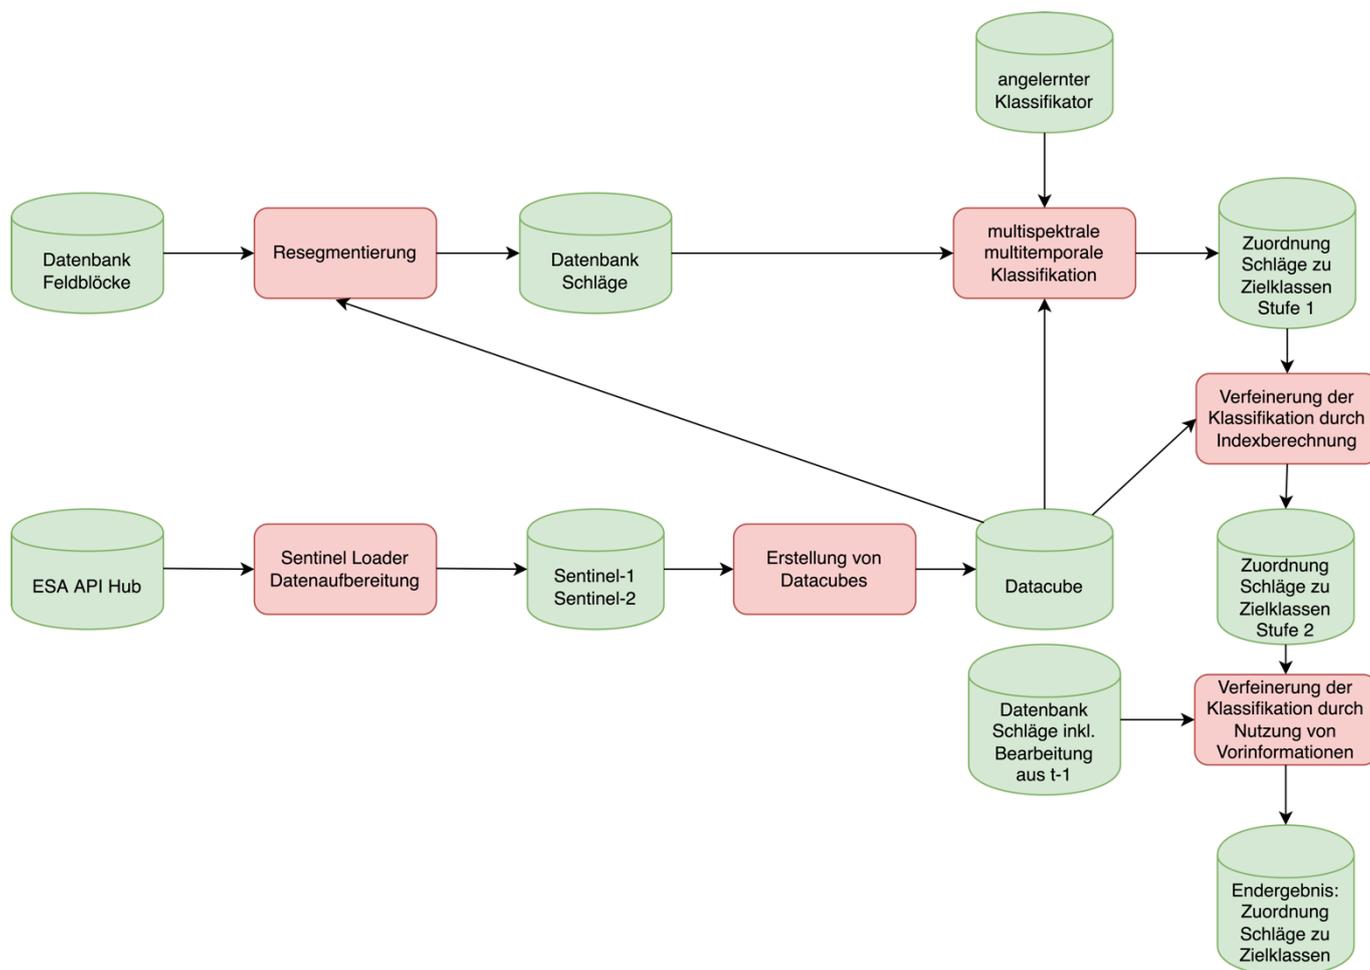


Abbildung 24: Systemarchitektur Monitoring

Da sich in der Studie ergeben hat, dass einige Klassen mit Hilfe von Indizes (hier CRC) weiter aufteilen lassen, ist an dieser Stelle eine Verfeinerung der Klassifikation durch Indexberechnung integriert worden. Es ist durchaus möglich, dass dieser Schritt nicht notwendig ist, da er bereits mit der Klassifikation im Schritt vorher abgegolten ist, insbesondere wenn die relevanten Indizes in den Datacube integriert werden. Dies könnte in einer weiteren Studie mit ausreichenden Referenzdaten separat geprüft werden.

Schließlich ist davon auszugehen, dass die Nutzung von Vorinformationen, was sich vorher auf dem jeweiligen Schlag befunden hat, zu einer weiteren Verfeinerung der Klassifikation genutzt werden kann. Dies ist ebenfalls dargestellt und führt letztlich zum Endergebnis.

7.3 Informationstechnische Infrastruktur zur Datenverarbeitung und notwendige Software

Für die informationstechnische Infrastruktur zum Aufbau eines Monitoringsystems gibt es zwei Möglichkeiten. Zum einen kann eine gut ausgestattete Workstation verwendet werden, um die notwendigen Monitoringfunktionen durchzuführen. Eine Beispielausstattung einer derartigen Workstation (ohne Monitor) ist in Tabelle 8 dargestellt.

Tabelle 8: Beispielkomponenten für eine Workstation

Komponente
RAM 2 x 32GB, DualChannel, 3200MHz, unbuffered für MSI Tomahawk Z490
SSD Gigabyte AORUS M22000GB M.2 2280 PCIe 4.0 x4 NVMe 1.3 3D-NAND TLC (GP-ASM2NE6200TTTD)
