



Master-Thesis

im Rahmen des
Universitätslehrganges „Geographical Information Science & Systems“
(UNIGIS MSc) am Interfakultären Fachbereich für GeoInformatik (Z_GIS)
der Paris Lodron-Universität Salzburg

zum Thema

Satellitenbasierter Nachweis der zeitlichen Heterogenität der Grünlandmahd in Heumilchbetrieben

vorgelegt von

Dr. agr. Anja Hartmann

Teilnehmerkennzahl 105493, UNIGIS MSc Jahrgang 2019

Betreuer: Assoz. Prof. Dr. Dirk Tiede, Dr. Martin Sudmanns

Zur Erlangung des Grades
„Master of Science - MSc“

Gilching, im September 2021

Erklärung

Ich versichere hiermit, die vorliegende Arbeit selbstständig und nur unter Verwendung der angegebenen Literatur und Hilfsmittel verfasst zu haben. Alle Aussagen dieser Arbeit, die wörtlich oder sinngemäß aus anderen Werken übernommen wurden, sind unter Angabe der Quelle kenntlich gemacht. Die vorliegende Arbeit wurde in gleicher oder ähnlicher Form noch keiner anderen Prüfungsbehörde vorgelegt.

.....

Ort, Datum

.....

Anja Hartmann

Kurzzusammenfassung

Zur Erhaltung der Biodiversität auf Grünland ist es sinnvoll, dass die Flächen eines Betriebes zu unterschiedlichen Zeitpunkten gemäht werden (zeitlich heterogen). Damit bleibt jeweils ein Teil der Flächen ungemäht und die Überlebenschancen von zahlreichen Insekten und kleinen Tieren werden verbessert, da stets Ausweichhabitate vorhanden sind. Laut der Arbeitsgemeinschaft Heumilch wirtschaften Heumilchbauern nach diesem mosaikartigen Prinzip. Bedingt durch den höheren Arbeitsaufwand der Heubereitung können nicht alle Flächen eines Betriebes auf einmal gemäht werden.

Ziel der vorliegenden Arbeit ist es zu untersuchen, ob und in welcher Form sich Satellitendaten (Sentinel-2) und der semantische Datenwürfel „Sen2Cube.at“ dazu nutzen lassen, um die zeitliche Heterogenität der Mahd auf Grünlandflächen darzustellen. Weiterhin soll geprüft werden, ob sich Unterschiede in der zeitlichen Verteilung der Mahd zwischen Heumilch- und Nicht-Heumilchbetrieben aufzeigen lassen.

In einem ersten Schritt wurde untersucht, ob Mähereignisse anhand von Vegetationsindices (NDVI, Greenness-Index) oder eines semantischen Informationslayers (SIAM-Vorklassifikation) definiert werden können. Zeitreihen von ausgewählten Referenzflächen zeigten, dass die Abnahme des NDVI, des Greenness-index und der SIAM-Klasse „strong vegetation with high NIR“ gut mit realen Mähereignissen übereinstimmt. Eine Ableitung der Mahd anhand von Differenzwerten zweier aufeinanderfolgender Satellitenaufnahmen (T1-T2) und eines definierten Grenzwertes erwies sich jedoch als ungenau. Die Zahl der richtig abgeleiteten Mähereignisse war sehr gering. Gründe hierfür können z. B. nicht gefilterte bewölkte Satellitenaufnahmen, große zeitliche Abstände zwischen den Aufnahmetermenen oder auch der deutliche Einfluss des gewählten Grenzwertes sein. Als alternative grenzwert-freie Methode wurden die Standardabweichung und der Mittelwert des Greenness-Index über alle Flächen (Pixel) eines jeweiligen Betriebes und für jeden Zeitpunkt berechnet. Anhand dieser Parameter ließ sich die zeitliche Verteilung des Aufwuchses bzw. der Mahd indirekt aufzeigen. Eine hohe Standardabweichung des Greenness-Index bedeutet, dass im Betrieb sowohl dicht bewachsene (hoher Greenness-Index) wie auch gemähte Flächen (niedriger Greenness-Index) zum jeweiligen Zeitpunkt vorhanden sind. Von einer heterogenen Verteilung der Mahd ist damit auszugehen. Eine niedrige Standardabweichung weist darauf hin, dass sich der Bewuchs auf den Flächen zum jeweiligen Zeitpunkt sehr ähnlich (homogen) darstellt. Anhand dieses Vorgehens war eine zeitlich heterogenere Verteilung der Mahd in Heumilchbetrieben im Vergleich zu Nicht-Heumilchbetrieben für ausgewählte Beispiele nachweisbar.

Inhaltsverzeichnis

Kurzzusammenfassung	1
Abbildungsverzeichnis	3
Tabellenverzeichnis.....	8
Abkürzungen.....	9
1 Einleitung	10
1.1 Problemstellung	10
1.2 Hintergrundwissen	11
1.2.1 Grünland.....	11
1.2.2 Biodiversität und Grünlandbewirtschaftung.....	13
1.2.3 Fernerkundungsmethoden im Grünlandmonitoring.....	14
1.2.4 Sentinel-2 Daten	18
1.2.5 Sen2Cube.at.....	19
1.3 Zielstellung	23
2 Datengrundlage und Methoden	24
2.1 Referenzdaten	24
2.1.1 Auswahl der Beispielbetriebe.....	24
2.1.2 Aufbereitung der Polygondaten	28
2.2 Identifikation von Mähereignissen auf Grünland anhand von Sentinel-2 Daten	30
2.3 Wolkenfilter	31
2.4 Verwendete Software	35
3 Ergebnisse & Diskussion.....	37
3.1 Zeitreihenanalyse	37
3.1.1 Vegetations-Indices und Mähereignis	37
3.1.2 SIAM-Vorklassifikation und Mähereignis.....	41
3.1.3 Detektion von Mähereignissen.....	45
3.2 Grenzwert-basierte Analyse von Mähereignissen mittels Greenness-Index	50
3.3 Grenzwert-freie Analyse von Mähereignissen mittels Greenness-Index	57

3.3.1	Einzelflächenvergleich der Heumilch- und Nicht-Heumilchbetriebe	57
3.3.2	Gesamtflächenvergleich der Heumilch- und Nicht-Heumilchbetriebe	61
4	Schlussfolgerungen	67
5	Ausblick.....	69
6	Ausführliche Zusammenfassung	72
7	Literaturverzeichnis.....	78
8	Anhang	84

Abbildungsverzeichnis

Abbildung 1: Passive und aktive Aufnahmesysteme (Bild: nach Lange (2013) und (Albertz 2013))	15
Abbildung 2: Typische spektrale Kurve einer Buchenkrone (Bild: Universität Rostock o.D. und Aberle 2017)	16
Abbildung 3: Spektrale Signatur der Blattflächenreflexion von Artemisia spp. bei unterschiedlichen LAI (Bild: Veroustraete et al. 2011)	17
Abbildung 4: Weboberfläche des Sen2Cube.at zur Abfrage des Datenwürfels	20
Abbildung 5: Informationsschichten von Sen2Cube.at (Bild: Tiede et al. 2017)	20
Abbildung 6: Beispiel für die Abfrage eines wolkenfreien RGB-Bildes. Es wird für jeden wolkenfreien Pixel (RGB) der betreffenden Region der Median über eine Zeitreihe ausgegeben und damit ein wolkenfreies Gesamtbild erstellt.	22
Abbildung 7: Lage der Untersuchungsbetriebe bzw. Betriebspaare	25
Abbildung 8: Gemähter Flächenanteil pro Schnittzeitpunkt je Betrieb in % im Jahr 2019 (Nicht-Heumilchbetrieb links, Heumilchbetriebe rechts); jedes Feldstück wird durch eine Farbe repräsentiert, aufgrund der Vielzahl wurden in der Legende jedoch nicht alle Feldstücke dargestellt	26
Abbildung 9: Gemähter Flächenanteil pro Schnittzeitpunkt je Betrieb in % im Jahr 2020 (Nicht-Heumilchbetrieb links, Heumilchbetriebe rechts); jedes Feldstück wird durch eine Farbe repräsentiert, aufgrund der Vielzahl wurden in der Legende jedoch nicht alle Feldstücke dargestellt	27
Abbildung 10: Mischpixel (roter Pfeil) an den äußeren Rändern der Grünlandfläche mit Übergang zur Siedlungsfläche oder Verkehrsweg (am Beispiel einer NDVI-Karte)	29
Abbildung 11: Sehr kleine und schmale Flächen (gelb markiert) wurden nicht in die Auswertung miteinbezogen	30
Abbildung 12: Sentinel-2-Aufnahme (RGB) mit witterungsbedingten Störungen	32
Abbildung 13: Bewölkung in % für die Flächen der Beispielbetriebe (Gesamtfläche) im Untersuchungszeitraum 2019 und 2020; blaue Punkte = Aufnahmedatum Sentinel-2; rote Linie = Grenzwert für „störungsfreies“ Bild	35
Abbildung 14: Greenness-Index (Linie) und Mähtermin (Balken) während der Vegetationsperiode 2019 bzw. 2020; blaue Punkte = wolkenfreie Satellitenaufnahme; Untersuchungsflächen der Betriebspaare ST1 und T1.	38
Abbildung 15: NDVI (Linie) und Mähtermin (Balken) während der Vegetationsperiode 2019 bzw. 2020; blaue Punkte = wolkenfreie Satellitenaufnahme; Untersuchungsflächen der Betriebspaare ST1 und T1.	39

Abbildung 17: Verlauf des Greenness-Index für obige Fläche (vergleiche Abbildung 16)	40
Abbildung 16: RGB-Sentinel-2 Aufnahme vom 24.04.2020 (links: vor der Mahd), 08.05.2020 (Mitte: Nach der Mahd, das Gras liegt noch auf der Fläche) und 18.05.2020 (rechts: Mähgut ist abgeräumt)	40
Abbildung 18: Pixelanteil je SIAM-Kategorie auf den ausgewählten Untersuchungsflächen in der Vegetationsperiode 2019 bzw. 2020. Die Mähtermine sind als graues Quadrat dargestellt. Untersuchungsflächen der Betriebspaare ST1 und T1.	42
Abbildung 19: Verlauf des als „strong vegetation with high NIR“ klassifizierten Pixelanteils (Linie, in Prozent) auf ausgewählten Untersuchungsflächen der Betriebspaare ST1 und T1 in der Vegetationsperiode 2019 bzw. 2020. 2020; Mähtermin = graue Balken.	44
Abbildung 20: Differenz T2 – T1 der untersuchten Parameter NDVI (oben), Greenness- Index (Mitte) und SIAM-Kategorie „strong veg. with high NIR“ (unten) sowie Darstellung ob im Zeitintervall zwischen zwei Satellitenaufnahmedaten (T1 und T2) eine Ernte stattgefunden hat; orange: Ernte; grün: keine Ernte; Daten aller Betriebe; 2019 (links), 2020 (rechts)	46
Abbildung 21: Vergleich der zeitlichen und räumlichen Verteilung der Mähereignisse in zwei Beispielbetrieben (Betriebspaar ST1) im Jahr 2019. Grün = keine Ernte zwischen Aufnahmetermin und vorangehendem Termin, orange = Ernte, gestreift = keine Daten	52
Abbildung 22: Vergleich der räumlichen und zeitlichen Verteilung der Mähereignisse in zwei Beispielbetrieben (Betriebspaar T1) im Jahr 2020. Grün = keine Ernte zwischen Termin und vorangehendem Termin, orange gefüllt = Ernte, gestreift = keine Daten, gelbe Umrandung = Nicht-Heumilchbetrieb, blaue Umrandung = Heumilchbetrieb	54
Abbildung 23: Ergebnisse der automatisierten Ernte-Klassifikation: prozentualer Anteil der jeweils gemähten Fläche an der Gesamtfläche pro Betrieb; in 2019 (Betriebspaar ST1: oben) und 2020 (Betriebspaar T1: unten)	55
Abbildung 24: Ergebnisse der automatisierten Ernte-Klassifikation: prozentualer Anteil der jeweils gemähten Fläche an der Gesamtfläche in den Gemeinden Seeham (Heumilch) und Frankenmarkt (Nicht-Heumilch) pro Woche in 2020	57
Abbildung 25: Zeitlicher Verlauf des Greenness-Index auf den Flächen des Heumilch- und Nicht-Heumilchbetriebs (Betriebspaar ST1) im Jahr 2019. Jede ID (Legende) repräsentiert ein Feldstück.	58

Abbildung 26: Zeitlicher Verlauf des Greenness-Index auf den Flächen des Heumilch- und Nicht-Heumilchbetriebs (Betriebspaar T1) im Jahr 2020. Jede ID (Legende) repräsentiert ein Feldstück.	59
Abbildung 27: Korrelationsmatrix der zeitlichen Verläufe des Greenness-Index für die Flächen des Heumilch- und Nicht-Heumilchbetriebs (Betriebspaar ST1) im Jahr 2019	60
Abbildung 28: Korrelationsmatrix der zeitlichen Verläufe des Greenness-Index für die Flächen des Heumilch- und Nicht-Heumilchbetriebs (Betriebspaar T1) im Jahr 2020	60
Abbildung 29: Ergebnisse der Korrelationsmatrix des Greenness-Index als Boxplot (links: Betriebspaar ST1, 2019; rechts: Betriebspaar T1, 2020)	61
Abbildung 30: Standardabweichungen (blau) und Mittelwert (grau) der Untersuchungsflächen für das Merkmal Greenness-Index; oben: Betriebspaar ST1 im Jahr 2019; unten: Betriebspaar T1 im Jahr 2020; mittlere Standardabweichung über den gesamten Zeitraum (blau gestrichelt)	62
Abbildung 31: Boxplot der Standardabweichungen des Greenness-Index (Zeitreihe) über alle Flächen (Pixel) des jeweiligen Betriebes; links: 2019, Betriebspaar ST1; rechts: 2020, Betriebspaar T1	64
Abbildung 32: Standardabweichungen (blau) und Mittelwert (grau) der untersuchten Regionen für das Merkmal Greenness-Index im Jahr 2020; mittlere Standardabweichung über den gesamten Zeitraum (blau gestrichelt)	65
Abbildung 33: Standardabweichung des Greenness-Index über alle Flächen (Pixel) der jeweiligen Gemeinde in 2020	66
Abbildung 34: Greenness-Index; Region Seeham (links: 28.04.2020; rechts: 08.05.2020)	69
Abbildung 35: Greenness-Index; Region Frankenmarkt (links: 28.04.2020; rechts: 08.05.2020)	69
Abbildung 36: SIAM-Kategorien; Region Seeham (links: 28.04.2020; rechts: 08.05.2020)	70
Abbildung 37: SIAM-Kategorien; Region Frankenmarkt (links: 28.04.2020; rechts: 08.05.2020)	70
Abbildung 38: Euklidische Distanz zwischen Pixeln der Kategorie „strong vegetation with high NIR“ (dicht bewachsen) und Pixeln anderer SIAM-Kategorien (08.05.2020; links: Seeham; rechts: Frankenmarkt)	71
Abbildung 39: Zeitlicher Verlauf des Greenness-Index auf den Flächen der Heumilch- und Nicht-Heumilchbetriebs (Betriebspaar ST1 in Jahr 2019: oben; Betriebspaar T1	

in Jahr 2020: unten). Jede Linie repräsentiert ein Feldstück. Das graue Band stellt die Spanne zwischen Maximum- und Minimumwerten dar.	74
Abbildung 40: Zusammenfassung der Korrelationsmatrix des Greenness-Index als Boxplot (links: Betriebspaar ST1, 2019; rechts: Betriebspaar T1, 2020)	75
Abbildung 41: Boxplot der Standardabweichungen des Greenness-Index über alle Flächen (Pixel) des jeweiligen Betriebes (links: 2019, Betriebspaar ST1; rechts: 2020, Betriebspaar T1)	76
Abbildung 42: Workflow des methodischen Vorgehens	77
Abbildung 43: Greenness-Index (Linie) und Erntetermine (Balken) während der Vegetationsperiode 2019; blaue Punkte = wolkenfreie Satellitenaufnahmetermine; Untersuchungsflächen des Betriebspaares ST1	85
Abbildung 44: Greenness-Index (Linie) und Erntetermine (Balken) während der Vegetationsperiode 2020; blaue Punkte = wolkenfreie Satellitenaufnahmetermine; Untersuchungsflächen des Betriebspaares T1	86
Abbildung 45: Pixelanteil (%) der SIAM-Kategorie „strong vegetation with high NIR“ (Linie) und Erntetermine (Balken) während der Vegetationsperiode 2019; blaue Punkte = wolkenfreie Satellitenaufnahmetermine; Betriebspaar ST1	87
Abbildung 46: Pixelanteil (%) der SIAM-Kategorie „strong vegetation with high NIR“ (Linie) und Erntetermine (Balken) während der Vegetationsperiode 2020; blaue Punkte = wolkenfreie Satellitenaufnahmetermine; Untersuchungsflächen des Betriebspaares T1	88
Abbildung 47: NDVI (Linie) und Erntetermine (Balken) während der Vegetationsperiode 2019; blaue Punkte = wolkenfreie Satellitenaufnahmetermine; Untersuchungsflächen des Betriebspaares ST1	89
Abbildung 48: NDVI (Linie) und Erntetermine (Balken) während der Vegetationsperiode 2020; blaue Punkte = wolkenfreie Satellitenaufnahmetermine; Untersuchungsflächen des Betriebspaares T1	90
Abbildung 49: Räumliche und zeitliche Verteilung der Mähereignisse in zwei Beispielregionen im Jahr 2020; grün = keine Ernte zwischen Termin und vorangehendem Termin; orange = Ernte; gestreift = keine Daten; es wurden nur Termine dargestellt an denen für beide Regionen Daten vorliegen	92
Abbildung 50: Standardabweichungen (blau) und Mittelwerte (grau) der Untersuchungsflächen für das Merkmal Greenness-Index; mittlere Standardabweichung über den gesamten Zeitraum (blau gestrichelt)	93

Abbildung 51: Standardabweichungen (blau) und Mittelwerte (grau) der Untersuchungsflächen für das Merkmal Greenness-Index; mittlere Standardabweichung über den gesamten Zeitraum (blau gestrichelt)	94
Abbildung 52: Sen2Cube Modell zur Abfrage des NDVI auf Basis von Sentinel-2 Daten	95
Abbildung 53: Sen2Cube Modell zur Abfrage der semantischen Information (SIAM-Vorklassifikation) auf Basis von Sentinel-2 Daten	95
Abbildung 54: Sen2Cube Modell zur Abfrage des Wolkenfilters (SIAM-Vorklassifikation) auf Basis von Sentinel-2 Daten	96
Abbildung 55: Sen2Cube Modell zur Abfrage des Greenness-Index (Mittelwert und Standardabweichung) auf Basis von Sentinel-2 Daten	96
Abbildung 56: Bewölkung in % für die Gesamtfläche der untersuchten Gemeinden; blaue Punkte = Aufnahmedatum Sentinel-2; rote Linie = Grenzwert für „störungsfreies“ Bild	97

Tabellenverzeichnis

Tabelle 1: Grünlandnutzungsarten (Bundesministerin für Nachhaltigkeit und Tourismus 2019)	11
Tabelle 2: Sentinel-2-Bänder (Abbildung: Satellite Imaging Corporation o. D.)	19
Tabelle 3: „Vegetation“ beinhaltende SIAM-Kategorien in Sen2Cube.at	21
Tabelle 4: Verwendete Python libraries	36
Tabelle 5: Konfusionsmatrix der Klassifikationsergebnisse, 2019	48
Tabelle 6: Konfusionsmatrix der Klassifikationsergebnisse, 2020	48
Tabelle 7: Fläche unter der Standardabweichung-Zeit-Kurve (Abbildung 30, berechnet mittels Trapezoid-Methode)	63
Tabelle 8: Median der Standardabweichungen des Greenness-Index (Zeitreihe) über alle Flächen (Pixel) des jeweiligen Betriebes	64
Tabelle 9: Konfusionsmatrix der Wolken-Klassifikation	84
Tabelle 10: Einschränkung des Untersuchungs- bzw. Darstellungszeitraumes aufgrund der unterschiedlichen Datenverfügbarkeit zwischen den Betriebspaaren (Bewölkung)	84
Tabelle 11: Untersuchungsflächen und Erntetermine im Jahr 2019 (HB = Heu mit Bodentrocknung, E = Eingrasen, HT = Heu mit Trocknungsanlage, HTa = Heu mit Aufbereiter und Trocknungsanlage, HBa= Heu Bodentrocknung mit Aufbereitung, SL = Silage; W =Weide); Daten: Suske et al. (2021)	98
Tabelle 12: Untersuchungsflächen und Erntetermine im Jahr 2020 (HB = Heu mit Bodentrocknung, E = Eingrasen, HT = Heu mit Trocknungsanlage, HTa = Heu mit Aufbereiter und Trocknungsanlage, HBa= Heu Bodentrocknung mit Aufbereitung, SL = Silage, W=Weide); Daten: Suske et al. (2021)	102

Abkürzungen

ARGE	Arbeitsgemeinschaft Heumilch
ESA	European Space Agency
ha	Hektar
INSPIRE	INfrastructure for SPatial InfoRmation in Europe
INVEKOS	Integrierte Verwaltungs- und Kontrollsystem
LAI	Leaf Area Index
LfL	Bayerische Landesanstalt für Landwirtschaft
MIR	Middle infrared
NDVI	Normalized Differenced Vegetation Index
NIR	Near infrared
QGIS	Quantum GIS
RGB	Rot-Grün-Blau
SIAM	Satellite Image Automatic Mapper™
SVHNIR	Strong Vegetation with High NIR
SWIR	Short wave infrared
ToA	Top of atmosphere
VIS	Visible radiometric spectrum

1 Einleitung

1.1 Problemstellung

Die abnehmende Artenvielfalt der Fauna auf landwirtschaftlich genutzten Flächen ist ein bekanntes Problem. Nicht nur enge Fruchtfolgen, fehlende Randstreifen und ein umfangreicher Pflanzenschutzmitteleinsatz im Ackerbau sind dafür verantwortlich. Auch auf Grünlandflächen hat die Bewirtschaftungsintensität zu- und die Artenvielfalt abgenommen. Hierbei spielen die zeitliche Heterogenität der Bewirtschaftung und die Parzellengröße eine Rolle. Es hat sich beispielsweise gezeigt, dass sich eine synchrone Mahd von großen Flächen negativ auf die Zusammensetzung und Populationsgröße von z.B. Arthropoden auswirkt (Cizek et al. 2012). Blüthgen et al. (2012) stellen fest, dass die Intensität der Grasproduktion von semi-natürlichen Wiesen, über Heuflächen bis hin zur Silageproduktion abnimmt. Grund dafür ist die geringere Schlagkraft bei einer Heubewirtschaftung, welche im Vergleich zur Silageproduktion eine zeitliche Synchronisierung großer Flächenanteile eines Betriebs erschwert. Die Arbeitsgemeinschaft Heumilch geht deshalb davon aus, dass eine „mosaikartige“ Bewirtschaftungsweise der Heumilchbauern zum Erhalt der Biodiversität auf Grünlandflächen beiträgt (ARGE Heumilch 2014).

Zur Untersuchung der zeitlichen Heterogenität (mosaikartig) der Bewirtschaftung auf Grünlandflächen unterschiedlicher Betriebsformen (Heumilch vs. Nicht-Heumilch) bieten sich satellitenbasierte Methoden an. Mit diesen können, unabhängig von der Informationsverfügbarkeit und von vor-Ort Aufnahmen, großflächige Analysen durchgeführt werden. Untersuchungen von (Kolecka et al. 2018) bestätigen beispielsweise das Potenzial von Sentinel-2 Daten für die Untersuchung der zeitlichen Frequenz der Grünlandmahd in der Schweiz.

1.2 Hintergrundwissen

1.2.1 Grünland

Grünland findet sich vorwiegend in niederschlagsreichen und kühleren Regionen und dort, wo die Boden- oder Grundwasserverhältnisse für den Ackerbau nicht geeignet sind (Dauergrünland). Es werden aber auch auf Ackerflächen zeitweise Gräser oder Gräsergemenge angebaut (Wechselgrünland). In Österreich hat Dauergrünland mit etwa 46 % Anteil an der landwirtschaftlichen Nutzfläche eine hohe Bedeutung (Bundesministerin für Nachhaltigkeit und Tourismus 2019). Die Grünlandflächen werden mit unterschiedlicher Intensität bewirtschaftet. **Intensivgrünland** wird mehrmals pro Jahr beweidet oder gemäht, zumeist auch intensiv gedüngt und macht in Österreich etwa 43 % (ohne Feldfutter) der Grünfutterfläche aus (Bundesministerin für Nachhaltigkeit und Tourismus 2019). **Extensivgrünland** weist eine geringe Nutzungshäufigkeit auf. Die Nutzungstermine sind mit der Regenerationsfähigkeit und den Fortpflanzungsmöglichkeiten der für Wiesen typischen Pflanzen- und Tierarten vereinbar. Verwaltungstechnisch (Beantragung von Fördermitteln) wird landwirtschaftlich genutztes Grünland in folgende Nutzungsarten unterteilt (Tabelle 1):

Tabelle 1: Grünlandnutzungsarten (Bundesministerin für Nachhaltigkeit und Tourismus 2019)

Nutzungsarten	Intensität der Bewirtschaftung
Mähwiese/-weide drei und mehr Nutzungen	intensiv
Dauerweide	
Mähwiese/-weide zwei Nutzungen	extensiv
Einmähdige Wiese	
Bergmähder	
Hutweide	
Sonstige	

Der Grünlandaufwuchs dient zumeist als Grundfutter in der Tierhaltung, insbesondere für die Milchviehwirtschaft. In den letzten Jahren hat sich durch die Nutzung als Substrat für Biogasanlagen ein weiteres Einsatzfeld ergeben. Zudem haben diese Flächen aber auch als Wasserspeicher, Erosionsschutz und Lebensraum für vielerlei Tiere ein wichtige Ökofunktion.

Die Konservierung des Aufwuchses für die Tierfütterung, sofern nicht in Form von Beweidung oder Eingrasen (Verfütterung von frischem Grünfutter im Stall) genutzt, erfolgt

als **Silage** oder **Heu**. Die Gründe für die Wahl des einen oder anderen Konservierungsverfahrens sind von betrieblichen, wirtschaftlichen aber auch von klimatischen oder produktbezogenen Faktoren abhängig (Hege et al. 1998). So sind das geringere Witterungsrisiko, ein geringerer Arbeitsaufwand, die größere Schlagkraft, geringe Nährstoffverluste bei der Ernte und z.T. höhere Energiegehalte im Erntegut für viele Landwirte gute Gründe für eine Konservierung durch Silierung (Ginzinger o.D.). Lange Zeit war die Heubereitung somit von insgesamt rückläufiger Bedeutung. In den letzten Jahren nimmt das Interesse an diesem Konservierungsverfahren zu. Durch ein intensives Marketingprogramm und aufgrund eines geänderten Konsumentenverhaltens hat sich der Markenname „Heumilch“ und „Heumilchkäse“ etabliert (Pöllinger 2015). Seit 2016 ist die Bezeichnung „Heumilch“ mit dem EU-Gütesiegel g.t.S. „garantiert traditionelle Spezialität“ ausgezeichnet. Produkte die mit diesem Gütesiegel vermarktet werden, dürfen beispielsweise keinerlei Gärfutter verfüttern und der Raufutteranteil an der Trockenfutter-Jahresration muss mindestens 75 % betragen (Europäische Kommission 2016). Für „Heumilch“ erhalten die Landwirte in der Regel einen höheren Milchpreis. Neben dem Heumilchzuschlag (finanzieller Ausgleich für höhere Konservierungskosten) sind auch ein „positives Image“ sowie pansenphysiologische Vorteile dieser Konservierungsmethode zu nennen (Galler et al. 2017).

Für die Heutrocknung stehen verschiedene Möglichkeiten zur Verfügung. Traditionell wurde Heu am Boden oder auf einem Gerüst getrocknet. Heute werden oft belüftete Trocknungsanlage unter Dach eingesetzt (Kaltbelüftung oder Warmbelüftung / Luftentfeuchtung / Dachabsaugung, (Lindner und Kittl 2016)). Den hohen Anforderungen von heutigen Hochleistungskühen an die Qualität des Grundfutters wird boden- oder gerüst-getrocknetes Heu oft nicht gerecht. Die Feldliegezeiten des Futters sind lang und die Flexibilität hinsichtlich des Nutzungszeitpunktes eingeschränkt (Pöllinger 2015), da in den Grünlandregionen Österreich im Frühjahr wetterbedingt oft nicht viele Feldarbeitstage zur Verfügung stehen. Kurze Feldliegezeiten, eine zügige Trocknung und Flexibilität beim Schnittzeitpunkt (optimaler Reifegrad der Gräser und Kräuter) helfen eine hohe Qualität des Futters zu sichern. Im Gegensatz zur hohen Schlagkraft bei der Silagebereitung, ist die Belüftungstechnik in der Heuproduktion meist nicht so dimensioniert, dass das gesamte Erntegut von allen Flächen pro Schnitt auf einmal getrocknet werden kann. Ein Schnitt muss somit zeitlich unterteilt, auf bis zu drei Mal stattfinden. Nach Thurner und Macuhova (2018) bedeutet das mehr Erntekampagnen im Vergleich zur Silagekonservierung, meist sechs bis zehn Heuernten pro Jahr. Auch ist bei der Belüftungsheuproduktion im Vergleich zur Grassilageproduktion mit einem höheren

Arbeitszeitbedarf und einer geringeren Schlagkraft pro Hektar zu rechnen (Bayerische Landesanstalt für Landwirtschaft 2020). Laut Untersuchungen der Bayerische Landesanstalt für Landwirtschaft (2020) wurden im Durchschnitt pro Betrieb und pro Charge bzw. Schnitt $23,14 \pm 14,30$ ha bei der Grassilageproduktion und $8,13 \pm 4,19$ ha bei der Belüftungsheuproduktion gemäht. Dies unterstützt die These der Arbeitsgemeinschaft Heumilch Österreich (ARGE Heumilch), dass das Grünland durch die Heumilchbauern „mosaikartig“ bewirtschaftet wird (ARGE Heumilch 2014), da bedingt durch den höheren Aufwand nicht alle Flächen eines Betriebes auf einmal gemäht werden können. Die ARGE Heumilch vereinigt und vertritt die rund 8.000 Heumilchbäuerinnen und -bauern und mehr als 60 Molkereien, Käsereien und Sennereien (Lindner und Kittl 2016).

In den weiteren Ausführungen werden die Begriffe „Ernte“, „Mahd“ und „Schnitt“ synonym verwendet. Zeitlich gesehen wird damit der Tag, an dem das Gras geschnitten wird, bestimmt.

1.2.2 Biodiversität und Grünlandbewirtschaftung

Eine mosaikartige Bewirtschaftung von Grünland kann sich vorteilhaft auf Flora und Fauna auswirken. Die ARGE Heumilch (2014, S. 21) fasst die Vorteile wie folgt zusammen:

„Bei der Heuwirtschaft werden die Mähzeitpunkte zeitlich gestaffelt und räumlich unterschiedlich über die Flächen gestreut. Durch diese kleinflächige, mosaikartige Bewirtschaftungsweise der Heumilchbauern werden nie alle Grünflächen auf einmal gemäht, sondern in einzelnen Wellen bewirtschaftet. Das bietet vor allem vielen Tieren wie der Biene, der Hummel oder dem Niederwild einen geeigneten Lebensraum. Denn so bleiben wichtige Nahrungsquellen und Rückzugsmöglichkeiten erhalten, bis auf den bereits gemähten Wiesen wieder ein ausreichend hoher Aufwuchs steht.“

Eine aktuelle Studie (Suske et al. 2021) beschäftigte sich mit oben genannter Thematik und untersuchte die Hypothese, ob sich durch eine kleinräumige, zeitlich versetzte Mahd im Vergleich zu einer homogenen Mahd von großflächigen Arbeitseinheiten die drastische Abnahme von Insekten nach einem Schnitvorgang reduzieren lässt. Die Ergebnisse der Studie zeigen, dass auf den Flächen von untersuchten Heumilchbetrieben im Vergleich zu Flächen mit vorwiegender Silageproduktion tendenziell eine etwas größere Zahl an Arten und Individuen zu finden ist. Auch andere Studien kamen zu ähnlichen Ergebnissen. Hierbei lag der Fokus allerdings nicht auf dem Vergleich von Heumilch- und Nicht-Heumilchbetrieben. Cizek et al. (2012) zeigten, dass sich das synchrone Mähen von großen Flächen negativ auf Populationsgröße und Diversität von Arthropoden auswirkt. Bonari et al. (2017) schlagen vor, dass große Grünlandflächen kleinteilig, zu

unterschiedlichen Zeitpunkten gemäht werden sollten, damit stets ein Teil der Fläche ungemäht bleibt, und das Überleben von zahlreichen Wirbellosen und auch die generative Vermehrung unterschiedlichster Pflanzenarten gesichert wird. Stein-Bachinger und Fuchs (2012) untersuchten unterschiedliche Schutzstrategien auf Grünlandflächen und deren Effekt auf einige Bodenbrüter wie Braunkelchen oder Schafstelze. Die Untersuchungen zeigten, dass sich durch das Stehenlassen ungemähter Streifen die Lebensräume der Vögel teilweise erhalten ließen und dadurch der reproduktive Erfolg der untersuchten Arten verbessert werden könnte. Auch die Empfehlungen von Gottwald und Stein-Bachinger (2016) zur Erhaltung der Artenvielfalt beinhalten die Mosaikmahd als geeignete Maßnahme. Demnach sollte für eine gleichzeitige Nutzung eine Grenze von max. 25 % des Grünlands im Abstand von 10 Tagen im Zeitraum Anfang Mai bis Ende Juli gelten.

Die genannten Untersuchungen belegen die positive Wirkung einer mosaikartigen Bewirtschaftung auf die faunistische Biodiversität auf Grünlandflächen.

1.2.3 Fernerkundungsmethoden im Grünlandmonitoring

Neben einer direkten vor Ort-Untersuchung und Befragung von Landwirten eignen sich Fernerkundungsmethoden für ein Grünlandmonitoring um z.B. Fragen der Bewirtschaftungsintensität oder der zeitlichen Heterogenität der Mahd zu untersuchen (Bekkema und Eleveld 2018).

In der Fernerkundung wird die elektromagnetische Strahlung, die von einem Objekt, z.B. einer Pflanze reflektiert oder emittiert wird, in relevanten Wellenlängenbereichen zerstörungsfrei „von der Ferne“ erfasst. Hierbei kommt der Mensch, Fahrzeuge jeglicher Art, Drohnen, Flugzeuge oder Satelliten als Sensorträger zum Einsatz. Die Fernerkundung unterteilt sich in aktive und passive Messverfahren (Abbildung 1). Die aktive Fernerkundung sendet Energie aus und misst das reflektierte Signal (z.B. Radar, Laserscanning). Passive Verfahren messen hingegen die von der Erdoberfläche reflektierte Energie bzw. Sonnenstrahlung sowie die emittierte Eigenstrahlung (Bundesministerium für Ernährung und Landwirtschaft (BMEL) 2019). Dabei können nur einzelne Wellenlängen (z.B. Nahinfrarot), eine ganze Bandbreite (multispektral) oder z.B. auch nur die Reflexion im roten, grünen und blauen Bereich (RGB) detektiert werden, je nach Fragestellung bzw. Sensor. Bei den passiven Verfahren wird zwischen optischen Sensoren und thermalen Sensoren unterschieden. Letztere messen auch die von der Oberfläche emittierte langwellige Wärmestrahlung.

Je vollständiger die reflektierten Wellenlängen des Objekts durch den Sensor detektiert werden, desto höher ist die **spektrale Auflösung**. Weiterhin ist die **geometrische**

Auflösung zu nennen. Sie gibt an, welche reale Fläche von einem Bildpixel dargestellt wird. Eine Pixelauflösung von 10 Metern (10 Meter x 10 Meter), wie sie z.B. bei Satellitendaten des Typ Sentinel-2 gegeben ist, bildet eine tatsächliche Fläche von 100 Quadratmetern ab (Bundesministerium für Ernährung und Landwirtschaft (BMEL) 2019). Die **temporale Auflösung** gibt an, in welchem zeitlichen Intervall der gleiche Geländeausschnitt wiederholt aufgenommen wurde. Dies spielt insbesondere bei Satellitenbildern eine Rolle, da Satelliten kontinuierlich Daten sammeln und alle paar Tage die gleiche Position auf der Erde überfliegen und aufnehmen. Ein Maß für die Fähigkeit des digitalen Sensors bei der Aufnahme Grauwerte zu unterscheiden, ist die **radiometrische Auflösung**.

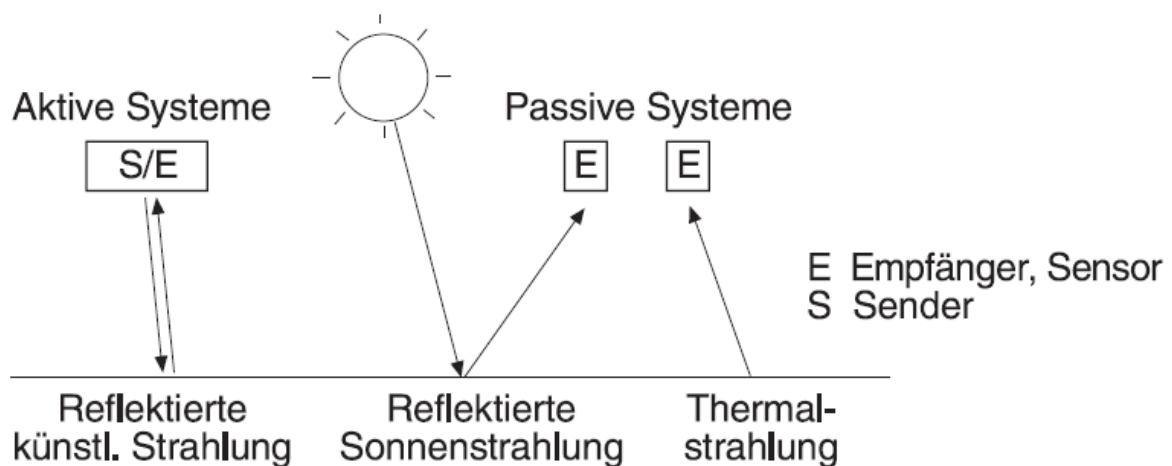


Abbildung 1: Passive und aktive Aufnahmesysteme (Bild: nach Lange (2013) und (Albertz 2013))

Für die vorliegende Arbeit ist die passive Messung der von Pflanzen reflektierten Strahlung mittels satellitengetragener Sensoren relevant. Folgende Ausführungen werden sich daher auf dieses Verfahren beschränken.

Grüne Biomasse weist ein sehr spezifisches Reflexionsprofil auf (Abbildung 2). D.h. die Wellenlängenbereiche in denen Pflanzen das Licht reflektieren bzw. absorbieren sind so spezifisch, dass sich daraus auch Rückschlüsse z.B. auf deren Zustand (Gesundheit) oder ihre Biomasse (leaf area index, LAI) ziehen lassen. Insbesondere das Chlorophyll grüner Blätter absorbiert das Licht im roten und blauen Wellenlängenbereich (Lillesand et al. 2015). Grünes Licht wird weniger absorbiert und mehr reflektiert, weshalb Pflanzen für das menschliche Auge grün erscheinen. Nimmt der Chlorophyllgehalt in den Pflanzen stress- oder reifebedingt ab, wird weniger blaues und rotes Licht absorbiert, deshalb sehen kranke oder absterbende Pflanzen dann bräunlich aus (Lillesand et al. 2015). Aufgrund der

zellulären Strukturen ist die Reflexion von gesunden Pflanzen im Nahinfrarotbereich deutlich höher als im sichtbaren Bereich des Lichts (Humboldt State University 2019).




Abbildung 2: Typische spektrale Kurve einer Buchenkrone (Bild: Universität Rostock o.D. und Aberle 2017)

Abbildung 3 zeigt wie die Reflexion von *Artemisia* spp. mit unterschiedlicher Blattmasse (LAI) aussieht. Es wird deutlich, dass sich insbesondere die Reflexion zwischen 500 - 600 nm (grün) und zwischen 700 - 950 nm (Nahinfrarot, NIR) durch die zunehmende Blattfläche ändert.

