



Hochschule Neubrandenburg  
University of Applied Sciences

Fachbereich Agrarwirtschaft und Lebensmittelwissenschaften  
Studiengang Agrarwirtschaft M.Sc.

Professor Dr. Eike Stefan Dobers

Professorin Dr. Becke Strehlow

## Masterthesis

Parametrisierung des Transferable Belief Models zur  
teilautomatisierten Zonierung von Grünland zum Zwecke  
der Ansprache von Standorten mit verschiedener  
Biomasseleistung auf einem Praxisbetrieb in der Prignitz

urn:nbn:de:gbv:519-thesis2023-0240-2

Vorgelegt von:

Linda Lechner

Neubrandenburg im Mai 2023

*“Vienna waits for you“  
- Billy Joel, 1977*

## Inhaltsverzeichnis

Inhaltsverzeichnis .....	III
Abbildungsverzeichnis .....	V
Tabellenverzeichnis .....	IX
Verzeichnis der Abkürzungen .....	X
Abstract .....	XII
1 Einleitung und Problemstellung .....	1
2 Das <i>Transferable Belief Model (TBM)</i> .....	3
2.1 Begrifflicher Rahmen .....	6
2.2 <i>Dempster's rule of combination</i> .....	8
2.3 Annahmen des Modells und deren Interpretation .....	10
3 Material und Methoden .....	13
3.1 Überblick über das Projektgebiet .....	13
3.2 Auswahl der Datenquellen .....	16
3.2.1 Bodenschätzung .....	17
3.2.2 Sentinel-2 Satellitenbilder .....	18
3.2.3 Topografischer Feuchteindex (TWI) .....	28
3.3 Interpretation der Datenquellen .....	28
3.3.1 Beschreibung der Validierungsmethode .....	29
3.3.2 Interpretation der Bodenschätzung .....	31
3.3.3 Interpretation von Satellitenbilddaten .....	34
3.3.4 Interpretation des TWI .....	35
3.4 Umgang mit Unsicherheiten der Geodatenquellen .....	38
3.4.1 Unsicherheiten an kategorialen Grenzen .....	40
3.4.2 Verlässlichkeit der Datenquellen .....	42
3.5 Datenverarbeitungsprozess .....	46
4 Ergebnisse .....	53
4.1 Vergleich der Variantensets mit der Validierungsdatenquelle .....	53
4.2 Darstellung und Vergleich der Konfliktwerte .....	56

---

4.3	Gegenüberstellung ausgewählter Ergebniskarten .....	59
5	Diskussion .....	64
5.1	Eignung des Transferable Belief Models zur Unterstützung einer teilautomatisierten Zonierung von Arealen unterschiedlichen Biomassewachstums im Grünland ..	65
5.2	Erarbeitung eines regional gültigen Prozessschemas.....	68
5.3	Relevanz der Konfliktwerte .....	71
6	Fazit und Ausblick .....	74
7	Literaturverzeichnis .....	77
A	Anhang.....	A-1
	Eidesstattliche Erklärung .....	A-16

## Abbildungsverzeichnis

Abbildung 1: Schematischer Ablauf der Geodatenfusion mit dem TBM. Eigene Darstellung 2023.....	5
Abbildung 2: Beispielhafte Datenquelle 1 (links) auf Rasterebene mit Interpretationstabelle (rechts oben) und zugeordneten Hypothesensets mit reliability. Eigene Darstellung 2023.....	7
Abbildung 3: Beispielhafte Datenquelle 2 (links) auf Rasterebene mit Interpretationstabelle (rechts oben) und zugeordneten Hypothesensets mit reliability. Eigene Darstellung 2023.....	8
Abbildung 4: Bodenarten auf der Fläche „Kombinat“ Quelle: LBG, 2022, Google Satellite, 2023. ....	14
Abbildung 5: Beobachtungspunkte der Flächenbegehung am 21.03.2023, Hintergrundbild: Google Satellite 2023. ....	15
Abbildung 6: Lage der Hypothesen-Punkte der NDVI-Analyse. Satellitenbild der Sentinel-2 Mission (18.06.2021), Quelle: ESA (2023). ....	21
Abbildung 7: Verlauf der NDVI-Werte nach Wüchsigkeits-Gruppen im Jahr 2021. Eigene Darstellung 2023.....	22
Abbildung 8: Darstellung der Wüchsigkeits-Gruppen an markanten Terminen (inklusive signifikanter Trennung der Gruppen) des Jahres 2021. Eigene Darstellung 2023.....	23
Abbildung 9: Verlauf der NDVI-Werte nach Wüchsigkeits-Gruppen im Jahr 2022. Eigene Darstellung 2023.....	23
Abbildung 10: Darstellung der Wüchsigkeits-Gruppen an markanten Terminen des Jahres 2022(inklusive signifikanter Trennung der Gruppen). Eigene Darstellung 2023.....	24
Abbildung 11: 14-tägige Wetteraufzeichnung des Jahres 2021, Standort Pritzwalk (Wetterdaten der betriebseigenen Wetterstation, PBK, 2023). ....	25
Abbildung 12: 14-tägige Wetteraufzeichnung des Jahres 2022, Standort Pritzwalk (Wetterdaten der betriebseigenen Wetterstation, PBK, 2023). ....	25
Abbildung 13: Darstellung des Topografische Feuchteindex der auf der Fläche Kombinat. Quelle: LGB 2023.....	28
Abbildung 14: True Color Image der Validierungsdatenquelle (31.07.2018). Quelle: Sentinel-2 Satellitenbild. EO-Browser 2023.....	29
Abbildung 15: Flächenhafte Übereinstimmung der Einteilungsmethoden der Bodenschätzung mit dem Validierungsdatensatz. Eigene Darstellung 2023.....	33

---

Abbildung 16: Flächenhafte Übereinstimmung der Einteilungsmethoden verschiedener Satellitenbild-Termine des Jahres 2022 mit dem Validierungsdatensatz. Eigene Darstellung 2023. ....	35
Abbildung 17: Flächenhafte Übereinstimmung der Einteilungsmethoden des TWI mit dem Validierungsdatensatz. Eigene Darstellung 2023. ....	36
Abbildung 18: links: Polygon einer Fläche mit Orthophoto im Hintergrund, Quelle: © GeoBasis-DE/LGB, dl-de/by-2-0, aufgerufen am 15.01.2023, rechts: Polygon derselben Fläche unterlegt mit der digitalen Version des Schmettauschen Kartenwerks aus den Jahren 1767-1787, Quelle: © Staatsbibliothek zu Berlin – Preußischer Kulturbesitz, dl-de/by-2-0, aufgerufen am 15.01.2023 .....	39
Abbildung 19: Darstellung der Zugehörigkeitsgrade zu Klassen nach der fuzzy logic. Lineare membership function. Eigene Darstellung 2023.....	40
Abbildung 20: Modellierung von Übergangsbereichen um ein geschlossenes Polygon. Quelle: Joos, 2001. ....	41
Abbildung 21: Zugehörigkeitsgrade zu Klassen bei direkt angrenzenden Objekten nach der fuzzy logic. Lineare membership function. Eigene Darstellung 2023. ...	41
Abbildung 22: Zugehörigkeitsgrade zu Klassen bei direkt angrenzenden Objekten nach der fuzzy logic. Normalisierte Werte einer linearen membership function. Eigene Darstellung 2023. ....	42
Abbildung 23: Hypothesen {s} und {g} aus zwei unterschiedlichen Datenquellen, die an n=25 Pixeln unterschiedliche reliabiliys aufweisen. Eigene Darstellung 2023.....	43
Abbildung 24: Fusionsergebnisse aus den in Abbildung 23 dargestellten n=25 Hypothesen-Kombinationen mit dem TBM. Links: Ergebnisse der Glaubensebene, rechts: Ergebnisse der pignistischen Ebene. Eigene Darstellung 2023. ....	44
Abbildung 25: Flächenhafte Übereinstimmung der unterschiedlichen Datenquellen mit dem Validierungsdatensatz. Eigene Darstellung 2023. ....	46
Abbildung 26: Legende der Ergebniskarte mit integrierten Konfliktwerten. Eigene Darstellung 2023. ....	52
Abbildung 27: Flächenhafte Übereinstimmung der TBM-basierten Datenfusion mit dem Validierungsdatensatz im Variantenset 1. Eigene Darstellung 2023. ....	53

Abbildung 28: Einfluss des Jahres, der Wahlmethode für Satellitenbilder sowie der Integration von Bodenzahlen der Bodenschätzung auf die flächenhafte Übereinstimmung der TBM-basierten Datenfusion mit dem Validierungsdatensatz hinsichtlich Biomassewachstum. Faktoren des Variantensets 1, Eigene Darstellung 2023 .....	54
Abbildung 29: Flächenhafte Übereinstimmung der TBM-basierten Datenfusion mit dem Validierungsdatensatz im Variantenset 2. Eigene Darstellung 2023.....	55
Abbildung 30: Einfluss des TWI auf die Übereinstimmung der TBM-basierten Datenfusion mit dem Validierungsdatensatz für das Variantenset 2. Links: n=12 ohne Variante TWI+BS, rechts n=15 mit der Variante TWI+BS. Eigene Darstellung 2023.....	55
Abbildung 31: Mittlere Konfliktwerte jeder Fusionsstufe der Varianten aus dem Variantenset 1. Gelbe Punkte: Summe der mittleren Konfliktwerte, rote Linie: auf eine Fusion normalisierte Konfliktwerte jeder Variante. Eigene Darstellung 2023.....	57
Abbildung 32: Mittlere Konfliktwerte jeder Fusionsstufe der Varianten aus dem Variantenset 2. Gelbe Punkte: Summe der mittleren Konfliktwerte, rote Linie: auf eine Fusion normalisierte Konfliktwerte jeder Variante. Eigene Darstellung 2023.....	59
Abbildung 33: Gegenüberstellung der Ergebniskarten. Links: Ergebniskarte der Variante J21Z_1, rechts: Ergebniskarte der Variante J22A_0. Ähnliche Bereiche: schwarze Rahmen, unterschiedliche Bereiche: weiße Rahmen. Eigene Darstellung mit TerrSet 2023.....	60
Abbildung 34: Gegenüberstellung der Konfliktkarten. Links: Konfliktkarte der Variante J21Z_1, rechts: Konfliktkarte der Variante J22A_0. Schwarze Rahmen: unterschiedliche Lage und Stärke der Konfliktwerte, Eigene Darstellung mit TerrSet 2023. ....	60
Abbildung 35: Histogramme der Konfliktwertkarten. Oben: Variante J22A_0, unten: Variante J21Z_1. Eigene Darstellung mit TerrSet 2023.....	62
Abbildung 36: Gegenüberstellung der Ergebniskarten mit integrierten Konfliktwerten. Links: Variante J21Z_1, rechts: Variante J22A_0. Kräftige Farben: hohe Überzeugung von den Hypothesen, blasser Farben: geringe Überzeugung von den Hypothesen. Eigene Darstellung mit TerrSet 2023. ....	63
Abbildung 37: Gegenüberstellung der Ergebniskarten. Links: Ergebniskarte der Variante J22A_0, rechts: Ergebniskarte der Variante J22A_1. Eigene Darstellung 2023.....	67

---

Abbildung A- 1:	Protokoll der Flächenbegehung am 21.03.2023.....	A-1
Abbildung A- 2:	Grafische Darstellung der Trennbarkeit der NDVI-Werte an vordefinierten Standorten. Eigene Darstellung 2023. ....	A-2
Abbildung A- 3:	Ergebnisse der Varianzanalysen und der Tukey HSD-Tests im Rahmen der Analyse der NDVI-Werte an vordefinierten Standorten. Jahre 2021 und 2022. Eigene Darstellung 2023. ....	A-3
Abbildung A- 4:	Chi-Quadrat-Wert und Cramer's V aus der Kontingenzanalyse der Einteilungsmethoden verschiedener Geodatenquellen. Eigene Darstellung 2023. ....	A-4
Abbildung A- 5:	Biomasse-Erntemengen der Jahre 2020, 2021 und 2022 auf der Fläche Kombinat. Quelle: PBK Pritzwalk, 2023.....	A-5
Abbildung A- 6:	Ergebnisse der Varianzanalysen bzw. Post-Hoc-Tests (TukeyHSD) für die Faktoren der Variantensets 1 und 2. Erstellt mit R. Eigene Darstellung 2023. ....	A-6
Abbildung A- 7:	Ergebniskarten der Variantensets 1 und 2. Eigene Darstellung 2023	A-8
Abbildung A- 8:	Konfliktkarten der Variantensets 1 und 2. Eigene Darstellung mit TerrSet 2023. ....	A-10
Abbildung A- 9:	Chi-Quadrat-Wert der Varianten des Variantensets 1 in Gegenüberstellung mit dem Validierungsdatensatz. Eigene Darstellung 2023. ....	A-12
Abbildung A- 10:	Cramer's V der Varianten des Variantensets 1 in Gegenüberstellung mit dem Validierungsdatensatz. Eigene Darstellung 2023. ....	A-12
Abbildung A- 11:	Chi-Quadrat-Wert der Varianten des Variantensets 2 in Gegenüberstellung mit dem Validierungsdatensatz. Eigene Darstellung 2023. ....	A-13
Abbildung A- 12:	Cramer's V der Varianten des Variantensets 2 in Gegenüberstellung mit dem Validierungsdatensatz, Eigene Darstellung, 2023. ....	A-13
Abbildung A- 13:	Histogramm der NDVI-Werte des Satellitenbilds vom 30.07.2021, Standort: Kombinat, PBK Pritzwalk. Eigene Darstellung 2023. ....	A-14
Abbildung A- 14:	Histogramm der NDVI-Werte des Satellitenbilds vom 03.07.2022, Standort Kombinat, PBK Pritzwalk. Eigene Darstellung 2023. ....	A-14



---

## Tabellenverzeichnis

Tabelle 1:	Beispiel für die Dempster'sche Kombinationsregel für das Pixel 1 aus Abbildung 2 und 3. Eigene Darstellung 2023.....	8
Tabelle 2:	Beispiel für die Dempster'sche Kombinationsregel für das Pixel 2 aus Abbildung 2 und 3. Eigene Darstellung 2023. ....	9
Tabelle 3:	Ergebnisse der Kombination nach der Dempster'schen Kombinationsregel nach Normalisierung der Werte. Eigene Darstellung 2023.....	10
Tabelle 4:	Bezeichnungen und Faktoren des Variantensets 1 in Vorbereitung auf die Datenfusion mit dem TBM. Eigene Darstellung 2023.....	49
Tabelle 5:	Bezeichnungen und Faktoren des Variantensets 2 in Vorbereitung auf die Datenfusion mit dem TBM. Eigene Darstellung 2023.....	49
Tabelle 6:	Klassifikations der Konfliktwerte für die Kombination mit der Ergebniskarte. Eigene Darstellung 2023.....	52
Tabelle 7:	Statistische Parameter des aus den einzelnen Fusionen resultierenden Konfliktwert-Datensatzes aus dem Variantenset 1. Fett markiert sind die Ergebnis-Varianten des Variantensets 1. Eigene Darstellung 2023 .....	56
Tabelle 8:	Mittelwerte der weights of conflict nach Prüfgliedern der Faktoren Jahreseinfluss, Wahlmethode und Ergänzung der Bodenschätzung. Eigene Darstellung 2023 .....	58
Tabelle 9:	Statistische Parameter des aus den einzelnen Fusionen resultierenden Konfliktwert-Datensatzes aus dem Variantenset 2. Fett markiert sind die Ergebnis-Varianten des Variantensets 2. Eigene Darstellung 2023 .....	58

---

## Verzeichnis der Abkürzungen

{g}	Hypothese: gutes Biomassewachstum
{m}	Hypothese: mittleres Biomassewachstum
{ $\emptyset$ }	Hypothese: leere Menge; eine nicht im vordefinierten Hypothesenraum enthaltene Hypothesenausprägung
{s}	Hypothese: schlechtes Biomassewachstum
{ $\Omega$ }	Hypothese: alle Hypothesenausprägungen
°C	Grad Celsius
BA	Einteilungsmethode nach Bodenart
BZ	Einteilungsmethode nach Bodenzahl
BZ+	Einteilungsmethode nach Bodenzahl und Kulturart
<i>Bel</i>	<i>belief function</i>
bzw.	beziehungsweise
DST	Dempster-Shafer-Theorie
dt/ha	Dezitonnen pro Hektar
eng.	im Englischen
EU	Europäische Union
G	Gruppenmethode
GIS	Geografisches Informations System
ha	Hektar
I	Intervallmethode
KI	Künstliche Intelligenz
m	Meter
mm	Niederschlag in mm pro m <sup>2</sup>
m ü. NN	Meter über Normalnull
<i>MOB</i>	<i>mass of belief</i>
$m_x$	<i>mass of belief</i> (Wert zwischen 0 und 1)
<i>NDVI</i>	<i>Normalized Difference Vegetation Index</i>

Q	Quantilmethode
SOE	<i>source of evidence</i>
TBM	<i>Transferable Belief Model</i>
TM	Trockenmasse
TWI	<i>Topografic Wetness Index</i> (Topografischer Feuchteindex)
UTM 33N	<i>Universal Transverse Mercator</i> (Koordinatensystem), Zone 33-Nord
VD	Validierungsdatensatz
vgl.	vergleiche
z.B.	zum Beispiel

## Abstract

The site-specific targeting of grassland enables resource-efficient management and can thus potentially contribute to the preservation of ecologically valuable biotopes, that are found there. For this purpose, different sources of geodata are necessary, which are often of varying quality and different scale. On this account, data fusion methods are suitable to generate a higher level of information about a location from several geodata during a combination process. Data fusion using the Transferable Belief Model (*TBM*) allows a combination of geospatial data and expert knowledge through belief structures. Processes of decision-making could be supported which in agriculture are classically characterized by large uncertainties. With this method a thematic map of results can be developed, which can be classified in its significance by conflict values. This work shows the possibility of subdividing grassland into zones of different biomass yield by combining satellite data, soil estimation data and the data of the Topographic Wetness Index using the *TBM*. First, different influencing factors were analyzed to achieve a parameterization of the fusion process. The Sites in the named geodata were classified according to expected biomass growth using the hypothesis of poor, moderate and good. Subsequently, the fusion was performed with eleven variations of geodata-combination and compared with a validation data set. It could be shown that especially the specific selection of data sources is crucial for the zoning of grassland with respect to biomass yield. Furthermore, the selection of the acquisition date of the satellite images was identified as a decisive factor for the results of the fusion. Additionally, the calculation of conflict values in the *TBM* seems to be profitable compared to similar classification methods. The results show potential for an extension of the method tests to further crops and regions as well as the transfer to agricultural practice.