CPU Intel Core i9 10850K - 3.6 GHz - 10 Kerne - 20 Threads - 20 MB Cache-Speicher - LGA1200 Socket - Box
Grafikkarte Zotac GeForce RTX 3090 Trinity OC 24GB GDDR6X
Mainboard MSI MAG Z490 TOMAHAWK - Motherboard - ATX - LGA1200-Socket - Z490
CPU-Kühler Noctua NH-D15, Premium CPU Kühler mit 2X NF-A15 PWM 140mm Lüftern (Braun)
Netzteil Corsair HX1000i 1000 Watt
Gehäuse Corsair Carbide Series 200R PC-Gehäuse (Mid-Tower ATX Performance), schwarz
Festplatte Synology HAT5300 - Festplatte - 8 TB - intern - 3.5" (8.9 cm) - SATA 6Gb/s - 7200 U/min - Puffer: 256 MB

Eine alternative Möglichkeit ist die Nutzung einer oder mehrerer Workstations in der Cloud. Hierzu werden die benötigten Rechenkomponenten der Workstation in der Cloud angemietet. Der Vorteil der Berechnung in der Cloud ist, dass viele Anbieter eine direkte Verbindung zu den Copernicus-Daten anbieten, somit entfällt das zeitaufwändige herunterladen. Zudem lassen sich i.d.R. die Berechnungen skalieren und somit an die aktuell benötigte Rechenkapazität anpassen.

7.4 Anfallende Datenmengen

Die anfallenden Datenmengen können auf Basis der in dieser Studie verwendeten Ergebnisse abgeschätzt werden. In Abschnitt 5.1 wurden zwei Zeiträume definiert, für die die Sentinel-Daten genutzt wurden für die Klassifikation: 17 Monate und 6 Monate. Die Ergebnisse der Klassifikation bei Verwendung der Daten über einen Zeitraum von 17 Monaten war besser. Daher werden 17 Monate hier angesetzt. In Tabelle 9 sind die geschätzten Datenmengen dargestellt.