Vegetationsindices nutzen solche charakteristischen Profile. Sie fassen die spektralen Informationen aus zwei oder mehr spezifischen Wellenlängenbereichen in einem Wert zusammen (Bill 2016). Ein im Grünlandmonitoring sehr häufig verwendeter Index ist der NDVI (Normalized Differenced Vegetation Index, Reiner mann et al. 2020). Der NDVI ($\text{NIR} - \text{Rot} / \text{NIR} + \text{Rot}$) nimmt Werte zwischen -1 und +1 an, wobei positive Werte auf die Existenz von grüner Biomasse hinweisen.

Ein weiterer in der vorliegenden Arbeit verwendeter Vegetationsindex ist der Greenness-Index (Baraldi et al. 2010). Dieser Index bezieht, im Gegensatz zum NDVI und vielen

anderen Vegetationsindices, den spektralen Bereich des short wave infrared (SWIR)¹ mit ein $((NIR / Red) + (NIR / SWIR_{1.55-1.75}) - (Red / SWIR_{1.55-1.75}))$. Sakowska et al. (2016) wie auch Cayrol (2000) nennen die Bedeutung diese Wellenlängenbereiches für die Ableitung biophysikalischer Parameter in Vegetation, insbesondere zum Wassergehalt in der Vegetationsdecke.

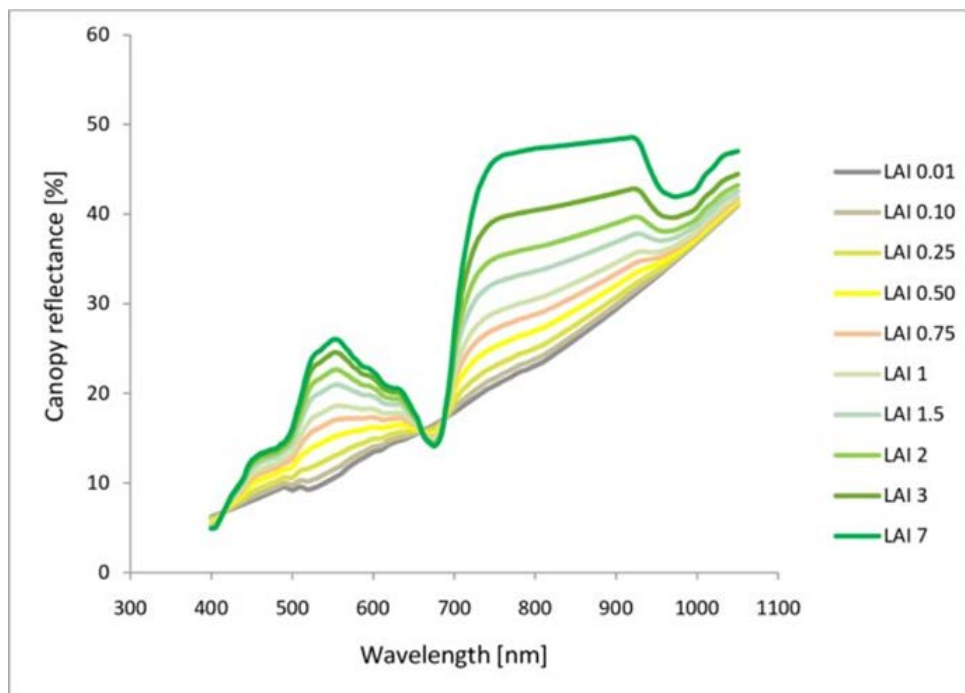


Abbildung 3: Spektrale Signatur der Blattflächenreflexion von *Artemisia* spp. bei unterschiedlichen LAI (Bild: Veroustraete et al. 2011)

Veränderungen in der Biomasse auf Grünlandflächen, z.B. durch Mahd, resultieren in einer Veränderung der reflektierten Strahlung, analog Abbildung 3. Nach Urf (2019) geht z.B. ein Mähereignis mit einer Abnahme in verschiedenen Vegetationsindices zwischen 0,3 bis 0,5 einher. Griffiths et al. (2020) nutzten Veränderungen im NDVI um die Häufigkeit und den Zeitpunkt der Grünlandmahd auf verschiedenen Standorten in Deutschland zu ermitteln. Hierbei wurde der Vegetationsindex in einer Zeitreihe betrachtet und durch Differenzbildung Veränderungen zwischen aufeinanderfolgenden Satellitenaufnahmen (T_n und T_{n+1}) untersucht um Mähereignisse aufzuspüren.

Neben dem oben genannten Vorgehen (Differenzbildung = Differencing) werden nach Reinermann et al. (2020) auch Klassifikationsmethoden angewendet um Mähereignisse

¹ SWIR ursprünglich MIR = middle infrared, 1-3 μ m (Lillesand et al. 2015, S. 6)

oder die Nutzungsintensität auf Grünlandflächen zu untersuchen. Hierbei wird jeder Pixel einer bestimmten Klasse (z.B. gemäht / nicht gemäht, Siedlung / Vegetation etc.) zugeordnet. Aus den kontinuierlichen, metrischen Daten (Intensitätswert einer Wellenlänge oder Vegetationsindex) werden folglich kategoriale Daten. Als Methoden kommen dabei nach Reinermann et al. (2020) decision trees, random forest, K-Nearest Neighbor, Support Vector Machine und weitere zum Einsatz. Bekkema und Eleveld (2018) nutzen beispielsweise Sentinel-2 Daten und Entscheidungsbäume auf Basis verschiedener Parameter um die Nutzungsintensität von Grünland im Norden der Niederlande zu klassifizieren.

1.2.4 Sentinel-2 Daten

Für die vorliegende Arbeit werden Daten der Sentinel-2 Satelliten genutzt. Die Sentinel-Satelliten sind das Kernelement des Copernicus Erdbeobachtungsprogramm der Europäischen Union (Deutsches Zentrum für Luft- und Raumfahrt e.V. (DLR) o.D.). *„Das Programm wird von der Europäischen Kommission koordiniert und verwaltet. Es wird in Partnerschaft mit den Mitgliedstaaten, der Europäischen Weltraumorganisation (ESA), der Europäischen Organisation für die Nutzung meteorologischer Satelliten (EUMETSAT), dem Europäischen Zentrum für mittelfristige Wettervorhersagen (ECMWF), den EU-Agenturen und Mercator Océan umgesetzt“ (European Union, Copernicus Sentinel-2 imagery o.D.).* Die Daten werden kostenlos für Jedermann zur Verfügung gestellt. Es befinden sich zwei Sentinel-2 Satelliten im All (A + B), welche in einer Tandemkonstellation fliegen, um die zeitliche Auflösung zu halbieren und die räumliche Abdeckung zu verbessern (European Space Agency 2015). Die multispektralen, optischen Sensoren der beiden Satelliten liefern hoch aufgelöste Bilder (10 bis 60 Meter) der Landoberfläche und Küstenbereiche im sichtbaren und infraroten Spektrum zwischen 443 und 2190 nm. Ihr Sensor umfasst 13 Bänder, die für die Beobachtung der Landoberfläche optimiert sind (Tabelle 2). Die Überflughäufigkeit (Revisit Time) beträgt für Österreich zwischen 2-3 bis 5 Tage (European Space Agency 2015), je nach Region.

Satellitendaten müssen vor der fachspezifischen Verwendung in der Regel einer Vorbearbeitung unterzogen werden. Eine radiometrische Korrektur ist notwendig, da die detektierte reflektierte Strahlung z.B. durch verschiedene Faktoren wie Beleuchtungsunterschiede, atmosphärische Einflüsse, Blickwinkel oder Charakteristika des Sensors selbst beeinflusst wird (Lange 2013). Die geometrische Korrektur behebt Verzerrungen aufgrund der Neigung des Sensors oder den topografischen Höhenunterschieden und beinhaltet die Zuordnung der Bildpunkte zu einem Koordinatensystem (Lange 2013; Albertz 2013). Für Sentinel-2 stellt die ESA jedoch

bereits vorbearbeitete Daten in verschiedenen Levels bereit. Die Bearbeitungsstufe Level-2A beinhaltet die vorangehend genannten Korrekturen.

Weltweite Sentinel-2 Daten können zum Beispiel kostenlos im Internet unter <https://scihub.copernicus.eu/dhus/#/home> abgerufen werden. Für Sentinel-2 Daten des österreichischen Gebietes besteht zudem die Möglichkeit den semantischen Datenwürfel Sen2Cube.at (demo.sen2cube.at/) zu nutzen.

Tabelle 2: Sentinel-2-Bänder (Abbildung: Satellite Imaging Corporation o. D.)

Sentinel-2 Bands	Central Wavelength (µm)	Resolution (m)
Band 1 - Coastal aerosol	0.443	60
Band 2 - Blue	0.490	10
Band 3 - Green	0.560	10
Band 4 - Red	0.665	10
Band 5 - Vegetation Red Edge	0.705	20
Band 6 - Vegetation Red Edge	0.740	20
Band 7 - Vegetation Red Edge	0.783	20
Band 8 - NIR	0.842	10
Band 8A - Vegetation Red Edge	0.865	20
Band 9 - Water vapour	0.945	60
Band 10 - SWIR - Cirrus	1.375	60
Band 11 - SWIR	1.610	20
Band 12 - SWIR	2.190	20

1.2.5 Sen2Cube.at

Sen2Cube.at ist ein raumzeitlicher, semantischer Datenwürfel, den man sich als übereinander gestapelte Satellitenbilder vorstellen kann. Neben der Dimension Zeit wurde der Datenwürfel um eine semantische Dimension (entspricht Landbedeckungskategorien, basierend auf einer automatisierten Vorklassifikation) erweitert (Anonym 2019). Somit ist die Abfrage und Analyse von Sentinel-2 Daten auf einer höheren semantischen Ebene möglich. Der Datenzugriff wird durch eine Weboberfläche (Abbildung 4) realisiert. Dort kann der Nutzer die Zielregion, ein Zeitintervall und ein Modell zur Datenabfrage definieren.

Als Ergebnis der Abfrage stehen verschiedene Informationsschichten zur Verfügung (Abbildung 5): Radiometrisch und geometrisch korrigierte Sentinel-2 Aufnahmen (ToA – Top of atmosphere) aller verfügbaren Sentinel-2-Bänder seit 2015, sowie ein Greenness-Index-Layer und ein Brightness-Layer. Weiterhin ist ein semantisches Informationslayer

abfragbar. Diese semantische Informationsschicht wird automatisch anhand des „Satellite Image Automatic Mapper™“ (SIAM™, Baraldi et al. 2010), sozusagen als Vorklassifikation, erstellt. Es handelt sich dabei um ein Expertensystem, basierend auf einem Entscheidungsbaum, das jeden Pixel anhand eines „physikalischen Modells der spektralen Reflexion“ einem „Farbnamen“ zuordnet (Baraldi et al. 2010). Dieser ist wiederum mit einer Art „Landnutzungskategorie“ assoziiert, welche aber nicht als finale Landbedeckungskategorie interpretiert werden sollte (Tiede 2013).

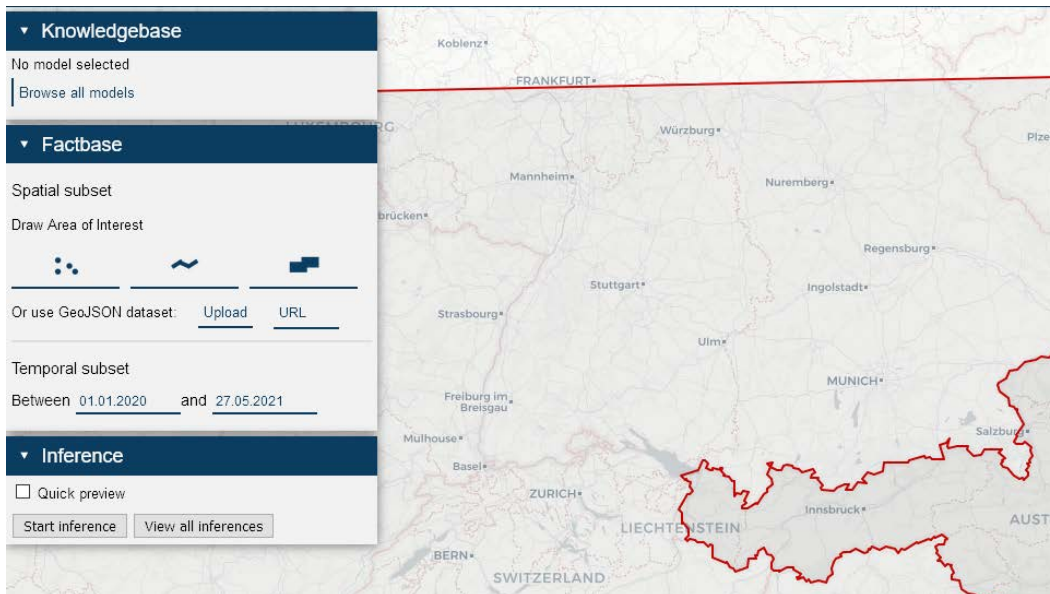


Abbildung 4: Weboberfläche des Sen2Cube.at zur Abfrage des Datenwürfels

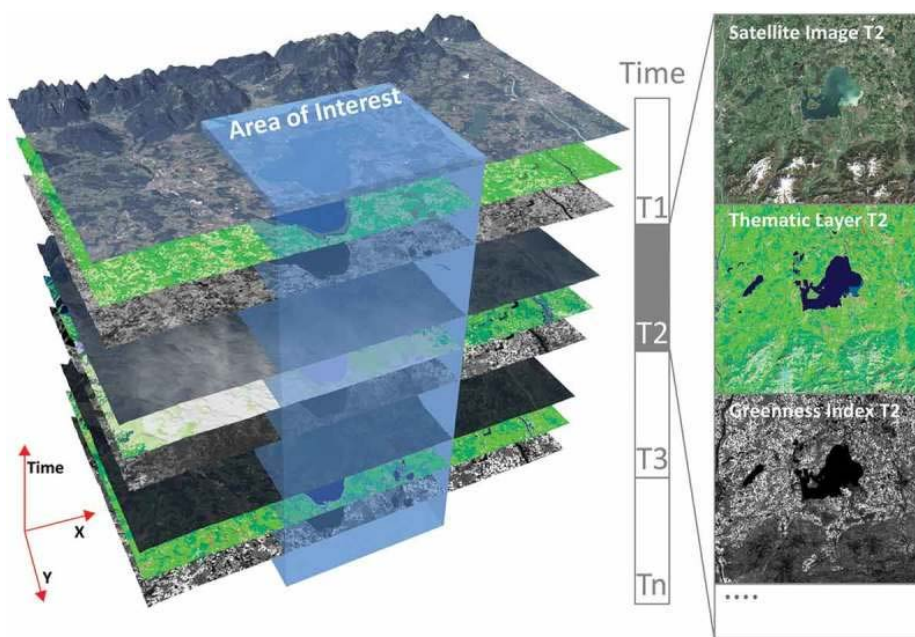


Abbildung 5: Informationsschichten von Sen2Cube.at (Bild: Tiede et al. 2017)

Das SIAM-Informationssystem beinhaltet 33 Kategorien, wobei 10 davon im Zusammenhang mit Vegetation stehen und für die vorliegende Arbeit relevant sind (Tabelle 3).

Tabelle 3: „Vegetation“ beinhaltende SIAM-Kategorien in Sen2Cube.at

Class	Abbreviation	Category
1	SVHNIR	Strong vegetation with high NIR
2	SVLNIR	Strong vegetation with low NIR
3	AVHNIR	Average vegetation with high NIR
4	AVLNIR	Average vegetation with low NIR
5	WV	Weak vegetation
6	SHV	Shadow area with vegetation
7	SHRBRHNIR	Shrub Rangeland with High NIR
8	SHRBRLNIR	Shrub Rangeland with Low NIR
9	HRBCR	Herbaceous Rangeland
10	WR	Weak Rangeland

Über die Definition eines Modells (Abbildung 6) in der Datenabfrage erhält der Nutzer eine Vielzahl an Möglichkeiten, Daten, Bilder (GeoTiff) und semantische Informationen (SIAM-Kategorie) abzufragen, zu filtern (Wolkenfilter) oder neu zu berechnen (z.B. Berechnung von Indices).

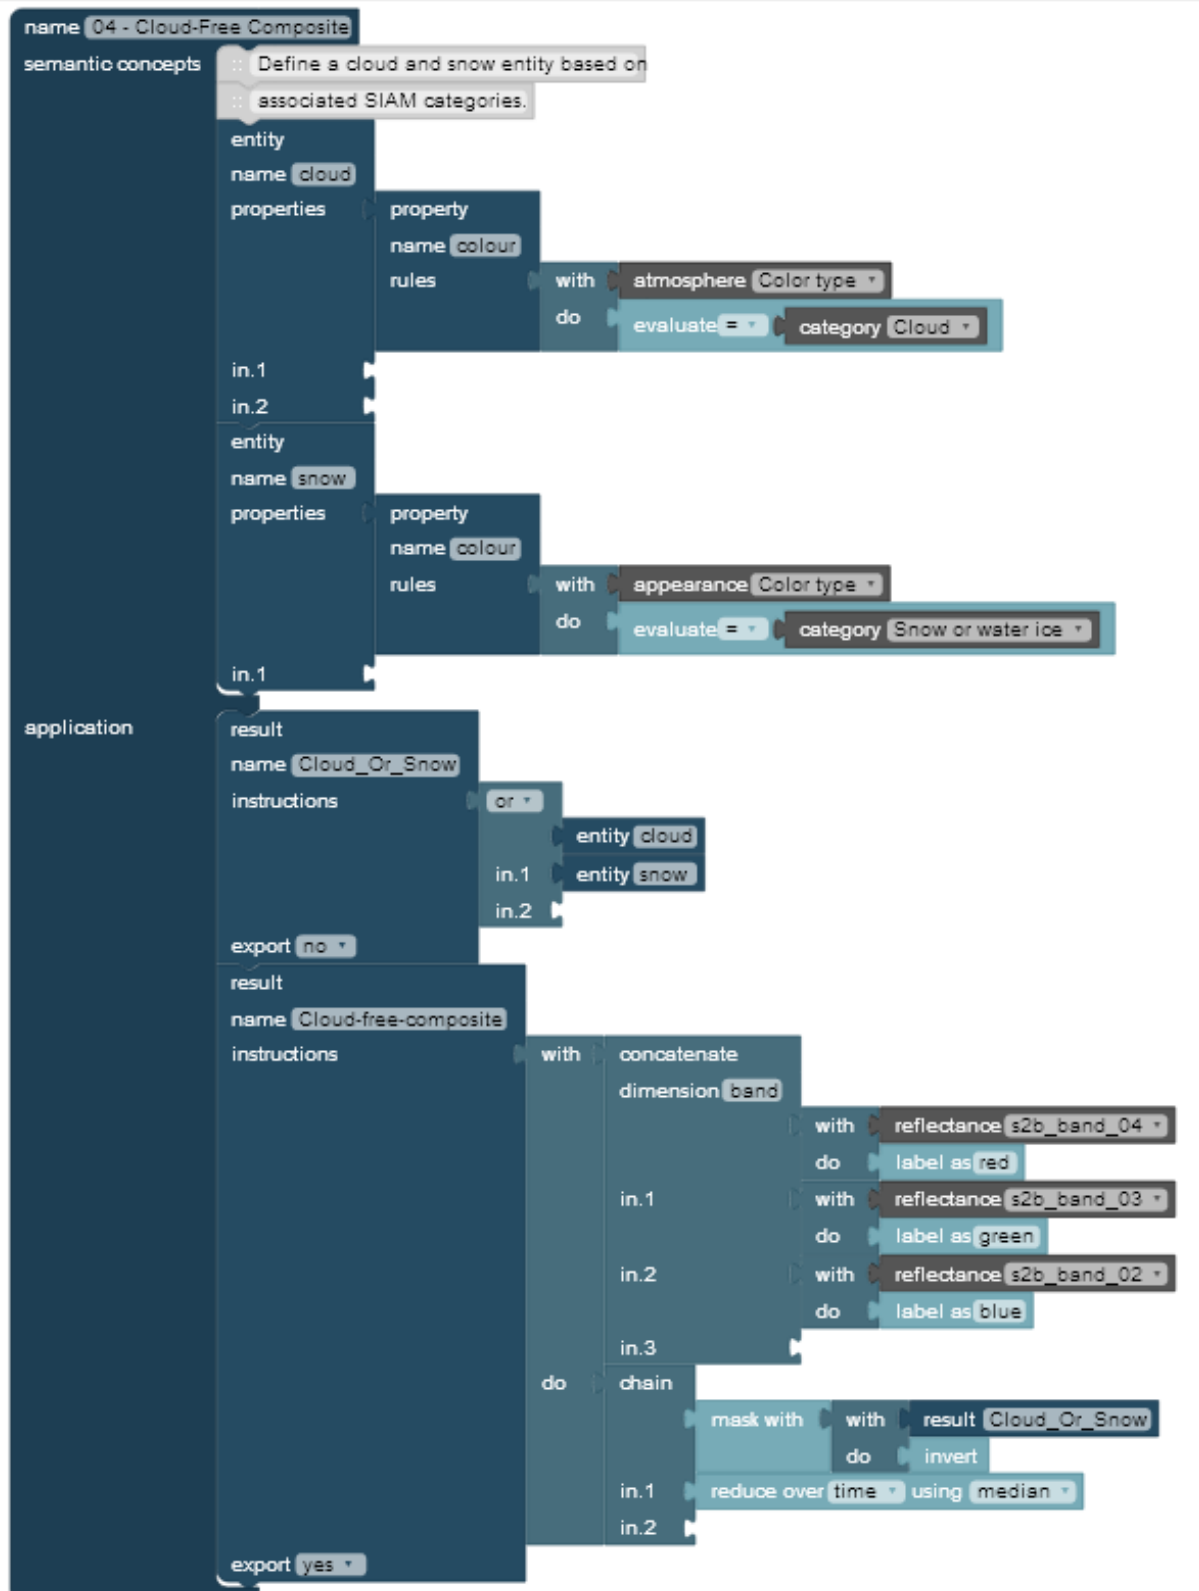


Abbildung 6: Beispiel für die Abfrage eines wolkenfreien RGB-Bildes. Es wird für jeden wolkenfreien Pixel (RGB) der betreffenden Region der Median über eine Zeitreihe ausgegeben und damit ein wolkenfreies Gesamtbild erstellt.

1.3 Zielstellung

Ziel der vorliegenden Arbeit ist es, die Anwendbarkeit satellitenbasierter Methoden zur Untersuchung und Darstellung der zeitlichen Heterogenität der Mahd auf Grünlandflächen zu prüfen und geeignete Methoden zu identifizieren. Dabei werden insbesondere ein semantischer Data Cube (Sen2Cube.at) und die darin vorgehaltenen Sentinel-2 Daten verwendet. Der Datenwürfel ermöglicht semantische Bild-, und Datenabfragen über die Zeit (Augustin et al., 2019) und deckt räumlich ganz Österreich ab.

Folgende Forschungsfragen werden im Rahmen der Arbeit beantwortet:

- Sind Sentinel-2 Daten geeignet, um die zeitliche Heterogenität der Mahd auf österreichischen Grünlandflächen darzustellen?
- Welches methodische Vorgehen ist unter Verwendung des semantischen Datenwürfels „Sen2Cube.at“ sinnvoll, bzw. welche Parameter können zur Darstellung der zeitlichen Heterogenität der Mahd genutzt werden?
- Lassen sich anhand des erarbeiteten methodischen Vorgehens Unterschiede in der zeitlichen Verteilung der Mahd zwischen Heumilch- und Nicht-Heumilchbetrieben nachweisen?

Zur Beantwortung oben genannter Fragen wird zunächst untersucht, welche der in Sen2Cube.at zur Verfügung stehenden Layer (NDVI, Greenness-Index, SIAM-Vorklassifikation) genutzt werden können, um Mähereignisse auf Grünlandflächen zu definieren. Geeignete Parameter und Grenzwerte werden getestet, um die höchstmögliche Genauigkeit bei der Ableitung der Mähereignisse zu erzielen. In einem weiteren Schritt wird ein alternatives methodisches Vorgehen zur Darstellung der zeitlichen Heterogenität der Grünlandbewirtschaftung, ohne eine grenzwert-basierte Bestimmung der Mähereignisse, entwickelt. Das erarbeitete Vorgehen wird jeweils an Heumilch- und Nicht-Heumilchbetrieben angewendet um etwaige Unterschiede zwischen den Bewirtschaftungsformen aufzeigen zu können.

Die Arbeit entsteht mit Unterstützung der Landwirtschaftskammer Salzburg und der Arbeitsgemeinschaft Heumilch. Die verwendeten Daten der untersuchten Beispielbetriebe wurden im Rahmen einer vom Land Salzburg in Auftrag gegebenen Studie erhoben (Suske et al. 2021) und freundlicherweise für vorliegende Arbeit zur Verfügung gestellt.

Herzlichen Dank!

2 Datengrundlage und Methoden

2.1 Referenzdaten

2.1.1 Auswahl der Beispielbetriebe

Für die vorliegende Arbeit standen Daten zu Mähterminen sowie analoge Hofkarten von zehn Beispielbetrieben zur Verfügung. Fünf der Betriebe produzieren Heumilch und wirtschaften nach den entsprechenden Vorgaben. Die anderen fünf Nicht-Heumilchbetriebe produzieren hauptsächlich Silage als Grundfutter. Auch in diesen Betrieben wurden einzelne Flächen für die Heuproduktion verwendet. Die Betriebe befinden sich in unterschiedlichen Regionen Österreichs (Abbildung 7). Die Daten entstammen einer vom Land Salzburg in Auftrag gegebene Studie zu den Auswirkungen von Silageverzicht auf die Biodiversität auf Grünlandflächen (Suske et al. 2021). Jeweils ein Heumilch- und ein Nicht-Heumilchbetrieb bilden ein Betriebspaar in enger Nachbarschaft und mit ähnlicher Betriebsgröße. Somit sollte eine Vergleichbarkeit der Betriebsform (Heumilch/Nicht-Heumilch) hinsichtlich Erntezeitpunkt und Flächenausmaß gegeben sein. Für fast alle Flächen der Betriebe aus der Studie lagen Informationen zu den Ernteterminen für das Jahr 2019 und 2020 vor und konnten für vorliegende Untersuchungen genutzt werden (siehe Anhang Tabelle 11 und Tabelle 12). Allerdings ist nicht bekannt, ob der Erntetermin den Tag der Mahd oder im Falle einer Bodentrocknung den Tag der Einfuhr des Grases definiert. Anhand der eingescannten Hofkarten, auf der die Schläge des jeweiligen Betriebes verzeichnet sind, wurden die Betriebsflächen manuell auf die INVEKOS-Polygone im shape-Format (Agrarmarkt Austria 2019 und Agrarmarkt Austria 2020) gemapped und die entsprechenden Attribute (z.B. Mähtermin, Betriebstyp etc.) zugewiesen. Fand eine differenzierte Bewirtschaftung statt (Flächenteilung), so wurde diese Teilung ebenfalls in die Polygondaten (INVEKOS-Polygon) übernommen.

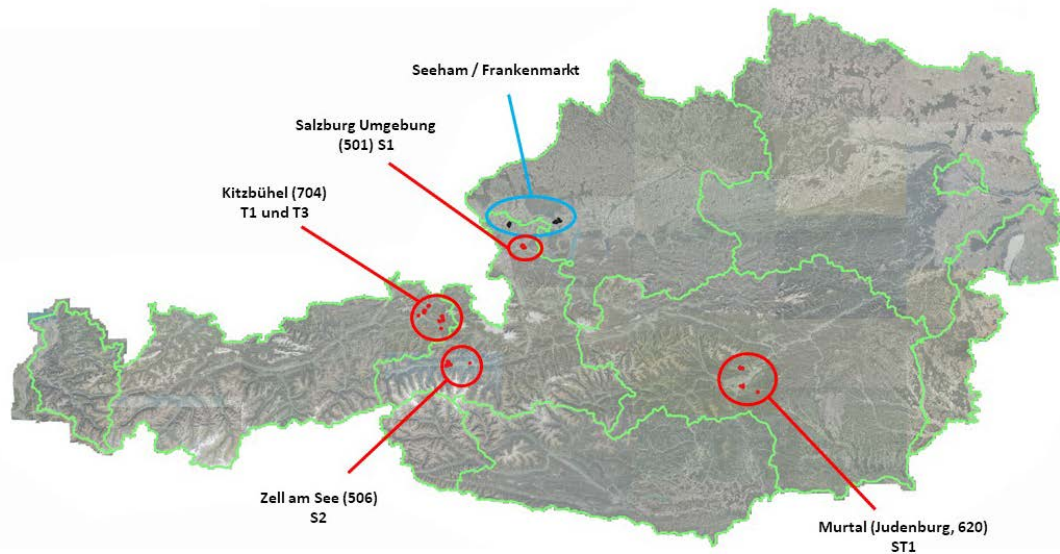


Abbildung 7: Lage der Untersuchungsbetriebe bzw. Betriebspaare

Für die Erarbeitung eines methodischen Vorgehens zum Nachweis der zeitlichen Verteilung der Mähzeitpunkte wurde jeweils für 2019 und 2020 ein Betriebspaar ausgewählt. Abbildung 8 und Abbildung 9 zeigen die zeitliche Verteilung der Mähzeitpunkte im jeweiligen Betrieb wie sie von den Landwirten dokumentiert wurden. Dargestellt ist der %-Anteil gemähter Fläche an der Gesamtfläche des Betriebes. Feldstücke die ausschließlich beweidet oder eingegrast wurden, sind in diesen Abbildungen nicht berücksichtigt. Hier kann kein exakter Erntetermin abgeleitet werden und eventuell ist auch nicht immer der gesamte Schlag betroffen. Eingegrast wird in der Regel täglich über einen Zeitraum von mehreren Tagen, wobei jeden Tag ein Teil der Fläche frisch gemäht wird. Auch die Beweidung kann als Portionsweide durchgeführt werden, d.h. die Tiere erhalten alle paar Tage ein anderes oder weiteres Flächenstück des Schlages als Futter. Dieses „stückweise“ Mähen oder Beweiden erschwert eine Auswertung des Erntegeschehens (Reinermann et al. 2020) sowohl den Zeitpunkt als auch das Reflexionsprofil (Satellitendaten) betreffend. Dies wird auch in Kapitel 3.1.1 deutlich. In die weitere Auswertung ab Kapitel 3.1.3, wurden deshalb nur Flächen miteinbezogen, auf denen weder Beweidung noch Eingrasen stattfand. In Abbildung 8 und Abbildung 9 sind Flächen mit einer zeitweisen Beweidung/Eingrasen noch enthalten. Für das Jahr 2019 standen im Heumilchbetrieb S1 generell keine exakten Mähzeitpunkte zur Verfügung und wurden deshalb auch nicht in die Auswertung miteinbezogen.

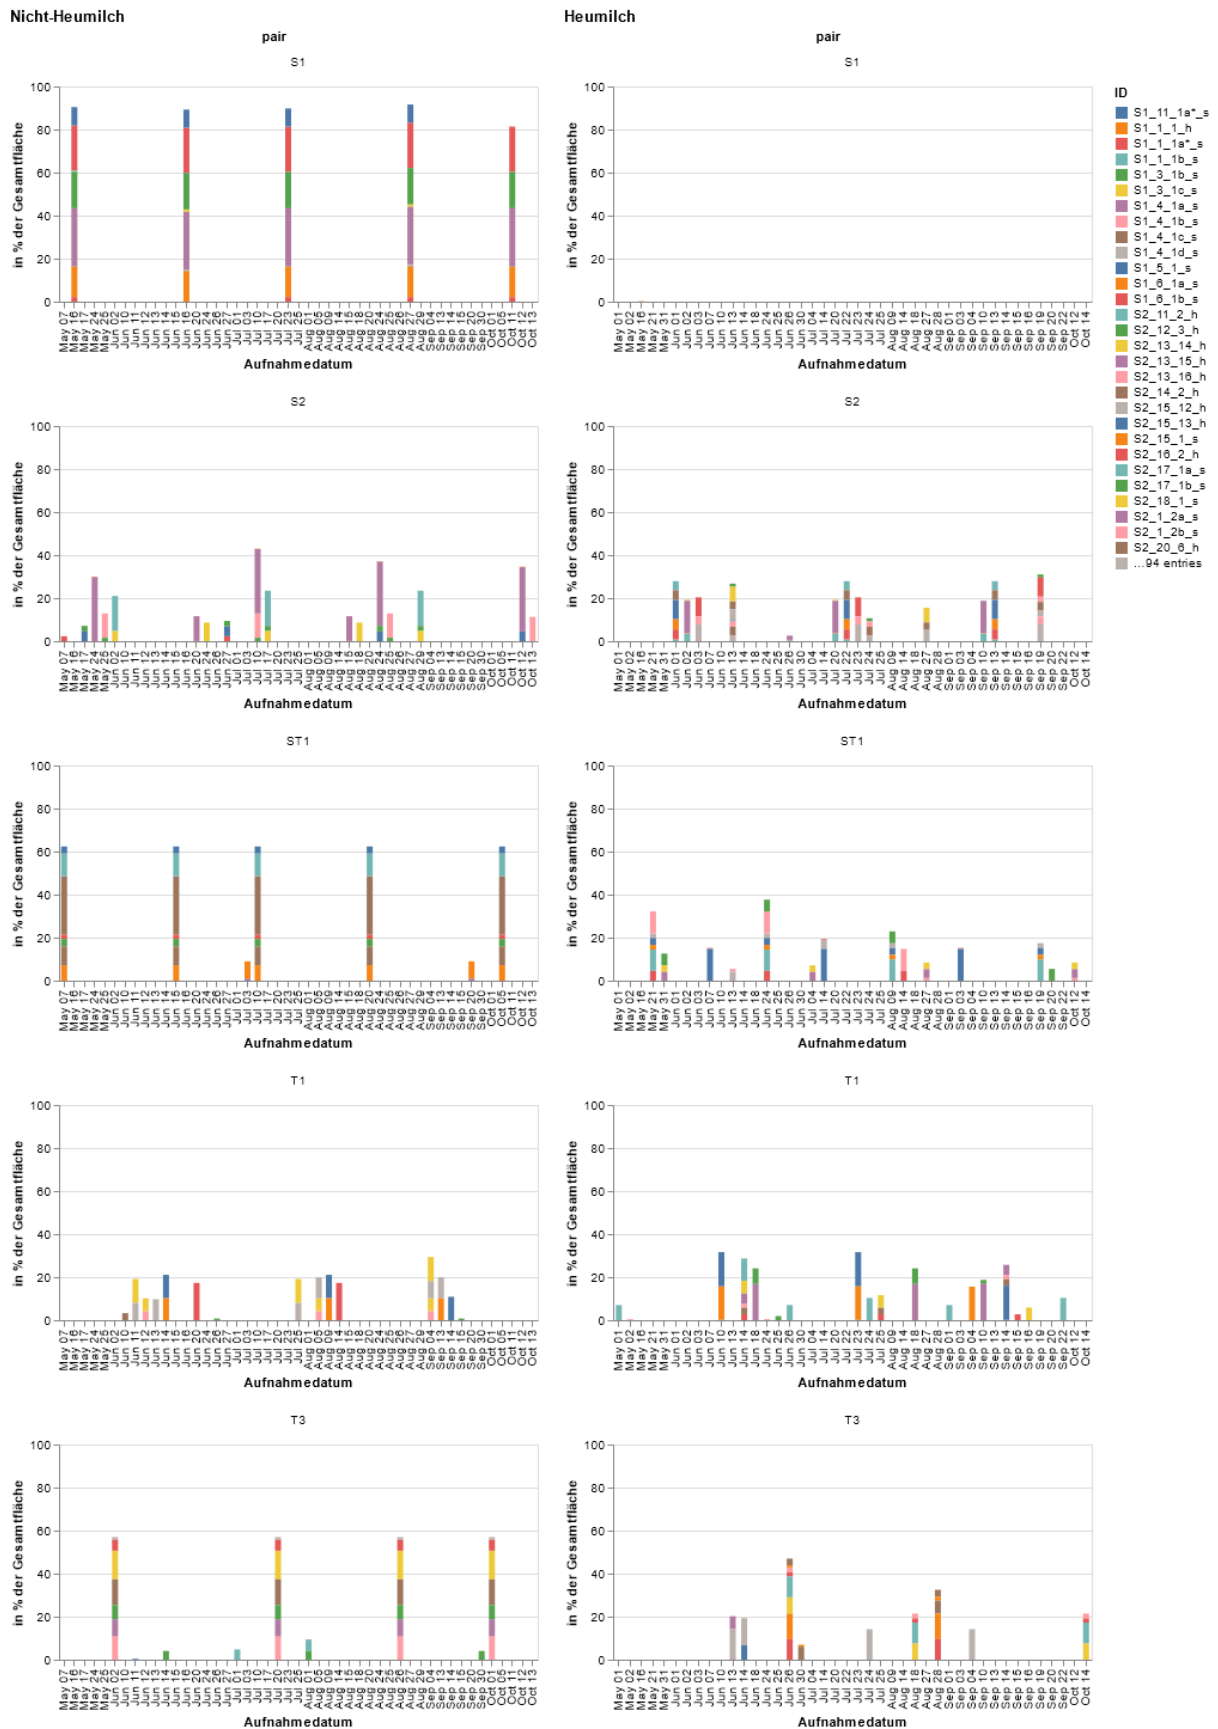


Abbildung 8: Gemähter Flächenanteil pro Schnittzeitpunkt je Betrieb in % im Jahr 2019 (Nicht-Heumilchbetrieb links, Heumilchbetriebe rechts); jedes Feldstück wird durch eine Farbe repräsentiert, aufgrund der Vielzahl wurden in der Legende jedoch nicht alle Feldstücke dargestellt

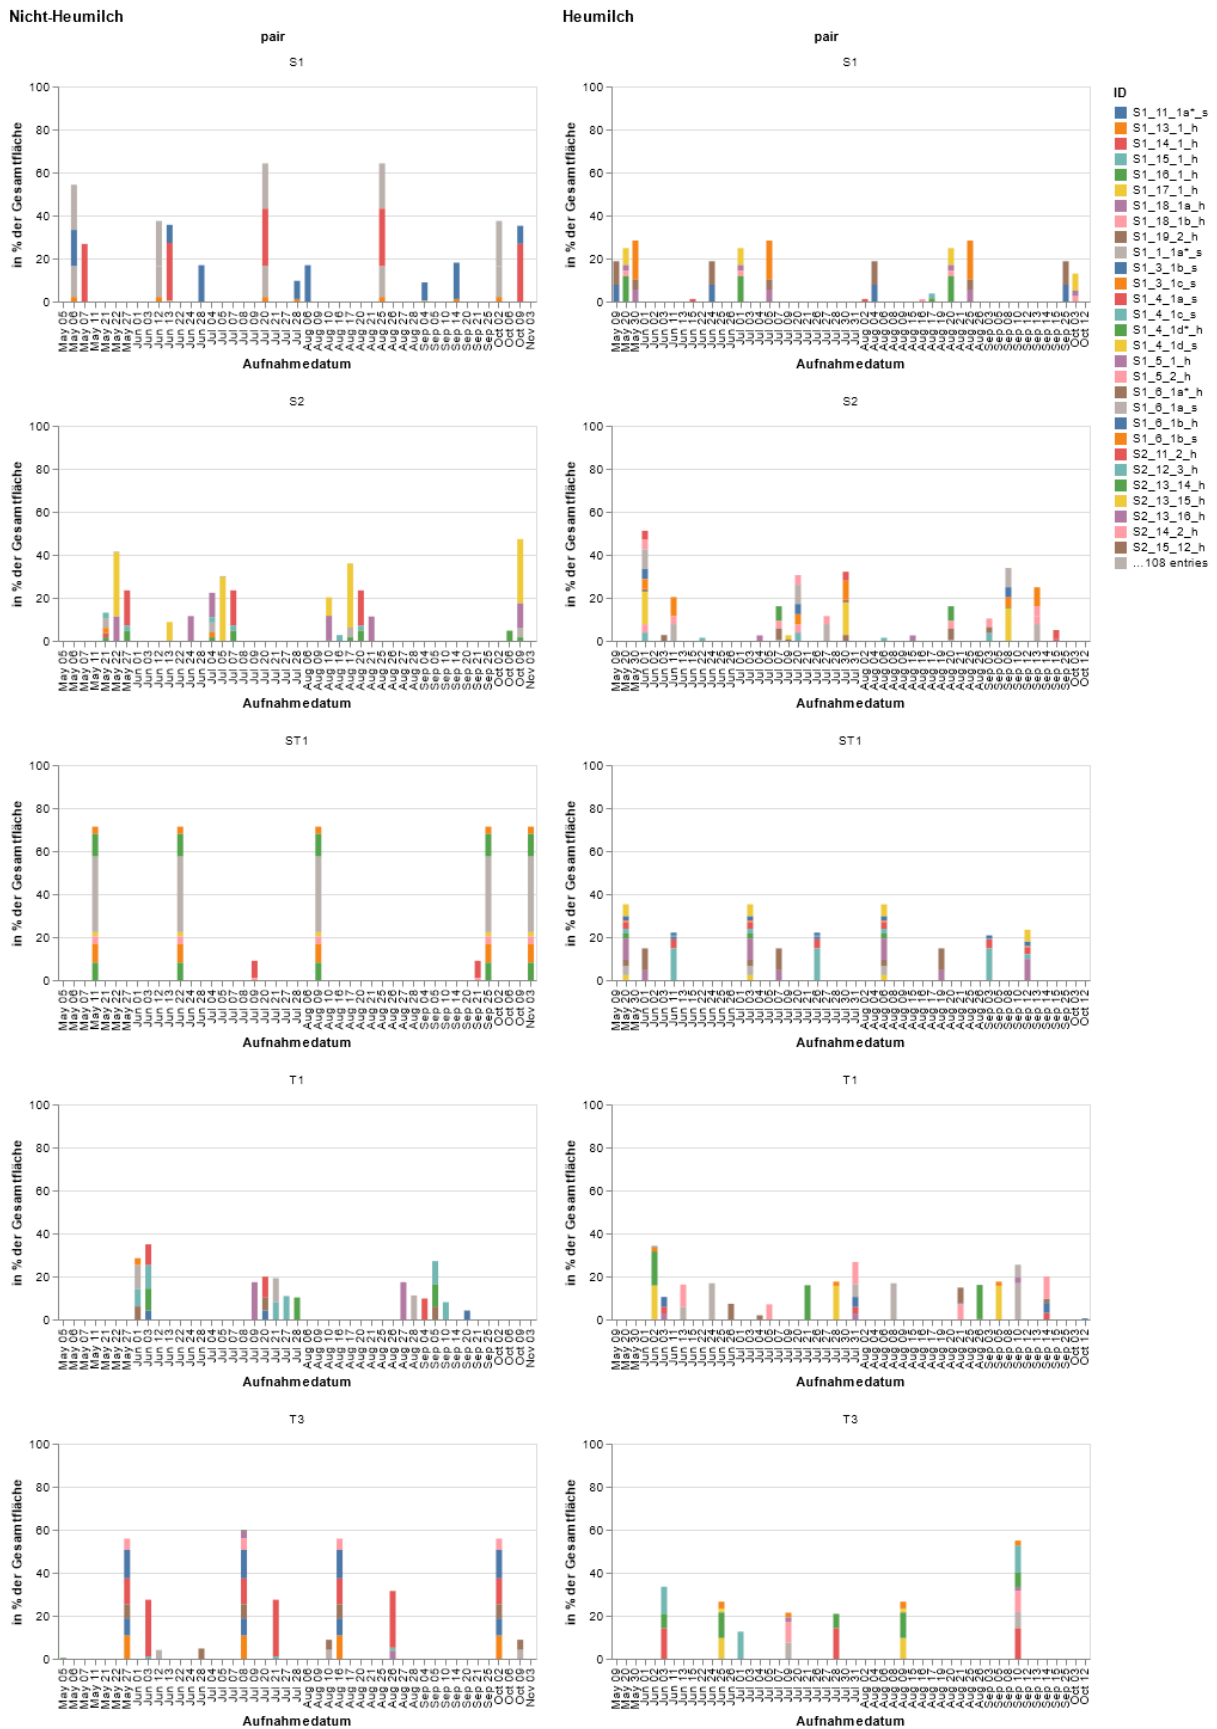


Abbildung 9: Gemähter Flächenanteil pro Schnittzeitpunkt je Betrieb in % im Jahr 2020 (Nicht-Heumilchbetrieb links, Heumilchbetriebe rechts); jedes Feldstück wird durch eine Farbe repräsentiert, aufgrund der Vielzahl wurden in der Legende jedoch nicht alle Feldstücke dargestellt

Aus Abbildung 8 und Abbildung 9 wird ersichtlich, dass die ausgewählten Nicht-Heumilchbetriebe tendenziell etwas früher mit der Ernte beginnen. Dies steht sicherlich im Zusammenhang mit der Witterung, die im zeitigen Frühjahr für die Trocknung des Heus weniger geeignet ist. Ein früherer Beginn der Grünlandmahd in den Nicht-Heumilchbetrieben kann jedoch nicht generell abgeleitet werden. Weiterhin zeigen die Abbildungen, dass in Heumilchbetrieben tendenziell mehr Schnitttermine für die Produktion des Grundfutters benötigt werden (Beispiel: Betrieb ST1 in 2019 und 2020) und/oder diese z.T. heterogener über die Saison verteilt sind (Beispiel: Betrieb T1 in 2020). Allerdings wird auch deutlich, dass zumindest unter den verwendeten Kriterien der Auswertung (keine Einbeziehung von Weide oder Eingrasen) davon nicht grundsätzlich ausgegangen werden kann. Für Betrieb S2 (2019) oder T3 (2020) treffen die vorgenannten Annahmen (Verteilung und Anzahl der Ernteterminen) nicht zu.