# 1 Einleitung und Problemstellung

Der wirtschaftliche Druck, der auf Agrarbetrieben lastet und der zunehmende Einfluss des Klimawandels konterkariert in jüngster Zeit eine positive ökologische Entwicklung des Grünlands. Das äußert sich im Rückgang von Dauergrünlandflächen, den die EU-Politik durch entsprechende Vorgaben seit 2013 einzudämmen versucht (Ittershagen, 2023). Trotzdem werden immer mehr marginale Flächen aufgegeben und produktive Standorte weiter intensiviert. Folgen davon sind die Reduktion der Artenanzahl bei Flora und Fauna, der Rückgang der genetischen Vielfalt vorhandener Arten, sowie die Verkleinerung bzw. Verdrängung von Nicht-Agrar-Ökosystemen zwischen landwirtschaftlich genutzten Arealen (Hopkins und Holz, 2006). Daraus leitet sich die Notwendigkeit ab, dass Grünlandbewirtschaftung so effizient und ressourcenangepasst wie möglich stattfinden muss, um den Zielkonflikt zwischen Ökologie und Ökonomie zu entschärfen und gleichzeitig ein ökologisch möglichst hochwertiges Grünland zu erhalten (Isselstein und Michaelis, 2015). Um in Zukunft eine weitere Degradation der Grünlandökosysteme zu verhindern und eine positive Grünlandentwicklung zu unterstützen, lohnt sich die flächendeckende Integration von Geoinformationssystemen (GIS) in Rahmen der Grünlandoptimierung. Schließlich ermöglicht dies teilflächenspezifische Ansätze, welche zum Beispiel die Basis für einen ressourcenschonenden Düngemiteleinsatz und eine kosteneffizientere Bewirtschaftung bilden. Um eine gezielte Flächenansprache zu erreichen, ist zunächst eine Klassifizierung einzelner Bereiche notwendig, die anschließend mit unterschiedlichen Maßnahmen adressiert werden. Diese Klassifizierung ist jedoch häufig nur durch die Kombination und Interpretation verschiedener Geodaten im Rahmen der Datenfusion möglich. Zahlreiche, meist auf künstlicher Intelligenz (KI) basierende Ansätze widmen sich diesem Problem (Ahmad et al., 2022; Barbedo, 2022). Auch für Grünland wurden im Zusammenhang mit der Biotopkartierung vielversprechende Erkenntnisse gewonnen (Buck et al., 2018). Eine Übertragbarkeit der oft erfolgversprechenden Studienergebnissen in die landwirtschaftliche Praxis findet jedoch nicht flächendeckend statt. Zum einen, da diese häufig auf eine spezifische Region bzw. einen spezifischen Anwendungsfall begrenzt und damit schlecht skalierbar sind (Barbedo, 2022), zum anderen mangelt es, aufgrund der geringen Nachvollziehbarkeit der Ergebnisse, an Akzeptanz der Klassifikations-Produkte bei gleichzeitiger Sorge um ausreichenden Datenschutz und Privatsphäre angesichts der großen Datenmengen, die benötigt werden (Dobers, 2008; Kaivosoja, 2019; Vallentin et al., 2020; Wolfert et al., 2017). Eine Datenfusions-Methode, die es ihren Nutzern<sup>1</sup> ermöglicht, mit eigener Erfahrung die zur Fusion verwendeten Geodaten bezüglich ihrer Unsicherheiten einzuschätzen, ist das *Transferable Belief Model (TBM)*

---

<sup>1</sup> Zur besseren Lesbarkeit wird in dieser Arbeit das generische Maskulinum verwendet. Die Personenbezeichnungen beziehen sich – sofern nicht anders kenntlich gemacht – auf alle Geschlechter.

(Dobers, 2008; Smets, 1994b). Gegenstand der vorliegenden Arbeit ist die Übertragung des *TBM* auf Fragestellungen im Grünland.

Die Vorzüge detaillierter, mithilfe von GIS und Datenfusion erstellter Arealkarten für die landwirtschaftliche Nutzung liegen auf der Hand. Inwieweit die Anwendung des *TBM* die Klassifizierung von Grünlandstandorten unterstützen kann, soll in der vorliegenden Arbeit betrachtet werden. Vor der praktischen Umsetzung der Methode sind demnach die folgenden grundlegenden Fragen zu klären:

1. Ist das *Transferable Belief Model (TBM)* geeignet, um im Grünland eine teilautomatisierte Zonierung von Arealen verschiedenen Biomassewachstums zu unterstützen?
2. Ist es möglich, für bestimmte Datenquellen ein in der betrachteten Region gültiges Interpretationsschema für Zonen unterschiedlichen Biomassewachstums im Grünland zu erarbeiten?
3. Inwieweit können die im *TBM* berechneten Konfliktwerte für eine differenzierte Standortansprache genutzt werden?

Die nachfolgende Abhandlung beginnt mit einer kurzen Einführung in die Prinzipien und Methoden des *Transferable Belief Models*. In Kapitel 3 wird nach verschiedenen Vorüberlegungen und Analysen eine Parametrisierung des *TBM* für die Anwendung im Grünland erarbeitet. Außerdem wird der Ablauf des Methodentests für den erarbeiteten Fusionsprozess beschrieben. In Kapitel vier werden die Ergebnisse des Methodentests dargestellt. In Kapitel fünf findet die Diskussion der Ergebnisse im Hinblick auf die vorher formulierten Forschungsfragen statt. Im letzten Teil werden Stärken und Schwächen der Methode aufgezeigt und Anknüpfungspunkte für weitere Studien herausgestellt.

## 2 Das *Transferable Belief Model* (TBM)

Die Nutzer von Smart-Farming-Technologien formulieren den Anspruch, durch den Einsatz von Informationstechnologien eine Effizienzsteigerung in der Landwirtschaft zu erreichen (von Wardenburg, 2023). Dafür muss neben der Sammlung von Daten, der genauen Positionierung von Arbeitsgerät und Betriebsmitteln auch eine Entscheidungsunterstützung geleistet werden, um komplexe landwirtschaftliche Problemstellungen zu erfassen und das Flächenmanagement übersichtlich im Blick zu behalten. Ziel der Bemühungen ist es, zum Zweck der Ressourceneinsparung aber auch zugunsten des Umweltschutzes und des Tierwohls Entscheidungen differenzierter und effizienter zu treffen. Dazu ist die zielgerichtete Sammlung und Verarbeitung großer Datenmengen notwendig, die es erlaubt, ein Kulturpflanzenökosystem oder das Befinden eines Nutztiers möglichst individuell zu beschreiben und nach einem Ist-Sollwert-Vergleich spezifische Maßnahmen anzubieten (Abdalla und El-Ramady, 2022).

Zur Datensammlung sind Sensoren im Einsatz, die kontinuierlich Informationen liefern. Foto-rezeptoren von Satelliten wie dem Sentinel-2 oder Temperatursensoren in Wetterstationen sind Beispiele. Weitere Informationsquellen sind aber auch die hoch aufgelösten und sorgfältig angefertigten Bodenkarten, die im Rahmen der Bodenschätzung angefertigt wurden und aus dem Zeitraum zwischen 1934 und der Mitte der 1950er Jahre stammen (Herche, 2019). Allerdings bilden sowohl Sensordaten als auch analoge Karten die Realität als Modell ab und sind dadurch zwangsläufig unvollständig, potenziell fehlerbehaftet und ungenau (Legros, 2006). Bei den frei verfügbaren Satellitenbildern der Sentinel-2 Mission liegt die geringste räumliche Bildauflösung bei 10 m (ESA, 2023). Das kann zum Beispiel bei einem Weizenschlag mit Fahrgassen, bei dem mithilfe des Satellitenbildes eine Aussage über die Biomasse getroffen werden soll, zu Problemen führen. Das Bodensignal der Fahrgassen wird in den gemittelten Wert auf Pixelebene mit einbezogen und kann zu einer Unterrepräsentation des tatsächlich vorhandenen Pflanzenbestandes führen. Aus den einzelnen Raumdatenquellen kann demnach nur in seltenen Fällen eine direkte Management-Unterstützung abgeleitet werden (Kaivosoja, 2019). Eine Verbesserungsansatz für diese Problemstellung wird in der Daten- bzw. Informationsfusion gesehen (Barbedo, 2022). Sie zielt darauf ab, durch die Kombination mehrerer, in verschiedener Weise unvollständiger und fehlerhafter Datenquellen präziseres Wissen zu erlangen. Mit verschiedenen Methoden werden Informationen über ein Objekt verglichen und Schnitt- sowie Vereinigungsmengen aus den Datenquellen herangezogen, um eine mehrfach gestützte Aussage über ein Objekt abzuleiten (Wald, 1999). Das steigert nicht nur die Qualität, sondern auch die Kosten- und Zeiteffizienz der Anwendungen, sowie die gesamte Ausnutzung von Informationen aus Datenquellen, die in Fusions-Prozesse integriert werden (Klaus, 1999; Ruser und León, 2007). Die Anwendungsfelder für die Datenfusion sind zahlreich (Ruser und León, 2006). So werden derzeit verschiedene Methoden der Datenfusion entwickelt, um im

---

Rahmen des komplexen Wirkungsgefüges von Kulturpflanzenökosystemen Entscheidungen zu unterstützen (Ahmad et al., 2022; Barbedo, 2022; Segl et al., 2018).

Tso und Mather (2001) stellen in ihrem Buch „*Classification Methods for Remotely Sensed Data*“ mehrere Verfahren der Datenfusion von Fernerkundungsdaten vor, darunter das *Bayes Theorem* und die Dempster-Shafer Theorie (DST). Erfolgreiche landwirtschaftliche Anwendung fanden darüber hinaus bereits andere Algorithmen wie Support Vector Machines (Kok et al., 2021) oder Random Forest (Buck, 2020).

Die vorliegende Arbeit basiert auf den Veröffentlichungen von Dobers (2006, 2008), der das *Transferable Belief Model* für landwirtschaftlich-bodenkundliche Fragestellungen nutzt. Dobers adaptiert das *Transferable Belief Model* für bodenkundliche Datenquellen auf der Ebene landwirtschaftlicher Flächen, um dort die Bodenkartierung zu erleichtern und zu verbessern. Das *TBM* ist eine Methode der Datenfusion, die durch ihren allgemeingültigen Ansatz jegliche Art von Informationen mit unterschiedlichen Arten und Graden der Unsicherheit verbinden kann. Andererseits kann eine nachvollziehbare Klassifizierung von Objekten, insbesondere durch die Einschätzung von Unsicherheit durch den Nutzer stattfinden, sodass landwirtschaftliches Erfahrungswissen in die Erstellung von Karten einfließen kann (Ristic et al., 2020; Vallentin et al., 2020).



In Abbildung 1 wird der schematische Ablauf einer Datenfusion mit dem TBM auf Ebene einer landwirtschaftlichen Anwendung dargestellt. Verschiedene Überzeugungen von Geodaten, welche völlig unterschiedliche Informationen über die Fläche bereitstellen, werden in mehreren Fusionsschritten zu einer Ergebniskarte kombiniert. Die ursprünglichen Datenquellen können dabei aufgrund des Zwischenschritts der Klassifizierung mit beliebigem Inhalt, Maßstab, Flächenabdeckung und Qualität ausgestattet sein. Die Integration von Erfahrungswissen findet bei der Auswahl der Datenquellen, der Interpretation und Klassifizierung, sowie der Zuordnung des Überzeugungswertes (*reliability*) statt. Auf der Ergebnisebene wird die Glaubensebene, auf der bekannte und noch nicht bekannte Hypothesen mit bestimmten Überzeugungen unterhalten werden, und der pignistischen Ebene, auf der die vorher festgelegten Hypothesen mit bestimmten Überzeugungen vorherrschen, unterschieden. Bei der pignistischen Transformation werden die Überzeugungswerte, die auf der Glaubensebene den ungekannten Hypothesen zugeordnet sind, auf die bekannten Hypothesen aufgeteilt. Die Konfliktwertkarte stellt dem Anwender eine Zusatzinformation über die Vertrauenswürdigkeit der Hypothesen in der Ergebniskarte bereit.

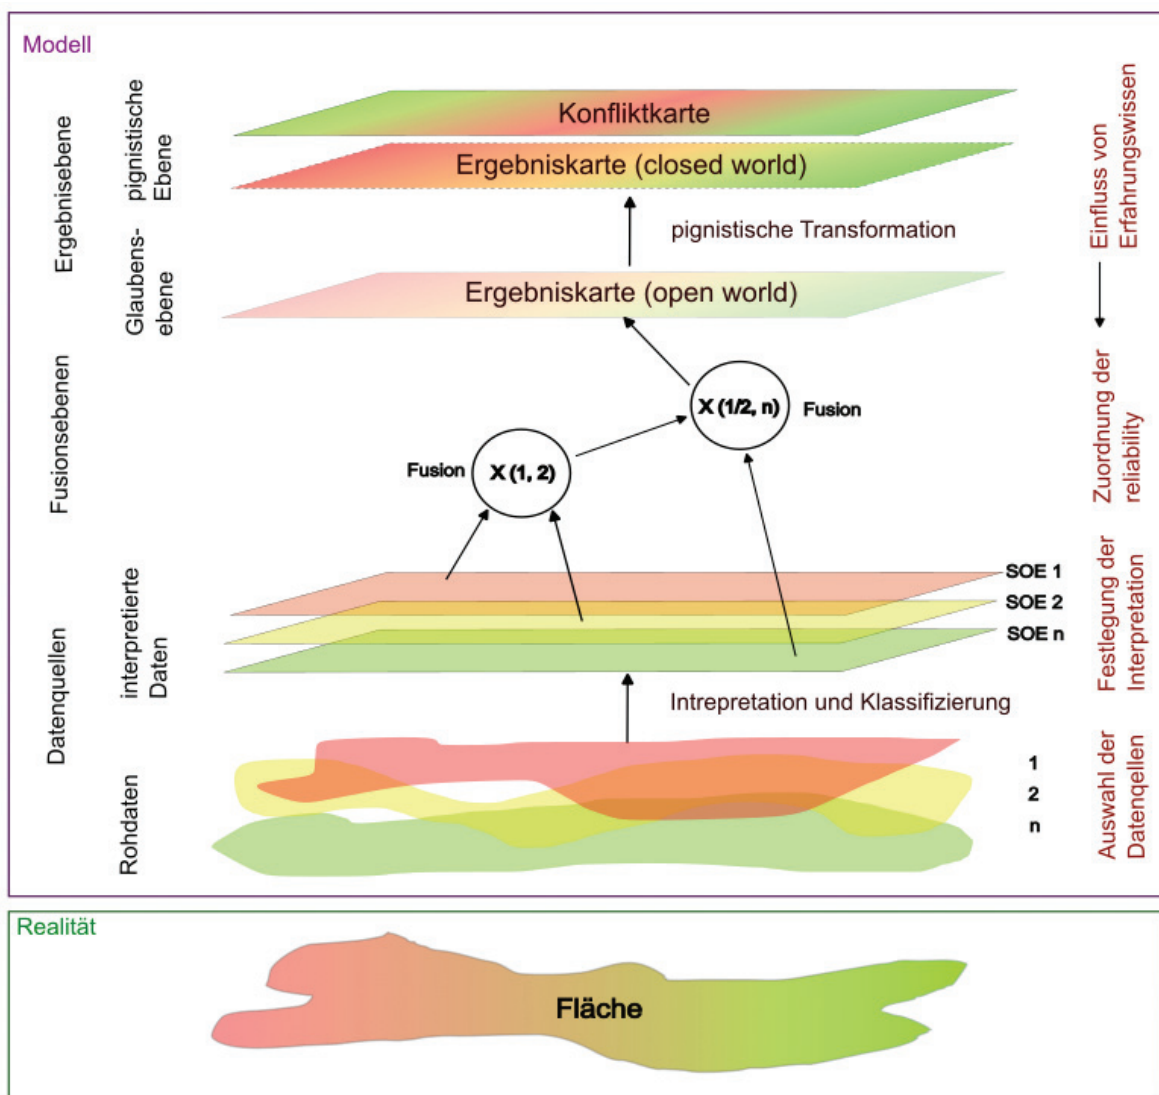


Abbildung 1: Schematischer Ablauf der Geodatenfusion mit dem TBM. Eigene Darstellung 2023.

## 2.1 Begrifflicher Rahmen<sup>2</sup>

Im *TBM* werden quantifizierte Überzeugungen durch *belief functions* auf Punktebene dargestellt (Smets, 2000a; 1994b). Auf landwirtschaftlicher bzw. GIS-basierter Ebene stellt Dobers (2006, 2008) in seiner Interpretation des *TBM* die angenommene Realität mithilfe eines Hypothesensets auf Rasterzellenebene dar. Diese Hypothesen repräsentieren die erwarteten Ausprägungen des Objekts und bilden dadurch ein Modell der Wirklichkeit ab. Für jeden Wert einer Datenquelle wird festgelegt, wie groß die Überzeugung ist, dass eine oder mehrere Hypothesen für diesen Punkt zutreffend sind. Dadurch erhält im Falle der GIS-basierten Anwendung jede Rasterzelle Informationen dazu, welche Ausprägungen die zugeteilten Hypothesen haben und wie hoch der Grad der Überzeugung der jeweiligen Hypothese ist. Dieser Grad der Überzeugung von einer Hypothese wird **mass of belief** (*MOB*) genannt und kann einen Wert zwischen 0 und 1 annehmen.

In der vorliegenden Arbeit soll versucht werden, mithilfe des *TBM* Areale mit verschiedenem Biomassewachstum im Grünland herauszuarbeiten, die als Karte dargestellt werden. Die Hypothesen können dabei die Ausprägungen {s} (schlechtes Wachstum), {m} (mittleres Wachstum) sowie {g} (gutes Wachstum) annehmen. Diese Spannweite der Hypothesenausprägung wird als **frame of discernment** bezeichnet und  $\Omega$  genannt. Das *TBM* lässt zu, dass sich die Anzahl der Hypothesen vergrößert, wenn zusätzliches Wissen erlangt wird oder ein grundlegendes Umdenken stattfindet. Deshalb schließt  $\Omega$  nicht nur die einzelnen Hypothesen, sondern auch alle ihre Vereinigungs- und Schnittmengen, sowie vorher nicht erwartete Hypothesen mit ein. Diese Darlegung trägt somit der *open world assumption* Rechnung und ist eine große Stärke des *TBM*.