Tabelle 9: Anfallende Datenmengen

	Sentinel-1 (GRD)	Sentinel-2	Schläge
Größe 1 Szene	Ca. 1GB	Ca. 1GB	
Abdeckung Sachsen	2 Szenen	5 Szenen	
Anzahl Szenen für 17 Monate	Ca. 170	Ca. 500	
Schätzung der aufgrund der Wetterlage nutzbaren Szenen	wetterunabhängig	Ca. 30% ⇒ 150	
Gesamtdatenmenge Rohdaten	170GB	150GB	<1GB
Gesamtdatenmenge für Prozessierung (Zwischenprodukte)	340GB	300GB	<1GB
Ergebnisdaten			<1GB

Für die Zwischenprodukte wurden aus der Erfahrung heraus 200% der Rohdatenmenge angesetzt. Wie zu erkennen ist, fallen insgesamt knapp 1TB an Daten an. Mit der unter 7.3 vorgeschlagenen Workstation kann diese Datenmenge gut und mit Redundanz verarbeitet werden.

8 Zusammenfassung

Im Rahmen dieser Machbarkeitsstudie war es das Ziel, Verfahren zu ermitteln, mit denen sich stoffeintragsmindernde Maßnahmen der Landbewirtschaftung sowie bestimmte Bewirtschaftungscharakteristiken bedeckter Ackerflächen mittels Fernerkundung identifizieren lassen. Zusätzlich sollten die Rahmenbedingungen für den Aufbau eines Monitoringprogramms zur kontinuierlichen Identifikation der landwirtschaftlichen Maßnahmen untersucht werden. Zu diesem Zweck wurden Zielklassen definiert, zu denen untersucht werden sollte, ob sie aus den Fernerkundungsdaten identifizierbar sind. Es wurden Fernerkundungsdaten von Sentinel-1 und Sentinel-2 aus dem Europäischen Copernicus-Programm verwendet. Zudem wurden für ein Testgebiet Referenzdaten samt Informationen zur Bewirtschaftung über einen Zeitraum von mehreren Jahren zur Verfügung gestellt.

Für die Ermittlung der Identifizierbarkeit der Zielobjekte wurden drei Untersuchungen durchgeführt: Zunächst erfolgte eine Literaturrecherche, um herauszufinden, was bisher in dem Bereich erforscht, entwickelt und umgesetzt wurde. In einem zweiten Schritt erfolgte, ausgehend von den Flächen der Referenzdaten, eine visuelle Überprüfung der zeitlichen Verläufe der Spektren bzw. daraus berechneter Merkmale, um zu ermitteln, ob sich visuell Unterschiede zwischen den Zielklassen zeigten. In einem dritten Schritt schließlich wurden die Referenzdaten verwendet, um multispektrale und multitemporale Klassifikationen durchzuführen und dadurch die Identifizierbarkeit der Zielobjekte zu untersuchen. Dazu wurde als Verfahren der klassischen Klassifikation das Random-Forest-Verfahren genutzt. Zudem wurden Neuronale Netze als Deep-Learning-Verfahren verwendet und dem klassischen Verfahren gegenübergestellt. Aus allen Untersuchungen heraus wurde schließlich eine Aussage zur Identifizierbarkeit der vorgegebenen Zielobjekte und den dazu benötigten Verfahren gemacht und die Rahmenbedingungen zum Aufbau eines Monitoringprogramms dargestellt.

Insgesamt ergab sich aus der Machbarkeitsstudie, dass sich einige der Zielklassen sehr gut mit Hilfe der automatischen Klassifikationsverfahren identifizieren lassen, wobei die Unterschiede zwischen den beiden untersuchten Verfahren (Random Forest und Deep Learning) gering waren. Für weitere Zielobjekte konnte die Klassifizierbarkeit nicht direkt bestätigt werden, sondern aufgrund der visuellen Überprüfungen bzw. der Literaturrecherche angenommen werden.