Da in der vorliegenden Arbeit das methodische Vorgehen zur Darstellung der postulierten Unterschiede zwischen Heumilch- und Nicht-Heumilchbetrieben im Fokus standen, wurden die weiteren Untersuchungen anhand zweier Beispielbetriebe durchgeführt. Die gewählten Betriebe ließen aufgrund obiger Auswertung Unterschiede in der zeitlichen Heterogenität der Grünlandmahd erwarten. Für das Jahr **2019** wurde das Betriebspaar **ST1** und für 2020 das Betriebspaar **T1** ausgewählt.

Weiterhin fanden Daten von zwei Beispielgemeinden in der vorliegenden Arbeit Verwendung. In der Gemeinde Seeham (Salzburg, Obertrumer See) gibt es eine Vielzahl von Heumilchbetrieben. Im etwa 25km entfernt liegenden Frankenmarkt (Oberösterreich) wird vorwiegend klassische Grünlandbewirtschaftung mit Silagebereitung betrieben (mündliche Aussage der Landwirtschaftskammer Salzburg, 2021). Die Polygondaten der Feldstücke (Agrarmarkt Austria 2020) in den genannten Gemeinden wurden nach Schlagnutzungsart gefiltert, um nur Flächen in die Auswertung einzubeziehen, welche mit einer der folgenden Nutzungsarten bezeichnet sind:

- Mähwiese/-weide drei und mehr Nutzungen
- Mähwiese/-weide zwei Nutzungen
- Einmähdige Wiese

2.1.2 Aufbereitung der Polygondaten

Die Flächeninformation in Form der Polygondaten im shape-Format wurden einer weiteren Aufbereitung unterzogen. Abbildung 10 zeigt, dass ein Einfluss der an die

Untersuchungsflächen angrenzender Siedlungen oder Verkehrswege auf die Reflexionsdaten oder die Klassifikationsergebnisse nicht ausgeschlossen werden kann. Mischpixel entstehen, wenn ein Pixel, bedingt durch die räumliche Auflösung, unterschiedliche Landbedeckungsklassen (Tempfli et al. 2009) oder unterschiedliche landwirtschaftliche Bewirtschaftungseinheiten enthält. Eine eindeutige Zuordnung zu einer Klasse oder die eindeutige Berechnung eines Vegetationsindex ist dann nicht mehr möglich, was zu Fehlern führen kann (Lange 2013). Um diese Randeffekte zu vermeiden wurden die Polygone der Untersuchungsflächen für die weitere Analyse um fünf Meter nach innen gepuffert. Sehr kleine Flächen gehen dabei allerdings verloren. So konnten kleine und sehr schmale, aber langgezogene Flächen nicht in der weiteren Auswertung berücksichtigt werden. Allerdings sind Flächen mit nur 0,02 ha und einer Breite von < 2 m (siehe Beispiel Abbildung 11) ohnehin nicht für eine Auswertung geeignet, da die Auflösung der Sentinel-2 Daten 10×10 m beträgt.



Abbildung 10: Mischpixel (roter Pfeil) an den äußeren Rändern der Grünlandfläche mit Übergang zur Siedlungsfläche oder Verkehrsweg (am Beispiel einer NDVI-Karte)




Abbildung 11: Sehr kleine und schmale Flächen (gelb markiert) wurden nicht in die Auswertung miteinbezogen

Eine Überführung der Polygone in das Datenformat geojson sowie in das Koordinatenreferenzsystem WGS84 war ebenfalls notwendig, da für die Abfrage der Satelliteninformation in Sen2Cube nur dieses Format und Koordinatenreferenzsystem akzeptiert wird. Intern werden die Daten dann jedoch in die europaweit gültige und flächentreue Projektion „ETRS89 / LAEA Europe“ (EPSG:3035), gemäß der EU-Richtlinie INSPIRE, umprojiziert und in dieser Form weiterverarbeitet.

2.2 Identifikation von Mähereignissen auf Grünland anhand von Sentinel-2 Daten

Ein Vergleich der Heterogenität der Grünlandbewirtschaftung von Heumilchbetrieben im Vergleich zu Nicht-Heumilchbetrieben kann anhand der Analyse und Darstellung der Verteilung der Mähereignisse (vergleiche Abbildung 8 und Abbildung 9) mit Fernerkundungsmethoden erfolgen (Kap. 1.2.3). Hierfür ist eine verlässliche Identifikation der Mähzeitpunkte erforderlich. In vorliegender Arbeit wurde die Eignung von zwei Vegetationsindices und der semantischen Information (SIAM-Vorklassifikation) des Sen2Cube.at zur Untersuchung obiger Fragestellung geprüft.

Vegetations-Indices: Vegetationsindices fassen die spektralen Informationen aus zwei oder mehr Bändern der Satellitensensoren in einem (Verhältnis-)Wert zusammen (Kapitel 1.2.3). Ein Vorteil von Verhältniswerten ist die geringere Sensitivität gegenüber der absoluten Helligkeit, da alle Bänder von einer eingeschränkten Belichtung, z.B. durch Schattenwurf, gleichermaßen betroffen sind (Lillesand et al. 2015). Hinsichtlich der

Beurteilung des Biomasseaufwuchses auf Grünland (Mähzeitpunkt) können anhand von Indexwerten, einem quantitativen und stetigen Merkmal, auch alle Zwischenstadien (beginnender Aufwuchs, mittlerer Aufwuchs etc.) dargestellt werden. Eine Mahd hat immer dann stattgefunden, wenn sich der Index-Wert zwischen zwei Aufnahmetermi- nen abrupt und deutlich ändert bzw. abfällt.

In vorliegender Arbeit wurde der NDVI sowie der Greenness-Index (Baraldi et al. 2010) für die Erkennung von Mähereignissen auf Grünland verwendet. Letzterer erfasst auch den spektralen Bereich des short-wave-Infrarot (SWIR) und ist in Sen2Cube.at integriert.

SIAM-Kategorien: Als semantische Information stehen in Sen2Cube.at Daten einer automatischen Vorklassifikation zur Verfügung. Diese basiert auf der SIAM™ Toolbox (Satellite Image Automatic Mapper, Baraldi et al. 2010, Kapitel 1.2.5). Es wurden alle SIAM-Kategorien verwendet, die im Zusammenhang mit Vegetation stehen (Kapitel 1.2.5). Die Ableitung eines Mähereignisses kann sich z.B. aus der Änderung der Pixelzuordnung zu den SIAM-Kategorien (z.B. Kategorie hohe Vegetation → Kategorie niedrige Vegetation) ergeben. Zwischenstadien können anhand dieses qualitativen und diskreten Merkmals nur insoweit betrachtet werden, wie dies im Klassifikationsschema vorgesehen ist.

In vorliegender Arbeit wurden eine Ableitung des Mähzeitpunktes sowohl anhand von Vegetationsindices als auch anhand von SIAM-Kategorien geprüft. Die Rohdaten (SIAM-Kategorien und Vegetationsindices) wurden mittels Sen2Cube.at in spezifischen Abfragen (Anhang: Abbildung 52 bis Abbildung 55) für den Vegetationseitraum von Anfang April bis Ende November für die Jahre 2019 und 2020 generiert. Da es sich hierbei nicht um die Betrachtung einer Einzelaufnahme, sondern eines Verlaufes/Zeitreihe handelt, müssen die Pixelinformationen pro Untersuchungsfläche und Aufnahmezeitpunkt „reduziert“ werden. Im Falle der Vegetationsindices wird der Mittelwert über die Fläche für jeden Aufnahmezeitpunkt und jedes Feldstück gebildet und kann rechnerisch weiterverarbeitet oder grafisch dargestellt werden. Die Ergebnisse der semantischen Abfrage (SIAM-Kategorien) werden als Prozent Flächenanteil (Pixelanteil) einer Kategorie pro Untersuchungsfläche (Feldstück) und Zeitpunkt zusammengefasst.

2.3 Wolkenfilter

Wolken, Schnee, Dunst oder Wolkenschatten verfälschen die Bildinformation in optischen Systemen, da das reflektierte Licht sie kaum durchdringen kann (Abbildung 12). Die Reflexionswerte der Satellitenaufnahmen sind bei Bewölkung entweder deutlich überhöht

bzw. zu hell, da ein Großteil des Lichts von den Wolken reflektiert wird (Wasser et al. 2021). Die Werte können aber auch zu niedrig bzw. zu dunkel sein, da aufgrund der geringeren Menge an einfallender Strahlung weniger reflektiert werden kann (Wasser et al. 2021). Durch Wolken oder ähnliche Störungen beeinflusste Aufnahmen oder Pixel sind dadurch unbrauchbar (Lilienthal und Greef 2017) und sollten anhand einer „Wolkenmaske“ von der Auswertung ausgeschlossen werden.

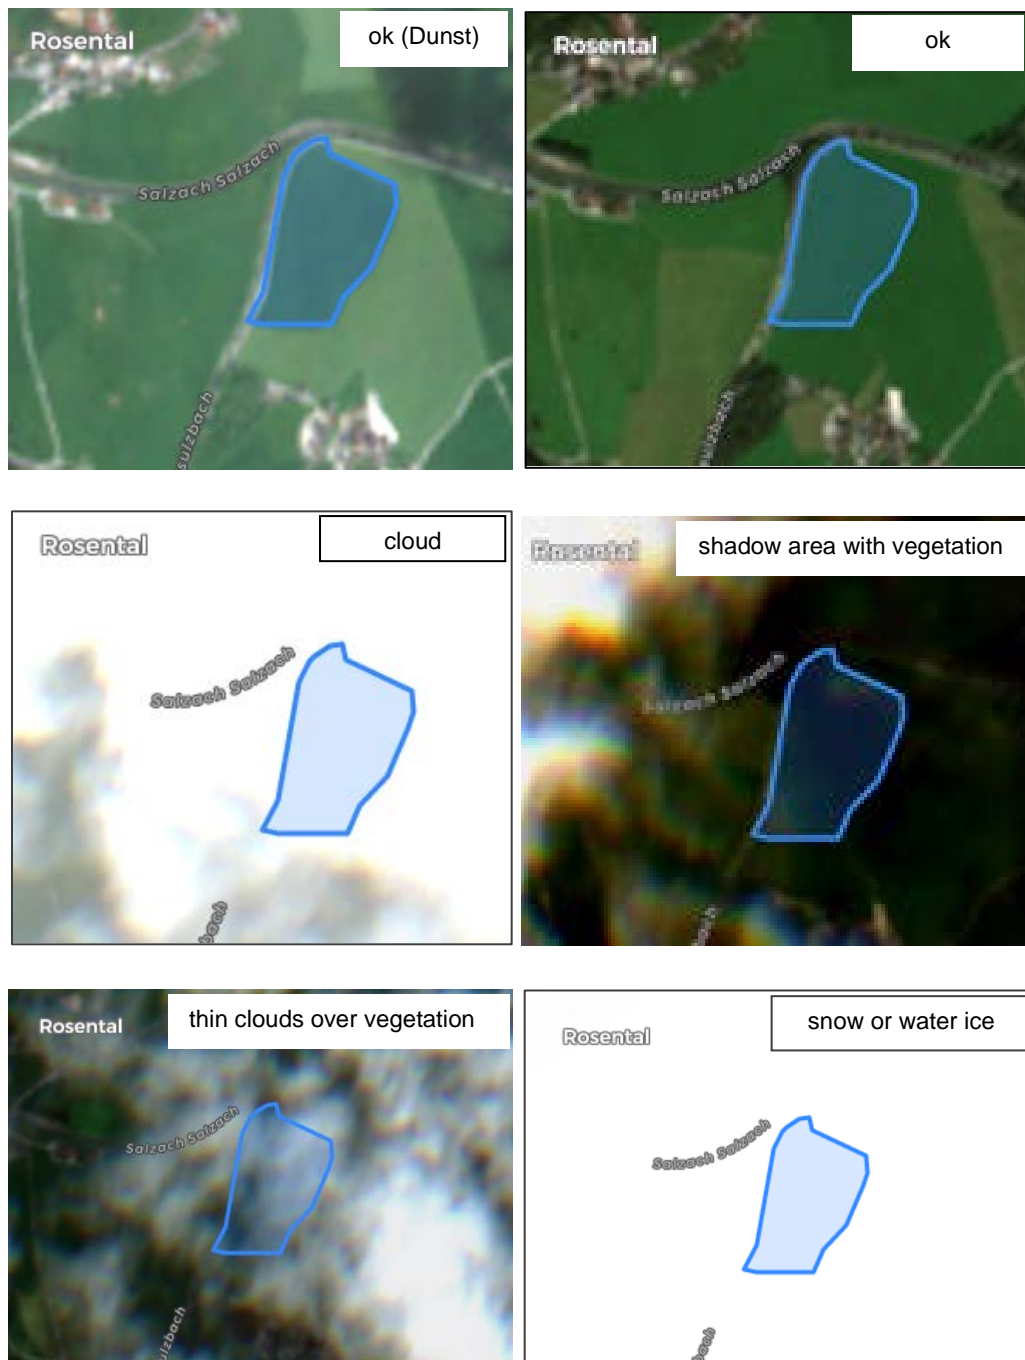


Abbildung 12: Sentinel-2-Aufnahme (RGB) mit witterungsbedingten Störungen

Zum einen besteht die Möglichkeit für jeden einzelnen Pixel die Entscheidung zutreffen, ob er aufgrund von Bildstörungen ausgeschlossen werden soll. Es kann aber auch das gesamte Bild oder alle Pixel einer zu untersuchenden Fläche dementsprechend klassifiziert werden, z.B. anhand eines Grenzwertes ($> 10\%$ -Anteil Pixel mit Wolken). In vorliegender Arbeit wurden Zeitreihen betrachtet und daher sollte sich die Untersuchungsfläche über die Zeit nicht ändern. Es wurde deshalb letztere Vorgehensweise gewählt und eine Untersuchungsfläche (Feldstück) anhand einer Wolkenmaske (10%) gänzlich als auswertbar oder nicht auswertbar klassifiziert. Die Wolkenmaske besteht aus einer Tabelle mit sämtlichen Aufnahmetermen der Sentinel-2 Daten im Untersuchungszeitraum und der Information, ob das Bild für das jeweilige Feldstück auswertbar (wolkenlos) ist oder nicht. Sie kann in der weiteren Auswertung als Filter verwendet werden. Die Wolkenmaske wurde aus dem semantischen Informationslayer bzw. den relevanten SIAM-Kategorien in Sen2Cube.at erstellt. Grundlage dafür war die Zuordnung der Pixel zur SIAM-Kategorie „cloud“. Es wurden jedoch weitere SIAM-Kategorien mit in das Modell aufgenommen:

- cloud
- shadow area with vegetation
- thin clouds over vegetation
- snow or water ice

In Vortests hatte sich gezeigt, dass einzelne, gänzlich bewölkte Aufnahmen nicht als „cloud“ sondern als „snow or water ice“ klassifiziert wurden. Gründe hierfür könnten sehr hohe Eiswolken sein, deren Reflexionsprofil sich von anderen Wolkenarten unterscheidet. Auch Wolkenschatten beeinträchtigen die Ergebnisse. Aus diesem Grund wurden diese Kategorien mit in das Modell aufgenommen. Weitere relevante Kategorien (z.B. „turbid water or shadow“) wurden in den bewölkten Aufnahmen nicht identifiziert.

Die Verlässlichkeit und Übertragbarkeit der Wolkenmaske für den Vegetationszeitraum von Anfang April bis November (2018 / 2019 / 2020) wurde anhand von manuell klassifizierten Aufnahmen für drei Grünlandflächen validiert. Der festgelegte Grenzwert für die automatisierte Erstellung der Wolkenmaske wurde mit $> 10\%$ festgelegt. D.h. bei einem Pixelanteil von $> 10\%$ der Kategorien „cloud“, „shadow area with vegetation“, „thin clouds over vegetation“ oder „snow or water ice“ wurden alle Pixel für das betreffende Feldstück von der weiteren Auswertung ausgeschlossen bzw. der Termin dementsprechend markiert. Für die Validierung wurden die oben genannten SIAM-Kategorien zu einer Klasse „bewölkt“ zusammengefasst, da für die weitere Analyse

letztendlich nur von Interesse war, ob ein Bild auswertbar („ok“) ist oder nicht. Welche Störung auftrat war in diesem Fall von nachgeordnetem Interesse.

Aus dem Vergleich der SIAM-Vorklassifikation und der manuellen Klassifikationsergebnisse (Referenz: manuell erstellte Wolkenmaske) wurde eine Fehlermatrix (Anhang, Tabelle 9) berechnet, um die Qualität des automatisch erstellten Wolkenfilters einzuschätzen und Schwachstellen aufzudecken. Die Produzentengenauigkeit lag bei 97,6 % der störungsfreien Bilder (Klasse „ok“). D.h. es hätten noch 2,4 % der Aufnahmen zusätzlich in die Auswertung einfließen können (falsch negativ). Diese wurden aber fälschlicherweise der Klasse „bewölkt“ zugeordnet und damit von der weiteren Auswertung ausgeschlossen. Eine Nutzergenauigkeit von 92,2 % bedeutet, dass 7,8 % der als störungsfrei/„ok“ klassifizierten Aufnahmen doch Störungen enthielten (falsch positiv) und damit das Ergebnis der weiteren Auswertung negativ beeinflussen können. Die Gesamtgenauigkeit der Klassifikation betrug 95 %.

Das Ergebnis entspricht dem von anderen Autoren angegebenen Genauigkeitsbereich (review: Mahajan und Fataniya 2020). Bei vorangehend beschriebenem methodischen Vorgehen (Kapitel 2.3) ist mit ca. 8 % falsch Positiven, d.h. mit Aufnahmen die Störungen enthalten aber als störungsfrei klassifiziert werden, zu rechnen. Diese falschen Klassifikationen waren vorrangig der Kategorie „thin clouds over vegetation“ zuzuschreiben, wurden aber nicht als solche klassifiziert. Allerdings stellte sich auch die manuelle Klassifikation (Referenz) dieser Klasse als sehr schwierig heraus. Es handelt sich hier um nicht wirklich messbare Faktoren. Die Einschätzung, ob es sich um leichten Dunst (Klasse: „ok“) oder dünne Wolken (Klasse: „thin clouds over vegetation“) handelt, und damit ob das Bild als gültig oder ungültig eingestuft werden sollte, ist sehr subjektiv. Ebenso problematisch scheint die Erkennung von durch Wolken beschatteten Bildern oder Bildteilen. Mehrheitlich wurden diese von Sen2Cube.at nicht der entsprechenden Kategorie zugeordnet und machten einen großen Teil der falsch negativen Ergebnisse aus. Aufgrund der insgesamt hohen Genauigkeit der Klassifikation von 95 % können die semantischen Informationsschichten von Sen2Cube.at mit den oben genannten SIAM-Kategorien jedoch zur Erstellung einer Wolkenmaske verwendet werden.

Für die unter Kap. 2.1.1 gewählten Beispielbetriebe ist die Bewölkung für den Untersuchungszeitraum in Abbildung 13 dargestellt. Es wird deutlich, dass durchgehend wolkenfreie Phasen im Untersuchungsgebiet eher selten sind. Trotz hoher temporaler Auflösung der Sentinel-2 Daten stehen für die Auswertung nur 9 (2019) bzw. 16 (2020) auswertbare Satellitenaufnahmen zur Verfügung.

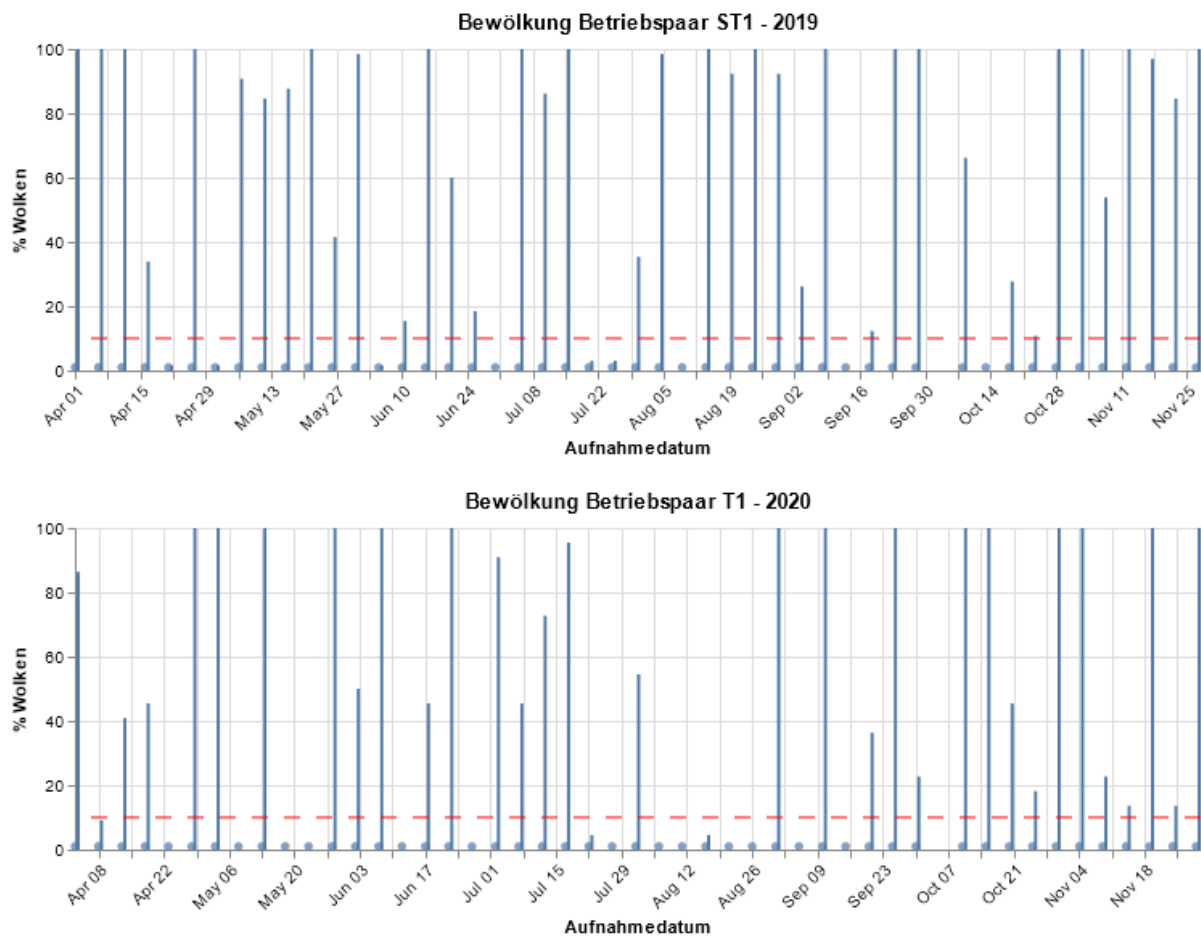


Abbildung 13: Bewölkung in % für die Flächen der Beispielbetriebe (Gesamtfläche) im Untersuchungszeitraum 2019 und 2020; blaue Punkte = Aufnahmedatum Sentinel-2; rote Linie = Grenzwert für „störungsfreies“ Bild

2.4 Verwendete Software

Sämtliche Sentinel-2 Daten (Reflexionswerte, NDVI, Greenness-Index) und semantischen Informationen (SIAM-Vorklassifikation) wurden über die Weboberfläche des semantischen Datenwürfels Sen2Cube.at (demo.sen2cube.at/) abgefragt oder dort berechnet (NDVI). Der Export der Daten erfolgte entweder als csv-Datei oder als Bilddatei im GeoTiff-Format (SIAM-Vorklassifikation). Die Bilddateien einer Zeitreihe werden im Ergebnis als eine GeoTiff-Datei mit mehreren Bändern ausgegeben, wobei jedes Band einem Aufnahmetermin entspricht.

Für eine Weiterverarbeitung der Daten kam Python in der Version 3.9.2 zum Einsatz. Python wurde innerhalb von JupyterLab (Version 3.0.14) verwendet. Folgende Python libraries (Tabelle 4) fanden in vorliegender Arbeit Verwendung:

Tabelle 4: Verwendete Python libraries

Library	Verwendet Funktion
skimage	Berechnung Otsu Grenzwert
glob	Auflistung aller Dateinamen in einem Arbeitsverzeichnis
datetime (date)	Umwandlung des Datums der Sentinel-2 Daten in ein Datumsformat
pandas	Dataframe-Operationen, Import csv.-Dateien
matplotlib.pyplot	Grafik zur Korrelationsmatrix
os	Definition Arbeitsverzeichnis
rasterio	Einlesen von Rasterdaten
gdal	Einlesen und Verarbeitung von Rasterdaten
seaborn	Grafik zur Korrelationsmatrix
altair	Grafiken allgemein
numpy	Array-Berechnungen, -Operationen
scipy.stats	statistische Tests
scipy	Flächenberechnung Trapezoid-Methode
pylab	Grafik

Die Software QGIS (Version 3.4) wurde für folgende Prozeduren verwendet:

- Mapping von analogen Hofkarten auf Invekos Polygone
- Bearbeitung der Polygone
- Konversion von shape- in das geojson-Format
- Koordinatensystemtransformation
- Berechnung der euklidischen Distanz
- Erstellung kartographischer Darstellungen

3 Ergebnisse & Diskussion

3.1 Zeitreihenanalyse

3.1.1 Vegetations-Indices und Mähereignis

Greenness-Index

Der zeitliche Verlauf des Greenness-Index entspricht den realen Mähereignissen auf einzelnen Flächen. In Abbildung 14 sind die Ergebnisse für einige Beispielflächen der ausgewählten Untersuchungsbetriebe (ST1 und T1) in 2019 und 2020 zu sehen. Weitere Grafiken sind im Anhang (Abbildung 43 bis Abbildung 48) zu finden. Die grauen Balken stellen den jeweiligen Mähetermin laut Angaben der Landwirte dar. Anhand der gezeigten Beispiele wird die relativ gute Übereinstimmung von Mähetermin und Abnahme des Greenness-Wertes deutlich. Die Abnahme der Biomasse auf der jeweiligen Fläche, bedingt durch die Mahd, spiegelt sich in der Veränderung des Greenness-Indexes wider. Zu Anfang und Ende der Saison wurden einige der Flächen beweidet oder eingegrast. Hierbei kann kein genauer Termin bestimmt werden und somit ist auch keine Ernte im Diagramm eingezeichnet. Zu sehen ist aber ein eher horizontaler Zick-Zack-Verlauf der Greenness-Kurve (z.B. Vegetationsende ST1_9_2_h). In einzelnen Fällen fällt die Kurve auch zweistufig ab (z.B. ST1_4_2_h, 2. Schnitt) oder der Mähetermin ist in der Grafik erst nach dem Abfall der Greenness-Kurve eingezeichnet (z.B. T1_4_1b_h). Für die Fläche T1_10_1_h gibt es Anfang August gar keine Übereinstimmung von Ernte und Index.

NDVI (Normalized Difference Vegetation Index)

Die zeitlichen Kurvenverläufe des NDVI-Index verhalten sich sehr ähnlich dem Greenness-Index (Abbildung 15). Ein Vorteil für den einen oder den anderen Index kann aus den Ergebnissen nicht abgeleitet werden. Auch hier stimmen Mähereignis und ein Abfall des NDVI in der Regel gut überein. Bedingt durch die Unterschiede in der Skalierung erscheint das Ergebnis etwas weniger deutlich als beim Greenness-Index.

Insgesamt sind beide geprüften Vegetationsindices zur Darstellung von Mähereignissen auf Grünland geeignet. Auch Bekkema und Eleveld (2018) und Kolecka et al. (2018) beschreiben die Ableitung von Mähereignissen anhand einer abrupten Änderung des NDVI. Beweidete Flächen sind, wie auch aus den Abbildungen ersichtlich, eher durch langsame Änderungen des Vegetationsindex charakterisiert (Stumpf et al. 2020). Ausschließlich oder teilweise beweidete Flächen wurden in dieser Arbeit deshalb nicht betrachtet.

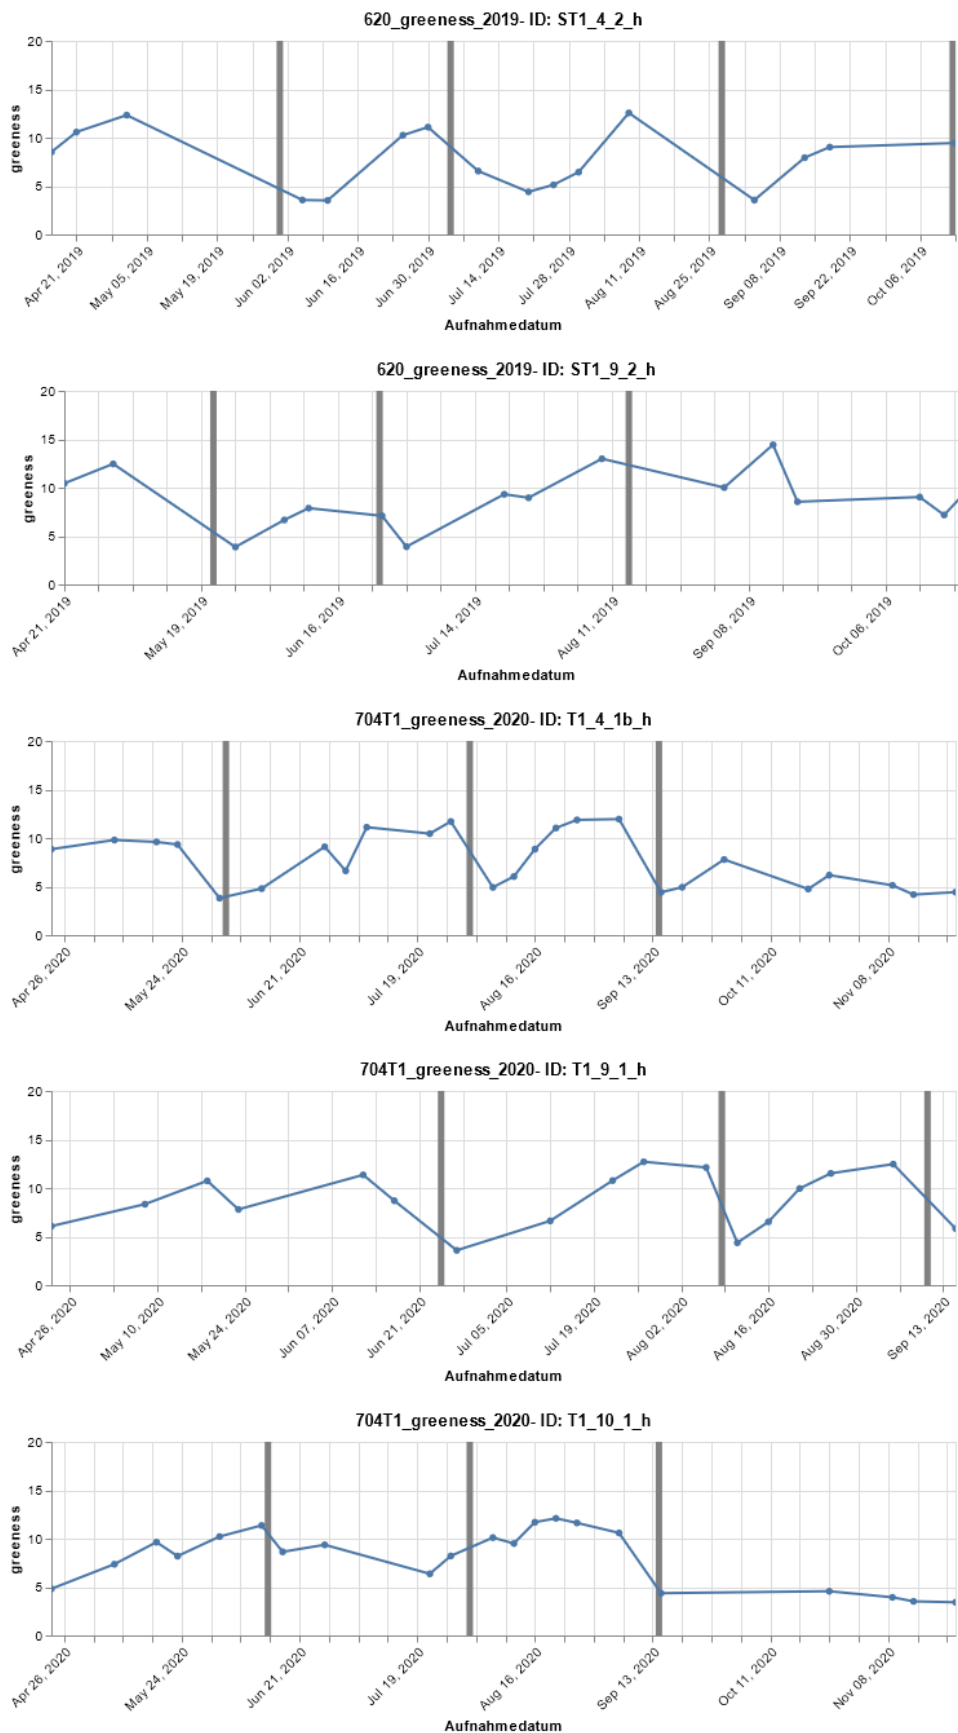


Abbildung 14: Greenness-Index (Linie) und Mähtermin (Balken) während der Vegetationsperiode 2019 bzw. 2020; blaue Punkte = wolkenfreie Satellitenaufnahme; Untersuchungsflächen der Betriebspaare ST1 und T1.




Abbildung 15: NDVI (Linie) und Mähtermin (Balken) während der Vegetationsperiode 2019 bzw. 2020; blaue Punkte = wolkenfreie Satellitenaufnahme; Untersuchungsflächen der Betriebspaare ST1 und T1.

Die fehlende Übereinstimmung von einigen Mähereignissen mit den Indexdaten kann verschiedene Ursachen haben. Zum einen könnte die Tatsache, dass das Gras zunächst geschnitten, dann aber z.T. einige Tage auf dem Boden getrocknet wird, eine Rolle spielen. Fallen die Aufnahmetermine der Satellitenbilder in diese Phase, so ergibt sich nach der Mahd eine erste Abnahme und nach Einfuhr des Heus eine weitere Abnahme des Indexwertes. Das Beispiel in Abbildung 16 und Abbildung 17 verdeutlicht diese Problematik. Kolecka et al. (2018) beziehen deshalb jeweils zwei aufeinanderfolgende Zeitabschnitte in ihre Untersuchungen mit ein. Bei einem zweifachen, aufeinander folgenden Abfall des Vegetationsindex wird nach ihrem methodischen Vorgehen nur das erste Ereignis als Mahd eingestuft. Betreffend der vorliegenden Referenzdaten ist nicht bekannt, ob die vom Landwirt angegebenen Mähetermine den Tag der Mahd oder den Tag der Einfuhr des Heus definieren. Ebenfalls nicht bekannt ist, ob alle Betriebe die gleiche Definition für den Mähetermin verwendet haben. Auch hieraus können sich Unstimmigkeiten ergeben.