Informationen über die Zonen der zukünftigen Biomassekarte werden durch Geodaten bereitgestellt. Diese Datenquellen werden **sources of evidence** (*SOE*) genannt. Alle *SOEs*, die zum aktuellen Zeitpunkt zur Verfügung stehen, werden unter dem Begriff **evidence corpus** versammelt. Sollten zukünftig weitere Datenquellen zu den betroffenen Arealen erscheinen, können diese jederzeit durch eine weitere Fusion ergänzt werden, was dann eine genauere Beschreibung des Feldes erlaubt. Bevor die Datenfusion stattfinden kann, muss jede *SOE* interpretiert werden. Dies geschieht, indem die Rohdaten aus der Geodatenquelle in die Hypothesen des *frame of discernment* umklassifiziert werden. Die Erarbeitung der Interpretation erfordert den Transfer von Expertenwissen und stellt eine subjektive Komponente dar. Interpretiert man beispielsweise eine Geodatenquelle, mit Bodenzahl, im Rahmen der Ertragser-

---

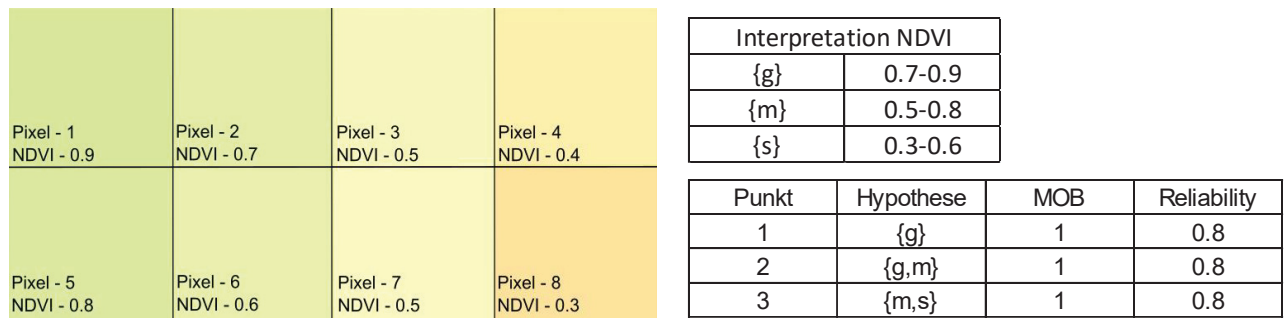
<sup>2</sup> Nach Tso, B., & Mather, P. M. (2001). *Multisource Classification*. In *Classification Methods for Remotely Sensed Data*. Taylor & Francis. .

wartung, so würde man einem Bereich mit der Bodenzahl 70 aufgrund der hohen repräsentierten Bodenfruchtbarkeit die Hypothese {g} zuordnen. Im *TBM* ist es aber möglich, dass für eine Teilfläche mehrere oder sogar alle Hypothesen zutreffend sein können. So könnten in einem Bereich mit der Bodenzahl 40 mehrere Hypothesen, beispielsweise {m, g} (mittleres und gutes Wachstum) passend sein. Bei der Interpretation eines Höhenmodells ist denkbar, dass es Bereiche gibt, von denen aufgrund ihrer Ausprägung keine Ableitungen im Hinblick auf das Biomassewachstum getroffen werden können. In diesem Fall würden dem Ort alle drei Hypothesen {s, m, g} zugeordnet werden. Es gilt, dass es kein richtig oder falsch gibt, da das *TBM* mit Überzeugungen arbeitet und davon ausgeht, dass durch zusätzliches Wissen in Form von Einbindungen weiterer *SOEs* eine höhere Genauigkeit der Ergebnisse erzielt werden kann. Bei der Interpretation werden den Datenquellen Hypothesen mit den jeweiligen *MOB*-Werte zugeordnet. In Summe ergeben alle *MOB*-Werte einer Teilfläche der Geodatenquelle den Wert 1.

Jeder *SOE* wird durch den Nutzer eine **reliability** zugeordnet, die einen Wert zwischen 0 und 1 aufweist. Dieser Überzeugungswert stellt ein weiteres Element im *TBM* dar, das auf der Einschätzung des Nutzers basiert. Mit der Zuteilung der *reliability* drückt der Experte sein Vertrauen in die Datenquelle insgesamt aus. Beim Vergleich mehrerer Datenquellen wird der erfahrene Landwirt den Einfluss der Bodenzahl als Indikator für das Biomassewachstum beispielsweise höher einschätzen als die aus dem Höhenmodell abgeleiteten Informationen über die Position im Relief. Weitere Grundlagen für die Herleitung der *reliability* können das Alter der Datenquelle oder deren Auflösung bzw. Maßstab sein. Im Falle von Satellitenaufnahmen ist die *reliability* im Hinblick auf das Biomassewachstum von Grünland stark vom Aufnahmezeitpunkt in der Saison abhängig (Schmidt et al., 2014).



**Abbildung 2:** Beispielhafte Datenquelle 1 (links) auf Rasterebene mit Interpretationstabelle (rechts oben) und zugeordneten Hypothesensets mit reliability. Eigene Darstellung 2023.



**Abbildung 3:** Beispielfhafte Datenquelle 2 (links) auf Rasterebene mit Interpretationstabelle (rechts oben) und zugeordneten Hypothesensets mit reliability. Eigene Darstellung 2023.

In den Abbildung 2 und 3 ist die Interpretation von zwei Datenquellen auf Pixelebene dargestellt. Jeder Rasterzelle wurde anhand der beispielhaften Interpretationstabelle ein Hypothesenset zugeordnet. Beide Datenquellen weisen einen farblich dargestellten Verlauf ihrer Eigenschaften auf. Von links nach rechts wird so ein geringeres Biomassewachstum repräsentiert. Laut der zugeordneten Interpretationstabelle werden für die Datenquelle 1 die Hypothesen {g} und {m} erwartet, in der Datenquelle 2 erwartet man zudem auch die Hypothese {s}. Im Beispiel wurde die Glaubwürdigkeit für die erste Datenquelle mit einem Wert von 0,7 und für die zweite Datenquelle mit einem etwas höheren Wert von 0,8 eingeschätzt.

## 2.2 Dempster's rule of combination <sup>3</sup>

Sofern die SOEs im Rahmen des  $\Omega$  interpretiert sind und ihnen Glaubwürdigkeitswerte zugeordnet wurden, kann die Dempster'sche Kombinationsregel angewandt werden. Fusioniert werden immer zwei SOEs, indem zunächst die jeweiligen MOB-Werte der Punkte einer Datenquelle mit der zugeordneten reliability multipliziert werden. Anschließend werden im Kreuzprodukt alle zu einem Punkt gehörenden masses of belief miteinander kombiniert und die dazugehörigen masses of belief ( $m_{1,2}$ ) der dominanten Hypothese abgetragen. Beispielhaft folgt die Anwendung der dempster's rule of combination für die vorher interpretierten Pixel eins (Tabelle 1) und zwei (Tabelle 2).

**Tabelle 1:** Beispiel für die Dempster'sche Kombinationsregel für das Pixel 1 aus Abbildung 2 und 3. Eigene Darstellung 2023.

	Pixel 1	SOE 1	
		{g}	{ $\Omega$ }
		$m_1(\{g\})=mob*r=1*0.7=0.7$	$m_1(\{\Omega\})=0.3$
SOE 2	{g}	$m_{1,2}(\{g\})=$ 0.56	$m_{1,2}(\{g\})=$ 0.24
	{ $\Omega$ }	$m_{1,2}(\{g\})=$ 0.14	$m_{1,2}(\{\Omega\})=$ 0.06
	$m_2(\{g\})=mob*r=1*0.8=0.8$		
	$m_2(\{\Omega\})=0.2$		

<sup>3</sup> Nach Tso und Mather *ibid.*.

Die Hypothese, welche in Summe die meisten *MOB*-Werte erhält, ist diejenige, die durch beide Datenquellen gestützt wird. Das Ergebnis von Pixel 1 sagt aus, dass drei Mal die Hypothese  $\{g\}$  überwiegt und drei Kreuzprodukte mit unterschiedlich hohen *MOB*-Werte diese Hypothese stützen. Das vierte Kreuzprodukt bei Pixel 1 ergibt die Hypothese  $\{\Omega\}$  (Tabelle 1). In einem weiteren Schritt werden alle *masses of belief*, die die Hypothese  $\{g\}$  stützen, zur **belief function**  $Bel(\{g\})$  aufsummiert. Im Fall von Pixel 1 ergibt sich dann  $Bel(\{g\}) = 0,56+0,24+0,14 = 0,94$ . Die *belief function* für  $\Omega$  ( $Bel(\{\Omega\})$ ) beträgt 0,06. Das Ergebnis ist so zu interpretieren, dass die Hypothese  $\{g\}$  überzeugt. Eine andere Hypothese erscheint als weitaus weniger überzeugend.

**Tabelle 2:** *Beispiel für die Dempster'sche Kombinationsregel für das Pixel 2 aus Abbildung 2 und 3. Eigene Darstellung 2023.*

Pixel 2		SOE 1	
		$\{g\}$	$\{\Omega\}$
		$m_1(\{g\})=mob*r=0.7*0.7=0.49$	$m_1(\{\Omega\})=0.51$
SOE 2	$\{m\}$	$m_{1,2}(\{\emptyset\})=$ 0.392	$m_{1,2}(\{m\})=$ 0.408
	$\{\Omega\}$	$m_{1,2}(\{g\})=$ 0.098	$m_{1,2}(\{\Omega\})=$ 0.102
	$m_2(\{\Omega\})=0.2$		

Im Fall von Pixel 2 wird mit einem Wert von  $Bel(\{m\}) = 0,408$  die Hypothese  $\{m\}$  unterstützt. Die Hypothese  $\{\Omega\}$  hat nach der Kombination eine *belief function* von  $Bel(\{\Omega\}) = 0,102$  und der Hypothese  $\{g\}$  kann nur eine geringe Überzeugung von  $Bel(\{g\}) = 0,098$  entgegengebracht werden (Tabelle 2). Den zweithöchsten Wert zeigt die aus dem direkten Konflikt der beiden Hypothesen  $\{g\}$  und  $\{m\}$  hervorgehende leere Menge  $Bel(\{\emptyset\}) = 0,392$ . In diesem Fall widersprechen sich die beiden Datenquellen. Die *open world assumption* als Prämisse des *TBM* berücksichtigend, wäre hier eine vorher nicht definierte Hypothese anzunehmen. Ein möglicher Anwendungsfall verlangt jedoch, die Ergebnisse auf die pignistische Ebene zu transformieren, in der nur von drei verschiedenen Zonen des Biomassewachstums ausgegangen wird. Die leere Menge wird integriert, indem man die Werte normalisiert. Dabei werden die *belief functions* jeweils durch den Kehrwert der *belief function* der leeren Menge  $Bel(\{\emptyset\})$  dividiert. Nach der Normalisierung bei Pixel 2 erreicht die Überzeugung von der Hypothese  $\{m\}$  einen Wert von 0,67. In Tabelle 3 sind die Ergebnisse der Kombinationen aus Pixel 1 und Pixel 2 aufgeführt.

**Tabelle 3:** *Ergebnisse der Kombination nach der Dempster'schen Kombinationsregel nach Normalisierung der Werte. Eigene Darstellung 2023.*

Kombination Pixel 1		Kombination Pixel 2	
<i>WOC</i>	-	<i>WOC</i>	0.22
{ $\emptyset$ }	-	{ $\emptyset$ }	0.39
Kehrwert { $\emptyset$ }	1.00	Kehrwert { $\emptyset$ }	0.61
<b>Bel ({g})</b>	<b>0.94</b>	Bel ({g})	0.16
Bel ({m})	-	<b>Bel ({m})</b>	<b>0.67</b>
Bel ({s})	-	Bel ({s})	-
Bel ({ $\Omega$ })	0.06	Bel ({ $\Omega$ })	0.17
	1.00		1.00

Die leere Menge ist ein Indikator für Widersprüche in den Datenquellen. Bei Pixel 1 tritt sie nicht auf, deshalb wird dort kein entsprechender Wert angeführt. Um widersprüchliche Daten über mehrere Fusionsvorgänge hinweg vergleichen zu können, wird der **weight of conflict** (*WOC*) berechnet. Der Wert ergibt sich für jedes Pixel aus dem negativen Logarithmus des Kehrwerts von  $Bel(\{\emptyset\})$ .

$$WOC = -\log(1 - Bel(\{\emptyset\}))$$

Er veranschaulicht, wo und in welchem Maße die Datenquellen widersprüchlich sind und beziffert, wie vertrauenswürdig die Hypothese mit der höchsten *belief function* ist. Bei Pixel 1 tritt auch dieser Wert nicht auf. Bei Pixel 2 erreicht der *WOC* einen Wert von 0.22. In Summe ergeben auch die richtig normalisierten *belief functions* 1. Zu den Ergebnissen der ersten Kombination kann nun eine weitere *SOE* hinzugezogen werden. Die *belief functions* der Ergebnisse aus der ersten Fusion sind den *MOB*-Werte gleichzusetzen, welche zu Beginn jeder Fusion den jeweiligen Hypothesen zugeordnet werden müssen. In welcher Reihenfolge und wie viele Kombinationen mit immer einer neuen Datenquelle durchgeführt werden, ist nicht relevant, da die Fusion multiplikativ ist. Die große Flexibilität und Nachvollziehbarkeit des Datenfusionsmodells *TBM* macht seine Anwendung im Bereich angewandter Wissenschaften attraktiv. Das gilt auch für die Landwirtschaft, wo das *TBM* die Entscheidungsfindung unterstützen kann, ohne den absoluten und häufig irrtümlichen Anspruch zu haben, dass alle Parameter im Vorhinein bekannt und abschätzbar sind.

## 2.3 Annahmen des Modells und deren Interpretation

Das *TBM* zählt zum mathematischen Bereich der Modellierung von Unsicherheiten mit *belief structures* (Ristic et al., 2020). Es wurde entwickelt, um eine allgemeingültige, der Wirklichkeit eines Objekts möglichst nahekommende Aussage abzuleiten, indem mehrere Informationen aus verschiedenen Quellen vereinigt werden. Die Fusion findet nach der Dempster'schen



Kombinationsregel statt, bei der durch ein Kreuzprodukt Informationen mehrerer Quellen verrechnet werden, die dann verschiedene Hypothesen über ein Objekt mehr oder weniger stark stützen (Tso und Mather, 2001). Dabei wird auch die subjektiv festgelegte Glaubwürdigkeit einer Information berücksichtigt, sodass fundiertes Expertenwissen über eine Datenquelle in die Betrachtung mit einbezogen werden kann. Smets (1994a, 2000b) grenzt das Transferable Belief Model von der Dempster-Shafer-Theorie ab, an der es ursprünglich angelehnt war. Er unterstützt die *open world assumption* gegenüber der *closed world assumption*. Erstere lockert die grundlegende Annahme, dass alle möglichen Ergebnisse und deren Wahrscheinlichkeiten vor der Fusion bekannt sind. Das *TBM* nutzt den Begriff der „Überzeugung“ anstelle von „Wahrscheinlichkeit“ (Smets, 2000a; Smets, 1994b). Dadurch ist eine gewisse Flexibilität in der Beschreibung von Objekten gegeben, für die insgesamt zu wenige valide Daten vorliegen, um Wahrscheinlichkeitsfunktionen abzuleiten. Bei diesem Ansatz werden zwei Ebenen beschrieben, die Ebene des Glaubens (*credal level*) und die pignistische Ebene (*pignistic level*) (Smets, 2000a). Die Glaubensebene, auf der Überzeugungen beschrieben werden, die sich laufend anpassen können wird unterschieden von der pignistische Ebene, auf der Überzeugungen genutzt werden, um Entscheidungen zu treffen. Die Glaubensebene enthält dabei mehrere Überzeugungen für ein Objekt, die alle in gewissen Anteilen zutreffend sein können. Werden mehr Informationen über ein Objekt erlangt, so können diese mit den bestehenden Überzeugungen auf der Glaubensebene verrechnet werden. Die pignistische Ebene wird durch die Normalisierung der Werte der Glaubensebene erreicht (Smets, 2005). Dabei wird das *mass of belief* der leeren Menge, die keine der im *frame of discernment* vorhandenen, vordefinierten Hypothesen repräsentiert, auf alle bekannten Hypothesen aufgeteilt, sofern keine Entscheidungen abgeleitet werden sollen. Die im *TBM* explizit berücksichtigte Glaubensebene macht diesen Ansatz so bedeutsam für die Fusion von unvollständigen, unsicheren oder potenziell fehlerbehafteten Datenquellen.

Aus diesem Grund erscheint das Modell für die landwirtschaftliche GIS-Anwendung geeignet. Geodatenquellen, die Informationen über standortspezifische Gegebenheiten wie Boden oder Relief enthalten, haben aufgrund ihres Abbild- bzw. Modellcharakters immer eine gewisse Diskrepanz zu tatsächlichen Gegebenheiten. Die Unschärfen in den Datenquellen sind der notwendigen Abstraktion und Vereinfachung geschuldet. Laut Joos (2001) werden diese Unschärfen beispielsweise durch Messfehler bei der Objektkartierung, ungenaue Objektklassifizierung, oder durch eine falsche Repräsentation von Objektübergängen durch eine scharfe Grenzziehung und Interpolation hervorgerufen. Jede Informationsquelle benötigt deshalb eine subjektive Einschätzung ihrer Glaubwürdigkeit durch den Nutzer. Das *TBM* ermöglicht es, verschiedene Aussagen von Geodaten bezüglich ihrer Hypothesen zu fusionieren. Das können dabei sehr unterschiedliche Datenquellen sein, die im Hinblick auf ein Interpretationsziel kom-

biniert werden. Nach jedem Fusionsschritt werden dabei Unsicherheiten und Widersprüchlichkeiten deutlich, die eine Mehrinformation über das zu beschreibende Objekt darstellen. (Valentin et al., 2020).



### 3 Material und Methoden

Im nachfolgenden Abschnitt werden Überlegungen angestellt, wie die Übertragung des *TBM* auf eine landwirtschaftliche Anwendung gelingen könnte. Zuerst werden die Parameter des Modells für eine Grünlandfläche in der Prignitz bestimmt. Landwirtschaftliches Erfahrungswissen fließt bei der Auswahl der Datenquellen, ihrer Interpretation sowie der Einschätzung ihrer Glaubwürdigkeit ein. Dabei wird stets versucht, die verschiedenen Ursachen von Unsicherheiten in Datenquellen zu berücksichtigen.

#### 3.1 Überblick über das Projektgebiet

Die Entwicklung von Karten zur Ermittlung des Biomasseaufwuchses im Grünland mit dem *TBM* wurde auf der ca. 40 ha große Grünlandfläche „Kombinat“ erprobt. Die Fläche gehört zur PBK Pritzwalk, einem breit aufgestellten landwirtschaftlichen Betriebsverbund. Die PBK bewirtschaftet insgesamt eine Fläche von ca. 2.850 ha und unterhält einen Milchviehbestand von ca. 920 Tieren. Der Betrieb liegt im Landkreis Prignitz in Nord-West Brandenburg, nahe der Stadt Pritzwalk. Die bewirtschaftete Grünlandfläche von rund 400 ha wird ausschließlich zur Erzeugung von Grundfutter in der Milchviehproduktion verwendet. Dementsprechend hoch sind die Ansprüche an Produktivität und Qualität des Grünlands (Frädrich, 2023; PBK, 2023).

Aus geologischer Sicht zählt das Gebiet rund um Pritzwalk zu einer Altmoränenlandschaft, die während der vergangenen beiden norddeutschen Eiszeiten Elster und Saale von einem periglazialen Klima beeinflusst war. Dadurch war die ehemals von Grund- und Endmoränen geprägte Landschaft einer Reliefeinebnung ausgesetzt (Liedtke und Marcinek, 2003). Die vorkommenden Bodentypen Fahlerde und Fahlerde-Braunerde, teilweise pseudovergleyt, entstanden über einem Geschiebemergel aus einer Schicht aus Geschiebedecksand. In den niedriger liegenden Flächenarealen können vereinzelt auch Gley-Fahlerden vorkommen (BGR, 2023). In Abbildung 4 sind die laut Bodenschätzung in der Projektfläche überwiegend vertretenen Bodenarten Sand und lehmiger Sand abzulesen (Landesamt für Digitalisierung, 2011). Die Höhe über dem Meeresspiegel bewegt sich innerhalb der Fläche zwischen 65 und 75 m ü. NN (LGB, 2023c).