Literaturverzeichnis

- AZZARI, G., GRASSINI, P., EDREIRA, J.I.R., CONLEY, S., MOURTZINIS, S., LOBELL, D.B. (2019): Satellite mapping of tillage practices in the North Central US region from 2005 to 2016. In: Remote Sensing of Environment 221, S. 417–429. <https://doi.org/10.1016/j.rse.2018.11.010>
- CAI, W., ZHAO, S., WANG, Y., PENG, F., HEO, J., DUAN, Z. (2019): Estimation of Winter Wheat Residue Coverage Using Optical and SAR Remote Sensing Images. In: Remote Sensing 11, S. 1163. <https://doi.org/10.3390/rs11101163>
- CLERC, S. (2021): S2 MPC - L1C Data Quality Report - Reference: S2-PDGS-MPC-DQR.
- DAUGHTRY, C.S.T. (2001): Discriminating Crop Residues from Soil by Shortwave Infrared Reflectance. In: Agron.j. 93, S. 125–131. <https://doi.org/10.2134/agronj2001.931125x>
- DENIZE, J., HUBERT-MOY, L., BETBEDER, J., CORGNE, S., BAUDRY, J., POTTIER, E. (2018): Evaluation of Using Sentinel-1 and -2 Time-Series to Identify Winter Land Use in Agricultural Landscapes. In: Remote Sensing 11, S. 37. <https://doi.org/10.3390/rs11010037>
- DING, Y., ZHANG, H., WANG, Z., XIE, Q., WANG, Y., LIU, L., HALL, C.C. (2020). A Comparison of Estimating Crop Residue Cover from Sentinel-2 Data Using Empirical Regressions and Machine Learning Methods. In: Remote Sensing 12, S. 1470. <https://doi.org/10.3390/rs12091470>
- HASTIE, T., TIBSHIRANI, R., FRIEDMAN, J.H. (2009): The elements of statistical learning: data mining, inference, and prediction. In: 2nd ed. ed, Springer series in statistics. Springer, New York, NY.
- HOCHREITER, S., SCHMIDHUBER, J. (1997). Long Short-Term Memory. In: Neural Computation 9, 1735–1780. <https://doi.org/10.1162/neco.1997.9.8.1735>
- HOLTGRAVE, A.-K., RÖDER, N., ACKERMANN, A., ERASMI, S., KLEINSCHMIT, B. (2020): Comparing Sentinel-1 and -2 Data and Indices for Agricultural Land Use Monitoring. In: Remote Sensing 12, 2919. <https://doi.org/10.3390/rs12182919>
- OCHSENBAUER, M., EHBAUER, W., BROHMEYER, F. (2019). Monitoring der Winterbegrünung auf Ackerflächen anhand von Satellitendaten. In: AGIT – Journal für Angewandte Geoinformatik 5–2019, S. 73–86.
- QUEMADA, M., DAUGHTRY, C. (2016): Spectral Indices to Improve Crop Residue Cover Estimation under Varying Moisture Conditions. In Remote Sensing 8, S. 660. <https://doi.org/10.3390/rs8080660>
- RUßWURM, M., KORNER, M. (2017): Temporal Vegetation Modelling Using Long Short-Term Memory Networks for Crop Identification from Medium-Resolution Multi-spectral Satellite Images. In: 2017 IEEE Conference on Computer Vision and Pattern Recognition Workshops (CVPRW). <https://doi.org/10.1109/CVPRW.2017.193>
- VISÚS, D.V., COCA, F.C.D., OLIVER-VILLANUEVA, J.-V., COLL ALIAGA, E. (2018): Validation of Sentinel-2 L2B LAI and FAPAR products from SNAP over forests and crops in a Mediterranean environment. <https://doi.org/10.13140/RG.2.2.31981.08169>.
- WODITSCH, S. (2019). Classification of multi-spectral and multi-temporal satellite images using deep learning LSTM networks“ - Agricultural crop prediction of Sentinel 2 images. Master Thesis im Rahmen des Universitätslehrganges „Geographical Information Science & Systems“ (UNIGIS MSc) am Interfakultären Fachbereich für Geoinformatik (Z_GIS) der Paris Lodron-Universität Salzburg.

- YUE, J., TIAN, Q. (2020): Estimating fractional cover of crop, crop residue, and soil in cropland using broadband remote sensing data and machine learning. In: International Journal of Applied Earth Observation and Geoinformation 89, 102089. <https://doi.org/10.1016/j.jag.2020.102089>
- ZHOU, W., RAO, P., JAT, M.L., SINGH, B., POONIA, S., BIJARNIYA, D., KUMAR, M., SINGH, L.K., SCHULTHESS, U., SINGH, R., JAIN, M. (2021): Using Sentinel-2 to Track Field-Level Tillage Practices at Regional Scales in Smallholder Systems. In: Remote Sensing 13, S. 5108. <https://doi.org/10.3390/rs13245108>