Abbildung 17: RGB-Sentinel-2 Aufnahme vom 24.04.2020 (links: vor der Mahd), 08.05.2020 (Mitte: Nach der Mahd, das Gras liegt noch auf der Fläche) und 18.05.2020 (rechts: Mähgut ist abgeräumt)

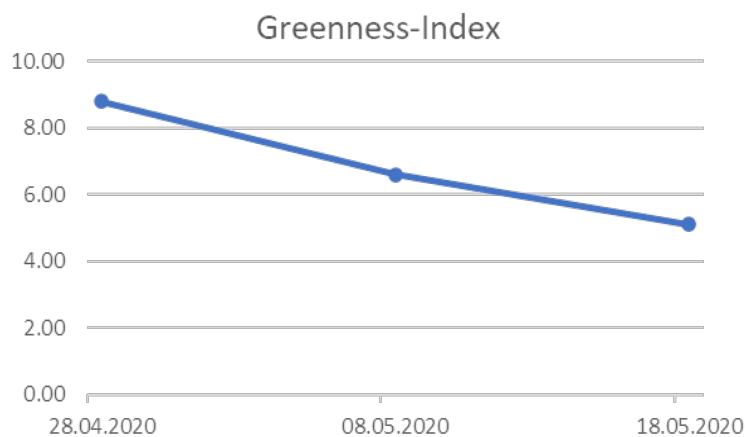


Abbildung 16: Verlauf des Greenness-Index für obige Fläche (vergleiche Abbildung 16)

Für das Feldstück T1_4_1b_h fällt der Indexwert (Abbildung 15) zwischen Ende Mai und Anfang Juni beispielsweise stark ab. Nach Angabe des Landwirtes fand die Ernte aber erst danach statt. Möglicherweise benennt der Erntetermin des Landwirtes den Tag der Einfuhr des Grases. Die Aufnahme des Satellitenbildes hat jedoch zwischen Mahd und Einfuhr stattgefunden. Deshalb könnte der Abfall des Indexwertes vor dem eigentlichen Erntetermin zu sehen sein.

Auch eine organische Düngung, welche in der Regel nach der Ernte ausgebracht wird, sollte als Einflussfaktor auf die Reflexion und dadurch bedingt eine Änderung des reflektierten Spektrums in Betracht gezogen werden (Gómez Giménez et al. 2017). Bei zeitig im Frühjahr aufgenommenen Satellitenbildern können Maßnahmen wie Walzen, Abschleppen oder Striegeln die reflektierte Strahlung beeinflussen (Griffiths et al. 2020).

Weiterhin kann eine fehlende Übereinstimmung der Indexwerte mit den Referenzdaten auf eine Beschattung durch Wolken oder Schleierbewölkung, welche durch das System nicht erkannt und somit nicht gefiltert wurde, zurückzuführen sein (Kap. 2.3). Griffiths et al. (2020) weisen darauf hin, dass durch Dunst oder Wolken beeinflusste und nicht gefilterte Pixel zu falschen Ergebnissen führen können, besonders dann, wenn das NDVI-Spektrum des Untersuchungsgebietes insgesamt recht klein ist.

Große zeitliche Abstände zwischen den Bildaufnahmen können dazu führen, dass eine Mahd nicht mit einer Abnahme des Kurvenverlaufes einhergeht, da das Gras bis zur folgenden Bildaufnahme bereits wieder nachgewachsen ist (Bekkema und Eleveld 2018). Halabuk et al. (2015) geben an, dass ein Zeitintervall von 16 Tagen zwischen den Aufnahmen ausreichend ist, um Mähereignisse zu identifizieren. In obigen Beispielen (Abbildung 14 und Abbildung 15) vergingen jedoch z.T. 25 oder 40 Tage zwischen zwei wolkenfreien Aufnahmen. Insbesondere in 2019 standen nur wenige auswertbare Aufnahmen zur Verfügung (Kap. 2.3, Abbildung 13).

In manchen Fällen kann keine Begründung gefunden werden. Auch Ungenauigkeiten in der Dokumentation der Erntetermine, Missverständnisse bei deren Übermittlung oder Fehler beim manuellen Mapping der analogen Hofkarten auf die digitalen INVEKOS Polygone können nicht gänzlich ausgeschlossen werden.

3.1.2 SIAM-Vorklassifikation und Mähereignis

In Abbildung 18 sind die Ergebnisse der SIAM-Vorklassifikation, dem semantischen Informationslayer von Sen2Cube.at, für die gewählten Untersuchungsflächen dargestellt. Die vorrangig vorkommende Kategorie vor der Mahd ist „strong vegetation with high NIR“.

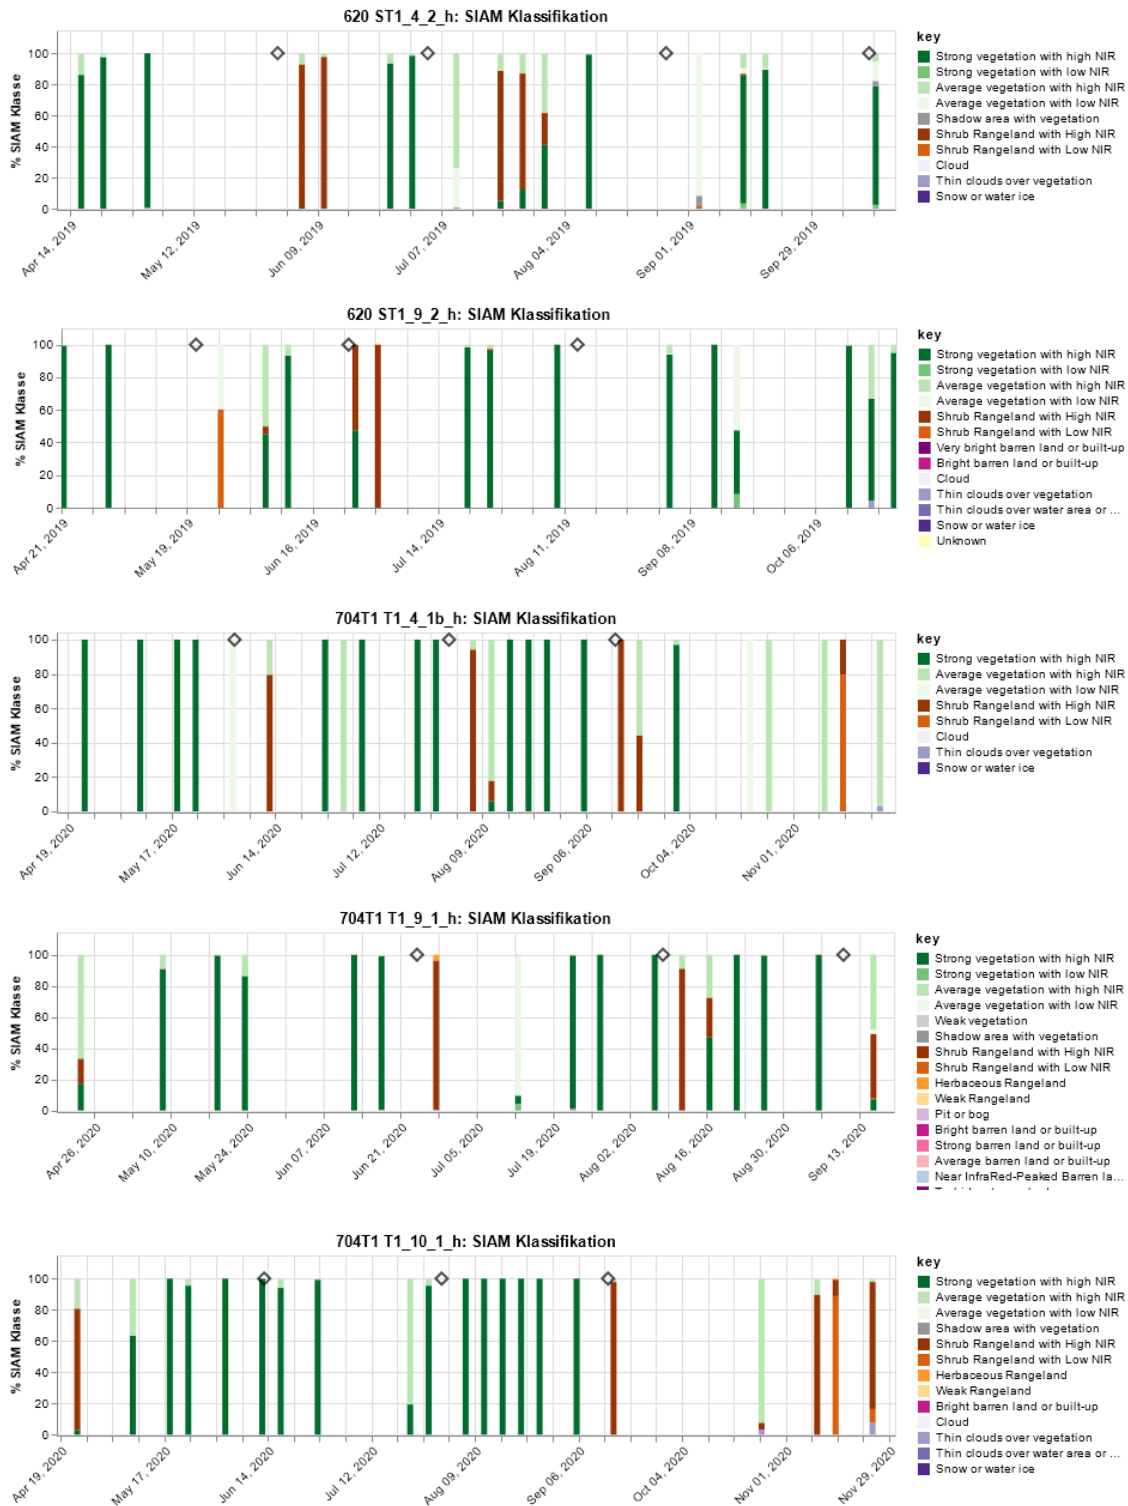


Abbildung 18: Pixelanteil je SIAM-Kategorie auf den ausgewählten Untersuchungsflächen in der Vegetationsperiode 2019 bzw. 2020. Die Mähetermine sind als graues Quadrat dargestellt. Untersuchungsflächen der Betriebspaare ST1 und T1.

In der Regel stimmt eine Veränderung der Zusammensetzung der SIAM-Vorklassifikation gut mit einem Mähereignis überein. Nach einer Ernte auf der Fläche nimmt der Anteil an

Pixeln der SIAM-Kategorie „strong vegetation with high NIR“ um etwa 40 – 100 % ab. Stattdessen werden die Pixel dann vorrangig den Kategorien

- Average vegetation with high NIR
- Average vegetation with low NIR
- Shrub Rangeland with low NIR
- Shrub Rangeland with high NIR

zugeordnet.

Für die Untersuchungsfläche ST1_9_2_h ist trotz Ernte im August keine Änderung der Klassifikation zu erkennen. Die Zeitspanne zwischen den Satellitenbildaufnahmen ist sehr groß. Innerhalb von 4 Wochen ist bei guter Witterung das Gras nach einer Ernte bereits wieder nachgewachsen. Wie vorangehend bereits diskutiert können potenzielle Erntetermine innerhalb solch großer Zeitabstände nicht erkannt werden. Der Greenness-Index hatte an dieser Stelle jedoch trotz der großen Zeitspanne eine leichte Abnahme gezeigt und ist für diesen Fall offenbar sensitiver. Auf der Fläche T1_4_1b_h verfälscht am 02.07.2020 Wolkenschatten das Ergebnis. Der Wolkenschatten wurde jedoch nicht als solcher vom System erkannt. Die Bilder wurden deshalb als gültig eingestuft; das Klassifikationsergebnis wird dadurch aber beeinflusst. Der Pixelanteil der SIAM-Kategorie „strong vegetation with high NIR“ nimmt stark ab und der Anteil der Kategorie „Average vegetation with high NIR“ stark zu, obwohl keine Ernte stattgefunden hat. Eine höhere Robustheit von Vegetationsindices gegenüber solchen Wolkenschatten, wie von Huete et al. (2002) festgestellt, kann aus den vorliegenden Daten nicht bestätigt werden. Auch der NDVI und der Greenness-Index zeigen zu diesen Zeitpunkten einen deutlichen Abfall vor dem eigentlichen Erntetermin. Für das Feldstück T1_10_1_h stimmen Mitte Juni und Anfang August, ähnlich wie schon bei den beiden Vegetationsindices, Ernte und SIAM-Kategorie nicht überein.

Trotz genannter Probleme (Bewölkung, org. Düngung etc.), welche sich auch durch die Verwendung der SIAM-Vorklassifikation nicht beheben lassen, kann insbesondere die SIAM-Kategorie „strong vegetation with high NIR“ ein guter Indikator für Mähereignisse auf Grünlandflächen sein. Abbildung 19 zeigt den Verlauf des als „strong vegetation with high NIR“ klassifizierten Pixelanteils auf den ausgewählten Untersuchungsflächen in der Vegetationsperiode 2019 bzw. 2020. Diese Kategorie kann, ähnlich wie ein Vegetations-Index, zur Charakterisierung des Biomasseaufwuchs auf Grünlandflächen und damit auch von Mähereignisses herangezogen werden.

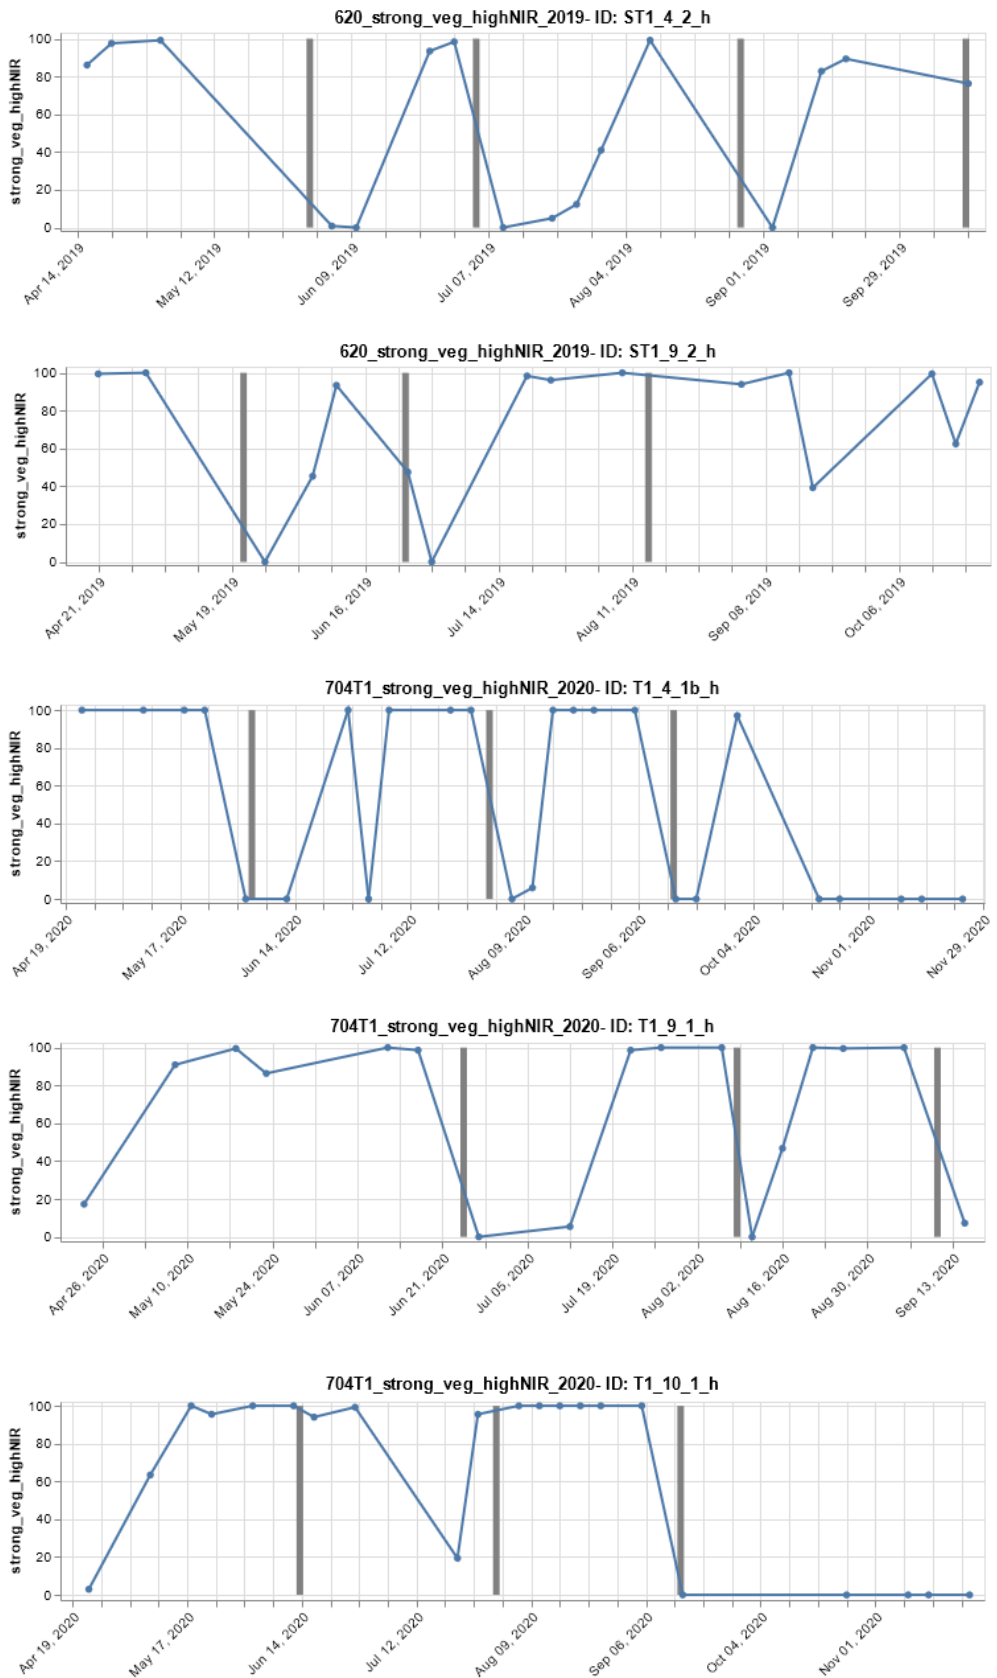


Abbildung 19: Verlauf des als „strong vegetation with high NIR“ klassifizierten Pixelanteils (Linie, in Prozent) auf ausgewählten Untersuchungsflächen der Betriebspaare ST1 und T1 in der Vegetationsperiode 2019 bzw. 2020. 2020; Mähtermin = graue Balken.

3.1.3 Detektion von Mähereignissen

In Kapitel 3.1.1 und 3.1.2 konnte anhand von ausgewählten Beispielen der enge Zusammenhang zwischen dem Mähereignis und einer Abnahme der Index-Werte (NDVI, Greenness) oder einer Änderung des Pixelanteils der SIAM-Kategorie „strong vegetation high NIR“ (SVHNIR) aufgezeigt werden. Um letztendlich ein Mähereignis abzuleiten ist die Definition eines Grenzwertes erforderlich. Anhand des Grenzwertes wird festgelegt ab welcher Ausprägung die Abnahme des Indexwertes oder der SIAM-Kategorie als Mähereignis gewertet wird. Im Folgenden wurde überprüft auf Basis welchen Grenzwertes und mit welcher Qualität ein Mähereignis anhand der untersuchten Parameter definiert werden kann. Es wurden dabei alle zur Verfügung stehenden Referenzdaten (alle Betriebspaare, alle Regionen) miteinbezogen, um eine möglichst breite Datenbasis zu erhalten.

In Abbildung 20 sind die Differenzwerte (Termin 2 – Termin 1) des NDVI, des Greenness-Index und des Pixelanteils der SIAM-Kategorie „strong vegetation high NIR“, jeweils zwischen zwei aufeinanderfolgenden Aufnahmetermen abgebildet. Die Berechnungen wurden mit Python durchgeführt. Der Wert zeigt wie sehr sich der Parameter im Vergleich zu vorherigem Aufnahmedatum geändert hat. Die Farbe der dargestellten Punkte gibt an, ob im Zeitintervall zwischen den Satellitenaufnahmedaten (T1 und T2) nach Angaben des Landwirtes tatsächlich eine Ernte stattgefunden hat oder nicht. Orange Punkte bedeuten hier „Ernte“ (Referenz). Diese Datenpunkte sollten also deutlich negativ sein, da erwartet wird, dass die Abnahme der Biomasse durch Mahd mit einer Abnahme des Indexwertes oder des Pixelanteils der Kategorie „strong vegetation high NIR“ einhergeht. Grüne Punkte stehen für „keine Ernte“ und sollten um Null oder im positiven Bereich liegen, da von einer einem Zuwachs oder zumindest von einer Stagnation Biomasse und damit auch des Indexwertes ausgegangen wird.

Aus Abbildung 20 wird deutlich, dass bei allen drei geprüften Parametern (NDVI, Greenness-Index und SIAM-Kategorie „strong vegetation with high NIR“) ein Zusammenhang zwischen der Abnahme des untersuchten Parameters und dem Mähetermin gegeben ist. Einzelne orange Punkte im Positivbereich der Grafik und grüne Punkte im Negativbereich der Grafik zeigen jedoch auch die deutliche Anzahl an falsch positiven oder falsch negativen Ergebnissen.

Anhand von definierten Grenzwerten wurden die Differenzwerte (T2-T1) den Klassen „Ernte“ und „keine Ernte“ zugeordnet und die Qualität dieser Zuordnung bestimmt.

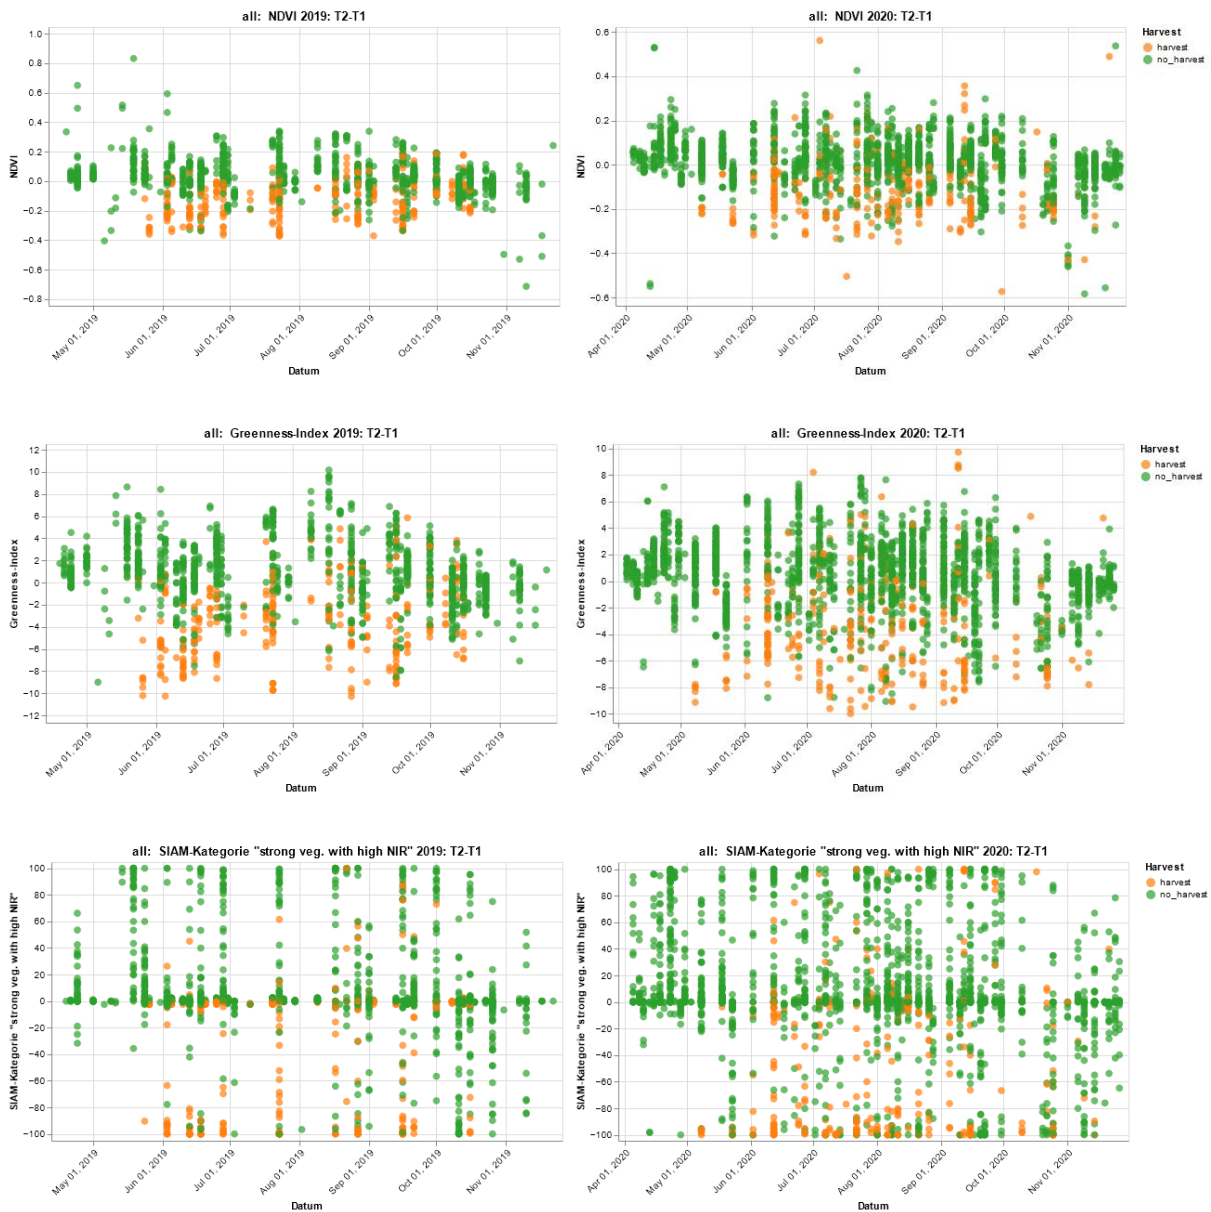


Abbildung 20: Differenz T2 – T1 der untersuchten Parameter NDVI (oben), Greenness-Index (Mitte) und SIAM-Kategorie „strong veg. with high NIR“ (unten) sowie Darstellung ob im Zeitintervall zwischen zwei Satellitenaufnahmedaten (T1 und T2) eine Ernte stattgefunden hat; orange: Ernte; grün: keine Ernte; Daten aller Betriebe; 2019 (links), 2020 (rechts)

Es wurden unterschiedliche Methoden der Grenzwertdefinition genutzt. Die Verwendung der Standardabweichung oder des Perzentils als Grenzwert trägt der Tatsache Rechnung, dass die Skalen der drei geprüften Parameter unterschiedlich und damit schlecht vergleichbar sind. Als Grenzwerte wurden eine Standardabweichung sowie das 10%-Perzentil definiert. Weiterhin wurde die Methode nach Otsu verwendet (Otsu 1979). Mittels dieser Methode wird ein Schwellenwert so bestimmt, dass die Varianz zwischen zwei Klassen ein Maximum erreicht. Bildlich gesprochen wird der Grenzwert so definiert,

dass sich die Werte in einem Histogramm in zwei Klassen unterteilen lassen, also im Idealfall zwischen zwei Erhebungen. Die eine Erhebung im Histogramm würde dann die Werte (Delta T2-T1) vor der Ernte, die andere Erhebung die Werte nach der Ernte beinhalten.

In einer Konfusionsmatrix lassen sich die Ergebnisse der Klassifikation auf Basis der Satellitendaten mit den tatsächlichen Mähterminen, nach Angaben der Landwirte, vergleichen. Die Datenpunkte wurden in Abhängigkeit vom geprüften Grenzwert den Klassen „Ernte“ oder „keine Ernte“ zugeordnet und mit der tatsächlichen Klassifikation (Referenz) abgeglichen. Aus der Anzahl der richtig oder falsch positiven Ergebnisse für beide Klassen konnte die Matrix erstellt werden (Tabelle 5 und Tabelle 6).

Es wurde ebenso geprüft, ob sich durch einen Ausschluss einer doppelten Ernte-Klassifikation (zwei aufeinander folgende, negative Differenzwerte) die Qualität des Ergebnisses verbessern ließe (Beispiel in Abbildung 17). In diesem Fall wurde nur der zweite negative Differenzwert als „Ernte“ klassifiziert. Die Nutzergenauigkeit konnte damit um 0,4%-Punkte verbessert werden. In gleichem Maße verschlechterte sich aber die Produzentengenauigkeit. Offensichtlich gab es ähnlich viele richtig wie falsch klassifizierte Werte im Referenzdatensatz, die durch diese Bedingung betroffen wären. Die Bedingung wurde deshalb in der weiteren Auswertung nicht angewendet.

Die Matrix in Tabelle 5 und Tabelle 6 zeigt mit welcher Genauigkeit eine Ernte auf einer Grünlandfläche anhand der drei Parameter abgeleitet werden konnte und wie dies durch den gewählten Grenzwert zur Klassifikation („Ernte / keine Ernte“) beeinflusst wird. Die Nutzergenauigkeit ist ein Maß für die Zuverlässigkeit, mit der Objekte der Testdaten der richtigen Klasse zugeordnet wurden (Lillesand et al. 2015) bzw. sie gibt falsch positive Ergebnisse an (100 – Nutzergenauigkeit). D.h. es wird ein Mähereignis angenommen obwohl gar keines stattgefunden hat. Die Produzentengenauigkeit erlaubt eine Aussage über falsch negative Ergebnisse, d.h. sie gibt Auskunft über die Vollständigkeit mit der Objekte einer Klasse (z.B. Ernte) erfasst worden sind (Lillesand et al. 2015). Die Produzentengenauigkeit beantwortet die Frage, wieviel Ereignisse nicht als Ernte klassifiziert wurden, obwohl eine Ernte stattgefunden hat.

Die Verlässlichkeit, mit der eine Ernte auf Grünlandflächen anhand der geprüften Parameter bestimmt werden konnte, variierte stark. Für die Klasse „Ernte“ wurde ein mittelmäßiges Ergebnis erreicht. Gut und relativ vollständig erfasst wurde die Klasse „keine Ernte“. Ein Grund dafür ist vermutlich eine deutlich größere Klassenbesetzung, die jedoch zu einer Verzerrung führen kann (Reinermann et al. 2020).

Tabelle 5: Konfusionsmatrix der Klassifikationsergebnisse, 2019

Grenzwert	Parameter	Produzenten- genauigkeit [%]		Nutzergenauigkeit [%]		Gesamt- genauigkeit [%]	Kappa- Koeffizient
		Ernte	keine Ernte	Ernte	keine Ernte		
1 Standard- abweichung	NDVI	46,5	94,7	68,6	87,7	85,1	0,5
	Greenness	52,7	94,3	69,6	88,9	86,0	0,5
	SIAM class "SVHNIR"	41,4	93,4	61,1	86,5	83,1	0,4
10% -Perzentil	NDVI	38,5	97,1	76,6	86,4	85,4	0,4
	Greenness	40,3	97,5	80,3	86,8	86,1	0,5
	SIAM class "SVHNIR"	35,2	96,3	70,1	85,6	84,1	0,4
Otsu Methode	NDVI	70,0	83,2	50,9	91,8	80,6	0,5
	Greenness	74,0	71,4	49,8	92,6	79,9	0,5
	SIAM class "SVHNIR"	41,8	92,5	58,2	86,4	82,4	0,4

Tabelle 6: Konfusionsmatrix der Klassifikationsergebnisse, 2020

Grenzwert	Parameter	Produzenten- genauigkeit [%]		Nutzergenauigkeit [%]		Gesamt- genauigkeit [%]	Kappa- Koeffizient
		Ernte	keine Ernte	Ernte	keine Ernte		
1 Standard- abweichung	NDVI	52,1	92,2	50,6	92,6	86,8	0,4
	Greenness	55,4	91,2	49,0	93,0	86,4	0,4
	SIAM class "SVHNIR"	54,1	91,1	48,0	92,9	86,2	0,5
10% - Perzentil	NDVI	42,3	94,9	56,3	91,5	87,9	0,4
	Greenness	45,9	95,5	60,9	92,0	88,9	0,5
	SIAM class "SVHNIR"	41,6	94,8	54,8	91,4	87,8	0,4
Otsu Methode	NDVI	67,4	81,8	36,3	94,2	79,8	0,4
	Greenness	71,8	78,3	33,6	94,8	77,4	0,3
	SIAM class "SVHNIR"	58,1	89,1	44,8	93,3	85,0	0,4

Insgesamt kann die Übereinstimmung zwischen den anhand von Sentinel-2 Daten klassifizierten Ernteereignissen und den Referenzdaten (Angaben der Landwirte) mit Hilfe des Kappa-Koeffizienten (0-1) quantifiziert werden. Nach Angaben von Lange (2013) deuten Werte von Kappa größer als 0,75 auf eine sehr gute, Werte kleiner als 0,4 auf eine schlechte Genauigkeit der Klassifizierung hin. Lange (2013) weist jedoch darauf hin, dass eine solche Bewertung immer auch vor dem Hintergrund des Klassifizierungsziels beurteilt werden sollte. Oben gezeigte Werte sind fast durchweg als mittleres Ergebnis einzustufen.

Die Verwendung des Greenness-Index mit einem Grenzwert von 10 % Perzentil erreichte die höchste Nutzergenauigkeit und wurde für die weiteren Untersuchungen festgelegt. Damit konnten rund die Hälfte aller Mähtermine mit einer Sicherheit von 60-80 % erfasst werden. Dies ist im Zusammenhang mit der Thematik von Bedeutung. Es sollten möglichst wenig falsch positive Mähtermine erfasst werden, da eine zu häufige oder homogene Mahd über mehrere Flächen als negativ eingeschätzt wird und zu falschen Gesamtschlussfolgerungen führen könnte. Allerdings geht dies zu Lasten der Produzentengenauigkeit. Die Gesamtgenauigkeit lag bei 86-89 %.

Halabuk et al. (2015) erreichten in ihren Untersuchungen zur Identifikation von Mähterminen auf Heuwiesen mittels NDVI in der Slowakei eine ähnliche Gesamtgenauigkeit von 85 %. Eine Studie aus Süddeutschland (Franke et al. 2012) verwendete verschiedene Vegetationsindices (NDVI, Normalized Red-Edge Vegetation Index) sowie den Parameter "Mean Absolute Spectral Dynamic" in einem Entscheidungsbaum, um die Nutzungsintensität auf Grünland zu klassifizieren. Die Gesamtgenauigkeit lag hier bei 83 %. Urf (2019) konnte in seinen Untersuchungen Mähereignisse bzw. die Nutzungsintensität auf österreichischen Flächen mit einer Gesamtgenauigkeit von 65 % und einer Nutzergenauigkeit von 61 bis 70 % klassifizieren. Hierbei wurde die NDVI-Differenz zwischen zwei Sentinel-2 Aufnahmen berechnet und ein Mähereignis anhand eines Grenzwertes definiert.

Wie bereits in Kapitel 3.1.1 ausgeführt, ist ein Teil der falsch positiven oder falsch negativen Ergebnisse auf Beschattung durch Wolken oder Schleierbewölkung zurückzuführen, welche im verwendeten Wolkenfilter nicht erfasst wurden. Eine sich ebenfalls aus der Bewölkung ergebende Fehlerquelle sind die daraus resultierenden großen Zeitabstände zwischen den auswertbaren Bildern. Kolecka et al. (2018) fanden in ihren Untersuchungen, dass in Phasen in denen klimabedingt ein rascher Aufwuchs stattfindet, sogar eine Woche Bewölkung zum Ausschluss eines Mähereignisses führen kann. Sie geben auch an, dass das Vorhandensein ausreichend dichter, wolkenfreier

Zeitreihen die größte Herausforderung für die Detektion von Mähereignissen ist. Dies legt die Schlussfolgerung nahe, dass ein großer Teil der fehlerhaften Klassifikationsergebnisse in engem Zusammenhang mit der in alpinen Regionen häufig auftretenden Bewölkung steht. Auch die großen Unterschiede in den Ergebnissen in Abhängigkeit vom gewählten Grenzwert sind auffällig. Zudem kann ein Einfluss der erwähnten Ungenauigkeiten in den Referenzdaten (z.B.: wurde die Mahd oder die Einfuhr des Grüngutes als Termin angegeben?) auf die Ergebnisse der Konfusionsmatrix nicht ausgeschlossen werden.

3.2 Grenzwert-basierte Analyse von Mähereignissen mittels Greenness-Index









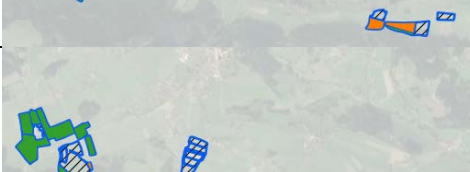

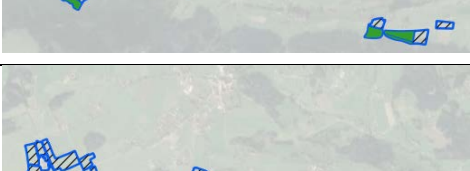



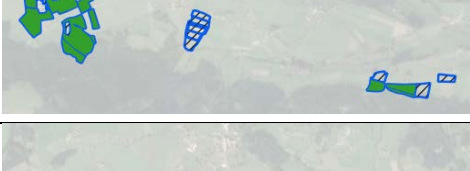



Vergleich der Beispielbetriebe

In den Kap. 3.1.1 und 3.1.2 wurde gezeigt, dass der Verlauf des NDVI und des Greenness-Index, als auch die SIAM-Kategorie „strong vegetation with high NIR“, gut mit dem jeweiligen Biomasseaufwuchs (gering = nach der Mahd, hoch = vor der Mahd) bzw. mit einem Mähereignis übereinstimmen. Eine starke Abnahme kann als Mähereignis zwischen den beiden Aufnahmetermenin gewertet werden. Erfolgt eine automatische Ableitung des Mähereignisses auf Basis eines definierten Grenzwertes, sind eine gewisse Anzahl an falsch positiven oder falsch negativen Ergebnissen (Kap. 3.1.3) in Kauf zu nehmen.

Im Folgenden sollte untersucht werden, ob sich die postulierte zeitlich verteilte (mosaikartige) Bewirtschaftung von Heumilchbetrieben im Vergleich zu Nicht-Heumilchbetrieben mittels des genannten, grenzwert-basierten Vorgehens darstellen lässt. Anhand der Veränderung des Greenness-Index und eines Grenzwertes (10%-Perzentil) erfolgte die Definition von Mähereignissen zwischen zwei Aufnahmetermenin. Es wurden hierfür wiederum die Daten der zwei Beispielbetriebe (2019: ST1, 2020: T1) aus Kapitel 2.1.1 verwendet.

Abbildung 22 und Abbildung 21 zeigen ob nach vorangehender Definition zwischen zwei Aufnahmetermenin ein Mähereignis stattgefunden hat oder nicht. Feldstücke für die keine Angaben zur Mahd vorliegen sind gestreift dargestellt. Dabei handelt es sich um Flächen die beweidet oder eingegrast wurden und damit von der Auswertung ausgeschlossen sind. Auch Flächen für die zum jeweiligen Datum aufgrund von Bewölkung keine Daten vorlagen, sind gestreift dargestellt. Weiterhin wurden zwei weit entfernt liegende Almflächen nicht in die bildliche Darstellung miteinbezogen.