Das Klima und die Witterung in Nord-Ostdeutschland sind geprägt von kontinentalen Einflüssen mit geringen Mengen an Jahresniederschlag und teilweise sehr ausgeprägten Temperaturamplituden. Die Niederschlagsverteilung wird im Laufe der letzten Jahre stetig ungleichmäßiger, was sich in ergiebigen Niederschlägen in den Wintermonaten sowie einer ausgeprägten

Vorsommertrockenheit abzeichnet. Der Niederschlag fällt zunehmend schauerartig und weniger kontinuierlich (DWD, 2023).



**Abbildung 4:** Bodenarten auf der Fläche „Kombinat“ Quelle: LBG, 2022, Google Satellite, 2023.

In den vergangenen Jahren wurde die Fläche „Kombinat“ als vier- bis fünfschnittige Wiese sehr intensiv bewirtschaftet. Das Erntegut wurde nach der Mahd und dem Schwaden mit einem Feldhäcksler geerntet und als Grassilage in den nahegelegenen Siloanlagen eingelagert. Aus Platzgründen dient der im Süden an die Milchviehanlage angrenzende Bereich der Fläche oft als Futterlagerstätte für Heu- und Strohballen oder zur Unterbringung von Feldrandmieten für Silage. Im Frühjahr beginnt die Bewirtschaftung mit dem Striegeln und gleichzeitigem Nachsäen der Wiesen. Dieser Arbeitsschritt findet bei ausreichender Befahrbarkeit und Bodenfeuchtigkeit Ende Februar bis Anfang März statt. Ausgebracht wird eine mehrjährige Ackergrasmischung mit Weidelgräsern (*Lolium ssp.*), Wiesenlieschgras (*Phleum pratense*), Wiesen-schwingel (*Festuca pratensis*) sowie Wiesenschweidel (*Festulolium*), einer Kreuzung aus Schwingel und Weidelgras (DSV, 2023). Im vergangenen Jahr musste die Nachsaat aufgrund der massiven Trockenheit im März entfallen. Eine starke Verunkrautung infolge des Trockenstresses und der im letzten Jahr fehlenden Nachsaat wurde deutlich sichtbar. Aus diesem Grund ist für das Frühjahr 2023 eine Herbizidmaßnahme mit dem selektiven Herbizid Ranger zur Bekämpfung der vorwiegend dikotylen Beikrautarten geplant.

Die Bodenuntersuchung wird in Abständen von drei Jahren durchgeführt. Die Grunddüngung wird anhand von Daten der Bodenschätzung teilflächenspezifisch angepasst. Im dreijährigen

Turnus wird eine Erhaltungskalkung ausgebracht. Die Düngung während der Vegetationsperiode erfolgt zum ersten Schnitt mineralisch, um zügig einen kräftigen Grünlandbestand etablieren zu können. Nach Bedarf werden Kalkammonsalpeter, Kornkali und Kiserit angewandt. Die Düngung zu den Folgeschnitten erfolgt organisch mit Rindergülle oder flüssigen Gärresten. Die Ernte läuft komplett eigenmechanisiert ab und wird mit einem Feldhäcksler mit integrierter Ertragskartierung durchgeführt (Frädrich, 2023).

Am 21.03.2023 wurden bei einer Feldbegehung einzelne, im Rahmen der intensiven Arbeit mit den Datenquellen ausgewählte, Punkte begutachtet. Am Tag der Besichtigung fand die Nachsaat mittels einer Striegel-Sä-Kombination statt, sodass über den Zustand des bisher angewachsenen Pflanzenbestands nur eine eingeschränkte Aussage getroffen werden konnte. Andererseits wurde durch die Verletzung der Grasnarbe Oberboden freigelegt, was Rückschlüsse auf die Bodenart erlaubt. An den unterschiedlichen Beobachtungspunkten zeigten sich verschiedene Brauntöne und Bindigkeiten (Abbildung 5).



**Abbildung 5:** *Beobachtungspunkte der Flächenbegehung am 21.03.2023, Hintergrundbild: Google Satellite 2023.*

Auf der Fläche waren deutliche Unterschiede im Bewuchs erkennbar. Gräser kamen nicht überwiegend an allen Standorten vor. Die Punkte 6 und 2 zeichneten sich besonders durch eine starke Verunkrautung mit winterannuellen Pflanzen, die Lücken der Grasnarbe besetzten, und sandige Bodentypen aus. Diesen Standorten sind eher schlechte Bedingungen für Pflanzenwachstum zu unterstellen. Im Gegensatz dazu zeigte sich ein üppiger Grasbestand besonders an den Punkten 1 und 4. Am Punkt 1 wurde ein Mineralstandort mit vermutlich höheren



Anteilen an Lehm im Oberboden vorgefunden. Der Punkt 4 zeichnete sich durch eine mächtige organische Auflage und eine gute Wasserversorgung aus. Die Punkte 3 (anmoorig) und 5 (mineralisch) können zwischen den vorher beschriebenen Standorteigenschaften eingeordnet werden (Abbildung A-1).

### 3.2 Auswahl der Datenquellen

Grundsätzlich können bei der Fusion mit dem *TBM* alle mit einem Objekt in Verbindung zu bringenden Daten einfließen, was durch die Interpretation der Informationen innerhalb des Hypothesensets ermöglicht wird. Die Übertragung der Methode auf eine Fläche setzt die Darstellbarkeit der Daten im GIS voraus. Neben Satellitenbildern, Höhenmodellen oder digitalisierten Bodenkarten können das auch Erfahrungswerte eines Landwirts über seinen Standort sein, die im GIS digitalisiert wurden. Die Auswahl der verwendeten Datenquellen hängt von der Fragestellung ab, die durch die Fusion beantwortet werden soll. Hier ist es die Abschätzung des unterschiedlichen Biomassewachstums von Grünland, weshalb Datenquellen gewählt wurden, die mit der aufwachsenden Biomassemenge in Verbindung stehende Faktoren abbilden. Im Grünland beeinflussen vor allem das Stickstoff- und Wasserangebot das Biomassewachstum. Die Stickstoffzufuhr ist eine Größe des Managements und variiert klassischerweise auf Flächenebene. Die Wasserversorgung ist von Standortfaktoren abhängig, die auf Teilflächenebene variieren. Sie findet zum einen über das Grundwasser und zum anderen über Niederschläge statt. In Abhängigkeit der Faktoren Bodenart, Bodentyp und Bodenstruktur, die unterschiedlich hohen Kapillaranstieg ermöglichen, können verschieden tiefe Grundwasserstände für die Wasserversorgung ausreichen. Dagegen werden die Pflanzen in grundwasserfernen Lagen ausschließlich von Niederschlägen versorgt (Dierschke und Briemle, 2008). Auf diesen Flächen ist eine ausdauernde Wasserspeicherefähigkeit des Standorts entscheidend, welche wiederum von Bodenart, Bodentyp und Bodenstruktur abhängt. Im Jahresverlauf setzt mit Wachstumsbeginn ein Wasserverbrauch aus dem Boden- und Grundwasservorrat ein, der sein Maximum im Hochsommer erreicht. Defizite, die in Abhängigkeit von Niederschlagsmengen, Niederschlagsverteilung, Hitzetagen und dem standortspezifischen Wasserspeichervermögen des Bodens auftreten, können im Laufe der Wachstumsperiode zu verringerter Biomasseentwicklung und Trockenschäden führen (Dierschke und Briemle, 2008). Das Relief der Fläche kann Hinweise auf die Wasserdynamik geben, da durch die unterschiedliche Topografie Fließvorgänge ausgelöst werden können. Neben der Aussagekraft der Daten waren die kostenlose Verfügbarkeit im Land Brandenburg und das Raster- oder Shape-Dateiformat eine weitere Prämisse für die Verwendung einer Geodatenquelle. Dadurch sollte eine potenzielle Übertragung der Methodik in die Praxis sichergestellt werden. Für das vorliegende Projekt wurden vor allem Geodaten, die die Wasserversorgung in Abhängigkeit von den Bodenverhältnissen abbilden, als Indikator für das Biomassewachstum herangezogen. Es wurden Satellitenbilder zur Repräsentation von unterschiedlichem Biomasseaufwuchs und Daten

der Bodenschätzung zur Charakterisierung der Bodenverhältnisse verwendet. Weiterhin wurde der Topografischen Feuchteindex als Geodatenquelle integriert.

### 3.2.1 Bodenschätzung

Die Bodenschätzung ist eine Quelle standardisierter Informationen über die Fruchtbarkeit von Böden. Ab 1934 flächendeckend auf den ehemals zum Deutschen Reich zählenden Territorien eingeführt, war sie ursprünglich für die ernährungspolitische und steuerliche Quantifizierung gedacht. Im Bereich der strukturellen Ansprache von Standortheterogenität in landwirtschaftlichen Fragestellungen hat sie einen hohen Informationswert und stellte vor der Etablierung digitaler Lösungen europaweit die höchste Dichte an Bodendaten bereit (Amelung et al., 2018). Mit der fortlaufenden Entwicklung der digitalisierten Landwirtschaft erlangt die Bodenschätzung weiterhin Bedeutung als wichtige Quelle in der Beschreibung von Bodenfunktionen (Herche, 2019).

Die Bodenzahlen, die bis heute maßgebend sind für die monetäre Bewertung landwirtschaftlicher Immobilien, werden nach wie vor zur Beurteilung der Ertragsfähigkeit eines Bodens herangezogen. Zur Herleitung der Bodenzahlen wurden bei der Erstschätzung nach 1934 bis Mitte der 1950er Jahre Bodeneigenschaften kartiert mit deren Hilfe der jeweilige Standort innerhalb des Acker- bzw. Grünlandschätzrahmens eingeordnet werden kann (Herche, 2019). Die kartierten Eigenschaften wie Bodenart, Zustandsstufe und Entstehungsart benennen die Ursachen für ein bestimmtes Ertragsniveau und sind demnach im landwirtschaftlichen Kontext häufig aussagekräftiger als die alleinige Bodenzahl (Amelung et al., 2018). Jedoch finden die Einflüsse des Managements und der Witterung im Wert der Bodenzahl keine Berücksichtigung. Relief- und Klimaeinflüsse werden durch Zu- bzw. Abschläge zur Bodenzahl im Wert der Acker- bzw. Grünlandzahl berücksichtigt. Diese Bewertung erfolgte durch eine Einordnung der Bodenschätzer (Amelung et al., 2018). Innerhalb einer Fläche kann die Bodenzahl hilfreich für die Ansprache von Teilstandorten sein. In der Betrachtung auf Schlagebene gleichen sich Witterung und oft auch Management, weshalb man die Bodenzahl als eine Art relative Einschätzung in Bezug auf die betrachtete Fläche ansehen kann.

Da bei der Bodenschätzung im Vorfeld der Kartierung zwischen den Kulturarten Acker und Grünland unterschieden wird, findet die Bewertung von Grünland nach dem Grünlandschätzrahmen statt. Die Einteilung erfolgt in etwa analog zum Ackerschätzrahmen. Unterschiede finden sich lediglich in der Anzahl der Ausprägungen von Bodenart und Zustandsstufe. Statt der Entstehungsart des Bodens werden Wasser- und Luftverhältnisse betrachtet, die in Form der Wasserstufe abgebildet werden. Weiterhin hat die Klimaeinteilung, welche von der Jahresdurchschnittstemperatur abgeleitet wird, Einfluss auf die Grünlandgrundzahl, die analog zur Bodenzahl gehandhabt wird. Einflüsse von Vegetationsdauer, Artzusammensetzung der

Flora, Luftfeuchtigkeit und Geländegestaltung finden Berücksichtigung in der Grünlandzahl (Amelung et al., 2018).

Die Kartierung der Bodeninformationen für die Anfertigung der Bodenschätzung fand bei der Erstschätzung in etwa im Raster von 50 x 50 m statt. Angesprochen wurde das Bodenprofil in einem Meter Tiefe, da dieser Bereich als einflussreich für die Ertragsbildung angesehen wird. Mit dieser Tiefe des Bohrstockeinschlags werden in der Regel die Bodenhorizonte A, B und C erreicht. So lassen sich über häufig im A-Horizont zu findende Hinweise Aussagen über die Bewirtschaftung treffen. Hinweise im B-Horizont machen den Fortschritt der Bodenbildung abschätzbar und das Substrat, auf dem die Pedogenese stattfindet, lässt sich durch Hinweise im C-Horizont erkennen (Amelung et al., 2018).

Der Wert der Daten der Bodenschätzung ist viel diskutiert. Sie enthält eine Fülle an hoch aufgelösten Bodeninformationen, die jedoch aufgrund ihres Alters zunehmend unsicher werden. Einerseits wird diese Entwicklung durch veränderte Umwelteinflüsse bedingt, andererseits wurde die Methodik der Schätzung verbessert, weshalb sich eine Interpretation der Daten nach neuen Maßstäben schwierig gestaltet (Eckelmann et al., 2005; Herche, 2019; Kühn und Müller, 2009).

In Bezug auf die Verwendung der Bodenschätzung im *TBM* zur Lokalisierung unterschiedlicher Areale des Biomassewachstums im Grünland, können verschiedene Teile des Datensatzes für eine Interpretation herangezogen werden. Ähnlich wie durch den Acker- und Grünland-schätzrahmen die damaligen Gegebenheiten punktuell in eine Bodenzahl übersetzt wurden, können heute einzelne Attribute wie Bodenart und Zustandsstufe neu interpretiert werden. Hat sich beispielsweise ein Niedermoor in den vorangegangenen 70 Jahren durch einen sinkenden Grundwasserstand zu einem anmoorigen Mineralboden verändert, kann dies Einflüsse auf das Biomassewachstum haben. Eine landwirtschaftlich weniger nützliche Feuchtwiesenvegetation aus Binsen und Seggen ist möglicherweise wertvollen Futtergräsern gewichen und der Standort hat sich zu einer frischen Wiese entwickelt. Die Daten der Bodenschätzung können im Rahmen des *TBM* durch den Nutzer hinsichtlich dieser Veränderungen bewertet werden.

Die Inhalte der Bodenschätzung wurden über das Geoportal der Landesvermessung und Geobasisinformation Brandenburg bezogen (LGB, 2023b; Schmitz und Müller, 2020).

### **3.2.2 Sentinel-2 Satellitenbilder**

Die Satelliten der Sentinel-Flotte der ESA ermöglichen eine Abbildung der Erde im 5 Tages-Rhythmus. Der Satellit Sentinel 2A nimmt seit dem 23.06.2015 und der Satellit Sentinel 2B seit dem 07.03.2017 kontinuierlich Bilder auf, die im GeoTIFF-Format zur freien Verfügung stehen. Auf den Satelliten-Plattformen sind mehrere hyperspektrale Sensoren installiert, wobei die im pflanzenbaulichen Kontext häufig genutzten spektralen Bänder Blau (02), Grün (03), Rot (04)

und Nahinfrarot (*NIR*, 08) eine räumliche Auflösung von 10 m besitzen (ESA, 2023). Die Bilder werden mithilfe zahlreicher Methoden für die Beantwortung pflanzenbaulicher Fragestellungen genutzt. Eine weit verbreitete, einfach anwendbare Methode ist die Berechnung von Vegetationsindizes, die Aussagen über Menge und Zustand der abgebildeten Biomasse erleichtern und vergleichbar machen (Xue und Su, 2017). Aufgrund seiner weiten Verbreitung, besonders auch in der praktischen Landwirtschaft, wird in dieser Arbeit der *Normalized Difference Vegetation Index (NDVI)* verwendet (Henrich et al., 2011; Huang et al., 2021).

$$NDVI = \frac{(NIR - RED)}{(NIR + RED)}$$

Der *NDVI* quantifiziert den Reflexionsunterschied der visuellen (*VIS*), darunter den roten Wellenlängenbereich (*RED*), und *NIR*-Wellenlängenbereiche eines in spektrale Bänder aufgelösten Bildes. Der Index bewegt sich deshalb in einem Wertebereich zwischen -1 und +1. Negative Werte lassen auf Wasseroberflächen schließen, Werte nahe 0 spiegeln unbewachsenen Boden wieder, während Werte nahe 1 auf dichte und vitale Pflanzenbestände hinweisen (GISGeography, 2023). Pflanzenbestände, die sich im ungestörten Biomasseaufbau befinden, absorbieren im visuellen Wellenlängenbereich (blau, grün und rot) hohe Strahlungsmengen und reflektieren gleichzeitig stark im nahinfraroten Wellenlängenbereich (Lilienthal, 2014). Diese Bestände werden durch sehr hohe Indexwerte wiedergegeben. Dementsprechend korreliert die Vitalität von Pflanzen mit dem *NDVI* (Huang et al., 2021). Für die optimale Photosynthese-Funktion müssen den Pflanzen im vegetativen Entwicklungsstadium vor allem Wasser aber auch Temperatur, Einstrahlung, Nährstoffe sowie Kohlenstoffdioxid aus der Atmosphäre in jeweils ausreichender Menge zur Verfügung stehen (Baeumer, 1992). Interessant für die Lokalisierung von Standortheterogenität sind dabei die Faktoren, die im kleinräumigen Maßstab zu nicht optimalem Pflanzenwachstum führen. Dazu gehören das Wasser- sowie das Nährstoffangebot, da es im Gegensatz zur Temperatur, der Strahlungsmenge und der Bewirtschaftung u. a. vom kleinräumig unterschiedlichen Boden abhängig ist. Um den Einfluss des Standorts, respektive der Bodenart auf den Wert des *NDVI*s zurückführen zu können, müssen Informationen über den Zeitpunkt der Bildaufnahme im Jahresverlauf, die betrachtete Kultur, den Witterungsverlauf, sowie die Bewirtschaftung vorliegen. Eine erfolgreiche Arbeit mit Satellitenbildern und den daraus berechneten Indizes funktioniert also nur unter der Bedingung, dass diese in Bezug auf die tatsächlichen Gegebenheiten einer Fläche eingeordnet werden können. Dafür ist zunächst zu klären, für welchen Zweck die Daten gesichtet werden: Stickstoffversorgung der Pflanzen, Ertragspotenziale von Flächen, Verunkrautung, Erosionsereignisse, etc. Verschiedene Kulturen haben unterschiedliche Vegetationszeiträume, die bei der Interpretation der Indexwerte berücksichtigt werden müssen. Fehlerquellen bei der Interpreta-

tion von Indexwerten aus Satellitenbildern können darüber hinaus zum Beispiel durch Wolkenbedeckung und Wolkenschatten, sowie durch Unsicherheiten in der Georeferenzierung der Bilder entstehen (Blaschka, 2003).

Im Grünland ist eine durchgehende Bodenbedeckung zu erwarten. Der NDVI kann jedoch auch hier durch hohe Blattflächenindizes, die komplexe Artenzusammensetzung oder menschliche Eingriffe wie Striegeln im Frühjahr oder Mahd im Sommer in seiner Aussagekraft bezüglich des potenziellen Biomassewachstums eines Standorts beeinflusst werden. So sind bei der Einordnung des NDVI im Grünland beispielsweise folgende Phänomene zu berücksichtigen:

- Zur späteren Biomassemenge gegensätzliche, auf leichten Standorten stärkere Biomasseentwicklung bei Vegetationsbeginn aufgrund schnellerer Erwärmung (Klapp, 1971).
- Sättigung des Index bei hoher Biomasseentwicklung und hohen Blattflächenindizes (Lilienthal, 2014; Reddersen et al., 2014)
- Einflüsse von Bewirtschaftungsmaßnahmen wie Mahd, Walzen, Striegeln, Nachsaat oder organischer Düngung
- Temporär auftretende Staunässe
- Mögliche Beeinflussung der NDVI-Werte durch gelb blühende Pflanzenbestände (Shen et al., 2009; Sulik und Long, 2015)

Im *TBM* können erst dann mehrere Satellitenbilder kombiniert werden, wenn ihr Wertebereich in den vorher festgelegten *frame of discernment* eingeordnet wurde. Bei der Klassifikation wird der NDVI-Wert jedes Pixels der Grünlandfläche jeweils einer oder mehreren Hypothesen zugeschrieben, die ein bestimmtes Biomassewachstum repräsentieren. Die Zuordnung eines Pixelwerts zu einer Hypothese wird überzeugender, je größer die Spannweite der NDVI-Werte im Ausschnitt der Untersuchungsfläche ist. Durch diese größere Wertespanne im Feld können auch die oben genannten Einflüsse besser abgeschätzt werden.

Jedes einzelne Satellitenbild muss individuell bewertet werden, sofern keine Information darüber vorliegt, zu welchem Zeitpunkt im Jahr eine möglichst aussagekräftige Einordnung von Grünland-Standorten im Hinblick auf ihren Biomassertrag möglich ist. Angesichts der großen Auswahl an Satellitenbilddaten ist eine jahreszeitliche Eingrenzung deshalb hilfreich. Ziel ist es außerdem, durch die Auswahl des Zeitpunktes die oben aufgeführten Fehlerquellen zu reduzieren, um eine effiziente und möglichst sichere Verwendung von Satellitendaten für Fragestellungen im Grünland zu gewährleisten. Daher wird im vorliegenden Kapitel untersucht, inwieweit die Auswahl der Aufnahmetermine von Satellitenbildern im Hinblick auf die Biomasseentwicklung im Grünland unterstützt werden kann. Dazu wurde die Standortgüte vordefinierter




Bereiche anhand von *NDVI*-Werten über eine Zeitreihe hinweg betrachtet. Es soll gezeigt werden, zu welcher Jahreszeit eine sichere Differenzierung von Grünlandstandorten möglich ist und inwieweit durch Anpassungen der Interpretationskriterien auch weniger deutlich trennende Bilder als aussagekräftige Datenquellen zur Verrechnung im *TBM* dienen können.

Zur Ermittlung der aussagekräftigsten Satellitenbilder wurde für die Versuchsfläche eine Zeitreihenanalyse aller in den Wachstumsperioden von zwei Jahren entstandenen Aufnahmen durchgeführt. Aus dem Jahr 2021 standen 13 und aus dem darauffolgenden Jahr 18 Aufnahmen zur Verfügung. Für alle Bilder wurden mithilfe der Software QGIS *NDVI*-Werte berechnet (QGIS Development Team, 2023). Die Anwendung fand die an die vorhandenen Satellitenbilddaten angepasste Formel 2, die Band 04 (*RED*) und Band 08 (*NIR*) zu dem *NDVI* verrechnet.


$$NDVI_{(Sentinel-2)} = \frac{(Band\ 08 - Band\ 04)}{(Band\ 08 + Band\ 04)}$$

Anschließend wurden mithilfe einer Validierungsaufnahme  $n=24$  Punkte auf der Fläche ausgewählt, die in gleicher Anzahl den drei Wüchsigkeiten gut, mittel und schlecht zuzuordnen sind (Abbildung 6).



**Abbildung 6:** Lage der Hypothesen-Punkte der *NDVI*-Analyse. Satellitenbild der *Sentinel-2 Mission* (18.06.2021), Quelle: *ESA* (2023).

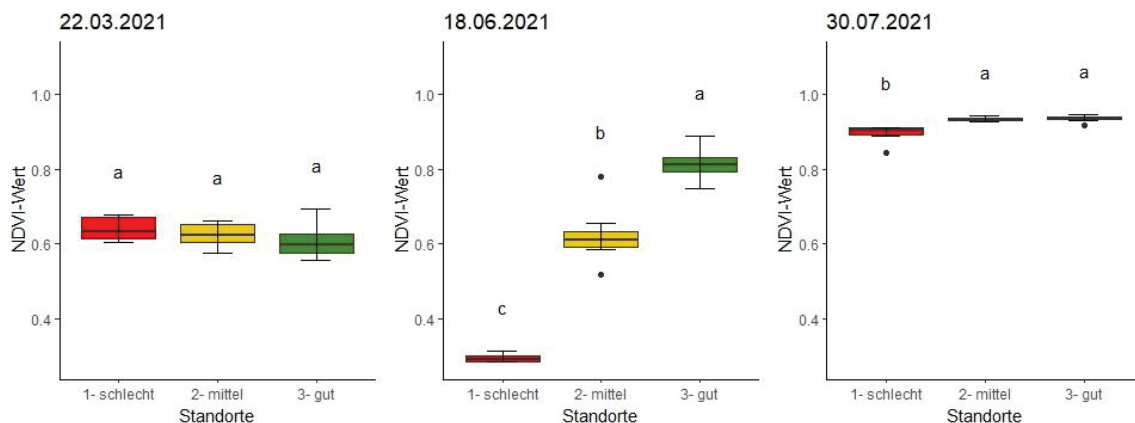
Durch Pufferung wurde um die Punkte ein Polygon mit einem Radius von 10 m erstellt. Anschließend wurden die Pixelwerte des Satellitenbildes, welche von dem Polygon bedeckt wurden, gemittelt. Somit wurde ein für die kreisförmigen Areale geltender Mittelwert der NDVI-Werte berechnet. Die  $n=8$  Punkte für jede Ertragszone wurden wiederum gemittelt und für die beiden Jahre 2021 und 2022 in einem Diagramm aufgetragen. Weiterhin wurden für jeden Termin Varianzanalysen (ANOVA) durchgeführt, um signifikante Unterschiede zwischen den drei Gruppen zu finden. Für jeden Termin mit positivem Ergebnis der ANOVA schloss sich ein *Post-Hoc-Test* (*Tukey Honest Significant Differences*) an. Die Ergebnisse der statistischen Analysen wurden, inklusive der Abbildung der Signifikanzniveaus aus den Post-Hoc-Tests, in Boxplots dargestellt. Die Auswertung der Zeitreihen erfolgte mit Microsoft Excel, die statistischen Analysen wurden mit der Statistiksoftware R durchgeführt (Microsoft Corporation, 2021; R Core Team, 2023).




**Abbildung 7: Verlauf der NDVI-Werte nach Wüchsigkeits-Gruppen im Jahr 2021. Eigene Darstellung 2023.**

Im Jahr 2021 steigen die NDVI-Werte aller Gruppen vom 25.02.2021 bis zum 09.05.2021 zunächst von 0,5 auf einen Wert von 0,9 an und fallen zum 31.05.2021 auf das Niveau von weniger als 0,6 ab. Bei keinem der vier Termine können durch die statistischen Tests signifikante Unterschiede zwischen den Gruppen festgestellt werden, obwohl sich am 22.03.2021 in der Abbildung eine leichte inverse Differenzierbarkeit der Standorte andeutet (Abbildungen 7 und 8 sowie Abbildung A-2). Bei den folgenden drei Juni-Terminen trennen sich sowohl in der Darstellung als auch bei der statistischen Untersuchung alle drei Gruppen signifikant voneinander. Im Laufe des Monats Juni liegen die Biomassezonen durch die unterschiedliche Entwicklung der NDVI-Werte am 18.06.2021 am deutlichsten voneinander entfernt. Der niedrigste Wert liegt dabei unter 0,3, wogegen sich der höchste Wert auf über 0,8 bewegt. Ungefähr

einen Monat später, am 15.07.2021, gleichen sich die Gruppen wieder auf ein nicht signifikant differenzierbares, hohes Wertenniveau zwischen 0,8 und 0,9 an. An allen sechs in der zweiten Jahreshälfte vorhandenen Terminen können wiederum alle drei Gruppen nicht eindeutig differenziert werden. Am 30.07.2021 wird der insgesamt höchste Wert mit 0.94 erreicht. Bis zum 08.09.2021 setzt sich das insgesamt hohe Wertenniveau fort. Der tiefste Wert der zweiten Jahreshälfte tritt am 28.10.2021 auf, zusammen mit einer wiederum nicht eindeutig abzusichernden inversen Ausprägung der Biomassezonen.



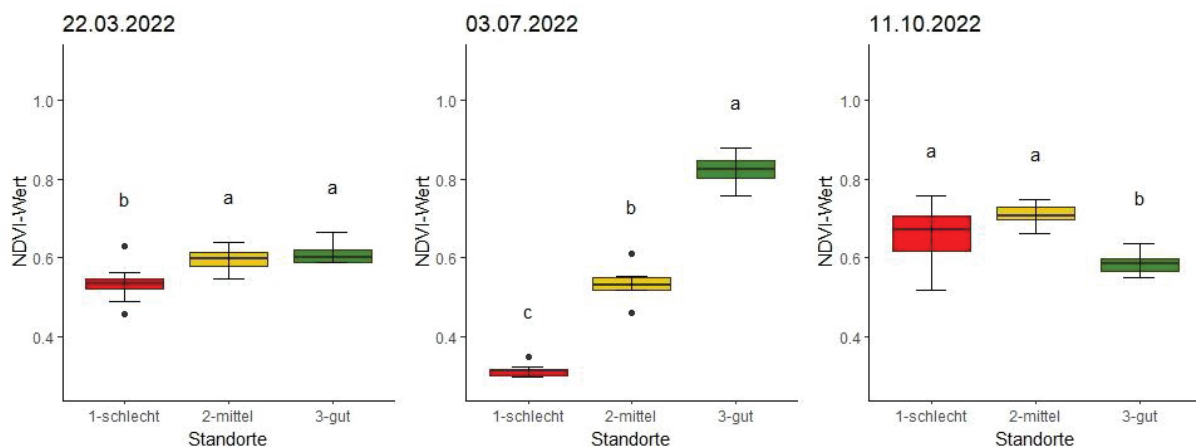
**Abbildung 8:** Darstellung der Wüchsigkeits-Gruppen an markanten Terminen (inklusive signifikanter Trennung der Gruppen) des Jahres 2021. Eigene Darstellung 2023.



**Abbildung 9:** Verlauf der NDVI-Werte nach Wüchsigkeits-Gruppen im Jahr 2022. Eigene Darstellung 2023.

Im Jahr 2022 können bereits die ersten beiden Termine Anfang März signifikant in drei Gruppen unterschieden werden, wobei die Gruppe {g} den höchsten NDVI-Wert, {m} den mittleren


und {s} den geringsten Wert aufweisen. Bis Ende März sinkt das Wertenniveau bei allen Standorten um rund 0,1, bevor es zum 16.04.2022 bei {g} und {m} auf über 0,8 und bei {s} auf 0,75 ansteigt. Das Niveau wird bis zum 09.05.2022 annähernd beibehalten. Bei den Terminen vom 22.03.2022 bis zum 09.05.2022 kann nur die Gruppe {s} mit einem signifikant niedrigeren Niveau von den anderen Werten differenziert werden. Es folgen, wiederum ab Anfang Juni bis zum 02.08.2022, sieben Aufnahmen, an denen sich die drei Gruppen statistisch signifikant und auch grafisch deutlich sichtbar auftrennen. Die Hypothese {g} weist dabei stets die höchsten Werte auf, gefolgt von {m} und {s}. Ein Sprung nach unten ist zwischen dem 03.06.2022 und dem 10.06.2022 zu beobachten. Dort sinken insbesondere die mittleren und guten Standorte um 0,3 in ihrem Niveau ab. Die Wertespanne ist 2022 am 03.07.2022 am größten (Abbildung 10). Auf eine Phase der deutlichen Trennung folgt eine längere Zeit ohne auswertbare Aufnahmen. Die anschließend vorhandenen Bilder aus dem Herbst weisen bis Ende Oktober eine starke Streuung in den Werten auf, weshalb einzelne Gruppen teilweise signifikant zu unterscheiden sind. Hier erschweren jedoch Ergebnisse, die den Hypothesen widersprechen, die Interpretation. Im November fällt wieder die Gruppe {s} auf, die auf einem niedrigen NDVI-Niveau liegend, von {g} und {m} signifikant zu unterscheiden ist.




**Abbildung 10:** Darstellung der Wüchsigkeits-Gruppen an markanten Terminen des Jahres 2022 (inklusive signifikanter Trennung der Gruppen). Eigene Darstellung 2023.

Der im NDVI wiedergegebene Biomasseverlauf auf der Fläche lässt auf den starken jahreszeitlichen Einfluss im Grünland schließen. Die Betrachtung der Zeitreihen zeigt, dass vor allem die im Frühsommer aufgenommenen Bilder eine deutliche Differenzierung unterschiedlicher Standorte zulassen. Die im Frühjahr 2021 auftretende, zu den Hypothesen leicht inverse Biomasseentwicklung lässt sich statistisch nicht absichern, deutet aber das Phänomen der schnelleren Erwärmung von Standorten mit leichten Böden gegenüber denen mit schweren, später potenziell länger wasserversorgten Böden an (Abbildung 8). 2022 kann ein solches Phänomen nicht beobachtet werden, jedoch tritt am 22.03.2022 ein plötzlicher Werteabfall in allen drei Biomassezonen auf. Eine Pflegemaßnahme, die den bereits vorhandenen Bestand

beeinflusst, wäre als Ursache denkbar. Die erste Ernte erfolgte im Jahr 2021 womöglich zwischen dem 09.05 und dem 31.05 und im Jahr 2022 vermutlich zwischen dem 03.06 und dem 10.06. Die starke Differenz der *NDVI*-Werte in auffallend kurzen Zeiträumen legt dies nahe. Es schließt sich in beiden Jahren ein Zeitraum an, in dem sich die Signaturen der Standorte sehr deutlich unterscheiden lassen. Diese Verstärkung der Standortausprägung ist möglicherweise auf die Witterungsbedingungen in diesen Zeiträumen zurückzuführen.



**Abbildung 11:** 14-tägige Wetteraufzeichnung des Jahres 2021, Standort Pritzwalk (Wetterdaten der betriebseigenen Wetterstation, PBK, 2023).



**Abbildung 12:** 14-tägige Wetteraufzeichnung des Jahres 2022, Standort Pritzwalk (Wetterdaten der betriebseigenen Wetterstation, PBK, 2023).

Ein Zusammenwirken aus der Entblätterung beim ersten Schnitt und der damit verbundenen Veränderung des Mikroklimas im Bestand, sowie aus hohen Temperaturen und oft geringen Niederschlagsmengen könnten besonders an Standorten mit geringer nutzbarer Feldkapazität zu dieser Ausprägung führen (Abbildung 11 und 12). Anzumerken ist, dass der regenreichste

Tag im Monat Juni 2021 der 30.06 war, was sich durch die Auswertung der Satellitenbilder bestätigen lässt. Bis einschließlich 18.06 können die Biomassezonen aufgrund der Trockenheit deutlich voneinander getrennt werden. Erst am 15.07.2021 bewegen sich die Signaturen aller Biomassezonen wieder in einem hohen Wertebereich.

In beiden Jahren schließen sich Zeiträume an, in denen sich die NDVI-Signaturen wieder annähern. Im regenreicheren Jahr 2021 mit einem Gesamtniederschlag von 696,5 mm geschieht das zu einem früheren Zeitpunkt als im trockeneren Jahr 2022 mit einem Gesamtniederschlag von 581,5 mm und ausgeprägten Trockenphasen im Februar, März, April und Juni (Abbildung 12). Die Einordnung der Satellitenbilder im Spätsommer und Herbst ist mit größerer Unsicherheit behaftet, was auch die statistischen Analysen zeigen. Die NDVI-Werte liegen wieder eng zusammen und signifikante Unterschiede zwischen den Gruppen treten zwar auf, grenzen jedoch nicht mehr alle Gruppen signifikant gegeneinander ab. Die NDVI-Werte der Biomassezonen wechseln von Termin zu Termin ihre Position zueinander und stimmen häufig nicht mit den vorher erwarteten Hypothesen überein. Mögliche Erklärungen für die Uneindeutigkeit der Bilder im Herbst sind vielfältig. Bei einer kühl-feuchten Witterung kann gerade in Bereichen, die eigentlich eine gute Biomasseproduktion aufweisen, eine vorübergehende Staunässe zu einer Wachstumsdepression führen. Hiervon sind insbesondere Senken und Bereiche mit tonhaltigen Böden betroffen. Zudem können niedrige Temperaturen nicht nur im Frühjahr zu einem verspäteten Vegetationsstart führen, sondern auch im Herbst für ein frühzeitiges Vegetationsende verantwortlich sein. Letzteres ist besonders auf schwereren, schnell auskühlenden Böden zu beobachten.

Zusammenfassend ist festzuhalten, dass die Varianzanalyse im niederschlagsärmeren Jahr 2022 häufiger signifikante Unterschiede zwischen den Gruppen detektieren konnte. Ein guter Zeitpunkt für die Verwendung eines Satellitenbildes als Datenquelle für Biomassezonen im Grünland scheint in den Wochen und Monaten nach dem ersten Schnitt zu liegen. Die Hypothesen wurden im Juni 2021 sowie zwischen Mitte Juni und Anfang August 2022 besonders gut von den NDVI-Werten unterstützt. Die Bilder im Frühjahr ließen oft keine gesicherten Aussagen zu (Februar bis Mai 2021, Abbildung 7), oft war nur die Biomassezone {s} mit einem niedrigeren Wert von {g} und {m} zu trennen (vgl. März bis Mai 2022, Abbildung 9). In der zweiten Jahreshälfte zeigen die Aufnahmen ab Mitte Juli 2021 keine eindeutige Hypothesenzuordnung. Auch im Jahr 2022 liegen zwischen 02.08 und 11.10 keine Aufnahmen vor und die folgenden, im Oktober und November aufgenommenen Satellitenbilder sind mit großen Schwankungen und dem Risiko einer falschen Interpretation behaftet. Die Autoren Schmidt et al. (2014) kamen zu ähnlichen Schlüssen. Für ein landwirtschaftlich ungenutztes Gebiet innerhalb der Döberitzer Heide werteten sie Satellitenbilder einer Grünlandfläche im Hinblick auf




---

ihre Aussagekraft über Landschaftsformen aus. Obwohl die Fläche durch menschliche Eingriffe nicht beeinflusst war, konnten auch sie zeigen, dass das Satellitenbildmaterial im Frühsommer am aussagekräftigsten war. Gemäß ihrer Analyse stiegen die Ungenauigkeiten bei den Bildern im Spätsommer und Herbst stark an. Für die Verwendung von Satellitenbildern im *TBM*-Algorithmus bedeuten die oben herausgearbeiteten Ergebnisse, dass sich eine Auswahl von Bildern aus dem Zeitraum Frühsommer/Sommer sehr gut für die Interpretation von Grünland eignet und deshalb nach Möglichkeit zu bevorzugen ist. Diese Ergebnisse sind jedoch zunächst auf die Region und die Jahre beschränkt, für die sie ermittelt wurden. Die Übertragbarkeit der Aspekte auf andere Grünlandgebiete ist erst zu prüfen. Es könnte sich herausstellen, dass sich in anderen Regionen mit besserem Wasserhaushalt weniger jahreszeitliche Unterschiede zeigen. Zudem ist die Verfügbarkeit von verwertbaren Satellitenbildern im optimalen Zeitraum nicht überall gesichert. Für das *TBM* bedeutet das jedoch nicht, dass die Aufnahmen, die im Vegetationsindex weniger deutliche Unterschiede zeigen, nicht verwendet werden könnten. In der Anwendung besteht immer die Möglichkeit, weniger deutlich trennenden Bildern eine geringere Überzeugung (*reliability*) zuzuordnen, oder Bereiche auszuweisen, die mehrere Hypothesen unterstützen. In Abbildung A-3 wird verdeutlicht, wie die Hypothesenzuweisung entlang des Bildverlaufs der analysierten Jahre aussehen könnte.