Ergebnisse & Diskussion

Datum	Heumilchbetrieb		Nicht-Heumilchbetrieb
21.04.2019			
01.05.2019			
26.05.2019			
05.06.2019			
10.06.2019			
20.06.2019			
25.06.2019			
30.06.2019			
20.07.2019			

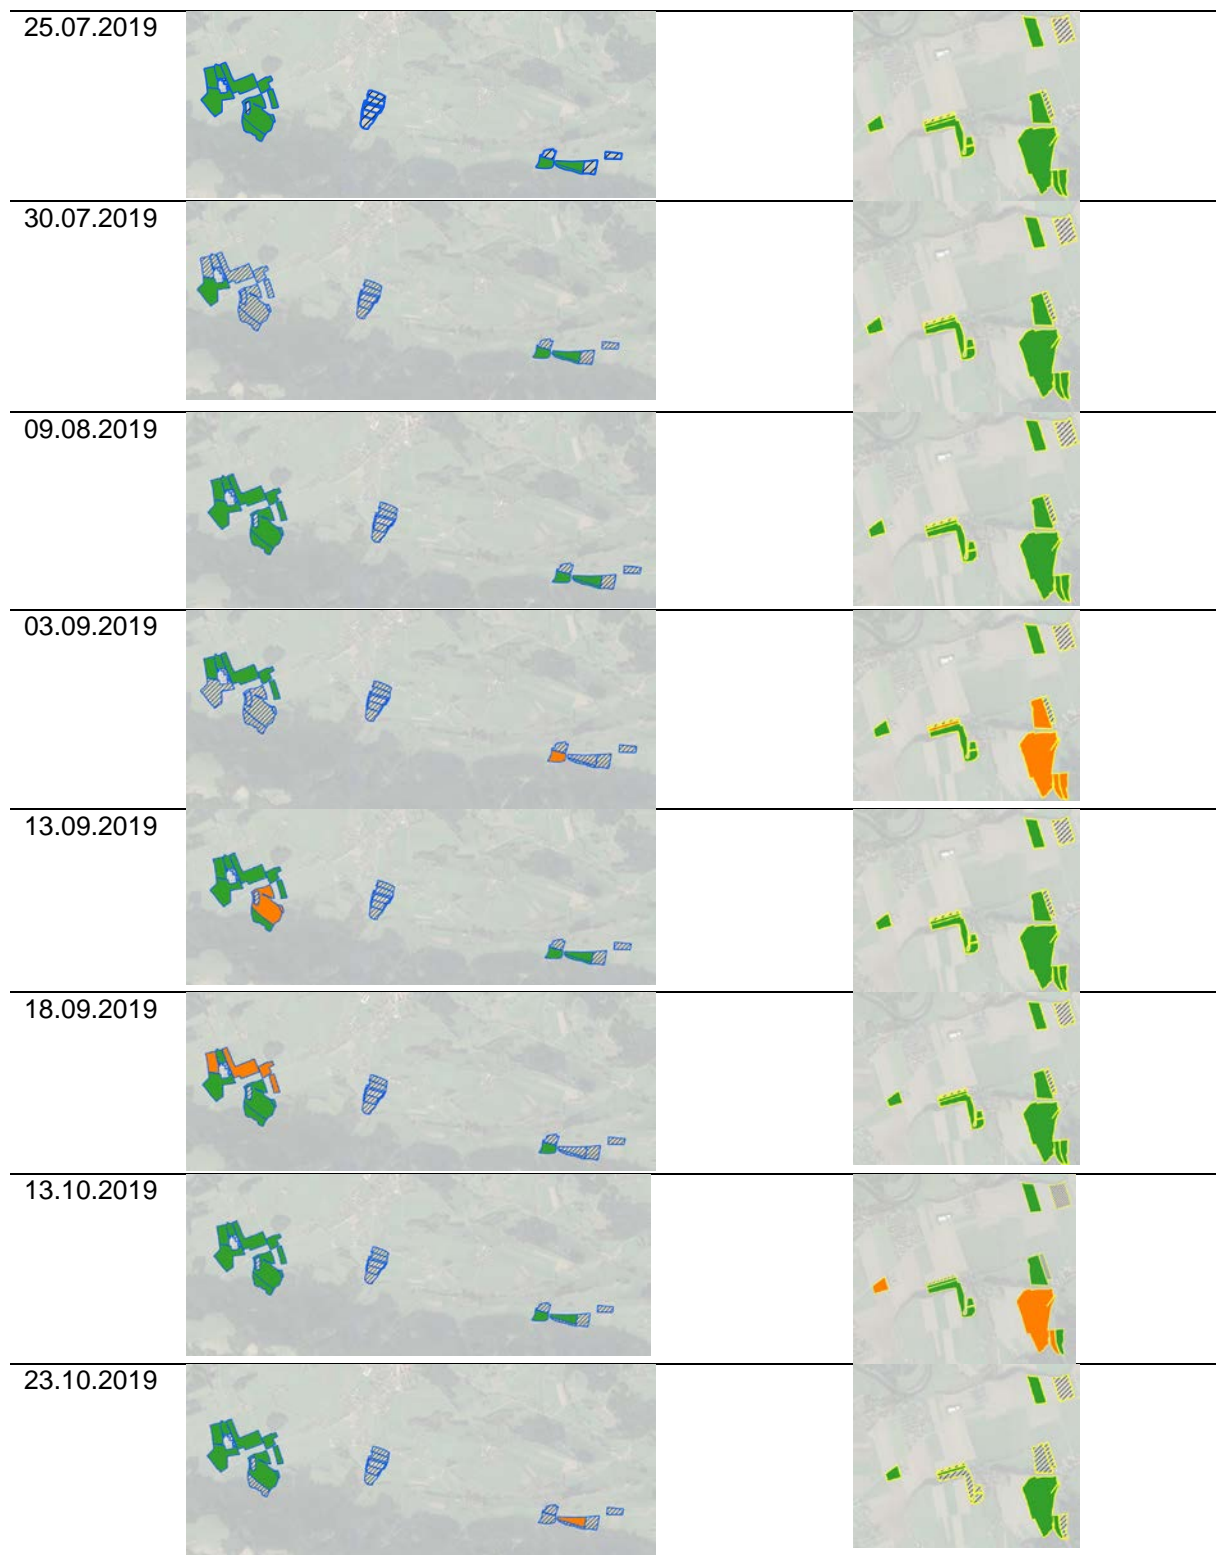
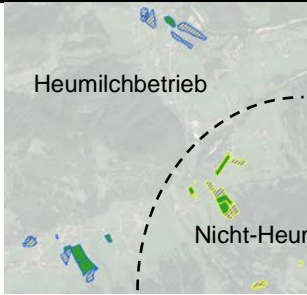

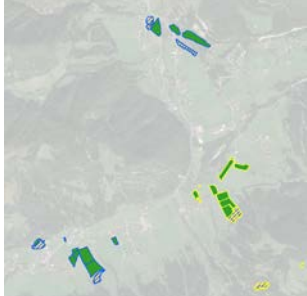






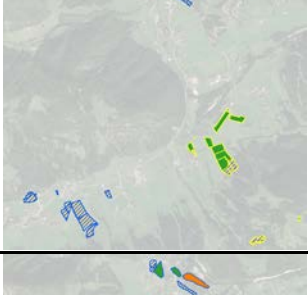

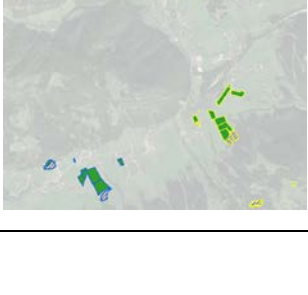


Abbildung 21: Vergleich der zeitlichen und räumlichen Verteilung der Mähereignisse in zwei Beispielbetrieben (Betriebspaar ST1) im Jahr 2019. Grün = keine Ernte zwischen Aufnahmetermin und vorangehendem Termin, orange = Ernte, gestreift = keine Daten

Ergebnisse & Diskussion

Datum		Datum	
23.04.2020		08.05.2020	
26.05.2019		02.06.2020	
12.06.2020		27.06.2020	
07.07.2020		22.07.2020	
27.07.2020		01.08.2020	
06.08.2020		11.08.2020	

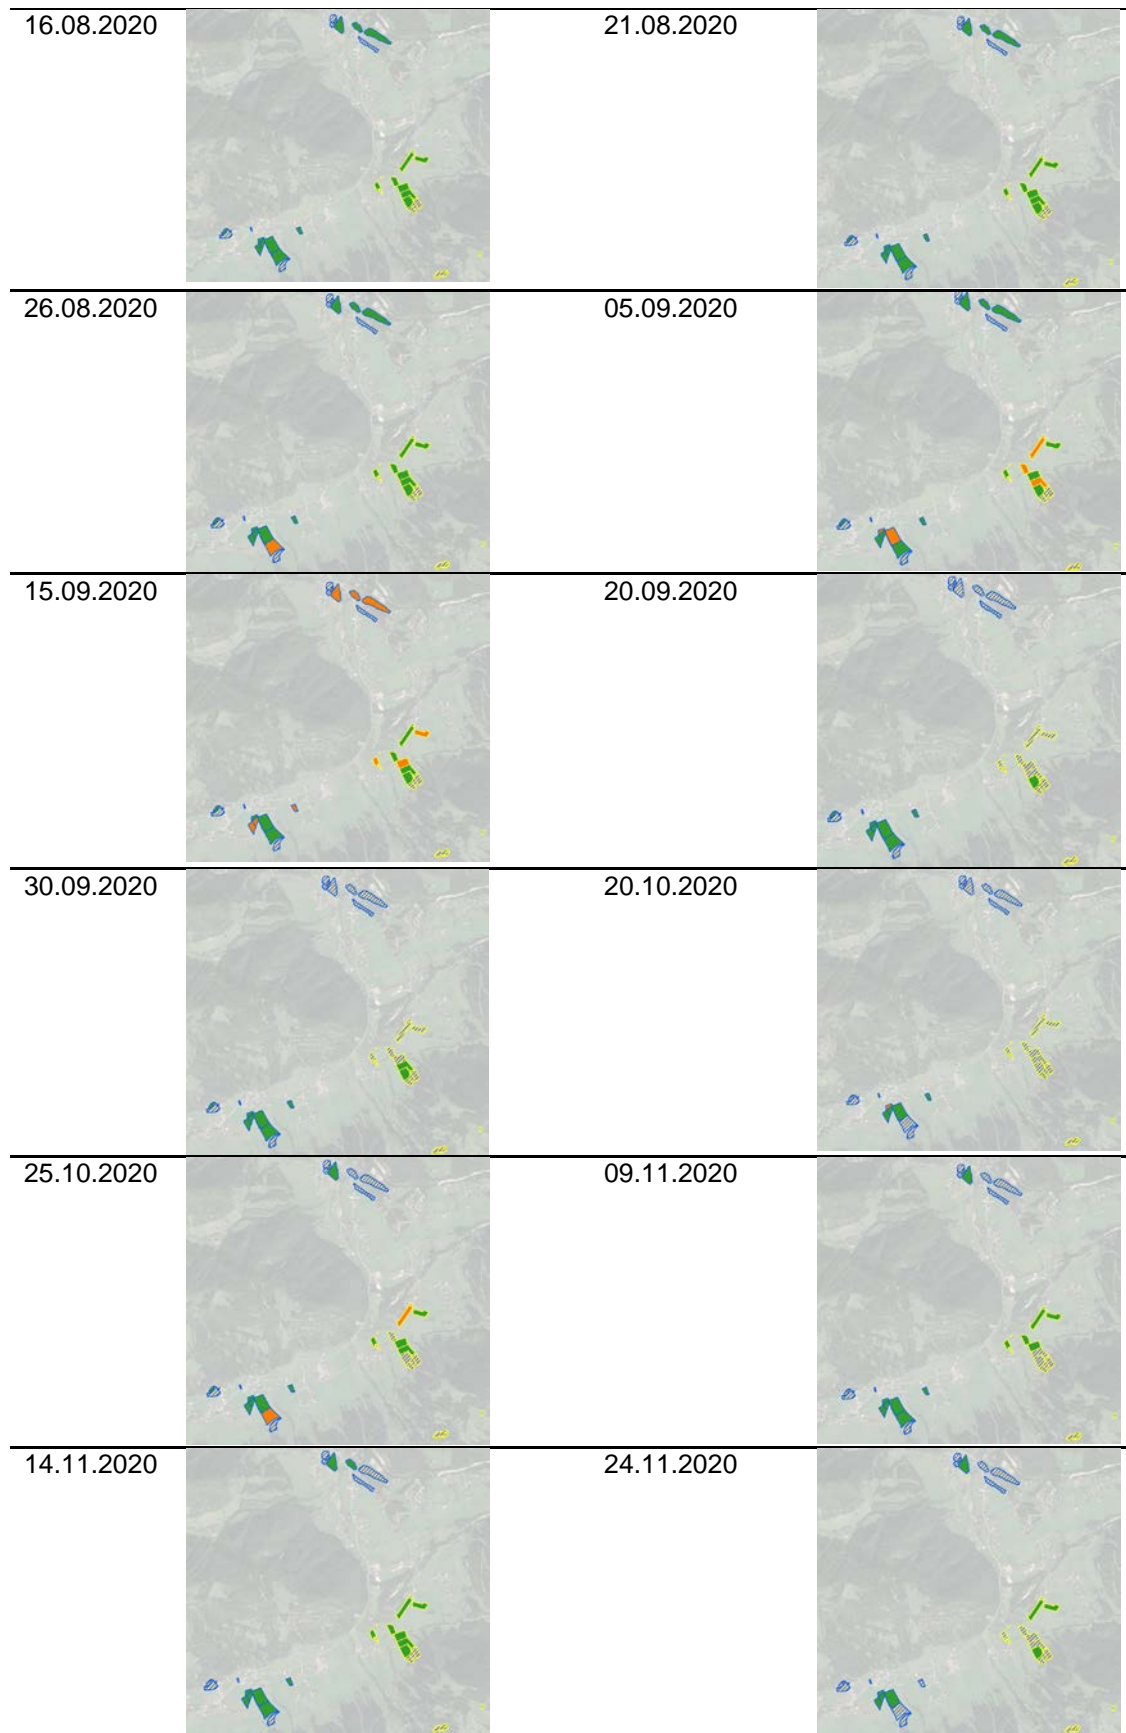


Abbildung 22: Vergleich der räumlichen und zeitlichen Verteilung der Mähereignisse in zwei Beispielbetrieben (Betriebspaar T1) im Jahr 2020. Grün = keine Ernte zwischen Termin und vorangehendem Termin, orange gefüllt = Ernte, gestreift = keine Daten, gelbe Umrandung = Nicht-Heumilchbetrieb, blaue Umrandung = Heumilchbetrieb

Eine zeitliche oder räumliche Clusterung von Mähereignissen im Nicht-Heumilchbetrieb lässt sich aus den obigen Abbildungen kaum erkennen. Die visuelle Beurteilung ist auf Basis der geringen Flächenanzahl und -verteilung wenig aussagekräftig; Abbildung 23 fasst die Ergebnisse zusammen.




Abbildung 23: Ergebnisse der automatisierten Ernte-Klassifikation: prozentualer Anteil der jeweils gemähten Fläche an der Gesamtfläche pro Betrieb; in 2019 (Betriebspaar ST1: oben) und 2020 (Betriebspaar T1: unten)

In den Betrieben ST1 wurden in 2019 nach obiger Auswertung jeweils ein größerer Anteil der Flächen sowohl im Heumilch- (Ende Mai, Mitte September) als auch im Nicht-Heumilchbetrieb (Mitte Juni, Anfang September, Mitte Oktober) gleichzeitig gemäht. In 2020 in den Betrieben T1 ist eine Häufung Mitte September (Heumilch), Mitte Juni und Anfang September (Nicht-Heumilch) zu beobachten. Insgesamt sind für die beiden Heumilchbetriebe mehr Mähetermine bestimmt worden. Als Gesamtfläche für die Berechnung wurden alle Grünlandflächen des jeweiligen Betriebes mit einbezogen (auch beweidete Flächen). Ein Vergleich mit den Angaben der Landwirte (Referenzdaten) zeigt, dass für das Jahr 2019 von den 81 Mähereignissen nur 23 auch korrekt erfasst worden sind. 10 der 33 als „Ernte“ klassifizierten Differenzwerte waren fälschlicherweise in dieser

Klasse. Diesen 10 Werten stehen 292 richtig klassifizierte Werte („keine Ernte“) gegenüber. Die Daten in 2020 ergaben 26 richtig und 11 fälschlicherweise als „Ernte“ klassifizierte Werte von insgesamt 52 Mähereignissen. Der Klasse „keine Ernte“ wurden 299 von 325 Werten richtig zugeordnet.

Die nach dieser Methode definierten Mähereignisse zeigen in der Tendenz eine etwas breitere Verteilung der Ernte in den beiden betrachteten Heumilchbetrieben. Ein klarer Vorteil für die eine oder andere Betriebsform ist schwer abzuleiten. Die Zahl der insgesamt richtig identifizierten Mähereignisse ist sehr gering.

Vergleich von zwei Beispielmunicipalitäten

Das oben vorgestellte methodische Vorgehen wurde zusätzlich anhand von Grünlandflächen der zwei Gemeinden Seeham (überwiegend Heumilchbetriebe) und Frankenmarkt (vorwiegend klassische Grünlandbewirtschaftung mit Silagebereitung) durchgeführt. Ziel war es, einen größeren Datensatz zu untersuchen, welcher eventuell deutlichere Unterschiede zeigt, da vorangehend untersuchte Datensätze nur wenige Flächen beinhalteten. Zudem sollte die Anwendbarkeit der Methode für größere Gebiete aufgezeigt werden. Allerdings waren die tatsächlichen Erntetermine für diese Daten unbekannt, so dass die Qualität des Ergebnisses nicht beurteilt werden kann. Auch ist nicht bekannt in wie weit auf den Flächen Beweidung stattgefunden hat.

Der kartographische Vergleich zeigt (Abbildung 49 im Anhang), dass mit vorangehend beschriebener methodischer Vorgehensweise in der Region Frankenmarkt tendenziell mehr Betriebe ihre Flächen gleichzeitig gemäht haben als in der Region Seeham (Heumilchregion). Eine Zusammenfassung dieser Ergebnisse bietet Abbildung 24. Aus der Abbildung geht hervor, dass in der Gemeinde Seeham an einem Termin 20 - 25 % der Gesamtfläche gleichzeitig gemäht wurde. In der Gemeinde Frankenmarkt war dies acht Mal der Fall. 25 % wurde von Gottwald und Stein-Bachinger (2016) als Maximalgrenze für eine gleichzeitige Flächennutzung im Zeitraum Anfang Mai bis Ende Juli definiert. Nach Abbildung 24 gab es in der Gemeinde Frankenmarkt auch insgesamt mehr Erntetermine. Hierbei ist jedoch zu beachten, dass für diese Region deutlich mehr Daten vorliegen, da hier die temporale Auflösung der Sentinel-2 Aufnahmen höher ist als in der Gemeinde Seeham (siehe Anhang Abbildung 56). Ein Vergleich der einzelnen Darstellungen in Abbildung 49 im Anhang legt jedoch auch den Schluss nahe, dass für die Gemeinde Frankenmarkt eventuell ein nicht zu unterschätzender Anteil an falsch positiven Ergebnissen enthalten ist. So wurden beispielsweise für einige Flächen sowohl am 11.08.2020 wie auch am 21.08.2020 ein Ernteereignis klassifiziert (Abbildung 49 im

Anhang). Der zeitliche Abstand zwischen den Terminen macht deutlich, dass es sich hierbei um ein falsches Ergebnis handeln muss.




Abbildung 24: Ergebnisse der automatisierten Ernte-Klassifikation: prozentualer Anteil der jeweils gemähten Fläche an der Gesamtfläche in den Gemeinden Seeham (Heumilch) und Frankenmarkt (Nicht-Heumilch) pro Woche in 2020

Die oben vorgestellten Ergebnisse wie auch Tabelle 5 und Tabelle 6 verdeutlichen, dass die Klasse „keine Ernte“ mit relativ hoher Sicherheit klassifiziert werden kann. Der Anteil richtig identifizierter Mähereignisse ist jedoch sehr gering. Die Ableitung einer heterogeneren, mosaikartigen Grünlandbewirtschaftung von Heumilchbetrieben im Vergleich zu Nicht-Heumilchbetrieben ist damit schwierig. Auf Basis der vorangehend vorgestellten grenzwert-abhängigen Vorgehensweise können keine verlässlichen Schlussfolgerungen gezogen werden. Die bereits angesprochenen Probleme wie Bewölkung oder die Unsicherheit in der Angabe des Mähetermins in den Referenzdaten beeinflussen die Ergebnisse stark. Diese Probleme können im Rahmen der Arbeit nicht gelöst werden. Wie von anderen Autoren diskutiert (Patra et al. 2011) erhöht auch die Abhängigkeit der Ergebnisse von der Definition des Grenzwertes die Unsicherheit. Um den Einfluss der Grenzwertdefinition zu umgehen und die damit einhergehenden Probleme zu vermeiden, wurde ein alternatives methodisches Vorgehen geprüft, welches unabhängig von der Anwendung eines Grenzwertes ist.

3.3 Grenzwert-freie Analyse von Mähereignissen mittels Greenness-Index

3.3.1 Einzelflächenvergleich der Heumilch- und Nicht-Heumilchbetriebe

Eine weitere Möglichkeit die zeitliche Hetero- oder Homogenität der Grünlandmäh auf Flächen mit unterschiedlichen Bewirtschaftungsformen aufzuzeigen, ist der graphische Vergleich von Zeitreihen des Greenness-Index der einzelnen Flächen im jeweiligen

Betrieb. Hierbei ist keine Anwendung eines Grenzwertes erforderlich. Es fanden wiederum Daten der oben genannten Beispielbetriebe (2019: Betriebspaar ST1; 2020: Betriebspaar T1) Verwendung.

In Abbildung 25 und Abbildung 26 ist der zeitliche Verlauf des Greenness-Index für die Flächen der Heumilch- und der Nicht-Heumilchbetriebe dargestellt. Ein Vergleich der Kurvenverläufe der Betriebe deutet auf ein heterogeneres Mähverhalten der Heumilchbetriebe hin. Die Greenness-Kurven der Feldstücke der Nicht-Heumilchbetriebe verlaufen relativ homogen, d.h. der Biomasseaufwuchs war auf den Flächen zu den Aufnahmezeitpunkten jeweils ähnlich. Die Kurven der Heumilchflächen weisen eine etwas höhere Heterogenität auf. Der Biomassenaufwuchs war dort zu den jeweiligen Terminen eher unterschiedlich. Dies legt die Schlussfolgerung nahe, dass hier die Flächen zeitlich versetzt gemäht wurden.



Abbildung 25: Zeitlicher Verlauf des Greenness-Index auf den Flächen des Heumilch- und Nicht-Heumilchbetriebs (Betriebspaar ST1) im Jahr 2019. Jede ID (Legende) repräsentiert ein Feldstück.




Abbildung 26: Zeitlicher Verlauf des Greenness-Index auf den Flächen des Heumilch- und Nicht-Heumilchbetriebs (Betriebspaar T1) im Jahr 2020. Jede ID (Legende) repräsentiert ein Feldstück.

Ein Zusammenhang zwischen Mähereignis und dem Verlauf des Greenness-Index wurde in Kapitel 3.1.1 aufgezeigt. In einer Korrelationsmatrix lassen sich die Korrelationen aller Zeitreihen innerhalb eines Betriebes miteinander vergleichen und darstellen, wie ähnlich oder unterschiedlich die Linien verlaufen. Im Nicht-Heumilchbetrieb wurden demnach höhere Korrelationskoeffizienten erwartet. Anhand einer grafischen dargestellten Korrelationsmatrix (heatmap) sind Unterschiede aber nur schwer zu erfassen (Abbildung 27 und Abbildung 28). In Abbildung 29 sind deshalb die Ergebnisse in einem Boxplot zusammengefasst. Hier zeigt der Median die insgesamt höhere Korrelation (ähnlicher Kurvenverlauf) im Nicht-Heumilchbetrieb. Für das Jahr 2020 sind die Unterschiede zwischen den Medianen ausgeprägter. Die einzelnen Werte streuen jedoch mehr als in 2019. Dies könnte daran liegen, dass der Sommer 2020 in Österreich zwar warm aber relativ feucht war (Zentralanstalt für Meteorologie und Geodynamik 2020). In 2019 war insbesondere der Juni, aber auch der gesamte Sommer warm, sonnig und relativ trocken (Zentralanstalt für Meteorologie und Geodynamik 2019). Insofern haben sich für die

Ergebnisse & Diskussion

Betriebe wahrscheinlich viele mögliche Erntetage ergeben, um das Heu oder auch die Silage in best-möglicher Qualität zu ernten und zu trocknen. Auch wenn die Ergebnisse nicht so deutlich wie erwartet sind, so unterstützen sie für die beiden untersuchten Beispielbetriebspaare, die eingangs genannte Hypothese zu den Unterschieden in der zeitlichen Heterogenität der Mähereignisse der beiden Betriebsformen.




Abbildung 27: Korrelationsmatrix der zeitlichen Verläufe des Greenness-Index für die Flächen des Heumilch- und Nicht-Heumilchbetriebs (Betriebspaar ST1) im Jahr 2019




Abbildung 28: Korrelationsmatrix der zeitlichen Verläufe des Greenness-Index für die Flächen des Heumilch- und Nicht-Heumilchbetriebs (Betriebspaar T1) im Jahr 2020




Abbildung 29: Ergebnisse der Korrelationsmatrix des Greenness-Index als Boxplot (links: Betriebspaar ST1, 2019; rechts: Betriebspaar T1, 2020)

3.3.2 Gesamtflächenvergleich der Heumilch- und Nicht-Heumilchbetriebe

Die Darstellung in Kapitel 3.3.1 gewichtet alle Flächen (Feldstücke) gleich, unabhängig von ihrer Größe. Jede Fläche geht mit ihrem mittleren Greenness-Index pro Aufnahmetermin gleichermaßen in das Ergebnis ein. Soll aber die Flächengröße Einfluss im Ergebnis finden, so können alle Flächen je Untersuchungsbetrieb im Ganzen betrachtet werden. Es ist davon auszugehen, dass die Mahd einer mehreren Hektar großen Grünlandfläche größere Auswirkungen auf den Lebensraum bzw. das Nahrungshabitat der Fauna hat, als eine wenige Quadratmeter große Wiese.

Um die Flächengröße zu berücksichtigen, wurde als weiteres Maß für die zeitliche Verteilung der Mähereignisse die Standardabweichung herangezogen. Hierbei wurde die Standardabweichung des Greenness-Index aller Pixel (aller untersuchten Flächen Pro Betrieb) für jeden Termin berechnet. Größere Flächen haben somit mehr Gewicht, da sie eine höhere Anzahl an Pixeln in das Ergebnis einbringen. Werden alle Flächen vorwiegend gleichzeitig gemäht, so ist ein über die Zeit stark schwankender Mittelwert (vor Mahd = Peak, nach Mahd = Senke) mit einer durchweg geringen Standardabweichung zu erwarten, da sich der Aufwuchs auf allen Flächen zeitlich gleichermaßen ändert. Findet eine zeitlich versetzte Mahd statt, so müsste sich der Mittelwert eher konstant im mittleren Bereich der Skala bewegen, da stets bewachsene und gemähte Flächen vorhanden sind

und sich maximale und minimale Werte zu einem „mittleren Wert“ verrechnen. Große Flächen haben hierbei mehr Einfluss. Die Standardabweichung sollte dann jedoch relativ hoch sein.

Vergleich der Beispielbetriebe

Die Ergebnisse in Abbildung 30 zeigen tendenziell, dass der Mittelwert der beiden Nicht-Heumilchbetriebe stärker schwankte. Ganz eindeutig ist das Ergebnis nicht. Zu Vegetationsbeginn, vor der ersten Mahd und zu Vegetationsende, nach der letzten Mahd, war der Biomasseaufwuchs naturgemäß in allen Betrieben einheitlich hoch bzw. niedrig. Vor der ersten Mahd wächst auf allen Flächen gleichermaßen viel Biomasse. Nach der letzten Mahd zum Vegetationsende hin findet kaum noch Zuwachs statt, deshalb war hier ein abfallender Mittelwert auf allen Flächen zu beobachten. Allerdings ist die Datenlage zum Vegetationsende bedingt durch Bewölkung eher „dünn“ und erschwert den Vergleich.




Abbildung 30: Standardabweichungen (blau) und Mittelwert (grau) der Untersuchungsflächen für das Merkmal Greenness-Index; oben: Betriebspaar ST1 im Jahr 2019; unten: Betriebspaar T1 im Jahr 2020; mittlere Standardabweichung über den gesamten Zeitraum (blau gestrichelt)

Die Standardabweichungen des Greenness-Index sind visuell schlecht zu vergleichen. Auffallend ist jedoch ein großer Peak im Nicht-Heumilchbetrieb Ende August 2020. Dieser ist der Tatsache geschuldet, dass hier die dritte Mahd zeitlich auf fünf Termine verteilt und somit sehr heterogen stattgefunden hat (vergleiche Abbildung 9). Eine Senke im Kurvenverlauf des Heumilchbetriebs Ende Juni (2019) bei gleichzeitig niedrigem Mittelwert zeigt, dass hier ein großer Flächenanteil gleichzeitig gemäht wurde. Dies mag den Witterungsbedingungen geschuldet gewesen sein.

Die Fläche unter den Standardabweichungskurven kann zur Quantifizierung und zum Vergleich der Kurven dienen (Tabelle 7). Die Datenlage ist für die Betriebe jedoch z.T. sehr unterschiedlich, für den Nicht-Heumilchbetrieb liegen im Herbst 2020 kaum Daten vor. Deshalb wurden die Daten der beiden Betriebe für diese Berechnung auf einen einheitlichen Zeitraum eingeschränkt (Tabelle 10, im Anhang).

Aus Tabelle 7 wird ersichtlich, dass die Standardabweichung in den Heumilchbetrieben insgesamt höher ist. Es ergibt sich für die untersuchten Heumilchbetriebe eine höhere Diversifizierung des Biomasseaufwuchses über die Vegetationsperiode.

Tabelle 7: Fläche unter der Standardabweichung-Zeit-Kurve (Abbildung 30, berechnet mittels Trapezoid-Methode)

	Heumilchbetrieb	Nicht-Heumilchbetrieb
2019	429,9	263,1
2020	394,9	311,4

Eine zusammenfassende Darstellung als Boxplot (Abbildung 31) verdeutlicht dieses Ergebnis. Für das Jahr 2019 und 2020 kann für die ausgewählten Untersuchungsbetriebe eine heterogenere zeitliche Verteilung des Biomasseaufwuchses in den beiden Heumilchbetrieben im Vergleich zu den Nicht-Heumilchbetrieben abgeleitet werden. Somit lassen sich anhand der Standardabweichung des Greenness-Index auf Basis von Sentinel-2 Daten die aus Abbildung 8 und Abbildung 9 (Kap. 2.1.1) ersichtlichen Tendenzen bestätigen.

Mit vorgestellter Methodik wurden auch die weiteren Betriebspaare (Kapitel 2.1.1; Abbildung 7) analysiert. Ein Vergleich der Mediane der Standardabweichungskurven zeigt auch hier, dass die Heumilchbetriebe tendenziell eine zeitlich breitere Streuung der Mähereignisse aufwiesen, wobei die Unterschiede mal mehr mal weniger ausgeprägt waren (Tabelle 8). Der Untersuchungszeitraum wurde eingeschränkt, so dass eine

ähnliche Datenabdeckung für jeweils beide Betriebe eines Betriebspaars gegeben war (Tabelle 10 im Anhang). Die entsprechenden Zeitreihen des Mittelwertes und der Standardabweichung sind im Anhang in Abbildung 50 und Abbildung 51 zu finden.




Abbildung 31: Boxplot der Standardabweichungen (berechnet jeweils über alle Flächen/Pixel des jeweiligen Betriebes) des Greenness-Index (Zeitreihe); links: 2019, Betriebspaar ST1; rechts: 2020, Betriebspaar T1

Tabelle 8: Median der Standardabweichungen des Greenness-Index (Zeitreihe) über alle Flächen (Pixel) des jeweiligen Betriebes

Betriebspaar	Jahr	Heumilch	Nicht-Heumilch
T3	2019	2.2	1.3
T3	2020	2.6	2.3
T1	2019	2.5	1.7
T1	2020	2.8	1.7
S2	2019	2.5	2.3
S2	2020	3	1.6
S1	Keine Daten	Keine Daten	Keine Daten
S1	2020	2.1	1.7
ST1	2019	2.6	1.7
ST1	2020	3.5	1.9

Vergleich von zwei Beispielgemeinden

Das vorangehend aufgezeigte methodische Vorgehen wurde im Folgenden auf zwei unterschiedliche, zum einen durch Heumilchwirtschaft und zum anderen durch Silagewirtschaft, geprägte Gemeinden angewendet. Es wurden die bereits in Kapitel 3.2 betrachteten Gemeinden Seeham und Frankenmarkt untersucht.

Anhand von Abbildung 32 lassen sich keine Unterschiede im Mittelwert des Greenness-Index ausmachen. Eine eindeutig homogenere zeitliche Verteilung der Mähereignisse in der Nicht-Heumilchregion Frankenmarkt im Vergleich zur Heumilchregion Seeham ist nicht zu erkennen. Ein Vergleich der beiden Regionen anhand der Standardabweichungs-Zeitkurve bzw. der Fläche unter der Kurve (Seeham: 482,8, Frankenmarkt: 446,9) oder mittels Boxplot (Abbildung 33) zeigt geringe Unterschiede und eine große Streubreite der Werte in der Nicht-Heumilch Gemeinde. Aufgrund der dünnen Datenlage zum Vegetationsende wurde hierfür nur der Zeitraum bis 20.09.2020 betrachtet.




Abbildung 32: Standardabweichungen (blau) und Mittelwert (grau) der untersuchten Regionen für das Merkmal Greenness-Index im Jahr 2020; mittlere Standardabweichung über den gesamten Zeitraum (blau gestrichelt)

Tendenziell ist in der Gemeinde Seeham die zeitliche Verteilung des der Grünlandmähd etwas heterogener, aber nicht so ausgeprägt wie die Unterschiede zwischen den Beispielbetrieben. In Frankenmarkt fällt die größere Streuung der Werte auf. Da eine genaue Verteilung der Bewirtschaftungsformen für die beiden Gemeinden unbekannt ist, können zwar Tendenzen, jedoch kein eindeutiger Zusammenhang zwischen Bewirtschaftungsform und diesem Ergebnis nachgewiesen werden. Die Gemeinden liegen in einer Entfernung von ca. 25km. Die Distanz ist gering, kann sich aber schon in ungleichen klimatischen Bedingungen und in einer unterschiedlichen Datenverfügbarkeit,

aufgrund von Bewölkung oder Überflughäufigkeit (Abbildung 56 im Anhang), auswirken. Es gehen hierbei alle Flächen in die Auswertung mit ein. So werden auch beweidete oder eingegraste Feldstücke betrachtet. Da unter Umständen portionsweise beweidet und gemäht wird, kann dies ebenfalls einen Einfluss auf die Standardabweichung des Greenness-Index in beiden Gemeinden haben; je nachdem wie hoch der Anteil dieser Flächen im jeweiligen Gebiet ist. In die Auswertung wurden auch zweimalig und einmalig genutzte Wiesen/Weiden mit einbezogen. Möglicherweise hätte eine Beschränkung auf intensiv bewirtschaftete Flächen die Eindeutigkeit der Ergebnisse erhöht. Genannte Faktoren erschweren den direkten Vergleich der Gemeinden bzw. eindeutige Schlussfolgerungen.




Abbildung 33: Standardabweichung des Greenness-Index über alle Flächen (Pixel) der jeweiligen Gemeinde in 2020

4 Schlussfolgerungen

Auf Grundlage der vorgehend vorgestellten Ergebnisse lässt sich feststellen, dass Sentinel-2 Daten zur Darstellung der zeitlichen Heterogenität des Biomasseauswuchses auf intensiv genutzten österreichischen Grünlandflächen geeignet sind. Voraussetzung dafür ist jedoch eine hinreichende Datenverfügbarkeit (wolkenfreie Aufnahmen) für das Untersuchungsgebiet. Ein grenzwert-freies methodische Vorgehen mittels der Standardabweichung des Greenness-Index, wie in Kapitel 3.3 aufgezeigt, hat sich dabei als sinnvoll erwiesen. Einzelne Mähereignisse lassen sich damit nicht direkt ableiten. Es ist jedoch möglich die zeitliche Verteilung des Biomasseauswuchses bzw. das zeitgleiche Vorhandensein von dicht und dünn bewachsenen Flächen darzustellen. Damit wird indirekt eine heterogene Verteilung der Mahd nachgewiesen. Der Zusammenhang zwischen Aufwuchs und Vegetationsindices ist in der Literatur bestätigt (NDVI, Wang et al. 2005). Da auch ein einheitlich hoher Bewuchs auf allen Flächen (keine Mahd) zu einer geringen Standardabweichung führt, dies ist aber nicht unbedingt negativ zu bewerten ist, sind die Ergebnisse immer gemeinsam mit dem Mittelwert (Abbildung 30) zu beurteilen.

Bei dieser Vorgehensweise wird die gesamte Vegetationsperiode und nicht Einzelereignisse betrachtet. Die Methode ist deshalb wahrscheinlich robuster gegenüber bewölkungsbedingten zeitlichen Lücken der Satellitenaufnahmen um den Mähzeitpunkt. Auch ist keine Festlegung eines Grenzwertes erforderlich, was die Unsicherheit der Ergebnisse oft erhöht.

Ein Vergleich von Flächen ausgewählter Heumilch- und Nicht-Heumilchbetriebe zeigte eine größere zeitliche Heterogenität der Mähereignisse in den Heumilchbetrieben. Unterschiede zwischen Heumilch- und Nicht-Heumilchbetrieben konnten somit anhand der Sentinel-2 Daten und dem genannten methodischen Vorgehen gezeigt werden. Ohne nähere Kenntnis der Betriebe kann im Rahmen dieser Arbeit jedoch nicht sicher beurteilt werden, ob die gefundenen Differenzen einzig auf die jeweilige Betriebsform zurückzuführen sind oder auch andere Unterschiede (z.B. technische Ausstattung der Betriebe etc.) einen Einfluss haben. Allerdings wurden die Betriebspaare so ausgewählt, dass sie möglichst vergleichbar sind. Sie sollten insbesondere eine ähnliche Betriebsgröße aufwiesen und sich in räumlicher Nähe zueinander befinden. Es wäre sinnvoll in weiteren Arbeiten eine größere Anzahl an Betriebspaaren zu untersuchen, um die beobachteten Zusammenhänge zu bestätigen.

Wie oben aufgeführt werden bei der erarbeiteten Methodik keine Mähereignisse, sondern Unterschiede im Biomasseaufwuchs ermittelt. In seltenen Fällen könnte z.B. auch eine

sehr trockene Witterungsphase zu einer Vereinheitlichung des Biomasseaufwuchses führen bzw. diesen einheitlich verhindern und die Standardabweichung dadurch beeinflussen.

Da dieses Vorgehen nicht Pixel derselben Fläche (Differenzberechnung → Mähereignis), sondern Pixel unterschiedlicher geografischer Lage vergleicht (wie sehr streuen Pixelwerte auf allen Flächen des Betriebes?), werden umso mehr ähnliche klimatische Gegebenheiten und eine ähnliche Pflanzenartenzusammensetzung auf den Untersuchungsflächen vorausgesetzt. Eine gewisse Kenntnis des Untersuchungsgebietes ist also notwendig. Es wurde nicht untersucht, ob z.B. Flächen unterschiedlicher Höhenlage verglichen werden können, da sich der Aufwuchs hier anders darstellen kann. Eine unterschiedliche Zusammensetzung der Pflanzenarten (z.B. intensives Grünland, natürliches Grünland, Alm) kann das Ergebnis beeinflussen und zu Unterschieden bzw. einer Erhöhung der Standardabweichung des Greenness-Index führen. Diese würde dann fälschlicherweise als zeitlich heterogene Bewirtschaftung/Mahd interpretiert. Shen et al. (2010) zeigen beispielsweise in ihren Untersuchungen die Beeinflussung des NDVI durch Pflanzen mit gelben Blüten auf Prärie-Grünland. Auch kleinräumige klimatische Unterschiede innerhalb des untersuchten Gebietes können zu einer Heterogenität im Greenness-Index führen, die aber letztendlich nicht in der Bewirtschaftungsweise begründet ist. Die Robustheit der Methodik gegenüber den genannten Einflussfaktoren wurde nicht geprüft. Für die in vorliegender Arbeit untersuchten Beispielbetriebe hat sich das methodische Vorgehen aber als gut anwendbar erwiesen.