### 3.2.3 Topografischer Feuchteindex (TWI)

Der Topografische Feuchteindex (TWI) ist ein Modell, welches eine Einschätzung der reliefbedingten Ansammlung von Wasser in der Landschaft aufgrund von Höhenunterschieden im Gelände zulässt.



**Abbildung 13:** Darstellung des Topografische Feuchteindex der auf der Fläche Kombinat. Quelle: LGB 2023.

Dementsprechend gilt der Wert als Indikator für die reliefbedingte Bodenfeuchte (FLF-JKI, 2023). Große Werte zeigen eine hohe Bodenfeuchte an, niedrige Werte weisen auf eine geringe Feuchte hin, wie in der Abbildung 13 für die Untersuchungsfläche gezeigt wird. Der Index wird mithilfe der von einem Punkt hangaufwärts gelegenen Fläche ( $a$ ) und der am Punkt vorhandenen Hangneigung im Bogenmaß ( $\beta$ ) bestimmt (Sörensen et al., 2006).

$$TWI = \ln \frac{a}{\tan \beta}$$

Die Grundlage zur Berechnung dieser Ausgangsdaten liefert das Digitale Geländemodell (DGM), welches für Brandenburg zum kostenfreien Download zur Verfügung steht. Die räumliche Auflösung der Datenquelle beträgt 10 m (LGB, 2023c).


## 3.3 Interpretation der Datenquellen

Nach der Auswahl der Datenquellen ist die Einschätzung der Rohdaten ein weiterer Schritt, der der Fusion mit dem *TBM* vorgelagert ist. Die Rohdaten werden zunächst in gleich große räumliche Einheiten gegliedert. In der vorliegenden Anwendung bietet sich die Orientierung an den Ausmaßen der am höchsten aufgelösten Datenquellen (Satellitenbilder) an. So wurden

alle Datenquellen in 10 x 10 m große Pixel unterteilt. Die inhaltliche Vergleichbarkeit wird durch die Überführung der Rohdaten in die Hypothesen des *frame of discernment* erreicht. Dazu bedarf es einer Klasseneinteilung, welche die Werte der Datenquelle mit den Ausprägungen des Hypothesensets verbindet. Da die verschiedenen Datenquellen unterschiedliche Aussagen über den Standort treffen, muss die Klassifizierung im Rahmen der Anwendung mithilfe von Einschätzungen aufgrund von Erfahrungswissen erfolgen. Im folgenden Abschnitt werden verschiedene methodische Ansätze zur Interpretation der verwendeten Datenquellen beschrieben.

### 3.3.1 Beschreibung der Validierungsmethode

Alle in den Kapiteln 3 und 4 durchgeführten Analysen wurden mit einem Validierungsdatensatz (VD) verglichen. Verwendung fand hier ein Satellitenbild aus dem Sommer 2018. Dieses Bild wurde herangezogen, da sich darauf deutlich unterschiedliche Standorte abzeichnen. Die Differenzierung gelingt sowohl mit berechneten Biomasseindizes aufgrund einer großen Spann-



**Abbildung 14:** *True Color Image der Validierungsdatenquelle (31.07.2018). Quelle: Sentinel-2 Satellitenbild. EO-Browser 2023.*

weite niedriger und hoher Werte als auch im True-Color-Image durch verschiedene Braun- und Grüntöne (Abbildung 14).

Für die Erstellung der Validierungskarten wurde der Biomasseindex *NDVI* verwendet. Bei der Bewertung der Validierungsergebnisse bei Satellitenbildern ist zu beachten, dass durch die gleiche Erstellungsmethode, die gleichen Inhalte und eine ähnliche Aktualität der Daten von Prüf- und Validierungsmaterial, besonders in den Sommermonaten von einer Übereinstim-

mung mit den Ergebnissen auszugehen ist, die nicht zwangsläufig den tatsächlichen Gegebenheiten entsprechen muss. Damit die Ergebnisse der Zonierungen abgeglichen werden können, muss auch dem VD vorher klassifiziert werden. Um die Wiederholbarkeit der Ergebnisse sicherzustellen, wurden die Rohdaten der VD auf unterschiedliche Weisen den Hypothesen {s}, {m} und {g} zugeteilt. Die Einteilung erfolgte nach Berechnung des Histogramms aus den NDVI-Werten des Satellitenbildes. Dadurch wird sowohl die Spannweite als auch die Häufigkeiten und die Verteilung der Werte ersichtlich. Bei der „Intervallmethode“ (I) wurde der gesamte Wertebereich mit Ausnahme der Werte unterhalb des 2 % Quantils und der oberhalb des 98 %-Quantils in gleich große Intervalle unterteilt. Bei der „Quantilmethode“ (Q) wurde die Häufigkeit der Werte mit Ausnahme der 2 % kleinsten und größten Werte herangezogen, um den VD zu klassifizieren. Jede Hypothese ist dadurch in etwa gleichen Flächenanteilen vertreten. Bei der „Gruppenmethode“ (G) wurde eine qualitative Einteilung anhand der Histogrammsichtung vorgenommen. Bei Häufungen von Werten wurde eine Gruppe vermutet. Die Grenze zu einer anderen Gruppe wurde an der Stelle gezogen, an welcher die Häufigkeiten geringer waren. So wurde der häufig auftretenden Multimodalität der Verteilungen Rechnung getragen.

In den folgenden Abschnitten werden Bewertungen der entwickelten Karten durch den Vergleich mit dem dreimal unterschiedlich klassifizierten VD angestellt. Zur Beurteilung von Zusammenhängen zwischen zwei zu vergleichenden Datenquellen wurde die Kontingenztafel berechnet. Die kategorialen Daten zweier gleich großer Stichproben wurden in einer Kreuztafel gegenübergestellt, wobei die Kategorien des VD nebeneinander in einer Zeile und die Kategorien der anderen Datenquelle untereinander in einer Spalte aufgetragen wurden. Bei einem Vergleich zweier erarbeiteter Karten, in denen jeder Pixelwert in eine Hypothesenkategorie eingeordnet ist, wurde die Häufigkeit der auftretenden Hypothesenkombinationen berechnet. Bei der Betrachtung von verschiedenen Wachstumspotenzialen der Biomasse handelt es sich zusätzlich um ordinale Daten, bei denen die Reihenfolge, in der sie angeordnet sind, Einfluss auf das Ergebnis hat. Eine große Übereinstimmung der Karten besteht, wenn ein hoher Anteil der Pixel beider Datenquellen die gleiche Kategorie enthält. Die Ähnlichkeit nimmt ab, je größer die Anteile an Pixeln werden, die zwei benachbarte Hypothesen enthalten, wie zum Beispiel {s} und {m}. Bei besonders ungleichen Ergebniskarten sind die Anteile derjenigen Pixel hoch, deren Werte den genau gegenteiligen Kategorien zugeordnet sind, also {s} und {g}. Zum Vergleich zweier Ergebniskarten wird die relative Häufigkeit der übereinstimmenden Pixel berechnet. Ein zusätzlicher Weg zur Einschätzung der Übereinstimmung zweier Karten wird durch die Betrachtung der Anteile sich moderat unterscheidender und sich stark unterscheidender Pixelwerte möglich. Die Kontingenzanalyse nimmt neben der reinen Übereinstimmung der beiden Karten zudem ihren statistischen Zusammenhang in den Blick. Wenn ein größerer Zusammenhang beider Karten besteht, ist die Übereinstimmung der Ergebnisse

in der Kreuztabelle wahrscheinlicher. Zur Ermittlung des Zusammenhangs zweier kategorisierter Datenquellen wird hier der Pearson'sche Chi-Quadrat-Test angewandt. Der Chi-Quadrat-Wert wird in Abhängigkeit der Freiheitsgrade mit dem jeweiligen Wert der Chi-Quadrat-Verteilung bei einem Ablehnungsbereich von  $p=0,05$  verglichen (DATAtab, 2023; Schwarz und Kohler, 2023). Ein positives Testergebnis ist dann vorhanden, wenn der errechnete Chi-Quadrat-Wert größer ist als der kritische Wert der Chi-Quadrat-Verteilung. Bei einem positiven Chi-Quadrat-Test kann zur Beurteilung der Stärke des Zusammenhangs der Cramer's  $V$  hinzugezogen werden. Dieser Cramer's  $V$  zeigt einen starken Zusammenhang an, wenn der Wert über 0,3 liegt. Die Analyse erfolgt deskriptiv mithilfe der Statistiksoftware R (R Core Team, 2023). Die sich ergebenden Boxplots ermöglichen eine visuelle Beurteilung.

### 3.3.2 Interpretation der Bodenschätzung

Die Bodenschätzung stellt in Form der unterschiedlichen Variablen, die am Bodenprofil bestimmt werden, eine hohe Dichte an Informationen über einen Standort bereit. Neben der daraus abgeleiteten Bodenzahl können auch Einzelaspekte, wie die Bodenart und die Zustandsstufe im Hinblick auf die jeweilige Ertragsfähigkeit eines Standortes interpretiert werden. Damit lassen sich Ursachen für die Ertragsausprägung feststellen und begründen. Die Bodenschätzung spiegelt damit die multifaktoriellen Eigenschaften der Ertragsfähigkeit eines Standorts in Bezug auf seine Bodeneigenschaften wider (Amelung et al., 2018). In dieser Differenzierbarkeit von Einflussfaktoren auf die Bodengüte bei gleichzeitig flächenmäßig hoher Informationsdichte liegt der große Wert dieser Datenquelle. Bei der Anwendung sollte aber immer hinterfragt werden, ob durch menschliche Beeinflussung oder Veränderungen der Umwelt möglicherweise andere Standorteigenschaften entstanden sind, als sie zum Zeitpunkt der Schätzung gegeben waren. Auch bezüglich der Lagegenauigkeit können bei den Bodenschätzungsdaten durch größere Maßstäbe oder Digitalisierungsungenauigkeiten Schwächen auftreten (Dobers, 2002 nach Hagan et al., 1998).

Von den insgesamt 44 auf der Untersuchungsfläche „Kombinat“ durchgeführten Bohrstockeinschlägen wurden 50 Klassenflächen abgeleitet, die zwischen 79 und 27.622 m<sup>2</sup> groß sind (LGB, 2023a). Für ca. 15 % des gesamten Untersuchungsbereichs liegt keine flächenmäßige Interpretation der Bodenschätzung vor. Die Daten der Bodenschätzung weisen für die betrachtete Fläche zwei Kulturarten aus. Als die Kartierung Ende des Jahres 1952 durchgeführt wurde, wurde der mittlere Teil der Fläche als Grünland und die beiden äußeren Bereiche als Ackerland deklariert, sodass auf dem Areal zwei verschiedene Bodenansprachen auftauchen. Mittlerweile wird die Gesamtfläche als Grünland genutzt. Die gemäß der Bodenschätzung vorkommenden Bodenarten sind Sand, anlehmiger Sand, lehmiger Sand, stark lehmiger Sand, sandiger Lehm und Moor, wobei die Bodenarten Moor und lehmiger Sand in den mittleren,

schon seit jeher als Grünlandstandort angesprochenen Bereichen anzutreffen sind. In der Aggregation der Einflüsse mithilfe des Acker- bzw. Grünlandschätzrahmens finden sich im nordöstlichen Bereich der Fläche die niedrigsten Bodenzahlen mit Werten um 16. Die Spanne der Werte erstreckt sich bis hin zu Bodenzahlen um 58, die in der südlichen Mitte der Fläche aufzufinden sind.

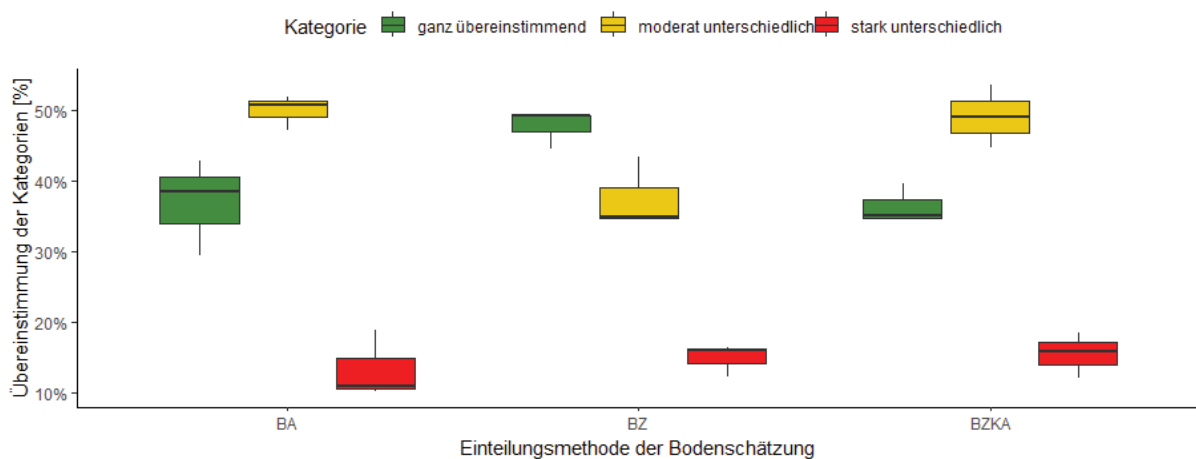
Für den Interpretationsansatz, der die Daten der Bodenschätzung zur Anwendung im *TBM* nutzbar machen soll, wurden exemplarisch drei Methoden verglichen. Im ersten Ansatz wurden die kartierten Bodenarten durch den Vergleich ihres potenziellen Wasserhaltevermögens im Hinblick auf die Biomassebildung im Grünland interpretiert (BA). Die fünf vorkommenden Mineralböden wurden mit steigenden Tongehalten der Reihe nach den Hypothesen {s}, {m}, {g} zugeordnet. Die Bodenart Moor wurde aufgrund des zu erwartenden Wasserregimes auch der Hypothese {g} zugeordnet. Ein zweiter Ansatz unterschied zunächst zwischen den ursprünglichen Kulturarten und teilte dann die Bodenzahl im Grünland und die Bodenzahl im Acker mit einem jeweils unterschiedlichen Interpretationsschlüssel den Hypothesen zu (BZ+KA). Der Wertebereich der Bodenzahlen wurde dabei in Intervalle unterteilt, wobei die Klassengrenzen der Bodenzahlen im Grünland um drei Bodenpunkte nach oben verschoben wurden. Grund für diese Entscheidung war die zunehmende Trockenheit seit der Schätzung im Jahr 1952, die vermutlich dafür sorgt, dass ehemals vernässte, minderwertige Grünlandareale inzwischen günstigere Wachstumsbedingungen bieten. Bei der dritten Methode wurden die Bodenzahlen der Gesamtfläche anhand von Erfahrungswerten klassifiziert und den Hypothesen zugeordnet (BZ). Die Festlegung der Klassengrenzen fand anhand der Sichtung des Histogramms statt. Bei den Bodenzahlen zeichneten sich dabei mehrere Gruppen ab, zwischen denen die beiden Klassengrenzen lokalisiert wurden. Aus allen drei Ansätzen wurde jeweils eine Interpretationskarte erstellt, aus der die Areale, die den jeweiligen Hypothesen zugeordnet wurden, ersichtlich sind.

Die Einschätzung, inwieweit eine Einteilungsmethode dem Biomassewachstum der Fläche entspricht, wurde vom Vergleich der unterschiedlich interpretierten Daten der Bodenschätzung mit den drei Ausprägungen der Validierungsdatenquelle abgeleitet. Um den Anteil übereinstimmender und sich unterscheidender Pixel zu ermitteln, wurde wiederum eine Kontingenztafel erstellt.

In Abbildung 15 sind die Ergebnisse des Methodenvergleichs dargestellt. Den höchsten Anteil mit dem Vergleichsdatensatz übereinstimmender Flächen weist die Methode BZ auf, bei der allein die Bodenzahl für die Zuordnung der Hypothesen diente. Bei durchschnittlich 48 % der Pixel wurde durch diese Einteilungsmethode eine Übereinstimmung der Kategorien erreicht. Durchschnittlich 37 % der Pixelwerte weisen einen moderaten Unterschied auf. Die Überein-



stimmung der Kategorien wird bei der Methode BA im Mittel nur bei 38 % erreicht. Die häufigste Kategorien-Konstellation ist die der moderaten Unterscheidung, die auf durchschnittlich 50 % der Pixelwerte zutrifft. Rund 13 % der Pixel liegen in stark unterschiedlichen Klassen. Etwa ähnliche Ergebnisse erzielt die zweifaktorielle Klassifizierung nach Kulturart und Bodenzahl. Die Übereinstimmung der Pixelwerte liegt bei einem Flächenanteil von ca. 36 % vor. Auf durchschnittlich 49 % des Areals trifft die Kategorie moderat unterschiedlich zu. Im Vergleich zu den vorgenannten Einteilungsmethoden entfällt ein etwas höherer Flächenanteil von durchschnittlich 15 % auf die Kategorie starker Unterschiede.



**Abbildung 15:** Flächenhafte Übereinstimmung der Einteilungsmethoden der Bodenschätzung mit dem Validierungsdatensatz. Eigene Darstellung 2023.

Für die Wahl der Einteilungsmethode der Bodenschätzung zur Nutzung als Datenquelle im TBM wird der maximale Wert an Übereinstimmung mit der Validierungsdatenquelle angestrebt. Aus diesem Grund kommt bei der untersuchten Grünlandfläche die Einteilungsmethode nach Bodenzahl zur Anwendung.

### 3.3.3 Interpretation von Satellitenbilddaten

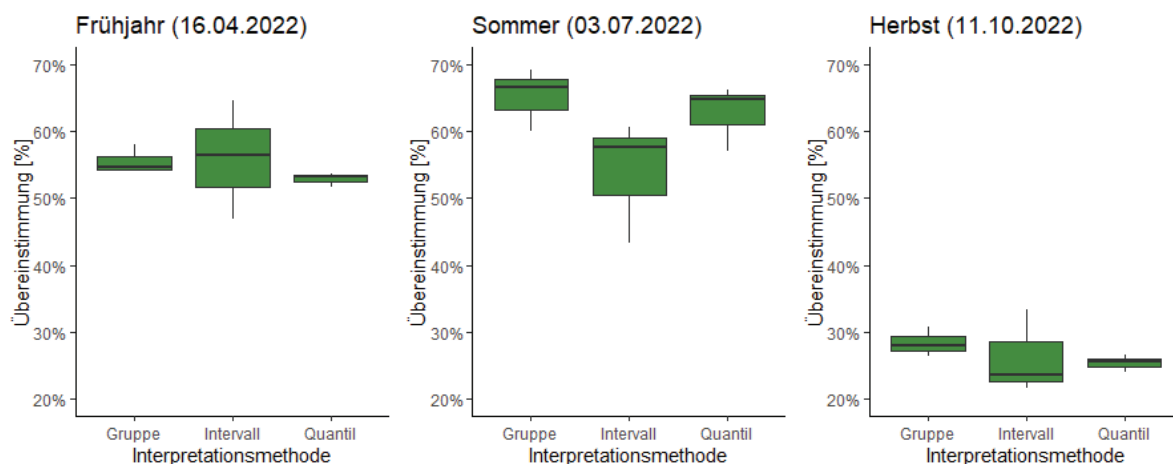
Satellitenbilder stellen durch ihre hohe zeitliche und räumliche Auflösung eine große Menge an Geodaten bereit. Da sie jedoch Messwerte von einer meist mit Vegetation bedeckten Oberfläche liefern, sind sie – anders als die Daten der Bodenschätzung – sehr stark von Klima und Witterung sowie der vorherrschenden Bewirtschaftung landwirtschaftlich genutzter Flächen beeinflusst. In Kapitel 3.2 wurde deshalb intensiv die Auswahl von Bildern nach jahreszeitlichen Aspekten beleuchtet. Ziel war es, die Bildauswahl aus Effizienzgründen einzugrenzen und möglichst aussagekräftige Termine zu wählen, um so eine verlässliche Interpretation der *NDVI*-Werte sicherzustellen. Da die Trennbarkeit der Standorte unabhängig vom Niveau der Pixelwerte gegeben sein kann, bleibt das Problem der Ermittlung der Klassengrenzen. Der starke Einfluss von Umweltfaktoren führt dazu, dass ein standardisierter Zuteilungsrahmen für *NDVI*-Werte nicht auf unterschiedliche Aufnahmetermine angewandt werden kann. Im folgenden Abschnitt wird deshalb versucht, eine Methode zur standardisierten Interpretation von Werten des Vegetationsindex zu erarbeiten. Das Ziel dabei ist, unabhängig von der Verteilung und der Spannweite von Reflexionswerten der aktuell vorherrschenden Vegetation, das gesamte Potenzial des Biomassewachstums der Standorte einschätzen zu können.

Alle folgenden Methoden der Einteilung basieren auf der Sichtung der Rasterhistogramme bzw. der Berechnung von Parametern der Häufigkeitsverteilung. Für den Vergleich von Einteilungsmethoden wurden zunächst drei unterschiedliche Satellitenbild-Termine aus dem Jahr 2022 ausgewählt, bei denen die Trennbarkeit der Standorte verschieden stark gegeben war. Die Histogramme der Bilder jedes einzelnen Termins wurden berechnet und in grafischer und numerischer Form dargestellt. Für die Interpretation wurde die Spannweite auf Werte zwischen dem 2 %- und dem 98 %-Quantil beschränkt, um den Einfluss von Extremwerten auf das Klassifizierungsergebnis abzuschwächen. Alle Hypothesen-Einteilungen erfolgten in der Reihenfolge schlecht {s}, mittel {m}, gut {g}, was einem Anstieg der *NDVI*-Werte entspricht. Dies basiert auf der Grundannahme, dass höhere *NDVI*-Werte mehr bzw. eine vitalere Biomasse repräsentieren. Verglichen wurde die Einteilung in gleich große Intervalle anhand der Werteskala innerhalb der Spannweite (I), die Einteilung in gleich große Quantile anhand der Häufigkeiten (Q) und die Einteilung in gleich große Gruppen anhand der Multimodalität der Histogramme (G) (vgl. Kapitel 3.3.1). Die Ergebnisse der Zuteilung wurden gegen die drei Varianten des VD validiert, indem die jeweilige Kontingenztafel berechnet und ausgewertet wurde.

Abbildung 16 zeigt für jeden der drei gewählten Termine die relative Häufigkeit der übereinstimmenden Pixelkategorien in Abhängigkeit von der Einteilungsmethode. Im Frühjahr zeigt die Intervallmethode tendenziell höhere Übereinstimmungswerte als die Gruppen- bzw. Quantilmethode, kann aber aufgrund ihrer starken Streuung nicht signifikant von den anderen Methoden differenziert werden. Mit der Gruppenmethode wird gegenüber der Quantilmethode an diesem Termin eine geringfügig höhere Übereinstimmung erzielt. Im Sommer bewirkt sowohl



die Gruppen- als auch die Quantilmethode eine deutlich höhere Übereinstimmung als die Intervallmethode. Dabei erzielt die Gruppenmethode die höchsten Übereinstimmungswerte. Im Herbst erreicht wiederum die Gruppenmethode die beste Zuordnung der Werte gegenüber des VD, gefolgt von der Quantilmethode und zuletzt der Intervallmethode. Jedoch bewegen sich die Unterschiede im nicht signifikanten Bereich. Das Wertenniveau ist in Herbst am niedrigsten. Die Streuung bei allen Methoden ist im Sommer am höchsten bei gleichzeitig höchstem Übereinstimmungsniveau. Auffällig ist, dass durch die Einteilung nach Intervallmethode an allen Terminen die größte Streubreite in den Ergebnissen verursacht wird.



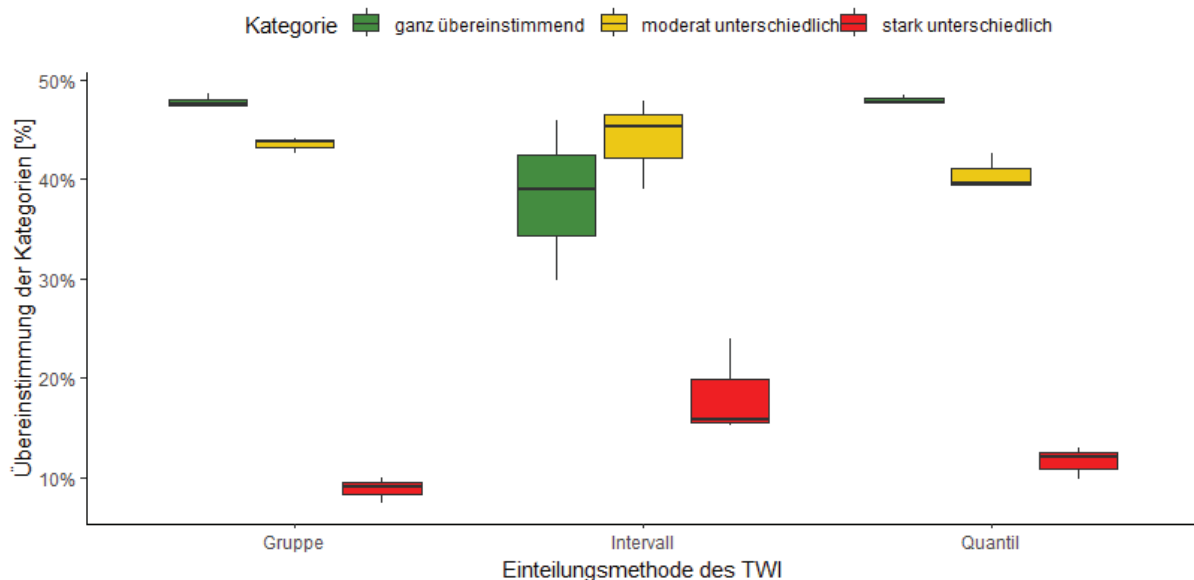
**Abbildung 16:** *Flächenhafte Übereinstimmung der Einteilungsmethoden verschiedener Satellitenbild-Termine des Jahres 2022 mit dem Validierungsdatensatz. Eigene Darstellung 2023.*

Die Ergebnisse der Methodenprüfung zur Frage der standardisierten Klassifizierung von Satellitenbildern hinterlassen ein uneindeutiges Bild. Im Sommer und im Herbst lässt sich durch die Gruppenmethode eine tendenziell höhere Übereinstimmung der Pixel erzielen, gefolgt von der Quantilmethode. Im Frühjahr wird hingegen durch die Intervallmethode der größte Anteil an gleichen Kategorie-Zuweisungen erreicht. Da die Intervallmethode jedoch bei jedem Termin die höchste Streuung der Werte aufweist, was eine gewisse Unstetigkeit in der Einteilung nach sich zieht, empfiehlt sich die Einteilung der Satellitenbilder nach der Gruppenmethode. Diese hat gegenüber den beiden rein numerischen Verfahren zudem den methodischen Vorteil, dass sie auf Signaturen in den Reflexionswerten eingehen kann, die durch tatsächliche Unterschiede in der Fläche verursacht wurden und sich durch mehrere Modalwerte im Histogramm abzeichnen können. Ein Blick auf das insgesamt erreichte Übereinstimmungsniveau zeigt deutliche jahreszeitliche Unterschiede, wobei die höchsten Werte im Sommer erreicht werden. Damit bestätigt sich die bereits im vorangegangenen Kapitel erörterte Beobachtung, dass dem Termin der Bildgebung eine zentrale Rolle zukommt.

### 3.3.4 Interpretation des TWI

Der Topografische Feuchteindex ist als relativer Index auch im Kontext der betreffenden Feldblockebene zu interpretieren. Um auch hier eine individuelle Interpretation ableiten zu können,

wurden für diese Datenquelle unter Zuhilfenahme des Histogramms wiederum die drei bereits erläuterten Verfahren, I, Q, G, zur Einteilung der Klassen verwendet. Die Zuordnung der Hypothesen {s}, {m} und {g} ist im Kontext der topografischen Wasserdynamik differenziert zu betrachten. Die Wasserversorgung im Grünland stellt einen der bedeutendsten Wachstumsfaktoren dar. Da sich jedoch nur bis zu einer gewissen Feuchtestufe hochwertige Pflanzenbestände für die Grobfutterproduktion entwickeln können, muss die für das Pflanzenwachstum optimale Bodenfeuchte in Abhängigkeit von standortspezifischen Faktoren eruiert werden. Dementsprechend ist bei der Einordnung des TWI ein regionaler Rahmen zu berücksichtigen. Auf der Untersuchungsfläche ist den Regionskenntnissen und fachkundigen Beobachtungen des Landwirts zufolge in den tieferen Lagen des Feldblocks, trotz gelegentlicher Staunässe, höherer Ertrag zu erwarten (Frädriich, 2023). Dementsprechend wurden in diesem Fall die Hypothesen {s}, {m} und {g} parallel zu den ansteigenden TWI-Werten vergeben.



**Abbildung 17:** *Flächenhafte Übereinstimmung der Einteilungsmethoden des TWI mit dem Validierungsdatensatz. Eigene Darstellung 2023.*

In Abbildung 17 sind die Ergebnisse der Einteilungsanalyse des TWI nach den bekannten Methoden Gruppe, Intervall und Quantil dargestellt. Bei der Einteilung nach Gruppe überwiegen die mit dem VD übereinstimmenden Pixel, gefolgt von den sich moderat unterscheidenden Bereichen. Stark unterschiedliche Pixelwerte treten deutlich seltener auf. Die Übereinstimmung erreicht ein Niveau von fast 50 % bei geringer Streuung der Stichprobenwerte. Vergleichbare Ergebnisse werden durch die Einteilung nach Quantilmethode erzielt, wobei der Anteil übereinstimmender Pixel leicht höher ist als bei der Gruppenmethode, der Anteil sich stark unterscheidender Bildwerte jedoch auch. Die Streuung ist vergleichbar. Eine deutlich schlechtere Übereinstimmung der TWI-Datenquelle mit dem VD ergibt sich bei der Zonierung nach der Intervallmethode. Im Mittel erreicht die Übereinstimmung bei einer starken Streuung einen Wert von nur etwa 38 %. Der Anteil sich moderat unterscheidender Pixel liegt im Bereich

von 47 % und die in der Klassenzuweisung stark verschiedenen Areale betragen etwas mehr als 15 %, wobei auch die beiden letztgenannten Ergebnisse eine starke Streuung aufweisen.


Aus den Ergebnissen lässt sich für die Datenquelle TWI ableiten, dass die Einteilungsmethode nach Intervall nicht zu empfehlen ist. Die beiden anderen Methoden sind, angesichts der geringen Anzahl an Wiederholungen, für die vorliegende Fläche als gleichwertig anzusehen. Die Quantilmethode hat dabei den Vorteil, dass sie ohne den Einfluss einer qualitativen Einteilung auskommt und dementsprechend gut automatisierbar ist. Ob diese Beobachtungen auf alle Fragestellungen und Standorte übertragbar sind, bleibt zu überprüfen.

Insgesamt werden bei der Verwendung der betrachteten Datenquellen verschiedene Übereinstimmungsniveaus der Geodaten mit dem VD erreicht. Bestimmte Satellitenbilddaten erzielen dabei die höchsten Übereinstimmungswerte, wogegen andere Satellitenbilder die geringsten Übereinstimmungswerte aufweisen. Die Datenquellen Bodenschätzung und TWI erreichen mittlere Übereinstimmungswerte.

### 3.4 Umgang mit Unsicherheiten der Geodatenquellen

Bei allen zur Verfügung stehenden Geodaten handelt es sich um grafisch unterschiedlich umgesetzte Modelle der Wirklichkeit (Legros, 2006). Objekte werden dabei entgegen ihrer Natur eindeutig definiert, um sie mit GIS erfassen zu können. Dies geht immer mit einer Vereinfachung gegenüber der Realität einher, weil einerseits die Modellierung an ihre Grenzen stößt, beispielsweise durch Einschränkungen bei der Erfassungsgenauigkeit, Vereinfachungen bei der Zustands- oder Objekterfassung oder unscharfe bzw. zu scharfe Abgrenzung von Objekten oder Standorteigenschaften (Joos, 2001; Schiewe, 2023; Walsh et al., 1997). Andererseits sind auch aufgrund der GIS-Software Vereinfachungen notwendig. Das führt dazu, dass bei der Verwendung der Datenquellen (je nach deren Qualität) eine mehr oder weniger große Differenz zwischen den enthaltenen Informationen und den realen Gegebenheiten besteht (Kaivosoja, 2019). Diese Unsicherheiten in den Datenquellen gilt es zu identifizieren und deren Einfluss bei der Ableitung von Entscheidungen zu minimieren. Die Unsicherheit im Zusammenhang mit Geodaten kann durch verschiedene Umstände hervorgerufen werden, die unterschiedlich bewertet werden müssen. Geometrische Unsicherheit oder Lageungenauigkeit bezeichnet den Umstand der Diskrepanz zwischen der Lage eines Objektes in der Natur und den aufgezeichneten Koordinaten in der Modellierung mit GIS. Diese Unsicherheit entsteht durch Messfehler bei der Bestimmung von Koordinaten. Mit kleiner werdenden Maßstäben steigt der Einfluss des durch Messung hervorgerufenen Fehlers. Eine andere Form der Lageungenauigkeit hängt mit dem Darstellungsmodell der Umwelt im GIS zusammen. In der Natur existieren fließende Übergänge zwischen Objektklassen, wie zum Beispiel die Veränderung des Reliefs zwischen Berg und Tal. Durch die in analogen Karten und im GIS verwendete trennscharfe Darstellung von Klassenflächen werden solche Übergänge nicht repräsentiert (Joos, 2001; Schauppenlehner und Muhar, 2004). Für die Beschreibung dieser Phänomene werden auch die Begriffe Zweideutigkeit oder Vagheit verwendet (Ristic et al., 2020). Semantische bzw. thematische Unsicherheit bezieht sich auf die Attribute, mit denen Objekte im GIS beschrieben sind. Sie tritt dann auf, wenn Objekte nicht eindeutig einer Objektklasse zuzuordnen sind (Fritsch et al., 1998; Hannemann, 2010; Joos, 2001). Des Weiteren kann es durch unterschiedliche Auffassungen der GIS-Anwender bezüglich der Klassenzugehörigkeit eines Objektes zu unterschiedlichen Zuordnungen von Phänomenen bei der Erstellung von Geodaten kommen. Umgekehrt gibt es auch den Fall der unterschiedlichen Objektauffassung bei späteren Nutzern der Geodaten. Darüber hinaus können Begriffe, die gegeneinander nicht scharf abgrenzbar sind oder Vorkommnisse in der Umwelt, für die keine Klasse angelegt werden kann, semantische Unschärfe hervorrufen (Joos, 2001). Zeitliche Unsicherheit in Datensätzen tritt dann auf, wenn sich die räumlich abgebildeten Objekte im Zeitverlauf verändern. Dabei unterliegen Vegetationsabbildungen wie zum Beispiel der Zustand der Biomasse auf einer landwirtschaftlichen Fläche einer großen zeitlichen Dynamik. Zeitliche Unschärfe kann je nach beabsichtigter

Modellierung durch verschiedenste Faktoren hervorgerufen werden, wobei der Grad der Veränderung von der Prozessgeschwindigkeit abhängt. So unterliegt die Biomasseentwicklung über eine Vegetationsperiode hinweg einer kurzweiligeren Veränderung als die Entstehung und Entwicklung von Böden. Vor diesem Hintergrund ist zu bewerten, ob Karten, die ja immer ein vergangenes Modell abbilden, in der Gegenwart noch eine Aussage über den Status Quo der vorhandenen Objekte zulassen.