Hinzuzufügen ist, dass sich die dargestellten Ergebnisse ausschließlich auf Flächen, auf denen keine Beweidung oder Eingrasen sondern nur Mahd stattgefunden hat, beziehen. Dies ist in der Fragestellung der Arbeit begründet, welche den Fokus auf den Vergleich von zwei Bewirtschaftungsformen (Heumilch- vs. Nicht-Heumilchbetrieb) in Bezug auf die Verteilung der Mähereignisse legt. Hinsichtlich der Beweidung oder des Eingrasens ist nicht von Unterschieden zwischen der Bewirtschaftungsformen auszugehen. Diese Flächen haben deshalb für die Fragestellung eine geringere Relevanz. Sie könnten Unterschiede „verfälschen“, da sie unabhängig von der jeweiligen Bewirtschaftungsform durchgeführt werden und kleinräumige Maßnahmen (z.B. Portionsweide oder tägliches Eingrasen von Teilflächen) zu einer Erhöhung der Standardabweichung des Greenness-Indexes führen würde. Soll jedoch die Gesamtsituation der Verteilung des Biomasseaufwuchses zwischen Betrieben, Flächen oder Regionen verglichen werden, so kann eine Hinzunahme der beweideten und eingegrasteten Flächen bei einer satellitenbasierten Betrachtung sinnvoll sein.

5 Ausblick

Anhand der vorgestellten Methodik wird die zeitliche Verteilung des Biomasseaufwuchses auf Grünlandflächen betrachtet. Ein hoher Greenness-Index entspricht einem hohen Biomasseaufwuchs (vor Mahd). Die räumliche Komponente findet hierbei keine Berücksichtigung. Sie hat jedoch ökologische Relevanz, da nur ein entsprechender Grünlandaufwuchs in räumlicher Nähe bei einem Mähereignis als Ausweichhabitat für Insekten oder kleinere Tiere dienen kann. Kartographische Darstellungen bieten sich an, die räumliche Heterogenität aufzuzeigen. Beispielhaft ist dies für die Regionen Seeham (Heumilchregion) und Frankenmarkt (Nicht-Heumilchregion) für einen typischen Erntetermin (ca. 07/08.05.) in 2020 dargestellt (Abbildung 34 und Abbildung 35).




Abbildung 34: Greenness-Index; Region Seeham (links: 28.04.2020; rechts: 08.05.2020)




Abbildung 35: Greenness-Index; Region Frankenmarkt (links: 28.04.2020; rechts: 08.05.2020)

Auch die Ergebnisse der SIAM-Vorklassifikation können hier gut verwendet werden. Flächen vor der Mahd werden als „strong vegetation with high NIR“ klassifiziert (dunkelgrün). Gemähtes Grünland wird vorwiegend den Klassen „average vegetation with high/low NIR“ oder „shrub rangeland with high/low NIR“ zugeordnet.




Abbildung 36: SIAM-Kategorien; Region Seeham (links: 28.04.2020; rechts: 08.05.2020)



Abbildung 37: SIAM-Kategorien; Region Frankenmarkt (links: 28.04.2020; rechts: 08.05.2020)

Anhand der SIAM-Klassifikation kann z.B. die euklidische Entfernung der Untersuchungsfläche berechnet werden. Abbildung 38 zeigt die Entfernung für jeden Pixel im Untersuchungsgebiet zum nächst gelegenen Pixel mit dichtem/hohen Gras („strong vegetation with high NIR“) am 08.05.2020. Für eine Interpretation der Ergebnisse oder eine weitere Auswertung ist jedoch eine genaue Kenntnis der relevanten Tierarten

notwendig. Ebenso müssten Minimumareale bzw. die Maximalabstände, den die jeweilige Art zwischen zwei Arealen überwinden kann, bekannt sein. Sind diese Informationen vorhanden, so ließe sich für zur Verfügung stehende Satellitenaufnahmen und relevante Termine (z.B. Brutzeit) auch der Flächenanteil mit ausreichender Nähe zu einem geeigneten Habitat (ausreichend Aufwuchs) quantifizieren. Hierbei hat allerdings nicht nur die räumliche und zeitliche Verteilung der Mahd sondern auch die Anordnung des Grünlandes und der Siedlungsfläche an sich einen Einfluss und muss berücksichtigt werden.

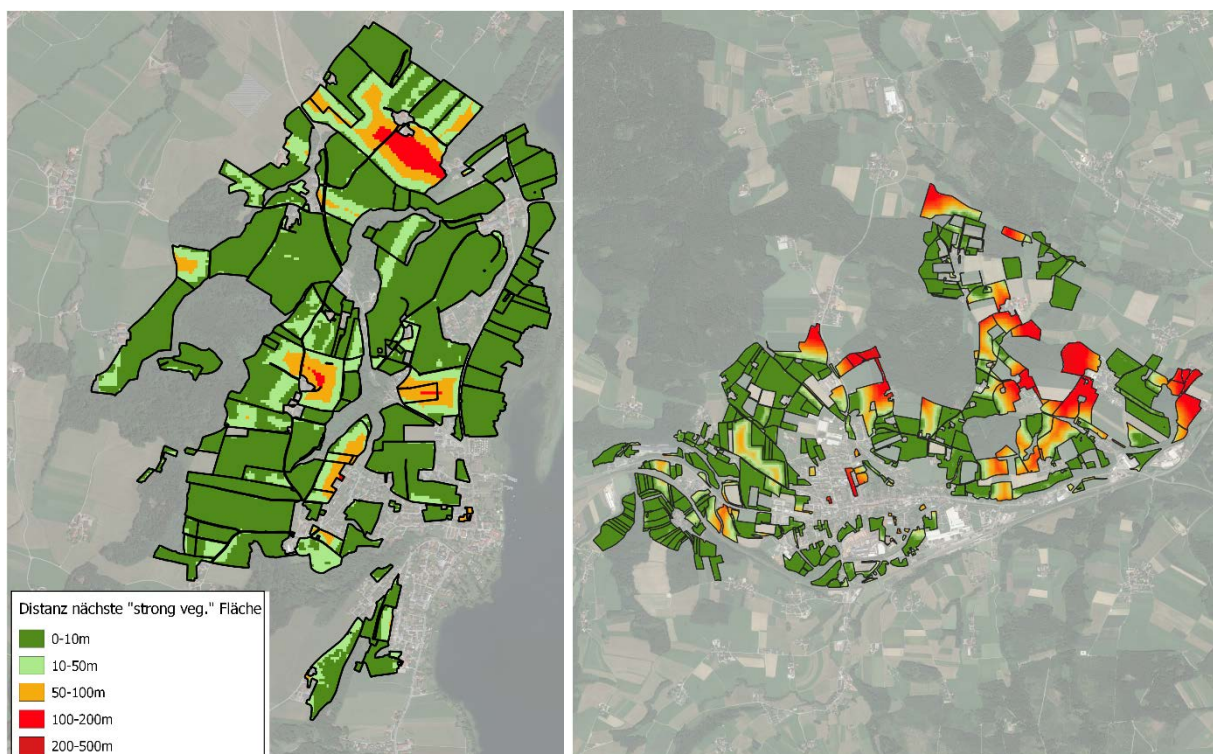


Abbildung 38: Euklidische Distanz zwischen Pixeln der Kategorie „strong vegetation with high NIR“ (dicht bewachsen) und Pixeln anderer SIAM-Kategorien (08.05.2020; links: Seeham; rechts: Frankenmarkt)

6 Ausführliche Zusammenfassung

In vorliegender Arbeit wurde untersucht, ob satellitenbasierte Methoden geeignet sind die zeitliche Heterogenität der Mahd auf Grünlandflächen von Heumilchbetrieben im Vergleich zu Nicht-Heumilchbetrieben darzustellen. Eine solch mosaikartige Mahd kann sich positiv auf die Artenvielfalt auswirken, da nie alle Flächen auf einmal gemäht, sondern immer auch bewachsene Flächen und damit Nahrungsquellen und Rückzugsgebiete für Insekten oder kleine Tiere vorhanden sind (ARGE Heumilch 2014). Als Bilddatenquelle wurde dabei ein semantischer Data Cube (Sen2Cube.at) und die darin vorgehaltenen, frei verfügbaren Sentinel-2 Daten genutzt. Anhand der Weboberfläche des Datenwürfels sind semantische bzw. inhaltsbasierte Bild- und Datenabfragen über die Zeit möglich (Augustin et al., 2019). Landwirtschaftliche Betriebsdaten aus 2019 und 2020 von fünf Betriebspaaren (jeweils ein Heumilchbetrieb und ein Nicht-Heumilchbetrieb) in enger Nachbarschaft und von ähnlicher Betriebsgröße wurden freundlicherweise von der Landwirtschaftskammer Salzburg und der Arbeitsgemeinschaft Heumilch als Referenz zur Verfügung gestellt. Die Daten entstammen einer vom Land Salzburg in Auftrag gegebenen Studie (Suske et al. 2021).

In einem ersten Schritt wurde anhand von Zeitreihen der Verlauf zweier Vegetationsindices (NDVI und Greenness-Index) und einer semantischen Vorklassifikation (SIAM) über die Vegetationsperiode analysiert und deren Übereinstimmung mit realen Mähereignissen auf ausgewählten Beispielflächen untersucht. Die Ergebnisse zeigten, dass reale Mähereignisse gut mit einer plötzlichen Abnahme der beiden Vegetationsindices übereinstimmten. Die Betrachtung der zeitlichen Entwicklung der SIAM-Klassifikation ergab, dass insbesondere der Pixelanteil der Kategorie „strong vegetation with high NIR“ einen deutlichen Zusammenhang mit Mähereignissen aufwies. Nach einem Mähereignis nahm der Anteil der Pixel dieser Klasse stark ab, vergleichbar mit dem Verlauf der Vegetationsindices. Als Probleme wurden insbesondere bewölkte oder beschattete Bilder identifiziert, welche der Wolkenfilter nicht erfasste. Auch die sich durch Bewölkung ergebenden langen Zeitabstände zwischen zwei auswertbaren Satellitenaufnahmen führten dazu, dass Mähereignisse schlichtweg „verpasst“ wurden.

Auf Basis der beobachteten Übereinstimmungen wurde geprüft, ob sich ein Mähereignis anhand der drei Parameter (NDVI, Greenness-Index, SIAM-Kategorie „strong vegetation with high NIR“) über den Differenzwert zwischen zwei aufeinanderfolgenden Satellitenaufnahmen (T2-T1) automatisch ableiten lässt. Ein negativer Differenzwert, d.h. ein stark abfallender Parameterwert zwischen den Aufnahmen, definiert ein Mähereignis.

Hierfür ist die Festlegung eines Grenzwertes erforderlich. Es wurden verschiedenen Methoden der Grenzwert-Definition zur Ableitung eines Mähereignisses getestet: 10%-Perzentil, eine Standardabweichung sowie die Methode nach Otsu (Otsu 1979). Differenzwerte ($T_2 - T_1$), die unterhalb des jeweiligen Grenzwertes lagen, wurden automatisch als Mähereignis („Ernte“) klassifiziert. Differenzwerte oberhalb des Grenzwertes wurden der Klasse „keine Ernte“ zugeordnet. Anhand eines Vergleiches der Klassifikationsergebnisse mit realen Mähereignissen der fünf Betriebspaare wurde eine Konfusionsmatrix erstellt. Es zeigte sich, dass die Klasse „keine Ernte“ mit relativ hoher Sicherheit (87 – 95 %) abgeleitet werden konnte. Dies lag jedoch in der Tatsache begründet, dass diese Klasse mit vielen Werten besetzt war. Die Genauigkeit mit der ein Mähereignis („Ernte“) bestimmt wurde, lag deutlich darunter (34 – 80 %). Je nach angewendetem Grenzwert variierten die Ergebnisse. Anhand des Greenness-Index in Kombination mit einem 10%-Perzentil-Grenzwert wurde die höchste Gesamtgenauigkeit der Klassifikation (87 – 89 %) erreicht.

Das oben genannte methodische Vorgehen (Greenness-Index mit 10%-Perzentil-Grenzwert) wurde auf Sentinel-2 Daten von Flächen zweier Betriebspaare angewendet, um automatisiert Mähereignisse abzuleiten. Die ausgewählten Betriebspaare (2019: ST1; 2020: T1), mit jeweils einem Heumilch- und einem Nicht-Heumilchbetrieb, ließen auf Basis der realen Erntetermine Unterschiede in der zeitlichen Verteilung der Mähereignisse zwischen den Bewirtschaftungsformen erwarten. Die Ergebnisse der automatisierten Ableitung von Mähereignissen waren jedoch unbefriedigend. Es konnten Tendenzen, aber keine deutlichen Unterschiede in der Verteilung oder Häufung der Mähereignisse zwischen den Bewirtschaftungsformen aufgezeigt werden. Dies lag unter anderem an durch Bewölkung verursachten Problemen. Auch zeigte ein Vergleich mit den realen Mähereignissen, dass die Genauigkeit der Klassifikation (Ernte/keine Ernte) insgesamt sehr niedrig war. Weiterhin wurde deutlich, dass das Ergebnis jeweils stark von der Definition des jeweiligen Grenzwertes abhängig ist.

Deshalb wurde im Rahmen der Arbeit eine weitere, grenzwert-freie Methode zum Nachweis der Heterogenität der Mahd auf Grünlandflächen geprüft. Bei diesem Vorgehen werden die Mähereignisse nicht direkt, sondern indirekt bestimmt. Eine Darstellung der zeitlichen Verläufe des Greenness-Index zeigt, dass die Kurven der Nicht-Heumilchbetriebe zumeist paralleler verlaufen als die der Heumilchbetriebe (Abbildung 39). Anhand einer Korrelationsmatrix wurde die Ähnlichkeit der zeitlichen Verläufe innerhalb eines Betriebes beurteilt. Hohe Korrelationen sprechen dafür, dass der Greenness-Index und damit auch der Aufwuchs auf den einzelnen Flächen zumeist

ähnlich sind. D.h. Aufwuchs und Mahd haben auf den Flächen des jeweiligen Betriebes zeitlich homogen stattgefunden. Niedrige Korrelationen deutet darauf hin, dass hier Aufwuchs und Mahd auf den Flächen zeitlich versetzt stattfanden.

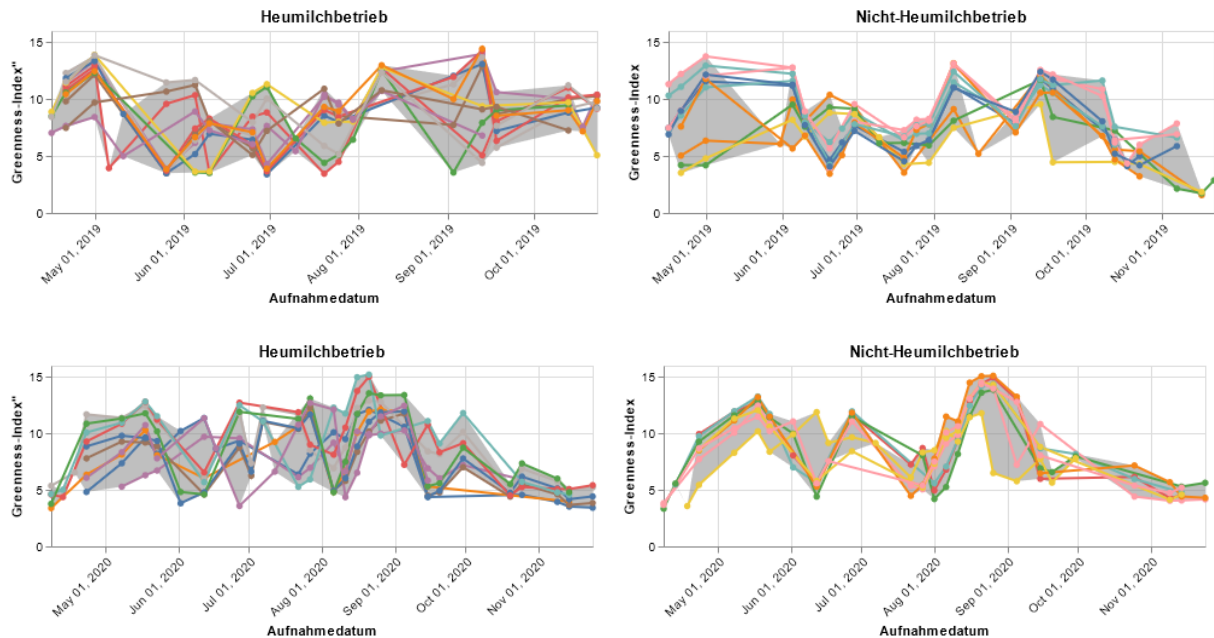


Abbildung 39: Zeitlicher Verlauf des Greenness-Index auf den Flächen der Heumilch- und Nicht-Heumilchbetriebe (Betriebspaar ST1 in Jahr 2019: oben; Betriebspaar T1 in Jahr 2020: unten). Jede Linie repräsentiert ein Feldstück. Das graue Band stellt die Spanne zwischen Maximum- und Minimumwerten dar.

In Boxplots wurden die Korrelationskoeffizienten zusammenfassend dargestellt (Abbildung 40). Es konnte gezeigt werden, dass die Mahd bzw. der Biomasseaufwuchs der Flächen in den untersuchten Heumilchbetrieben weniger korrelierte als in den Nicht-Heumilchbetrieben. Dies unterstützt die Annahme einer zeitlich heterogeneren Verteilung der Mahd in den untersuchten Heumilchbetrieben.

Nachteil dieser genannten grenzwert-freien Methode ist, dass hierbei alle Flächen, unabhängig von ihrer Größe, gleichermaßen mit ihrem Greenness-Index-Mittelwert in das Ergebnis eingehen. Für Insekten und kleine Tiere hat die Mahd einer mehreren Hektar großen Grünlandfläche jedoch sicherlich größere Auswirkungen als die Mahd einer wenige Quadratmeter großen Wiese. Um die Flächengröße zu berücksichtigen wurde die Standardabweichung des Greenness-Index aller Pixel für jeden Aufnahmezeitpunkt berechnet (dies umfasste alle untersuchten Flächen eines Betriebes). Größere Flächen




Abbildung 40: Zusammenfassung der Korrelationsmatrix des Greenness-Index als Boxplot (links: Betriebspaar ST1, 2019; rechts: Betriebspaar T1, 2020)

haben somit mehr Gewicht, da sie mit einer höheren Anzahl an Pixeln in das Ergebnis eingehen. Werden alle Flächen vorwiegend gleichzeitig gemäht, so ist eine über die Zeit insgesamt geringe Standardabweichung zu erwarten, da sich der Aufwuchs und damit auch der Greenness-Index auf allen Flächen zeitlich gleichermaßen ändert. Findet eine zeitlich versetzte Mahd statt, so müsste die Standardabweichung durchgehend relativ hoch sein, da stets bewachsene und gemähte Flächen vorhanden sind. Dies erhöht die Streubreite der Indexwerte. Die Daten der Betriebspaare wurden hinsichtlich der Standardabweichung des Greenness-Index analysiert. Im Ergebnis war auf den betrachteten Heumilchflächen im Vergleich zu den Nicht-Heumilchflächen eine höhere Streuung des Greenness-Index zu beobachten (Abbildung 41). Die Untersuchung weiterer Betriebspaare bestätigte diese Tendenz. Auch bei einer Betrachtung der Gesamtbetriebsflächen ist somit ein zeitlich heterogenerer Biomasseaufwuchs und damit eine zeitlich besser verteilte Mahd in den untersuchten Heumilchbetrieben zu beobachten. Als Grund für die beobachteten Differenzen sind Unterschiede in der Bewirtschaftungsform (Heumilch vs. Nicht-Heumilch) anzunehmen. Ob diese jedoch einzig dafür verantwortlich sind, oder auch andere Unterschiede einen Einfluss haben (z.B. technische Ausstattung der Betriebe etc.), kann ohne genaue Kenntnis der Betriebe nicht sicher beurteilt werden. Die Betrachtung einer größeren Anzahl von Betriebspaaren wäre anzustreben, um die beobachteten Zusammenhänge zu bestätigen.




Abbildung 41: Boxplot der Standardabweichungen des Greenness-Index über alle Flächen (Pixel) des jeweiligen Betriebes (links: 2019, Betriebspaar ST1; rechts: 2020, Betriebspaar T1)

Bei vorgestelltem methodischem Vorgehen wird nicht das Mähereignis an sich, sondern die Heterogenität des Aufwuchses, also zwischen dicht bewachsenen und spärlich bewachsenen Flächen, bestimmt. In seltenen Fällen könnte z.B. eine sehr extreme Witterungsphase (Trockenheit) zu einer Vereinheitlichung des Aufwuchses führen (keine Biomassewachstum ohne Niederschlag) und dadurch die Standardabweichung beeinflussen. Dies ist bei der Anwendung des methodischen Vorgehens zu beachten. Es ist deshalb sinnvoll als zusätzlichen Parameter den Mittelwert des Greenness-Index zu betrachten. Dieser zeigt an, wie hoch bzw. grün die Flächen insgesamt bewachsen waren.

In fortführenden Arbeiten ließe sich ermitteln, ab welcher Ausprägung die Heterogenität des Aufwuchses von ökologischer Relevanz ist. Die vorliegende Arbeit beschränkt sich auf eine Betrachtung der Unterschiede zwischen den Bewirtschaftungsformen, nimmt jedoch keine Bewertung vor.

Um letztendlich eine mosaikartige Bewirtschaftungsweise nachzuweisen müsste zusätzlich zur zeitlichen Komponente noch die räumliche Verteilung des Biomasseaufwuchses betrachtet werden. Eine hohe Standardabweichung definiert die Unterschiedlichkeit zu einem Zeitpunkt, nicht aber ob die Flächen mit hohem Aufwuchs räumlich verteilt oder aber geclustert vorliegen (siehe Kapitel 5). Eine erste visuelle Einschätzung lässt sich anhand kartographischer Darstellungen des Greenness-Index für relevante Zeitpunkte (z.B. Brutzeit oder typische Erntetermine) vornehmen. Aufgrund der geringen Flächenanzahl und -verteilung war dies für die gewählten Beispielbetriebe jedoch

nicht aussagekräftig. In weiteren Analysen könnten Berechnungen zur Entfernung von wenig und dicht bewachsenen Flächen die nötigen Informationen liefern, um eine räumlich mosaikartige oder nicht-mosaikartige Bewirtschaftungsweise zu definieren und eine ökologische Bewertung zu ermöglichen.

Zusammenfassend lässt sich feststellen, dass Sentinel-2 Daten geeignet sind um, die zeitliche Heterogenität der Grünlandbewirtschaftung, mit Fokus auf der Mahd, nachzuweisen. Im Rahmen der vorliegenden Arbeit wurde dazu ein methodisches Vorgehen, unter Nutzung der Sen2Cube Datenwürfels, erarbeitet (Abbildung 42) und geeignete Parameter (Standardabweichung und Mittelwert des Greenness-Index) identifiziert. Anhand dieses Vorgehens und anhand ausgewählter Beispielbetriebe ließen sich auch Unterschiede zwischen den Bewirtschaftungsformen „Heumilchbetrieb“ und „Nicht-Heumilchbetrieb“ aufzeigen. Die zeitliche Heterogenität war in den untersuchten Heumilchbetrieben höher.

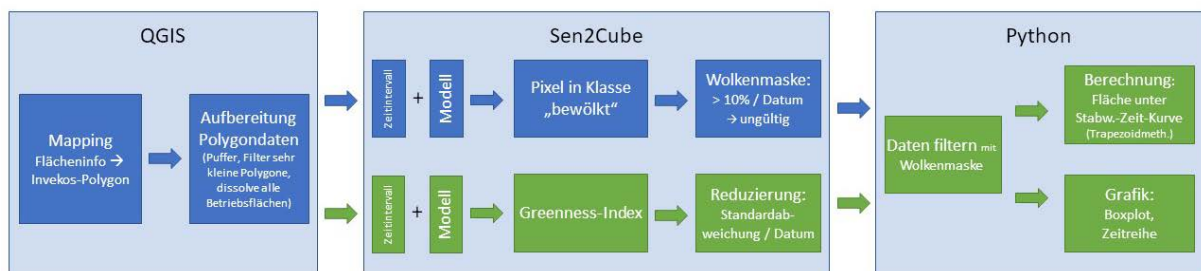


Abbildung 42: Workflow des methodischen Vorgehens

Geprüft wurde das Vorgehen für vorwiegend intensiv bewirtschaftete Grünlandflächen in Österreich. Beweidete oder eingegraste Flächen wurden in den Untersuchungen nicht betrachtet. Voraussetzung für die Anwendbarkeit des Vorgehens ist, dass die betrachteten Flächen eine gewisse Konformität innerhalb der Vergleichsgruppe hinsichtlich des Standortklimas und der Artenzusammensetzung des Bewuchses aufweisen. Andernfalls könnte sich dadurch die Standardabweichung der Ergebnisse erhöhen, ohne dass dies ursächlich im Zusammenhang mit dem Mähereignis steht. Auf die Notwendigkeit einer ausreichenden Anzahl an wolkenfreien Satellitenbildern ist ebenfalls hinzuweisen.

7 Literaturverzeichnis

Aberle, H. (2017): Hyperspectral Remote Sensing and Field Measurements for Forest Characteristics. A Case Study in the Hainich National Park, Central Germany. Dissertation. Georg-August-Universität, Göttingen.

Agrarmarkt Austria (2019): INVEKOS Feldstücke Österreich 2019. Online verfügbar unter <https://www.data.gv.at/katalog/dataset/invekosschlgerreich2019>, zuletzt geprüft am 09.03.2021.

Agrarmarkt Austria (2020): INVEKOS Feldstücke Österreich 2020. Online verfügbar unter https://www.data.gv.at/katalog/dataset/ama_invekosschlgerreich2020, zuletzt geprüft am 09.03.2021.

Albertz, J. (2013): Einführung in die Fernerkundung. Grundlagen der Interpretation von Luft- und Satellitenbildern. 5., aktualisierte Auflage. Darmstadt: WBG (Wissenschaftliche Buchgesellschaft).

Anonym (2019): Sen2Cube.at: Sentinel-2 Semantic Data Cube Austria. In: *gis.Business* (5), S. 48–49.

ARGE Heumilch (Hg.) (2014): Nachhaltigkeitsfibel. Wie Heumilch die Umwelt schont. Unter Mitarbeit von W. Zollitsch und S. J. Hörtenhuber.

Baraldi, A.; Durieux, L.; Simonetti, D.; Conchedda, G.; Holecz, F.; Blonda, P. (2010): Automatic Spectral Rule-Based Preliminary Classification of Radiometrically Calibrated SPOT-4/-5/IRS, AVHRR/MSG, AATSR, IKONOS/QuickBird/OrbView/GeoEye, and DMC/SPOT-1/-2 Imagery—Part II: Classification Accuracy Assessment. In: *IEEE Trans. Geosci. Remote Sensing* 48 (3), S. 1326–1354.

Bayerische Landesanstalt für Landwirtschaft (Hg.) (2020): Info-Tag. Hofeigene Heubelüftungsanlagen. Grub, 11. März 2020. Institut für Landtechnik und Tierhaltung.

Bekkema, M. E.; Eleveld, M. (2018): Mapping Grassland Management Intensity Using Sentinel-2 Satellite Data. In: *giform* 1, S. 194–213.

Bill, R. (2016): Grundlagen der Geo-Informationssysteme. 6. Auflage. Berlin: Wichmann.

Blüthgen, N.; Dormann, C. F.; Prati, D.; Klaus, V. H.; Kleinebecker, T.; Hölzel, N. et al. (2012): A quantitative index of land-use intensity in grasslands: Integrating mowing, grazing and fertilization. In: *Basic and Applied Ecology* 13 (3), S. 207–220.

Bonari, G.; Fajmon, K.; Malenovský, I.; Zelený, D.; Holuša, J.; Jongepierová, I. et al. (2017): Management of semi-natural grasslands benefiting both plant and insect diversity: The importance of heterogeneity and tradition. In: *Agriculture, Ecosystems & Environment* 246, S. 243–252.

Bundesministerin für Nachhaltigkeit und Tourismus (Hg.) (2019): Grüner Bericht 2019. Die Situation der österreichischen Land- und Forstwirtschaft. 60. Aufl. Wien. Online verfügbar unter www.gruenerbericht.at, zuletzt geprüft am 18.02.2021.

Bundesministerium für Ernährung und Landwirtschaft (BMEL) (Hg.) (2019): Programm des BMEL zur Fernerkundung. Chancen für Land-, Forst- und Fischereiwirtschaft, für Politik und Verwaltung. Referat 715 Tier und Technik. Bonn. Online verfügbar unter <https://www.bmel.de/SharedDocs/Downloads/DE/Broschueren/Fernerkundung.pdf>, zuletzt geprüft am 04.05.2021.

Cayrol, P. (2000): Grassland modeling and monitoring with SPOT-4 VEGETATION instrument during the 1997–1999 SALSA experiment. In: *Agricultural and Forest Meteorology* 105 (1-3), S. 91–115.

Cizek, O.; Zamecnik, J.; Tropek, R.; Kořánek, P.; Konvicka, M. (2012): Diversification of mowing regime increases arthropods diversity in species-poor cultural hay meadows. In: *Journal of Insect Conservation* 16 (2), S. 215–226.

Deutsches Zentrum für Luft- und Raumfahrt e.V. (DLR) (o.D.): Die Copernicus Sentinel-Satelliten. Online verfügbar unter https://www.dlr.de/eoc/desktopdefault.aspx/tabid-16002/25948_read-66677/, zuletzt geprüft am 29.06.2021.

Europäische Kommission (2016): Durchführungsverordnung (EU) 2016/304 zur Eintragung einer Bezeichnung in das Register der garantiert traditionellen Spezialitäten, vom 02.03.2016.

European Space Agency (2015): Sentinel-2 User Handbook, 2015.

European Union, Copernicus Sentinel-2 imagery (o.D.): Über Copernicus. Online verfügbar unter <https://www.copernicus.eu/de/ueber-copernicus>, zuletzt geprüft am 29.06.2021.

Franke, J.; Keuck, V.; Siegert, F. (2012): Assessment of grassland use intensity by remote sensing to support conservation schemes. In: *Journal for Nature Conservation* 20 (3), S. 125–134.

Galler, J.; Kittl, M.; Wirleitner, G. (2017): Heutrocknung von A bis Z. Pflanzenbau – Trocknungssysteme – Kenngrößen. Landwirtschaftskammer Salzburg.

Ginzinger, W. (o.D.): Vorteile der Heumilch. Online verfügbar unter http://www.heumilch.at/wp-content/uploads/2014/05/Vorteile_Heumilch.pdf, zuletzt geprüft am 18.01.2020.

Gómez Giménez, M.; Jong, R. de; Della Peruta, R.; Keller, A.; Schaepman, M. (2017): Determination of grassland use intensity based on multi-temporal remote sensing data and ecological indicators. In: *Remote Sensing of Environment* 198, S. 126–139.

Gottwald, F.; Stein-Bachinger, K. (2016): Landwirtschaft für Artenvielfalt. Ein Naturschutzmodul für ökologisch bewirtschaftete Betriebe. 2. überarbeitete Auflage. Berlin, Germany: WWF Deutschland.

Griffiths, P.; Nendel, C.; Pickert, J.; Hostert, P. (2020): Towards national-scale characterization of grassland use intensity from integrated Sentinel-2 and Landsat time series. In: *Remote Sensing of Environment* 238, S. 111124.

Halabuk, A.; Moyses, M.; Halabuk, M.; David, S. (2015): Towards Detection of Cutting in Hay Meadows by Using of NDVI and EVI Time Series. In: *Remote Sensing* 7 (5), S. 6107–6132.

Hege, U.; Diez, T.; Brandhuber, R.; Tischner, H.; Pommer, G.; Kreitmayr, J. et al. (1998): Pflanzliche Erzeugung. 11., völlig Neubearb. und erw. Aufl. München: BVL Verlagsgesellschaft (Die Landwirtschaft, 1).

Huete, A.; Didan, K.; Miura, T.; Rodriguez, E.P.; Gao, X.; Ferreira, L.G. (2002): Overview of the radiometric and biophysical performance of the MODIS vegetation indices. In: *Remote Sensing of Environment* 83 (1-2), S. 195–213.

Humboldt State University (2019): Introduction to Remote Sensing. Vegetation Spectral Reflectance Curves. Hg. v. Humboldt State University. Online verfügbar unter https://gsp.humboldt.edu/OLM/Courses/GSP_216_Online/lesson2-1/vegetation.html, zuletzt geprüft am 04.05.2021.

Kolecka, N.; Ginzler, C.; Pazur, R.; Price, B.; Verburg, P. (2018): Regional Scale Mapping of Grassland Mowing Frequency with Sentinel-2 Time Series. In: *Remote Sensing* 10 (8), S. 1221.

Lange, N. de (2013): Geoinformatik. Berlin, Heidelberg: Springer.

- Lilienthal, H.; Greef, J.-M. (2017): Monitoring landwirtschaftlicher Flächen mit Satellitenfernerkundung. In: *Journal für Kulturpflanzen* 69 (2), S. 76–79.
- Lillesand, T. M.; Kiefer, R. W.; Chipman, J. W. (2015): Remote sensing and image interpretation. Seventh edition. Hoboken, NJ: Wiley.
- Lindner, G.; Kittl, M. (2016): Heumilchproduktion in Österreich. Bestandserhebung und Implikationen für die Weiterbildung und Beratung. Bachelorarbeit. Hochschule für Agrar- und Umweltpädagogik, Wien.
- Mahajan, S.; Fataniya, B. (2020): Cloud detection methodologies: variants and development—a review. In: *Complex Intell. Syst.* 6 (2), S. 251–261.
- Otsu, N. (1979): A Threshold Selection Method from Gray-Level Histograms. In: *IEEE Trans. Syst., Man, Cybern.* 9 (1), S. 62–66.
- Patra, S.; Ghosh, S.; Ghosh, A. (2011): Histogram thresholding for unsupervised change detection of remote sensing images. In: *International Journal of Remote Sensing* 32 (21), S. 6071–6089.
- Pöllinger, A. (2015): Heutrocknungsverfahren im Vergleich. In: Lehr- und Forschungsanstalt für Landwirtschaft Raumberg-Gumpenstein (Hg.): Bericht über das 19. Alpenländische Expertenforum zum Thema Futterkonservierung - aktuelle Entwicklungen in der Silage- und Heuproduktion. 03. April 2014 LFZ Raumberg-Gumpenstein. Irdning: LFZ, S. 35–44.
- Reinermann, S.; Asam, S.; Kuenzer, C. (2020): Remote Sensing of Grassland Production and Management—A Review. In: *Remote Sensing* 12 (12), S. 1949.
- Sakowska, K.; Juszczak, R.; Gianelle, D. (2016): Remote Sensing of Grassland Biophysical Parameters in the Context of the Sentinel-2 Satellite Mission. In: *Journal of Sensors* 2016, S. 1–16.
- Satellite Imaging Corporation (Hg.) (o. D.): Sentinel-2A (10m) Satellite Sensor. Online verfügbar unter <https://www.satimagingcorp.com/satellite-sensors/other-satellite-sensors/sentinel-2a/>, zuletzt geprüft am 27.05.2021.
- Shen, M.; Chen, J.; Zhu, X.; Tang, Y.; Chen, X. (2010): Do flowers affect biomass estimate accuracy from NDVI and EVI? In: *International Journal of Remote Sensing* 31 (8), S. 2139–2149.

- Stein-Bachinger, K.; Fuchs, S. (2012): Protection strategies for farmland birds in legume–grass leys as trade-offs between nature conservation and farmers' needs. In: *Organic Agriculture* 2 (2), S. 145–162.
- Stumpf, F.; Schneider, M. K.; Keller, A.; Mayr, A.; Rentschler, T.; Meuli, R. G. et al. (2020): Spatial monitoring of grassland management using multi-temporal satellite imagery. In: *Ecological Indicators* 113, S. 106201.
- Suske, W.; Huber, J.; Depisch, B.; Frieß, T.; Holzinger, W.; Derbuch, G. et al. (2021): Analyse der Zielerfüllung der ÖPUL- Maßnahme „Silageverzicht“ in Bezug auf Biodiversität. Studie im Auftrag von Land Salzburg, Land Tirol, Land Steiermark und Land Vorarlberg.
- Tempfli, K.; Huurneman, G.C.; Bakker, W.H.; Janssen, L.L.F.; Feringa, W.F.; Gieske, A.S.M. et al. (Hg.) (2009): Principles of remote sensing. An introductory textbook. 4th edition. Enschede: ITC (ITC Educational Textbook Series, 2).
- Turner, S.; Macuhova, J. (2018): Heu - da steckt viel mehr drin. In: *Bayerisches Landwirtschaftliches Wochenblatt*, 2018 (8), S. 49–50.
- Tiede, D. (2013): Automatische Vorklassifikation von optischen Multi-Sensor Fernerkundungsdaten als Grundlage für semantische Abfragen in FE-Datenarchiven. Vortrag. ESA Technologie Transfer Tag. Österreichische Forschungsförderungs GmbH. Wien, 05.12.2013.
- Tiede, D.; Baraldi, A.; Sudmanns, M.; Belgiu, M.; Lang, S. (2017): Architecture and prototypical implementation of a semantic querying system for big Earth observation image bases. In: *European journal of remote sensing* 50 (1), S. 452–463.
- Universität Rostock (o.D.): OpenGeoEdu. Vegetationsmonitoring. Online verfügbar unter <https://learn.opengeoedu.de>, zuletzt geprüft am 13.06.2021.
- Urf, S. (2019): Estimation of grassland use intensity and mowing events based on SAR coherence and Sentinel-2 MSI time series. Masterthesis. Paris Lodron-Universität, Salzburg. Fachbereich Geoinformatik – Z_GIS.
- Veroustraete, F.; Fang, H.; Xi, C.; Bao, A. M.; Dong, Q.; Tie, L.; Willems, P. (2011): Diachronic Mapping of LUCC in the Northwest of China over the last half Century: Conversion of CORONA Panchromatic reflectance into LANDSAT NDVI Imagery. In: *Insciences J.*, S. 194–210.

Wang, J.; Rich, P. M.; Price, K. P.; Kettle, W. D. (2005): Relations between NDVI, Grassland Production, and Crop Yield in the Central Great Plains. In: *Geocarto International* 20 (3), S. 5–11.

Wasser, L.; Korinek, N.; Palomino, J. (2021): Intermediate earth data science textbook. Chapter 9: Landsat data. Lesson 3. Clean Remote Sensing Data in Python - Clouds, Shadows & Cloud Masks. Online verfügbar unter <https://www.earthdatascience.org/courses/use-data-open-source-python/multispectral-remote-sensing/landsat-in-Python/remove-clouds-from-landsat-data/>, zuletzt geprüft am 10.06.2021.

Zentralanstalt für Meteorologie und Geodynamik (2019): Zweitwärmster Sommer der Messgeschichte. Online verfügbar unter <https://www.zamg.ac.at/cms/de/klima/news/zweitwaermster-sommer-der-messgeschichte>, zuletzt geprüft am 08.06.2021.

Zentralanstalt für Meteorologie und Geodynamik (2020): Sommer 2020: sehr warm und relativ feucht. Online verfügbar unter <https://www.zamg.ac.at/cms/de/klima/news/sommer-2020-sehr-warm-und-relativ-feucht>, zuletzt geprüft am 08.06.2021.

8 Anhang

Tabelle 9: Konfusionsmatrix der Wolken-Klassifikation

	bewölkt	ok	Summe	Nutzergenauigkeit
bewölkt	175	4	179	97,8%
ok	14	165	179	92,2%
Summe	189	169	358	
Produzentengenauigkeit	92,6%	97,6%		
Gesamtgenauigkeit			95,0%	

Tabelle 10: Einschränkung des Untersuchungs- bzw. Darstellungszeitraumes aufgrund der unterschiedlichen Datenverfügbarkeit zwischen den Betriebspaaren (Bewölkung)

Betriebspaar	2019	2020
S1	-	bis 27.09.
S2	bis 16.10.	ab 18.04. und bis 25.09.
ST1	ab 21.04. und bis 23.09.	ab 30.04. und bis 22.09.
T1	ab 03.06. und bis 01.10.	ab 23.04. und bis 15.09.
T3	bis 16.10.	ab 23.04. und bis 30.09.

620_result_greeness_2019

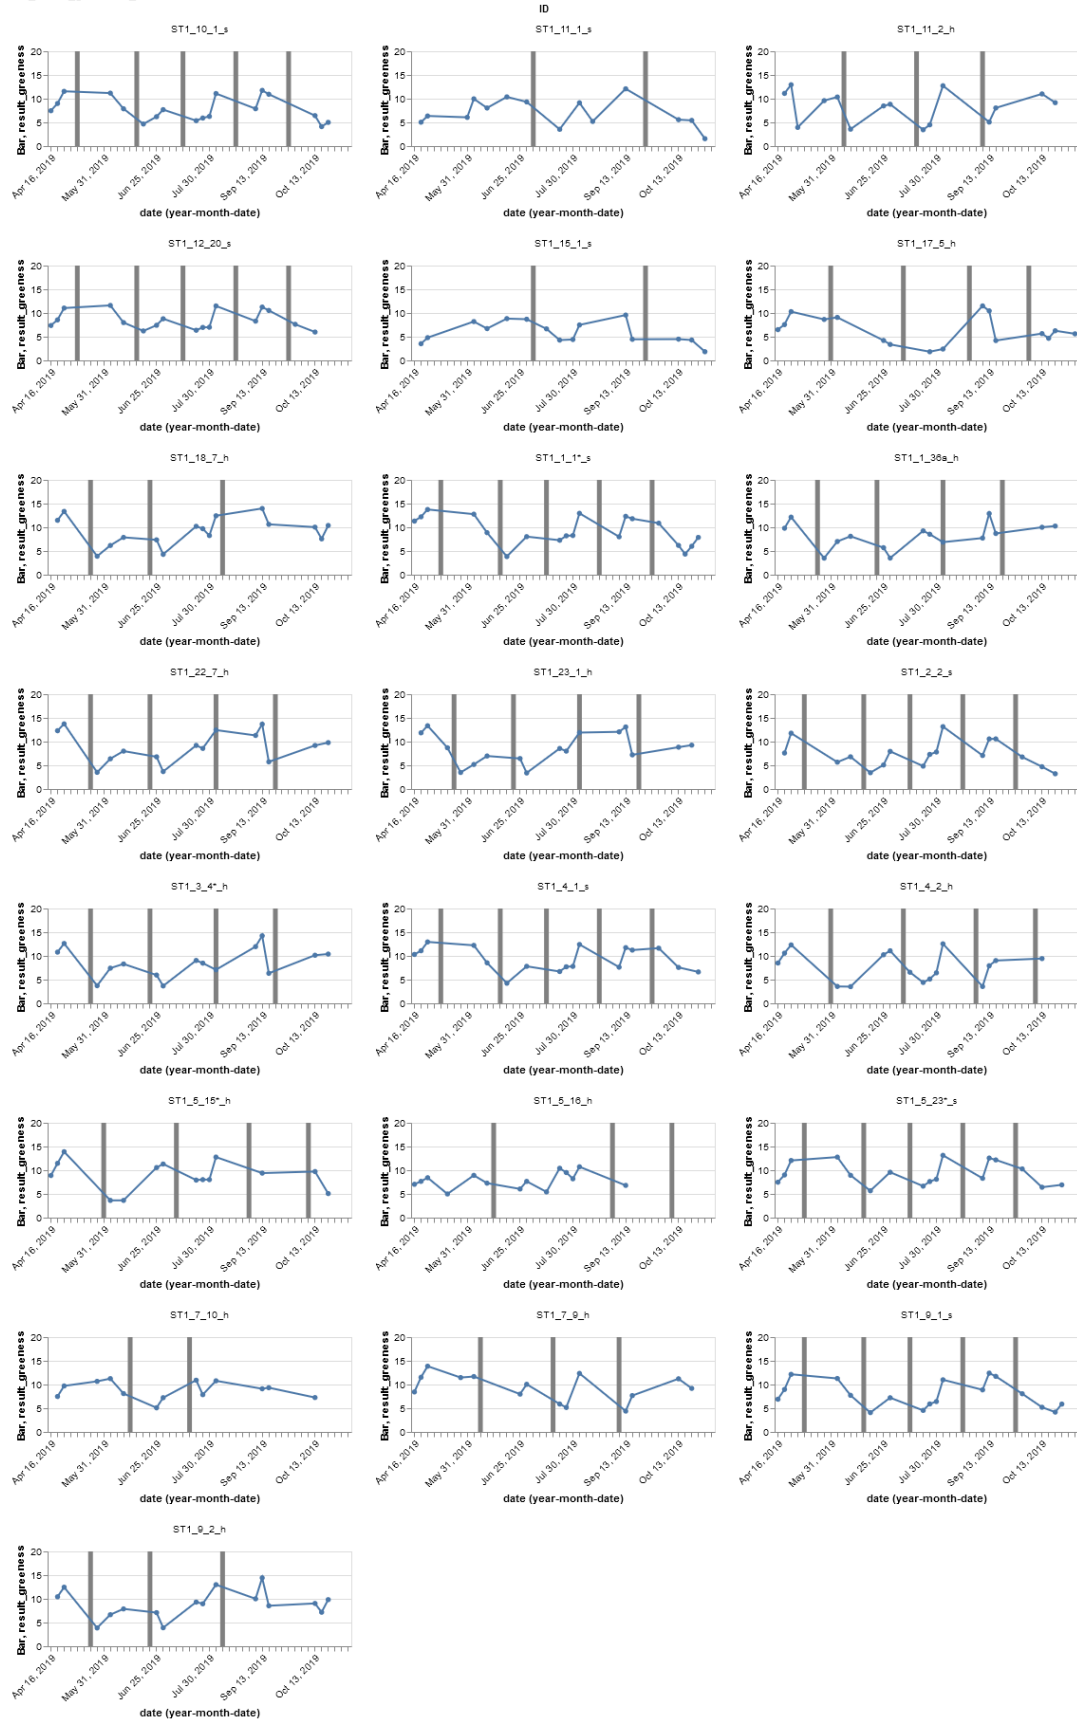


Abbildung 43: Greenness-Index (Linie) und Erntetermine (Balken) während der Vegetationsperiode 2019; blaue Punkte = wolkenfreie Satellitenaufnahmetermine; Untersuchungsflächen des Betriebspaars ST1

704T1_result_greenness_2020

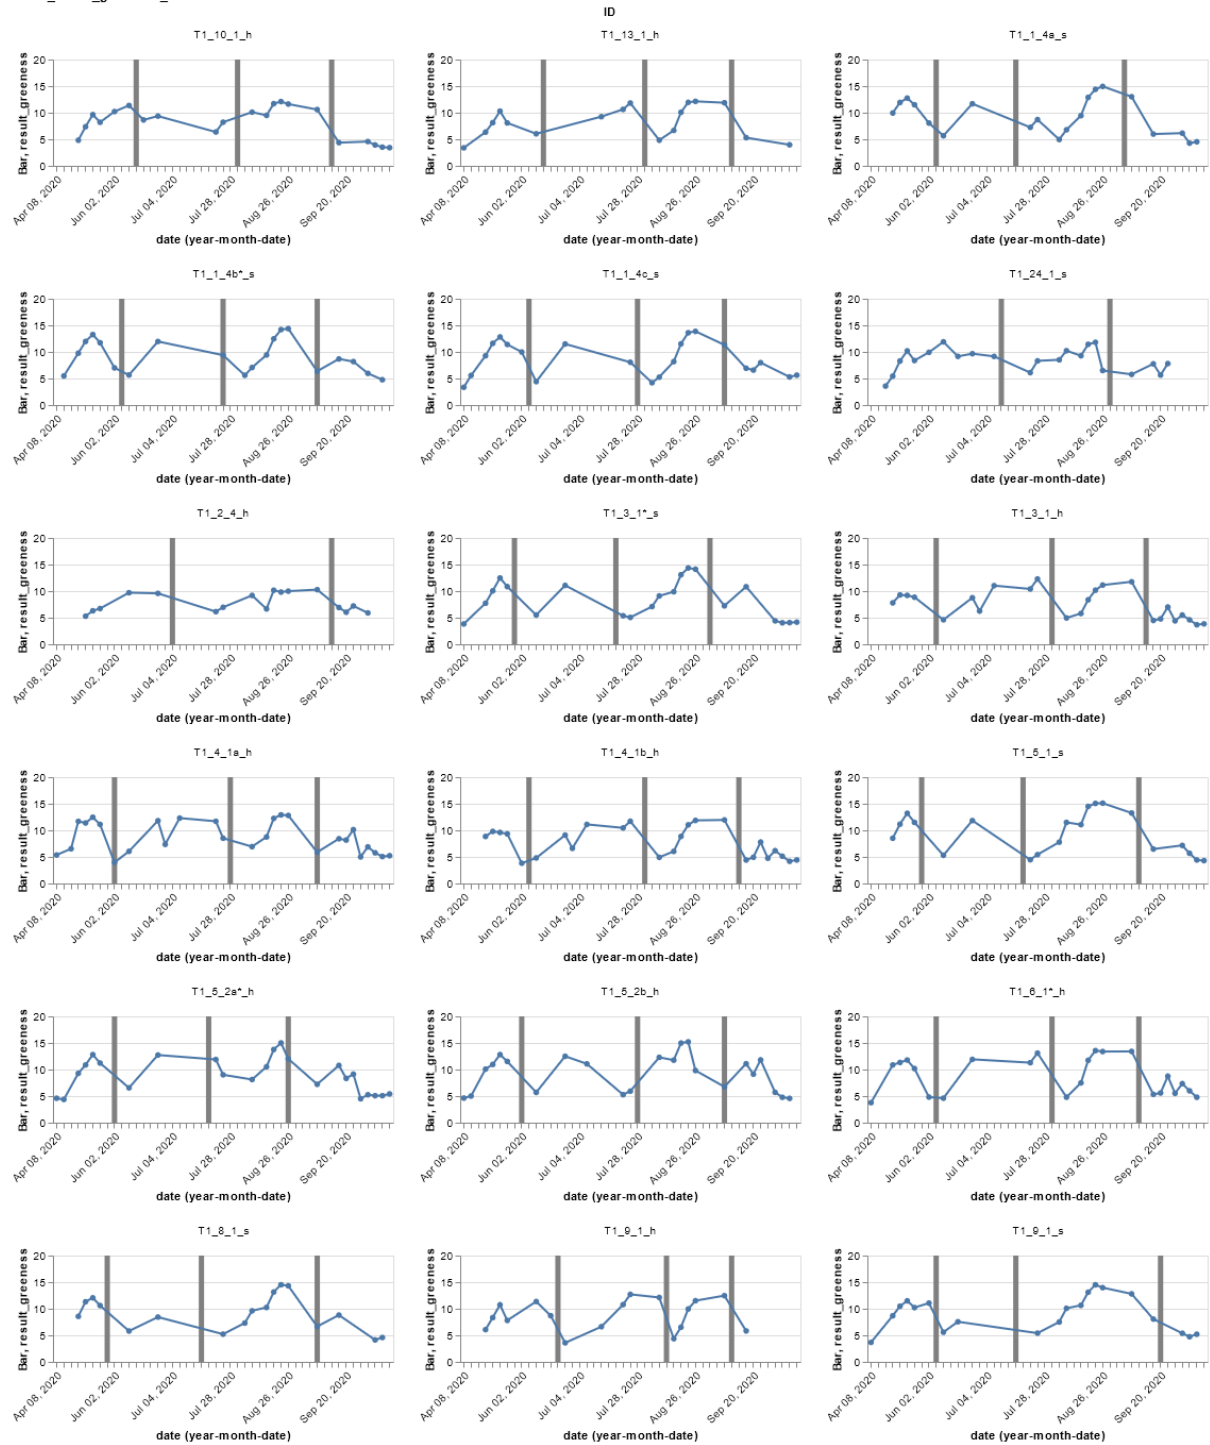


Abbildung 44: Greenness-Index (Linie) und Erntetermine (Balken) während der Vegetationsperiode 2020; blaue Punkte = wolkenfreie Satellitenaufnahmetermine; Untersuchungsflächen des Betriebspaars T1

620_strong_veg_highNIR_2019



Abbildung 45: Pixelanteil (%) der SIAM-Kategorie „strong vegetation with high NIR“ (Linie) und Erntetermine (Balken) während der Vegetationsperiode 2019; blaue Punkte = wolkenfreie Satelitenaufnahmetermine; Betriebspaar ST1

704T1_strong_veg_highNIR_2020

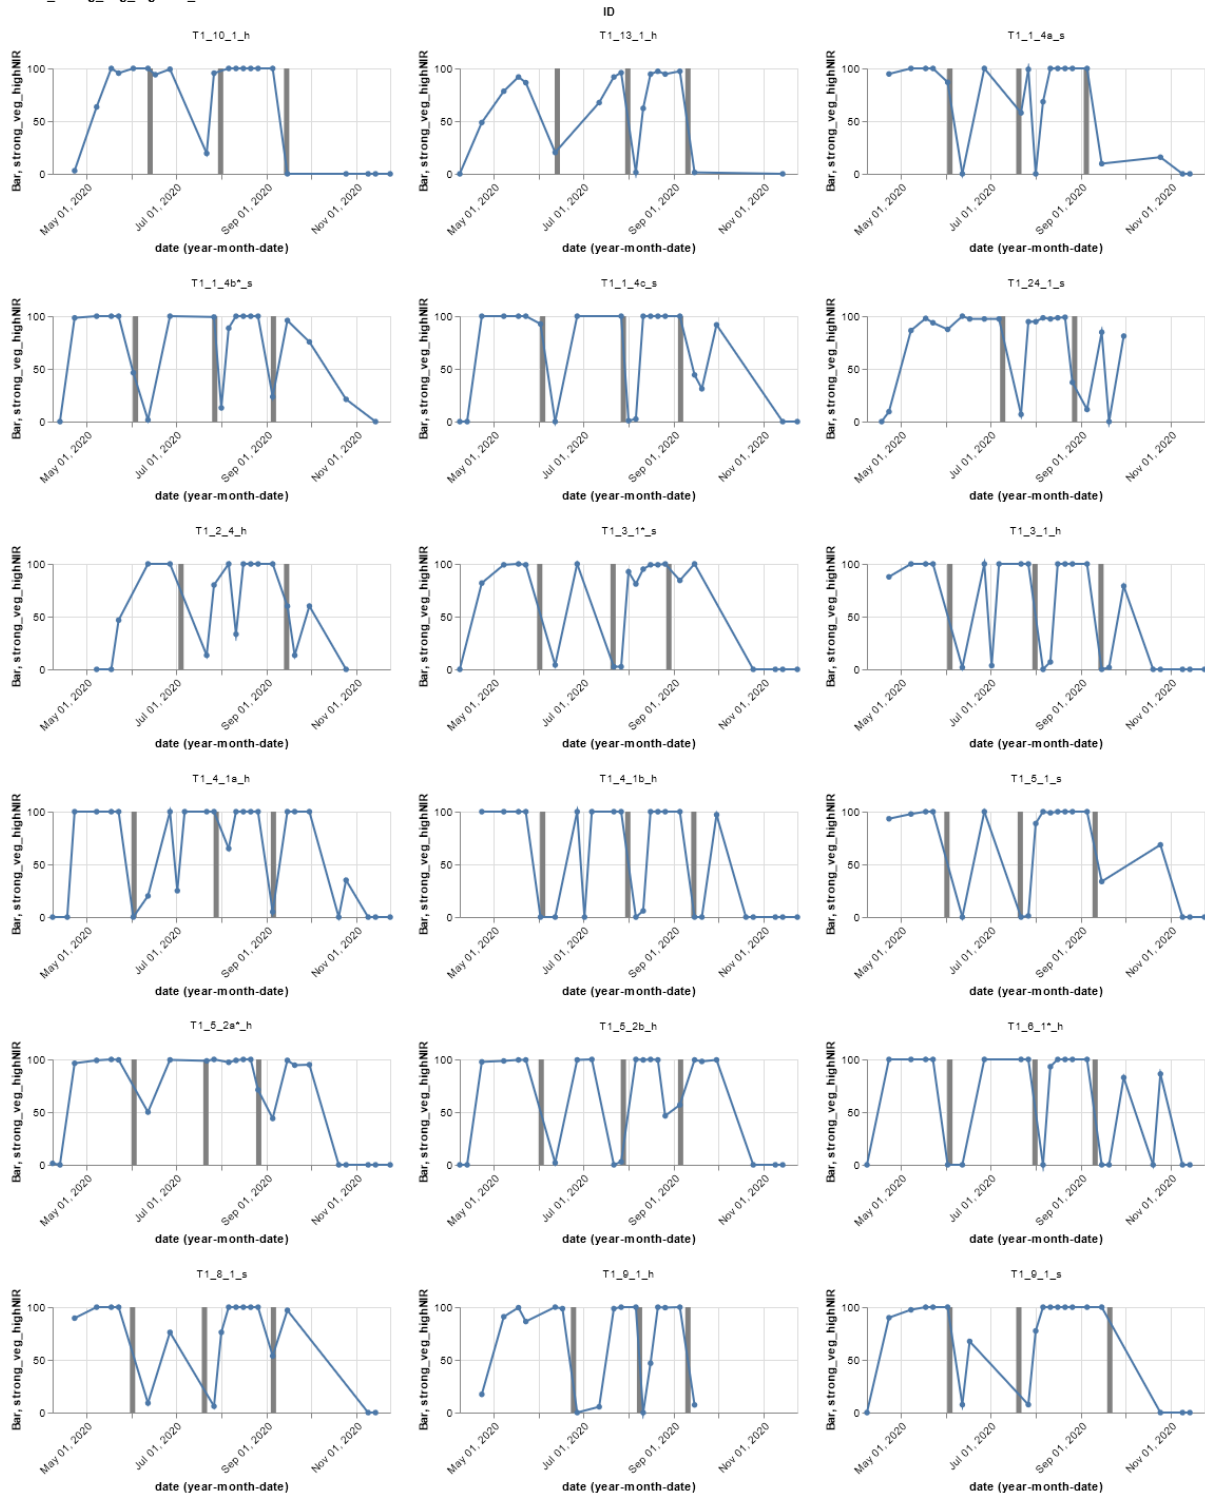


Abbildung 46: Pixelanteil (%) der SIAM-Kategorie „strong vegetation with high NIR“ (Linie) und Erntetermine (Balken) während der Vegetationsperiode 2020; blaue Punkte = wolkenfreie Satelitenaufnahmetermine; Untersuchungsflächen des Betriebspaars T1

620_NDVI8_2019

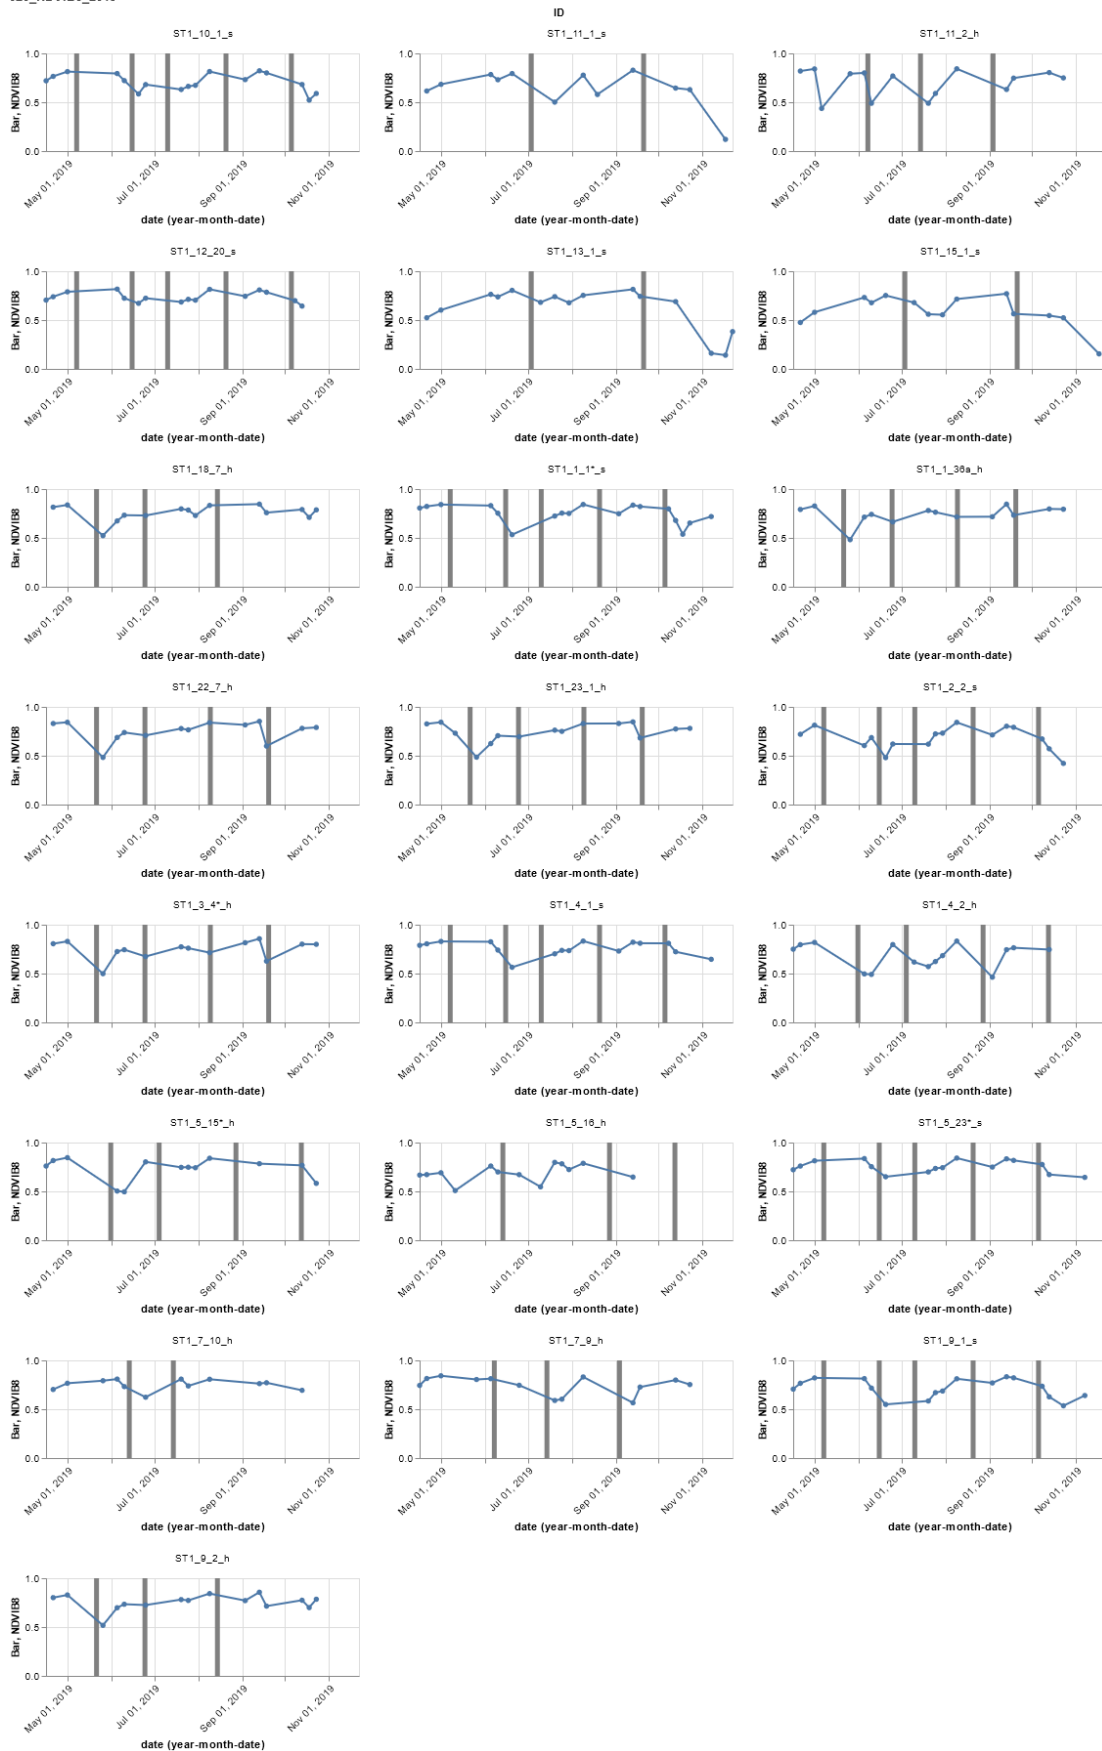


Abbildung 47: NDVI (Linie) und Erntetermine (Balken) während der Vegetationsperiode 2019; blaue Punkte = wolkenfreie Satellitenaufnahmetermine; Untersuchungsflächen des Betriebspaares ST1

704T1_result_NDVI08_2020

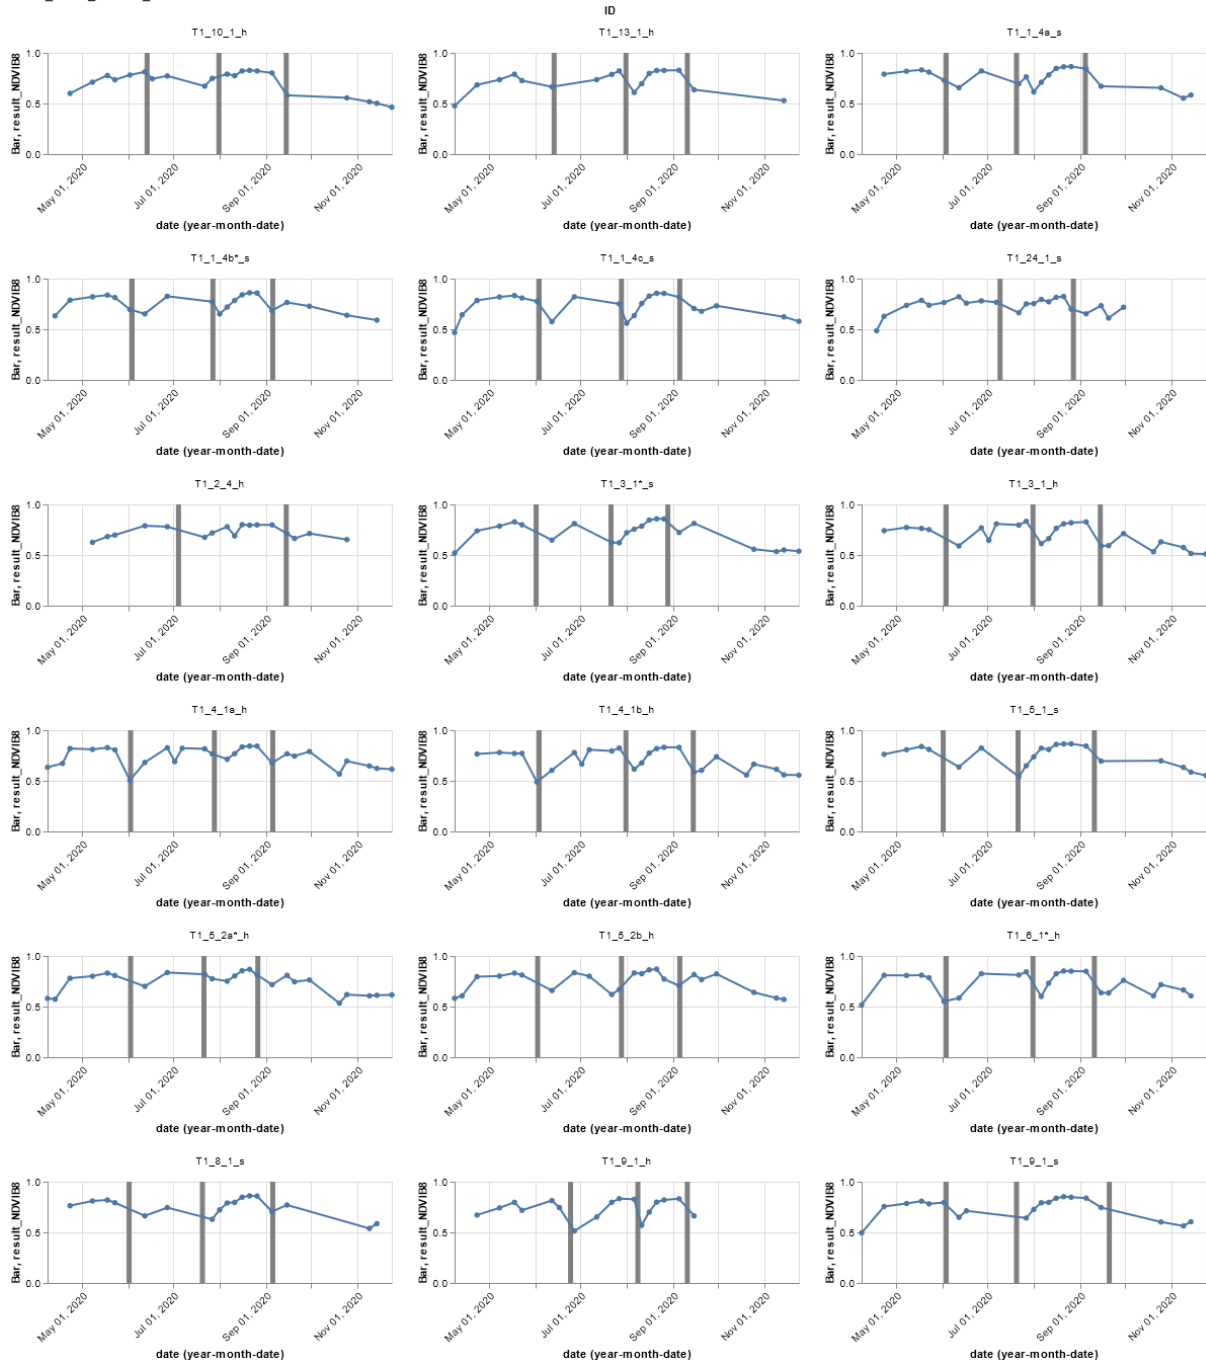









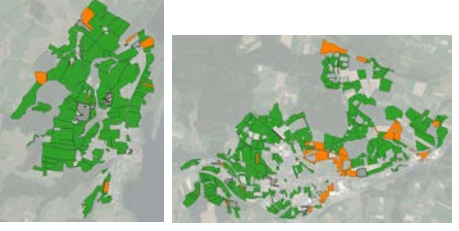






Abbildung 48: NDVI (Linie) und Erntetermine (Balken) während der Vegetationsperiode 2020; blaue Punkte = wolkenfreie Satellitenaufnahmetermine; Untersuchungsflächen des Betriebspaars T1

Datum	Heumilchregion Seeham (links) Nicht-Heumilchregion Frankenmarkt (rechts)		Heumilchregion Seeham / Nicht- Nicht-Heumilchregion Frankenmarkt (rechts)
28.04.		08.05.	
18.05.		02.06.	
12.06.		27.06.	
07.07.		17/14.07.	
27.07.		01.08.	
06.08.		11.08.	
16.08.		21.08.	

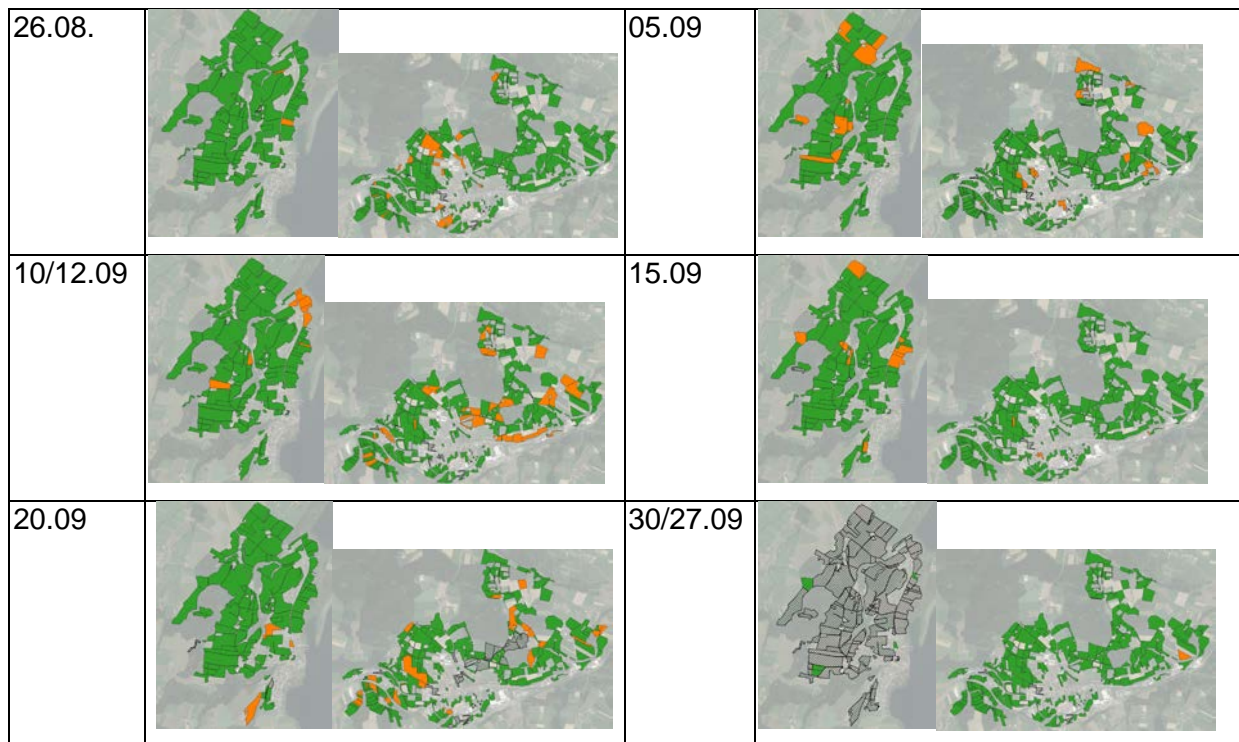




Abbildung 49: Räumliche und zeitliche Verteilung der Mähereignisse in zwei Beispielregionen im Jahr 2020; grün = keine Ernte zwischen Termin und vorangehendem Termin; orange = Ernte; gestreift = keine Daten; es wurden nur Termine dargestellt an denen für beide Regionen Daten vorliegen

Betriebspaar S1



Betriebspaar S2



Betriebspaar ST1






Abbildung 50: Standardabweichungen (blau) und Mittelwerte (grau) der Untersuchungsflächen für das Merkmal Greenness-Index; mittlere Standardabweichung über den gesamten Zeitraum (blau gestrichelt)

Betriebspaar T1



Betriebspaar T3



Betriebspaar T3




Abbildung 51: Standardabweichungen (blau) und Mittelwerte (grau) der Untersuchungsflächen für das Merkmal Greenness-Index; mittlere Standardabweichung über den gesamten Zeitraum (blau gestrichelt)

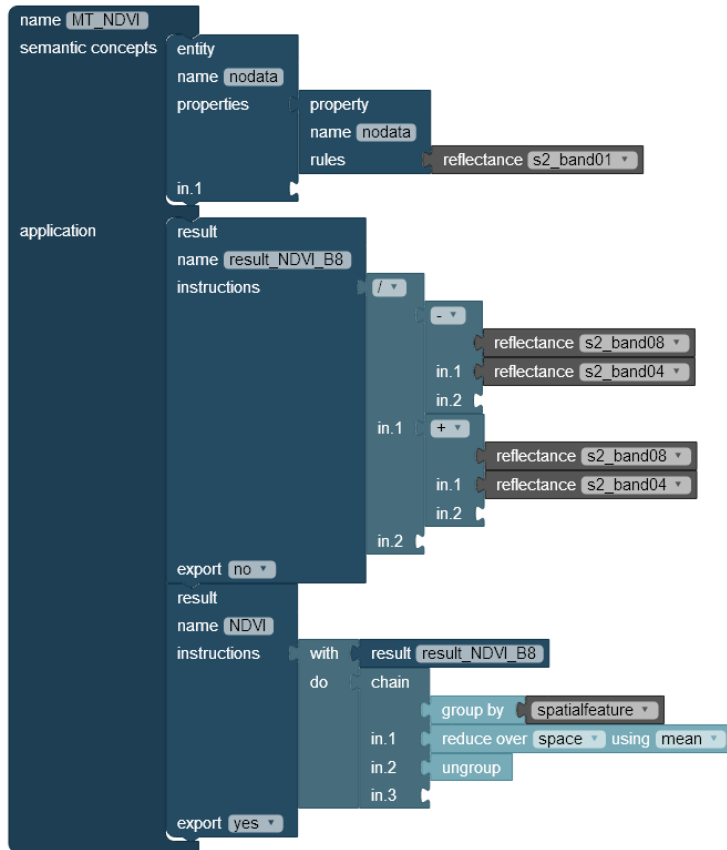


Abbildung 52: Sen2Cube Modell zur Abfrage des NDVI auf Basis von Sentinel-2 Daten

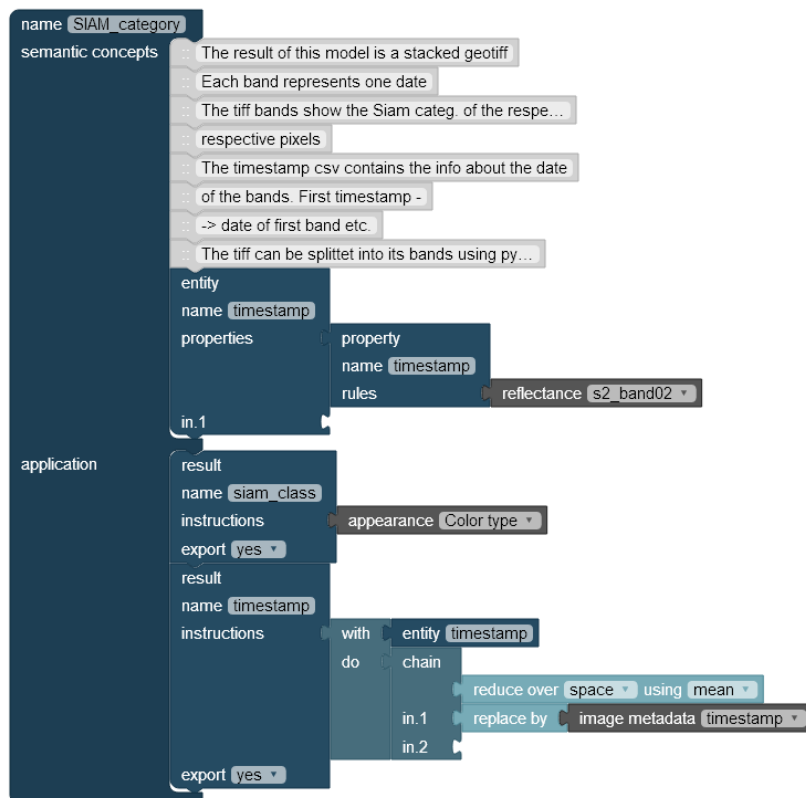


Abbildung 53: Sen2Cube Modell zur Abfrage der semantischen Information (SIAM-Vorklassifikation) auf Basis von Sentinel-2 Daten

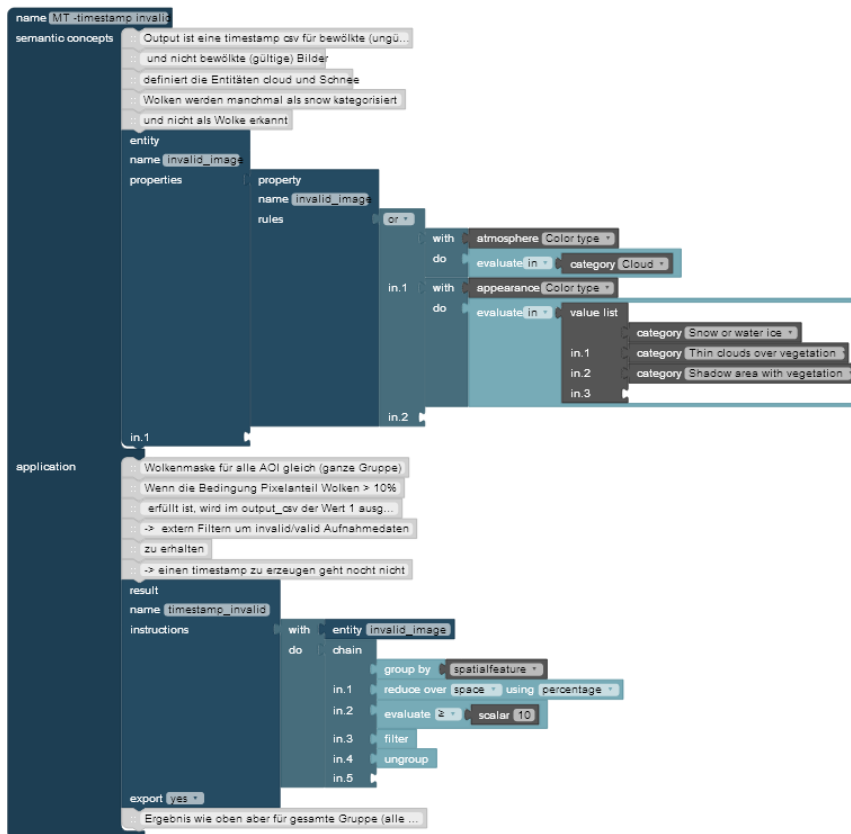


Abbildung 54: Sen2Cube Modell zur Abfrage des Wolkenfilters (SIAM- Vorklassifikation) auf Basis von Sentinel-2 Daten

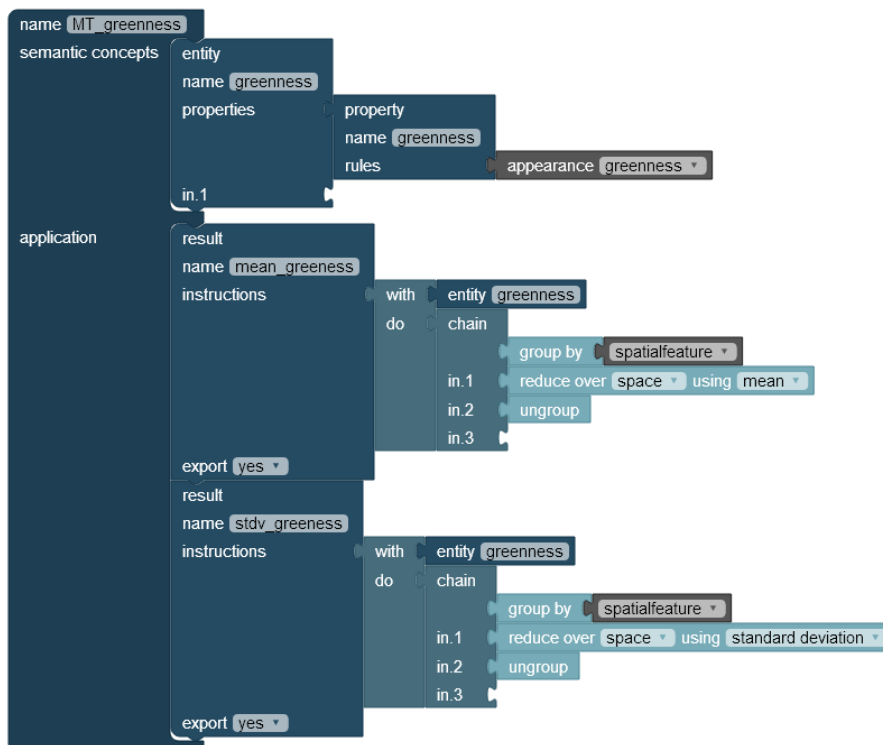


Abbildung 55: Sen2Cube Modell zur Abfrage des Greenness-Index (Mittelwert und Standardabweichung) auf Basis von Sentinel-2 Daten




Abbildung 56: Bewölkung in % der Gesamtfläche der untersuchten Gemeinden; blaue Punkte = Aufnahmedatum Sentinel-2; rote Linie = Grenzwert für „störungsfreies“ Bild

Tabelle 11: Untersuchungsflächen und Erntetermine im Jahr 2019 (HB = Heu mit Bodentrocknung, E = Eingrasen, HT = Heu mit Trocknungsanlage, HTa = Heu mit Aufbereiter und Trocknungsanlage, HBa= Heu Bodentrocknung mit Aufbereitung, SL = Silage; W=Weide); Daten: Suske et al. (2021)

NR	Fläche	Betriebsp.	Betriebstyp	1. Mahd	Art	2. Mahd	Art	3. Mahd	Art	4. Mahd	Art	5. Mahd	Art	Filter*
S1_1_1a*_s	6.58	S1	Nicht-Heu	2019_05_16	SL	2019_06_16	HB	2019_07_23	SL	2019_08_27	SL	2019_10_11	SL	x
S1_1_1b_s	0.19	S1	Nicht-Heu	2019_05_16	SL		W							
S1_11_1a*_s	2.64	S1	Nicht-Heu	2019_05_16	SL	2019_06_16	HB	2019_07_23	SL	2019_08_27	SL			x
S1_3_1b_s	5.28	S1	Nicht-Heu	2019_05_16	SL	2019_06_16	HB	2019_07_23	SL	2019_08_27	SL	2019_10_11	SL	x
S1_3_1c_s	0.37	S1	Nicht-Heu	2019_06_16	HB	2019_08_27	HB							x
S1_4_1a_s	8.37	S1	Nicht-Heu	2019_05_16	SL	2019_06_16	HB	2019_07_23	SL	2019_08_27	SL	2019_10_11	SL	x
S1_4_1b_s	0.07	S1	Nicht-Heu	2019_08_27	HB									
S1_4_1c_s	0.04	S1	Nicht-Heu	2019_06_16	HB	2019_08_27	HB							x
S1_4_1d_s	0.1	S1	Nicht-Heu	2019_06_16	HB	2019_08_27	HB							x
S1_5_1_s	0.08	S1	Nicht-Heu	2019_05_16	SL	2019_06_16	HB	2019_07_23	SL	2019_08_27	SL	2019_10_11	SL	x
S1_6_1a_s	4.45	S1	Nicht-Heu	2019_05_16	SL	2019_06_16	HB	2019_07_23	SL	2019_08_27	SL	2019_10_11	SL	x
S1_6_1b_s	0.67	S1	Nicht-Heu	2019_05_16	SL			2019_07_23	HB	2019_08_27	SL	2019_10_11	SL	
S2_11_2_h	1.59	S2	Heu	2019_06_01	HB	2019_07_22	HB	2019_09_13	HB					x
S2_12_3_h	0.55	S2	Heu	2019_06_13	HT	2019_07_24	HT	2019_09_19	HT					x
S2_13_14_h	2.59	S2	Heu	2019_06_13	HB	2019_08_27	HB							x
S2_13_15_h	0.75	S2	Heu	2019_06_26	HB									
S2_13_16_h	0.02	S2	Heu	2019_06_13	HB	2019_08_27	HB							x
S2_14_2_h	1.32	S2	Heu	2019_06_13	HB	2019_08_27	HB							x
S2_15_12_h	1.98	S2	Heu	2019_06_13	HB	2019_08_27	HB							x
S2_15_13_h	0.2	S2	Heu	2019_06_13	HB									
S2_16_2_h	3.37	S2	Heu	2019_06_03	HB	2019_07_23	HB	2019_09_19	HB					x
S2_2_1_h	0.32	S2	Heu	2019_06_01	HB	2019_07_22	HB	2019_09_13	HB					x
S2_20_6_h	1.73	S2	Heu	2019_06_01	HB	2019_07_22	HB	2019_09_13	HB					x
S2_24_12_h	0.23	S2	Heu	2019_06_26	HB									
S2_27_1_h	3.4	S2	Heu	2019_06_01	HB	2019_07_22	HB	2019_09_13	HB					x
S2_28_1*_h	1.81	S2	Heu	2019_06_01	HB	2019_07_22	HB	2019_09_13	HB					x
S2_29_1_h	1.75	S2	Heu	2019_06_01	HB	2019_07_22	HB	2019_09_13	HB					x
S2_3_40_h	0.18	S2	Heu	2019_06_02	HT	2019_07_20	HT							x
S2_3_41a_h	5.73	S2	Heu	2019_06_02	HT	2019_07_20	HT	2019_09_10	HT					x
S2_3_41b_h	0.95	S2	Heu	2019_06_13	HT	2019_07_24	HT	2019_09_19	HT					x
S2_3_42_h	1.53	S2	Heu	2019_06_13	HT	2019_07_24	HT	2019_09_19	HT					x

Anhang

NR	Fläche	Betriebsp.	Betriebstyp	1. Mahd	Art	2. Mahd	Art	3. Mahd	Art	4. Mahd	Art	5. Mahd	Art	Filter*
S2_3_43_h	1.02	S2	Heu	2019_06_13	HT	2019_07_24	HT	2019_09_19	HT					x
S2_4_2_h	0.09	S2	Heu	2019_06_02	HT	2019_07_20	HT	2019_09_10	HT					x
S2_5_4_h	1.31	S2	Heu	2019_06_02	HT	2019_07_20	HT	2019_09_10	HT					x
S2_8_2_h	1.43	S2	Heu	2019_06_03	HB	2019_07_23	HB	2019_09_19	HB					x
S2_9_2*_h	2.94	S2	Heu	2019_06_03	HB	2019_07_23	HB	2019_09_19	HB					x
S2_1_2a_s	9.7	S2	Nicht-Heu	2019_05_24	SL	2019_07_10	SL	2019_08_24	SL	2019_10_12	SL			x
S2_1_2b_s	3.67	S2	Nicht-Heu	2019_05_25	SL	2019_07_10	HB	2019_08_25	SL	2019_10_13	SL			x
S2_15_1_s	0.06	S2	Nicht-Heu	2019_05_24	SL	2019_07_10	SL	2019_08_24	SL	2019_10_12	SL			x
S2_17_1a_s	5.3	S2	Nicht-Heu	2019_06_02	SL	2019_07_17	SL	2019_08_29	SL					x
S2_17_1b_s	0.77	S2	Nicht-Heu		W	2019_07_17	SL	2019_08_29	SL					
S2_18_1_s	1.54	S2	Nicht-Heu	2019_06_02	SL	2019_07_17	SL	2019_08_29	SL					x
S2_3_2*_s	0.84	S2	Nicht-Heu	2019_05_17	SL	2019_06_27	SL	2019_08_24	SL			W		
S2_4_1_s	1.47	S2	Nicht-Heu	2019_05_17	SL	2019_06_27	SL	2019_08_24	SL	2019_10_12	SL			x
S2_5_10_s	0.75	S2	Nicht-Heu	2019_05_07	SL	2019_06_27	SL		W					
S2_6_1*_s	0.52	S2	Nicht-Heu	2019_05_25	SL	2019_07_10	HB	2019_08_25	SL					x
S2_7_17_s	2.81	S2	Nicht-Heu	2019_06_24	HB	2019_08_18	HB							x
S2_7_2_s	3.73	S2	Nicht-Heu	2019_06_20	HB	2019_08_15	HB							x
S2_9_1_s	0.04	S2	Nicht-Heu	2019_06_20	HB	2019_08_15	HB							x
ST1_1_36a_h	1.02	ST1	Heu	2019_05_21	HTa	2019_06_24	HTa	2019_08_09	HTa	2019_09_19	HTa			x
ST1_11_2_h	0.19	ST1	Heu	2019_06_07	HTa	2019_07_14	HTa	2019_09_03	HTa					x
ST1_13_14_h	2.53	ST1	Heu	2019_05_31	EG	2019_06_24	HTa	2019_08_09	HTa	2019_09_20	HTa			
ST1_18_7_h	4.73	ST1	Heu	2019_05_21	HTa	2019_06_24	HTa	2019_08_14	HTa					x
ST1_22_7_h	1.47	ST1	Heu	2019_05_21	HTa	2019_06_24	HTa	2019_08_09	HTa	2019_09_19	HTa			x
ST1_23_1_h	1.01	ST1	Heu	2019_05_21	HTa	2019_06_24	HTa	2019_08_09	HTa	2019_09_19	HTa			x
ST1_3_4*_h	4.58	ST1	Heu	2019_05_21	HTa	2019_06_24	HTa	2019_08_09	HTa	2019_09_19	HTa			x
ST1_4_2_h	1.44	ST1	Heu	2019_05_31	HTa	2019_07_04	HTa	2019_08_27	HTa	2019_10_12	HTa			x
ST1_5_15*_h	1.88	ST1	Heu	2019_05_31	HTa	2019_07_04	HTa	2019_08_27	HTa	2019_10_12	HTa			x
ST1_5_16_h	0.59	ST1	Heu	2019_06_13	HTa	2019_08_27	HTa	2019_10_12	HTa					x
ST1_7_10_h	1.96	ST1	Heu	2019_06_13	HTa	2019_07_14	HTa							x
ST1_7_9_h	6.85	ST1	Heu	2019_06_07	HTa	2019_07_14	HTa	2019_09_03	HTa					x
ST1_9_2_h	2.12	ST1	Heu	2019_05_21	HTa	2019_06_24	HTa	2019_08_14	HTa					x
ST1_1_1*_s	12.62	ST1	Nicht-Heu	2019_05_07	SL	2019_06_15	SL	2019_07_10	SL	2019_08_20	SL	2019_10_05	SL	x
ST1_10_1_s	1.2	ST1	Nicht-Heu	2019_05_07	SL	2019_06_15	SL	2019_07_10	SL	2019_08_20	SL	2019_10_05	SL	x
ST1_11_1_s	2.82	ST1	Nicht-Heu	2019_07_03	HB	2019_09_20	HB							x

Anhang

NR	Fläche	Betriebsp.	Betriebstyp	1. Mahd	Art	2. Mahd	Art	3. Mahd	Art	4. Mahd	Art	5. Mahd	Art	Filter*
ST1_12_20_s	3.75	ST1	Nicht-Heu	2019_05_07	SL	2019_06_15	SL	2019_07_10	SL	2019_08_20	SL	2019_10_05	SL	x
ST1_13_1_s	0.04	ST1	Nicht-Heu	2019_07_03	HB	2019_09_20	HB							x
ST1_15_1_s	0.36	ST1	Nicht-Heu	2019_07_03	HB	2019_09_20	HB							x
ST1_2_2_s	0.7	ST1	Nicht-Heu	2019_05_07	SL	2019_06_15	SL	2019_07_10	SL	2019_08_20	SL	2019_10_05	SL	x
ST1_4_1_s	1.24	ST1	Nicht-Heu	2019_05_07	SL	2019_06_15	SL	2019_07_10	SL	2019_08_20	SL	2019_10_05	SL	x
ST1_5_23*_s	3.13	ST1	Nicht-Heu	2019_05_07	SL	2019_06_15	SL	2019_07_10	SL	2019_08_20	SL	2019_10_05	SL	x
ST1_9_1_s	2.58	ST1	Nicht-Heu	2019_05_07	SL	2019_06_15	SL	2019_07_10	SL	2019_08_20	SL	2019_10_05	SL	x
T1_1_1_h	0.08	T1	Heu	2019_05_02	EG	2019_06_24	HB							
T1_10_1_h	1.62	T1	Heu	2019_06_14	HB	2019_07_24	HB	2019_09_22	HB					x
T1_12_1_h	1.14	T1	Heu	2019_06_18	HB	2019_08_18	HB							x
T1_13_1_h	0.92	T1	Heu	2019_06_14	HB	2019_07_25	HB	2019_09_16	HB					x
T1_15_1a_h	0.58	T1	Heu	2019_06_14	HB	2019_07_24	HB	2019_09_22	HB					x
T1_2_1_h	1.1	T1	Heu	2019_05_01	W	2019_06_26	HB	2019_09_01	HB					
T1_2_4_h	0.3	T1	Heu	2019_06_25	HB	2019_09_10	HB							x
T1_3_1_h	0.74	T1	Heu	2019_06_14	HB	2019_09_14	HB							x
T1_4_1a_h	0.31	T1	Heu	2019_06_14	HB	2019_09_14	HB							x
T1_4_1b_h	0.47	T1	Heu	2019_06_14	HB	2019_07_25	HB	2019_09_14	HB					x
T1_5_2a*_h	2.49	T1	Heu	2019_06_10	HB	2019_07_23	HB	2019_09_14	HB					x
T1_5_2b_h	2.44	T1	Heu	2019_06_10	HB	2019_07_23	HB	2019_09_04	HB					x
T1_6_1*_h	0.43	T1	Heu	2019_06_14	HB	2019_07_25	HB	2019_09_15	HB					x
T1_7_1_h	0.02	T1	Heu	2019_06_10	HB	2019_07_23	HB	2019_09_14	HB					x
T1_9_1_h	2.63	T1	Heu	2019_06_18	HB	2019_08_18	HB	2019_09_10	HB					x
T1_1_1_s	0.46	T1	Nicht-Heu	2019_06_10	SL		W							
T1_1_4a_s	1.37	T1	Nicht-Heu	2019_06_13	SL	2019_08_05	SL	2019_09_13	SL					x
T1_1_4b*_s	1.53	T1	Nicht-Heu	2019_06_14	SL	2019_08_09	SL	2019_09_14	SL					x
T1_1_4c_s	1.44	T1	Nicht-Heu	2019_06_14	HB	2019_08_09	SL	2019_09_13	SL					x
T1_24_1_s	2.44	T1	Nicht-Heu	2019_06_20	SL	2019_08_14	HB							x
T1_3_1*_s	1.57	T1	Nicht-Heu	2019_06_11	SL	2019_07_25	SL	2019_09_04	SL					x
T1_5_1_s	1.13	T1	Nicht-Heu	2019_06_11	SL	2019_07_25	SL	2019_09_04	SL					x
T1_7_1_s	0.11	T1	Nicht-Heu	2019_06_26	HB	2019_09_15	EG							
T1_8_1_s	0.85	T1	Nicht-Heu	2019_06_12	EG	2019_08_05	SL	2019_09_04	SL					
T1_9_1_s	0.58	T1	Nicht-Heu	2019_06_12	HB	2019_08_05	SL	2019_09_04	SL					x
T3_1_1a_h	1.67	T3	Heu	2019_06_13	HBa		W							
T3_10_1_h	0.88	T3	Heu	2019_06_26	HBa	2019_08_28	HBa							x

Anhang

NR	Fläche	Betriebsp.	Betriebstyp	1. Mahd	Art	2. Mahd	Art	3. Mahd	Art	4. Mahd	Art	5. Mahd	Art	Filter*
T3_11_1_h	0.27	T3	Heu	2019_06_26	HBa	2019_08_28	HBa							x
T3_2_1a_h	3.5	T3	Heu	2019_06_14	HBa		W							
T3_2_1b_h	1.86	T3	Heu	2019_06_14	HBa		W							
T3_27_2_h	0.62	T3	Heu	2019_06_26	HBa	2019_08_18	HBa	2019_10_14	HBa					x
T3_30_1_h	0.25	T3	Heu	2019_06_30	HBa	2019_08_28	HBa							x
T3_33_1_h	0.55	T3	Heu	2019_06_26	HBa	2019_08_18	HBa	2019_10_14	HBa					x
T3_35_1_h	2.69	T3	Heu	2019_06_26	HBa	2019_08_18	HBa	2019_10_14	HBa					x
T3_4_1*_h	2.09	T3	Heu	2019_06_26	HBa	2019_08_18	HBa	2019_10_14	HBa					x
T3_5_1_h	1.68	T3	Heu	2019_06_30	HBa	2019_08_28	HBa							x
T3_6_1*_h	3.94	T3	Heu	2019_06_13	HBa	2019_07_24	HBa	2019_09_04	HBa					x
T3_7_1_h	0.03	T3	Heu	2019_06_26	HBa	2019_08_18	HBa	2019_10_14	HBa					x
T3_8_1_h	3.31	T3	Heu	2019_06_26	HBa	2019_08_28	HBa							x
T3_9_1_h	2.64	T3	Heu	2019_06_26	HBa	2019_08_28	HBa							x
T3_10_2_s	0.28	T3	Nicht-Heu	2019_06_02	SL	2019_07_20	SL	2019_08_26	SL	2019_10_01	SL			x
T3_10_3_s	0.11	T3	Nicht-Heu	2019_06_11	HB	2019_08_01	HB							x
T3_13_1_s	1.39	T3	Nicht-Heu	2019_06_02	SL	2019_07_20	SL	2019_08_26	SL	2019_10_01	SL			x
T3_14_1_s	1.26	T3	Nicht-Heu	2019_07_01	HB	2019_08_01	HB							x
T3_14_3_s	1.08	T3	Nicht-Heu	2019_06_14	HB	2019_08_01	HB	2019_09_30	SL					x
T3_15_1_s	3.52	T3	Nicht-Heu	2019_06_02	SL	2019_07_20	SL	2019_08_26	SL	2019_10_01	SL			x
T3_2_1*_s	3.17	T3	Nicht-Heu	2019_06_02	SL	2019_07_20	SL	2019_08_26	SL	2019_10_01	SL			x
T3_3_1_s	1.74	T3	Nicht-Heu	2019_06_02	SL	2019_07_20	SL	2019_08_26	SL	2019_10_01	SL			x
T3_4_1_s	2.14	T3	Nicht-Heu	2019_06_02	SL	2019_07_20	SL	2019_08_26	SL	2019_10_01	SL			x
T3_5_1*_s	2.84	T3	Nicht-Heu	2019_06_02	SL	2019_07_20	SL	2019_08_26	SL	2019_10_01	SL			x

* = angewendeter Filter für Datenauswertung ab Kapitel 3.1.3; es wurden nur Flächen miteinbezogen, auf denen weder Beweidung noch Eingrasen stattfand

Anhang

Tabelle 12: Untersuchungsflächen und Erntetermine im Jahr 2020 (HB = Heu mit Bodentrocknung, E = Eingrasen, HT = Heu mit Trocknungsanlage, HTa = Heu mit Aufbereiter und Trocknungsanlage, HBa= Heu Bodentrocknung mit Aufbereitung, SL = Silage, W=Weide); Daten: Suske et al. (2021)

NR	Fläche	Betriebsp.	Betriebstyp	1. Mahd	Art	2. Mahd	Art	3. Mahd	Art	4. Mahd	Art	5. Mahd	Art	Filter*
S1_13_1_h	5.26	S1	Heu	2020_05_30	HB	2020_07_05	HB	2020_08_25	HB					x
S1_14_1_h	0.34	S1	Heu	2020_06_15	HB	2020_08_02	HB							x
S1_15_1_h	0.64	S1	Heu	2020_08_17	HB									x
S1_16_1_h	0.44	S1	Heu	2020_08_17	HB									x
S1_17_1_h	2.27	S1	Heu	2020_05_20	HB	2020_07_01	HB	2020_08_20	HB	2020_10_03	HB			x
S1_18_1a_h	0.77	S1	Heu	2020_05_20	HB	2020_07_01	HB	2020_08_20	HB	2020_10_03	HB			x
S1_18_1b_h	0.71	S1	Heu	2020_05_20	HB	2020_07_01	HB	2020_08_20	HB	2020_10_03	HB			x
S1_19_2_h	1.32	S1	Heu	2020_05_30	HB	2020_07_05	HB	2020_08_25	HB					x
S1_4_1d*_h	3.42	S1	Heu	2020_05_20	HB	2020_07_01	HB	2020_08_20	HB		E			
S1_5_1_h	1.61	S1	Heu	2020_05_30	HB	2020_07_05	HB	2020_08_25	HB					x
S1_5_2_h	0.33	S1	Heu	2020_08_16	HB									x
S1_6_1a*_h	3.16	S1	Heu	2020_05_09	HB	2020_06_24	HB	2020_08_04	HB	2020_09_25	HB			x
S1_6_1b_h	2.25	S1	Heu	2020_05_09	HB	2020_06_24	HB	2020_08_04	HB	2020_09_25	HB			x
S1_1_1a*_s	6.58	S1	Nicht-Heu	2020_05_06	SL	2020_06_12	HT	2020_07_20	SL	2020_08_25	SL	2020_10_02	SL	x
S1_11_1a*_s	2.64	S1	Nicht-Heu	2020_06_13	HB	2020_07_28	HB	2020_09_04	HB	2020_10_09	SL			x
S1_3_1b_s	5.28	S1	Nicht-Heu	2020_05_06	SL	2020_06_28	HB	2020_08_06	SL	2020_09_14	SL			x
S1_3_1c_s	0.37	S1	Nicht-Heu	2020_07_28	HT	2020_09_14	SL							x
S1_4_1a_s	8.37	S1	Nicht-Heu	2020_05_07	SL	2020_06_13	HB	2020_07_20	SL	2020_08_25	SL	2020_10_09	SL	x
S1_4_1c_s	0.04	S1	Nicht-Heu	2020_06_13	HB	2020_09_04	SL							x
S1_4_1d_s	0.1	S1	Nicht-Heu	2020_06_13	HB	2020_09_04	SL							x
S1_6_1a_s	4.45	S1	Nicht-Heu	2020_05_06	SL	2020_06_12	HB	2020_07_20	SL	2020_08_25	SL	2020_10_02	SL	x
S1_6_1b_s	0.67	S1	Nicht-Heu	2020_05_06	SL	2020_06_12	HB	2020_07_20	SL	2020_08_25	SL	2020_10_02	SL	x
S2_11_2_h	1.59	S2	Heu	2020_06_01	HB	2020_07_30	HB	2020_09_15	HB					x
S2_12_3_h	0.55	S2	Heu	2020_06_22	HT	2020_08_06	HT		W					
S2_13_14_h	2.59	S2	Heu	2020_07_07	HB	2020_08_20	HB							x
S2_13_15_h	0.75	S2	Heu	2020_07_09	HB									x

Anhang

NR	Fläche	Betriebsp.	Betriebstyp	1. Mahd	Art	2. Mahd	Art	3. Mahd	Art	4. Mahd	Art	5. Mahd	Art	Filter*
S2_13_16_h	0.02	S2	Heu	2020_07_07	HB	2020_08_20	HB							x
S2_14_2_h	1.32	S2	Heu	2020_07_07	HB	2020_08_20	HB							x
S2_15_12_h	1.98	S2	Heu	2020_07_07	HB	2020_08_20	HB							x
S2_15_13_h	0.2	S2	Heu	2020_07_07	HB	2020_08_20	HB							x
S2_16_2_h	3.37	S2	Heu	2020_06_11	HB	2020_07_30	HB	2020_09_13	HB					x
S2_2_1_h	0.32	S2	Heu	2020_06_01	HB	2020_07_30	HB	2020_09_15	HB					x
S2_20_6_h	1.73	S2	Heu	2020_06_01	HB	2020_07_20	HB	2020_09_13	HT					x
S2_24_12_h	0.23	S2	Heu	2020_07_09	HB									x
S2_27_1_h	3.4	S2	Heu	2020_06_01	HB	2020_07_20	HB	2020_09_08	HB					x
S2_28_1*_h	1.81	S2	Heu	2020_06_01	HB	2020_07_20	HB	2020_09_08	HB					x
S2_29_1_h	1.75	S2	Heu	2020_06_01	HB	2020_07_20	HB	2020_09_08	HB					x
S2_3_40_h	0.18	S2	Heu	2020_06_01	HT	2020_07_30	HT	2020_09_08	HT					x
S2_3_41a_h	5.73	S2	Heu	2020_06_01	HT	2020_07_30	HT	2020_09_08	HT					x
S2_3_41b_h	0.95	S2	Heu	2020_07_04	HB	2020_08_15	W							
S2_3_42_h	1.53	S2	Heu	2020_06_01	HT	2020_07_20	HT	2020_09_03	HT					x
S2_3_43_h	1.02	S2	Heu	2020_06_03	HT	2020_07_30	HT	2020_09_03	HT					x
S2_4_2_h	0.09	S2	Heu	2020_06_01	HT	2020_07_20	HT	2020_09_03	HT					x
S2_5_4_h	1.31	S2	Heu	2020_06_01	HT	2020_07_20	HT	2020_09_03	HT					x
S2_8_2_h	1.43	S2	Heu	2020_06_11	HB	2020_07_27	HB	2020_09_13	HT					x
S2_9_2*_h	2.94	S2	Heu	2020_06_11	HB	2020_07_27	HB	2020_09_13	HB					x
S2_1_2a_s	9.7	S2	Nicht-Heu	2020_05_22	SL	2020_07_05	SL	2020_08_17	SL	2020_10_09	SL			x
S2_1_2b_s	3.67	S2	Nicht-Heu	2020_05_22	SL	2020_07_04	SL	2020_08_21	HB	2020_10_09	SL			x
S2_15_1_s	0.06	S2	Nicht-Heu	2020_05_22	SL	2020_07_05	SL	2020_08_16	SL			W		
S2_17_1a_s	5.3	S2	Nicht-Heu	2020_05_27	SL	2020_07_07	SL	2020_08_20	SL			W		
S2_17_1b_s	0.77	S2	Nicht-Heu	2020_05_27	SL	2020_07_07	SL	2020_08_20	SL			W		
S2_18_1_s	1.54	S2	Nicht-Heu	2020_05_27	SL	2020_07_07	SL	2020_08_20	SL	2020_10_06	SL			x
S2_3_2*_s	0.84	S2	Nicht-Heu	2020_05_21	SL	2020_07_04	SL	2020_08_16	SL					x
S2_4_1_s	1.47	S2	Nicht-Heu	2020_05_21	SL	2020_07_04	SL	2020_08_17	SL	2020_10_09	SL			x
S2_5_1_s	0.67	S2	Nicht-Heu	2020_05_21	SL		W							

Anhang

NR	Fläche	Betriebsp.	Betriebstyp	1. Mahd	Art	2. Mahd	Art	3. Mahd	Art	4. Mahd	Art	5. Mahd	Art	Filter*
S2_5_10_s	0.75	S2	Nicht-Heu	2020_05_21	SL	2020_07_04	SL							x
S2_6_1*_s	0.52	S2	Nicht-Heu	2020_05_21	SL	2020_07_04	SL	2020_08_17	SL	2020_10_09	SL			x
S2_7_17_s	2.81	S2	Nicht-Heu	2020_06_13	HB	2020_08_10	HB		W					
S2_7_2_s	3.73	S2	Nicht-Heu	2020_06_24	HB	2020_08_10	HB		W					
S2_9_1_s	0.04	S2	Nicht-Heu	2020_06_13	HB	2020_08_10	HB		W					
ST1_1_36a_h	1.02	ST1	Heu	2020_05_20	HTa	2020_07_03	HTa	2020_08_06	HTa	2020_09_12	HTa			x
ST1_1_36b_h	0.26	ST1	Heu	2020_05_20	HTa	2020_07_03	HTa	2020_08_06	HTa	2020_09_12	HTa			x
ST1_10_1_h	0.65	ST1	Heu	2020_06_11	HTa	2020_07_26	HTa	2020_09_03	HTa					x
ST1_11_2_h	0.19	ST1	Heu	2020_06_11	HTa	2020_07_26	HTa	2020_09_03	HTa		EG			
ST1_13_14_h	2.53	ST1	Heu	2020_05_20	HTa	2020_07_03	HTa	2020_08_06	HTa	2020_09_12	HTa			x
ST1_18_7_h	4.73	ST1	Heu	2020_06_01	HTa	2020_07_07	HTa	2020_08_19	HTa					x
ST1_2_2_h	1.08	ST1	Heu	2020_05_20	HTa	2020_07_03	HTa	2020_08_06	HTa		EG			
ST1_22_7_h	1.47	ST1	Heu	2020_05_20	HTa	2020_07_03	HTa	2020_08_06	HTa	2020_09_12	HTa			x
ST1_23_1_h	1.01	ST1	Heu	2020_05_20	HTa	2020_07_03	HTa	2020_08_06	HTa	2020_09_12	HTa			x
ST1_3_4*_h	4.58	ST1	Heu	2020_05_20	HTa	2020_07_03	HTa	2020_08_06	HTa	2020_09_12	HTa			x
ST1_4_2_h	1.44	ST1	Heu	2020_05_20	HTa	2020_07_03	HTa	2020_08_06	HTa		EG			
ST1_5_15*_h	1.88	ST1	Heu	2020_05_20	HTa	2020_07_03	HTa	2020_08_06	HTa		EG			
ST1_5_16_h	0.59	ST1	Heu	2020_06_11	HTa	2020_07_26	HTa		EG					
ST1_7_10_h	1.96	ST1	Heu	2020_06_11	HTa	2020_07_26	HTa	2020_09_03	HTa					x
ST1_7_9_h	6.85	ST1	Heu	2020_06_11	HTa	2020_07_26	HTa	2020_09_03	HTa					x
ST1_8_3_h	1.07	ST1	Heu	2020_05_20	HTa	2020_07_03	HTa	2020_08_06	HTa		EG			
ST1_9_2_h	2.12	ST1	Heu	2020_06_01	HTa	2020_07_07	HTa	2020_08_19	HTa					x
ST1_1_1*_s	12.62	ST1	Nicht-Heu	2020_05_11	SL	2020_06_22	SL	2020_08_09	SL	2020_09_25	SL	2020_11_03	SL	x
ST1_10_1_s	1.2	ST1	Nicht-Heu	2020_05_11	SL	2020_06_22	SL	2020_08_09	SL	2020_09_25	SL	2020_11_03	SL	x
ST1_11_1_s	2.82	ST1	Nicht-Heu	2020_07_09	HB	2020_09_21	SL							x
ST1_12_20_s	3.75	ST1	Nicht-Heu	2020_05_11	SL	2020_06_22	SL	2020_08_09	SL	2020_09_25	SL	2020_11_03	SL	x
ST1_13_1_s	0.04	ST1	Nicht-Heu	2020_07_09	HB	2020_09_21	SL							
ST1_15_1_s	0.36	ST1	Nicht-Heu	2020_07_09	HB	2020_09_21	SL							x
ST1_2_2_s	0.7	ST1	Nicht-Heu	2020_05_11	SL	2020_06_22	SL	2020_08_09	SL	2020_09_25	SL	2020_11_03	SL	x

Anhang

NR	Fläche	Betriebsp.	Betriebstyp	1. Mahd	Art	2. Mahd	Art	3. Mahd	Art	4. Mahd	Art	5. Mahd	Art	Filter*
ST1_4_1_s	1.24	ST1	Nicht-Heu	2020_05_11	SL	2020_06_22	SL	2020_08_09	SL	2020_09_25	SL	2020_11_03	SL	x
ST1_5_23*_s	3.13	ST1	Nicht-Heu	2020_05_11	SL	2020_06_22	SL	2020_08_09	SL	2020_09_25	SL	2020_11_03	SL	x
ST1_8_2_s	2.92	ST1	Nicht-Heu	2020_05_11	SL	2020_06_22	SL	2020_08_09	SL	2020_09_25	SL	2020_11_03	SL	x
T1_1_1_h	0.08	T1	Heu	2020_06_02	HB	2020_08_21	HB	2020_10_12	EG					
T1_10_1_h	1.62	T1	Heu	2020_06_13	HB	2020_07_31	HB	2020_09_14	HB					x
T1_12_1_h	1.14	T1	Heu	2020_06_26	HB	2020_08_21	HB							
T1_13_1_h	0.92	T1	Heu	2020_06_13	HB	2020_07_31	HB	2020_09_10	HB					x
T1_2_1_h	1.1	T1	Heu		W	2020_07_05	HB	2020_08_21	HB					
T1_2_4_h	0.3	T1	Heu	2020_07_04	HB	2020_09_14	HB							x
T1_3_1_h	0.74	T1	Heu	2020_06_03	HB	2020_07_31	HB	2020_09_14	HB					x
T1_4_1a_h	0.31	T1	Heu	2020_06_02	HB	2020_07_28	HB	2020_09_05	HB					x
T1_4_1b_h	0.47	T1	Heu	2020_06_03	HB	2020_07_31	HB	2020_09_14	HB					x
T1_5_2a*_h	2.49	T1	Heu	2020_06_02	HB	2020_07_21	HB	2020_08_26	HB					x
T1_5_2b_h	2.44	T1	Heu	2020_06_02	HB	2020_07_28	HB	2020_09_05	HB					x
T1_6_1*_h	0.43	T1	Heu	2020_06_03	HB	2020_07_31	HB	2020_09_10	HB					x
T1_7_1_h	0.02	T1	Heu	2020_06_02	HB	2020_08_26	HB							
T1_9_1_h	2.63	T1	Heu	2020_06_24	HB	2020_08_08	HB	2020_09_10	HB					x
T1_1_1_s	0.46	T1	Nicht-Heu	2020_06_01	SL		W							
T1_1_4a_s	1.37	T1	Nicht-Heu	2020_06_03	SL	2020_07_20	SL	2020_09_04	SL					x
T1_1_4b*_s	1.53	T1	Nicht-Heu	2020_06_03	SL	2020_07_27	SL	2020_09_05	SL					x
T1_1_4c_s	1.44	T1	Nicht-Heu	2020_06_03	HB	2020_07_28	HB	2020_09_05	SL					x
T1_22_1_s	0.02	T1	Nicht-Heu	2020_09_20	HB									x
T1_24_1_s	2.44	T1	Nicht-Heu	2020_07_09	HB	2020_08_27	HB							x
T1_3_1*_s	1.57	T1	Nicht-Heu	2020_06_01	SL	2020_07_21	HB	2020_08_28	SL					x
T1_5_1_s	1.13	T1	Nicht-Heu	2020_06_01	SL	2020_07_21	HB	2020_09_10	SL					x
T1_8_1_s	0.85	T1	Nicht-Heu	2020_06_01	SL	2020_07_20	SL	2020_09_05	SL					x
T1_9_1_s	0.58	T1	Nicht-Heu	2020_06_03	SL	2020_07_20	SL	2020_09_20	SL					x
T3_10_1_h	0.88	T3	Heu	2020_06_25	HBa	2020_08_09	HBa							x
T3_11_1_h	0.27	T3	Heu	2020_06_25	HBa	2020_08_09	HBa							x

Anhang

NR	Fläche	Betriebsp.	Betriebstyp	1. Mahd	Art	2. Mahd	Art	3. Mahd	Art	4. Mahd	Art	5. Mahd	Art	Filter*
T3_2_1a_h	3.5	T3	Heu	2020_06_03	HBa	2020_07_01	W	2020_09_10	W					
T3_2_1b_h	1.86	T3	Heu	2020_06_03	HBa	2020_07_28	HBa	2020_09_10	HBa					x
T3_27_2_h	0.62	T3	Heu	2020_07_09	HBa	2020_09_10	HBa							x
T3_30_1_h	0.25	T3	Heu	2020_06_25	HBa	2020_08_09	HBa							x
T3_33_1_h	0.55	T3	Heu	2020_07_09	HBa	2020_09_10	HBa							x
T3_35_1_h	2.69	T3	Heu	2020_07_09	HBa	2020_09_10	HBa							x
T3_4_1*_h	2.09	T3	Heu	2020_07_09	HBa	2020_09_10	HBa							x
T3_6_1*_h	3.94	T3	Heu	2020_06_03	HBa	2020_07_28	HBa	2020_09_10	HBa					x
T3_7_1_h	0.03	T3	Heu	2020_07_09	HBa	2020_09_10	HBa							x
T3_8_1_h	3.31	T3	Heu	2020_06_25	HBa	2020_08_09	HBa							x
T3_9_1_h	2.64	T3	Heu	2020_06_25	HBa	2020_08_09	HBa							x
T3_9_2_h	0.02	T3	Heu	2020_06_25	HBa	2020_08_09	HBa							x
T3_10_1_s	6.99	T3	Nicht-Heu	2020_06_03	HB	2020_07_21	HB	2020_08_26	HB					x
T3_10_2_s	0.28	T3	Nicht-Heu	2020_06_03	HB	2020_07_21	HB	2020_08_26	HB					x
T3_10_3_s	0.11	T3	Nicht-Heu	2020_05_05	W	2020_07_08	HB	2020_08_26	HB					
T3_12_2_s	0.96	T3	Nicht-Heu		W	2020_07_08	HB	2020_08_26	HB					
T3_13_1_s	1.39	T3	Nicht-Heu	2020_05_27	SL	2020_07_08	SL	2020_08_16	SL	2020_10_02	SL			x
T3_14_1_s	1.26	T3	Nicht-Heu	2020_06_28	SL	2020_08_10	HB	2020_10_09	SL					x
T3_14_3_s	1.08	T3	Nicht-Heu	2020_06_12	SL	2020_08_10	HB	2020_10_09	SL					x
T3_15_1_s	3.52	T3	Nicht-Heu	2020_05_27	SL	2020_07_08	SL	2020_08_16	SL	2020_10_02	SL			x
T3_2_1*_s	3.17	T3	Nicht-Heu	2020_05_27	SL	2020_07_08	SL	2020_08_16	SL	2020_10_02	SL			x
T3_3_1_s	1.74	T3	Nicht-Heu	2020_05_27	SL	2020_07_08	HB	2020_08_16	SL	2020_10_02	SL			x
T3_4_1_s	2.14	T3	Nicht-Heu	2020_05_27	SL	2020_07_08	SL	2020_08_16	SL	2020_10_02	SL			x
T3_5_1*_s	2.84	T3	Nicht-Heu	2020_05_27	SL	2020_07_08	SL	2020_08_16	SL	2020_10_02	SL			x

* = angewendeter Filter für Datenauswertung ab Kapitel 3.1.3; es wurden nur Flächen miteinbezogen, auf denen weder Beweidung noch Eingrasen stattfand