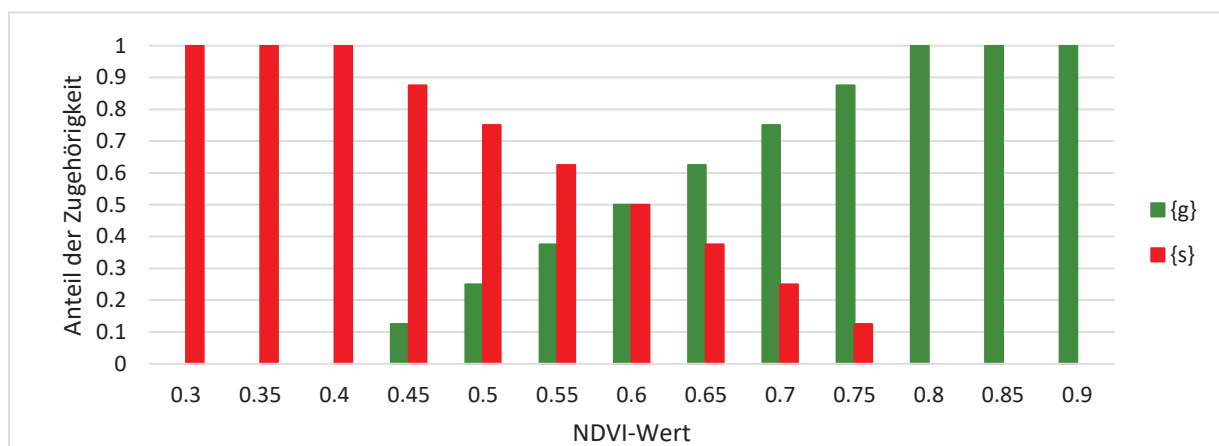
**Abbildung 18:** links: Polygon einer Fläche mit Orthophoto im Hintergrund, Quelle: © GeoBasis-DE/LGB, dl-de/by-2-0, aufgerufen am 15.01.2023, rechts: Polygon derselben Fläche unterlegt mit der digitalen Version des Schmettauschen Kartenwerks aus den Jahren 1767-1787, Quelle: © Staatsbibliothek zu Berlin – Preußischer Kulturbesitz, dl-de/by-2-0, aufgerufen am 15.01.2023

Abbildung 18 zeigt Darstellungen einer landwirtschaftlichen Fläche aus zwei zeitlichen Epochen. Auf dem linken Bild, das aus dem Jahr 2020 stammt, stellt sich die Fläche sehr homogen dar, was auf eine einheitliche Nutzung hindeutet. Auf dem rechten Ausschnitt, der aus den Jahren 1767-1787 stammt, lässt sich durch die grafische Andeutung von Bäumen eine heterogenere Nutzung der Fläche ableiten. Würde die Fragestellung an den Datensatz „Wie ist die aktuelle landwirtschaftliche Nutzung der beobachteten Fläche?“ lauten, so würde man die historische Quelle sicher nicht hinzuziehen. Lautet die Frage jedoch „Wo liegen pflanzenbauliche Standortunterschiede innerhalb der beobachteten Fläche?“, so kann die Einbeziehung der historischen Quelle unter Umständen hilfreich sein, da hier eine ehemals andere Nutzung ablesbar ist, was potenziell andere Standorteigenschaften andeutet.



### 3.4.1 Unsicherheiten an kategorialen Grenzen


In der geodatenbasierten Anwendung des *TBM* können Unsicherheiten in mehreren Aspekten berücksichtigt werden. Ein Bereich, den es zu Betrachten gilt, ist der Umgang mit Unsicherheit an Grenzen der Kategorien bei einer Klassifizierung der verwendeten Datenquellen. Die Festlegung von Grenzwerten der Zuordnung verursacht Fehler, da die Natur nicht nach mathematischer Logik in exakt trennscharfe Bereiche zu unterteilen ist (Jana und Mahanta, 2022). Zadeh entwickelte zur mathematischen Darstellung eben dieses Problems die *fuzzy logic* (1965). Er definierte das *fuzzy set* als eine Objektklasse, die ein Kontinuum von Zugehörigkeitsgraden zu einer Klasse enthält. Somit wird die Zugehörigkeit zu einer Klasse nicht mehr nur durch die Werte 0 und 1 repräsentiert, sondern kann in Anteilen gegeben sein (Nedeljkovic, 2004; Zadeh, 1965). Die Theorie der *fuzzy logic* wurde für verschiedene GIS-Anwendung weiterentwickelt, unter anderem zur Objektklassifizierung, zur Modellierung von Grenzen aber auch zur Entscheidungsunterstützung (Heiß et al., 2020; Jana und Mahanta, 2022; Nedeljkovic, 2004). Die mathematische Funktion, die die Zugehörigkeitsgrade zu einer Klasse definiert, ist die *membership function*. Am Beispiel der Klassifizierung von Werten der *NDVI*-Karten nach den Hypothesen  $\{g\}$ ,  $\{m\}$ ,  $\{s\}$  kann der Verlauf dieser Funktion illustriert werden. Es wird angenommen, dass ein *NDVI*-Wert von 0,9 eindeutig, also zu 100 % der Klasse  $\{g\}$  zugeordnet wird. Der Wert 0,3 wird zu 100 % der Klasse  $\{s\}$  zugeordnet. Werte, bei denen nicht sicher festgelegt werden kann, ob sie eher zur Hypothese  $\{g\}$  oder zu  $\{s\}$  gehören, können, wie in Abbildung 19 dargestellt, nach der *fuzzy logic* anteilig zu beiden Klassen gehören.



**Abbildung 19:** Darstellung der Zugehörigkeitsgrade zu Klassen nach der *fuzzy logic*. Lineare membership function. Eigene Darstellung 2023.

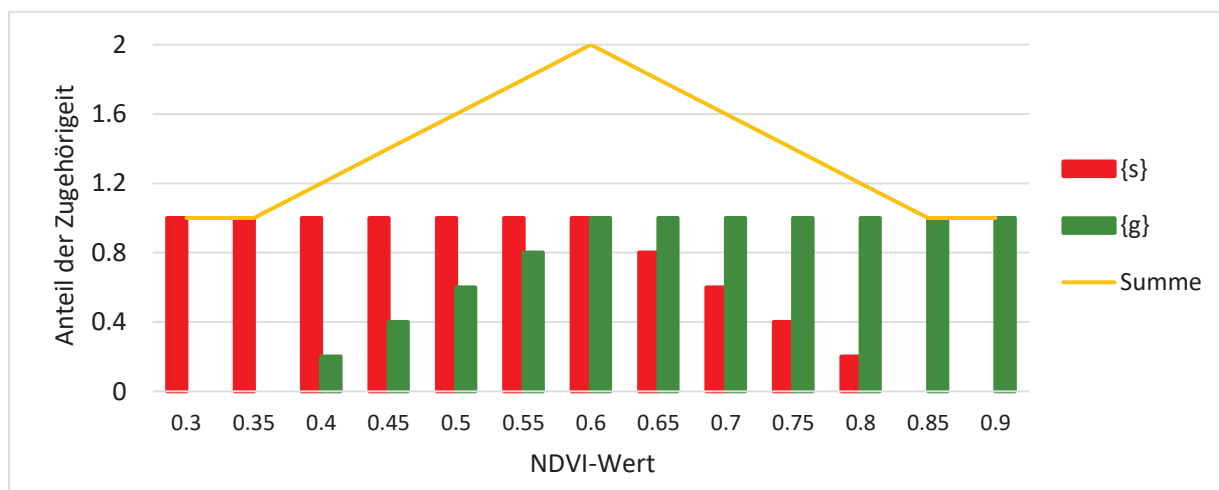
Die *membership function* kann verschiedene mathematische Verläufe annehmen, was je nach Anwendungsfall auszuwählen ist (Clark Labs, 1987-2016; Wu, 2012). Aus Gründen der Abstraktion wurde für die vorliegende Arbeit ein linearer Funktionsverlauf gewählt. Auf Flächen-

ebene wird ein Übergang nach der *fuzzy logic* von einer Grenze aus zu beiden Seiten zweidimensional in den Raum modelliert (Abbildung 20). Dazu ist es notwendig, die Breite des Übergangsbereiches zu kennen.



**Abbildung 20:** Modellierung von Übergangsbereichen um ein geschlossenes Polygon. Quelle: Joos, 2001.

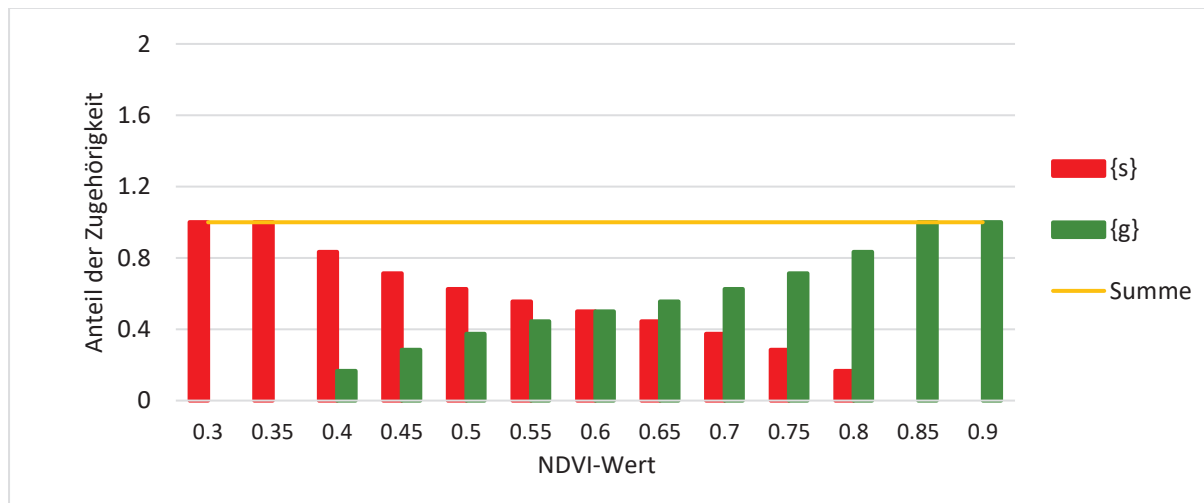
Die in der Vorbereitung auf die Datenfusion mit dem *TBM* getätigte Interpretation implementiert diese Übergangsbereiche nicht, da die Modellierung hier in einem Folgeschritt stattfindet. Die Modellierung setzt demnach direkt an der Grenze zwischen zwei Klassen in den jeweils benachbarten Raum hinein an (Abbildung 21). Somit sind die Zugehörigkeitsanteile vorübergehend größer als 1, wie an der dargestellten Summe der Werte abzulesen ist. Im Prozessablauf wird das Verhältnis beider Klassen zueinander herangezogen und auf den Wertebereich zwischen 0 und 1 übertragen.



**Abbildung 21:** Zugehörigkeitsgrade zu Klassen bei direkt angrenzenden Objekten nach der fuzzy logic. Lineare membership function. Eigene Darstellung 2023.



Abbildung 22 zeigt, wie sich die Anteile der Zugehörigkeit zu einer Klasse nach der Normalisierung verhalten. Die Ähnlichkeit zum Verlauf der membership function in Abbildung 19 ist deutlich erkennbar.



**Abbildung 22:** Zugehörigkeitsgrade zu Klassen bei direkt angrenzenden Objekten nach der fuzzy logic. Normalisierte Werte einer linearen membership function. Eigene Darstellung 2023.

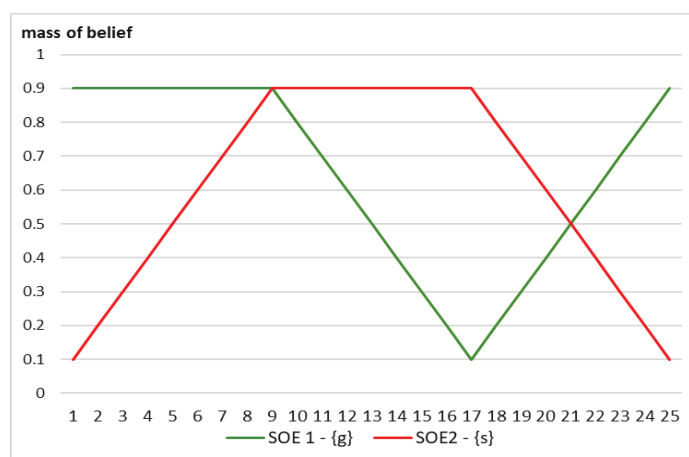
### 3.4.2 Verlässlichkeit der Datenquellen

Mit der Zuweisung der *reliability* versteht der Anwender des *TBM* die *sources of evidence* mit einer Gewichtung. Jede durch Zahlen repräsentierte Aussage spiegelt so die Überzeugung eines Betrachters wider. Hier wird also die subjektiv erwartete Eintrittsmöglichkeit einer Hypothese, die nicht zwangsläufig mit der tatsächlichen Realität eines Objekts übereinstimmt, beschrieben. Demnach kann keine einzelne Hypothese mit dem vollkommenen Überzeugungswert 1 beziffert werden, da nach der Theorie des *TBM* immer eine gewisse Restmöglichkeit besteht, dass sich der *frame of discernment* über den erwarteten Hypothesenrahmen hinaus erweitert. Eine zweite, eher pragmatische Zuordnung der *reliability* ist durch ein generelles Ranking von Datenquellen gegeben. Nach Auswahl und Interpretation der zur Fusion gewählten Geodaten können diese gegeneinander abgewogen und bewertet werden. Die Beurteilung der verschiedenen Arten von Unsicherheiten in den Datenmodellen hilft bei der Einschätzung. Beispielsweise könnte ein Satellitenbild gegenüber der Bodenschätzung, aufgrund der höheren Auflösung und der zeitlichen Aktualität, ein höheres Maß an Vertrauen erzielen.

Grundsätzlich wird jedem Element einer Datenquelle der gleiche Überzeugungswert zugeordnet. Die *reliability* kann einen Wert zwischen 0 und 1 annehmen, wobei ein höherer Wert eine größere Überzeugungskraft ausdrückt. Im Rahmen des Datenfusionsprozesses erfolgt die Zuordnung des Überzeugungswertes im Anschluss an die Klassifizierung der Datenquellen. Alle durch den Nutzer vorher für ein Pixel definierten *masses of belief* werden mit dem Grad der Überzeugung multipliziert, sodass sie in Summe alle vorher erwarteten Hypothesenwerte für die jeweilige *SOE* ergeben. Die verbleibende Differenz zu 1 wird durch die Ergänzung der

Hypothese ( $\{\Omega\}$ ) repräsentiert. Diese neue Hypothese drückt die Annahme aus, dass sich das betreffende Pixel in der Realität unter anderem auch in einem Zustand befinden kann, der bei der ursprünglichen Definition des *frame of discernment* noch nicht impliziert wurde. Auch dieser neuen Hypothese wird ein gewisser Überzeugungsgrad zugeschrieben. Das führt dazu, dass nach Hinzufügen der *reliability* jedes Element einer *SOE* durch mindestens zwei *masses of belief* wiedergegeben wird. Bei einer Fusion zweier Datenquellen kann die einem Pixel zugeordnete *reliability* ausschlaggebend für die Auswahl der Hypothese in der Entscheidungskarte sein - insbesondere dann, wenn sich zwei Hypothesen widersprechen.

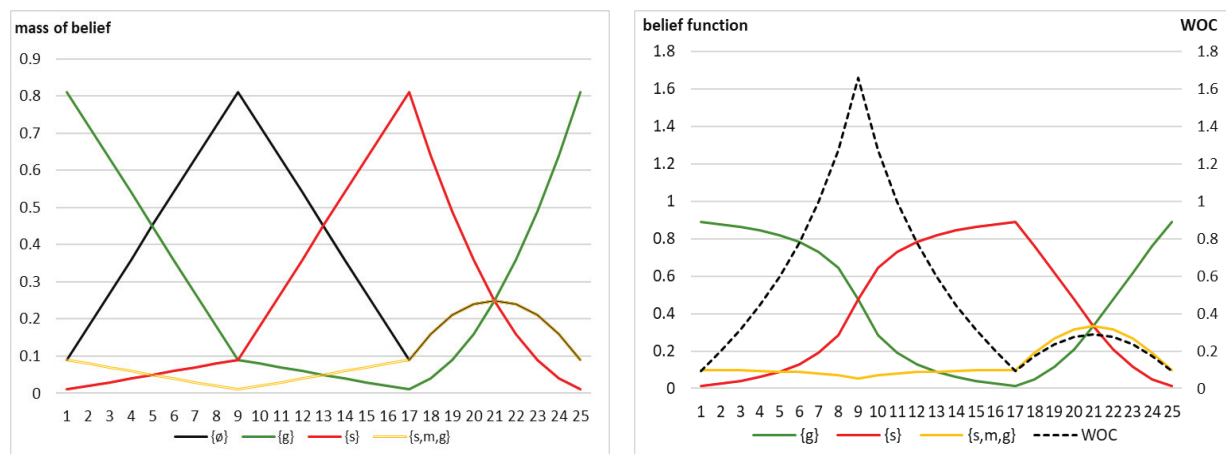
Das folgende Beispiel zeigt, dass die Bedeutung der *reliability*-Zuordnung bei zwei sich widersprechenden Hypothesen. Betrachtet werde zwei Datenquellen, bei denen sich die *MOB*-Werte der widersprüchlichen Hypothesen  $\{s\}$  und  $\{g\}$  im Verlauf verändern. Dabei entstehen 25 Konstellationen, bei denen sich die erwarteten Hypothesen beider Datenquellen unterscheiden. Abbildung 23 zeigt in Grün, inwieweit der Anwender des *TBM* von der *SOE* 1 und der Hypothese  $\{g\}$  für ein Objekt überzeugt ist. In Rot ist die Überzeugung des Nutzers von der *SOE* 2, welche die Hypothese  $\{s\}$  wiedergibt, dargestellt. Zunächst ist die *reliability* der *SOE* 1 auf hohem Niveau gleichbleibend, während die *reliability* von *SOE* 2, von einem niedrigen Wert ausgehend, bis auf das Niveau von *SOE* 1 ansteigt. Anschließend verharrt die *reliability* der *SOE* 2 auf hohem Wert, während die *reliability* der *SOE* 1 abnimmt. Zum Ende hin verliert die *SOE* 2 an Überzeugungskraft, während *SOE* 1 dazugewinnt, sodass sich die beiden Linien der *MOB*-Werte schneiden. Die dargestellten Datenquellen erhalten durch diese Zuordnung verschiedene Überzeugungswerte für eine vordefinierte Hypothese. So treten an jedem Pixel die Hypothesen  $\{g, m, s\}$  in der Ausprägung auf, die dem jeweiligen Anteil des modellierten Vertrauens entspricht.



**Abbildung 23:** Hypothesen  $\{s\}$  und  $\{g\}$  aus zwei unterschiedlichen Datenquellen, die an  $n=25$  Pixeln unterschiedliche reliabiliys aufweisen. Eigene Darstellung 2023

Für die 25 fiktiven Konstellationen wurde das Kreuzprodukt berechnet. Die Ergebnisse teilen sich zunächst auf in *masses of belief* für  $\{g\}$ ,  $\{s\}$ ,  $\{g, m, s\}$  und  $\{\emptyset\}$  (Abbildung 24, links). Die Summe aus allen *MOB*-Werten an jedem Punkt der x-Achse ergibt 1. Da von der leeren Menge

$\{\emptyset\}$  keine Entscheidung über den Zustand eines Pixels getroffen werden kann, wird diese normalisiert (vgl. Kapitel 2.3). Für jede fiktive Konstellation von Überzeugungen sind nun an jedem Pixel mehrere eindeutige Hypothesen abzuleiten. Die Konstellation, die den höchsten Wert der *belief function* erreicht, ist entscheidungsgebend. Der *weight of conflict* wurde analog zur Normalisierung berechnet und in Abbildung 24 (rechts) zusammen mit den Ergebnissen der *belief functions* aufgetragen (schwarz gestrichelt). Er ist besonders hoch, wenn bei einem Objekt zwei Hypothesen mit jeweils großem Überzeugungswert verschiedene Aussagen treffen (vgl. Konstellation Nr. 9). Der *WOC* steigt auch dann an, wenn auf einem Pixel viele gleich gewichtete Hypothesen mit moderater Überzeugung zutreffend sind (vgl. Konstellation Nr. 21).



**Abbildung 24:** Fusionsergebnisse aus den in Abbildung 23 dargestellten  $n=25$  Hypothesen-Kombinationen mit dem TBM. Links: Ergebnisse der Glaubensebene, rechts: Ergebnisse der pignistischen Ebene. Eigene Darstellung 2023.

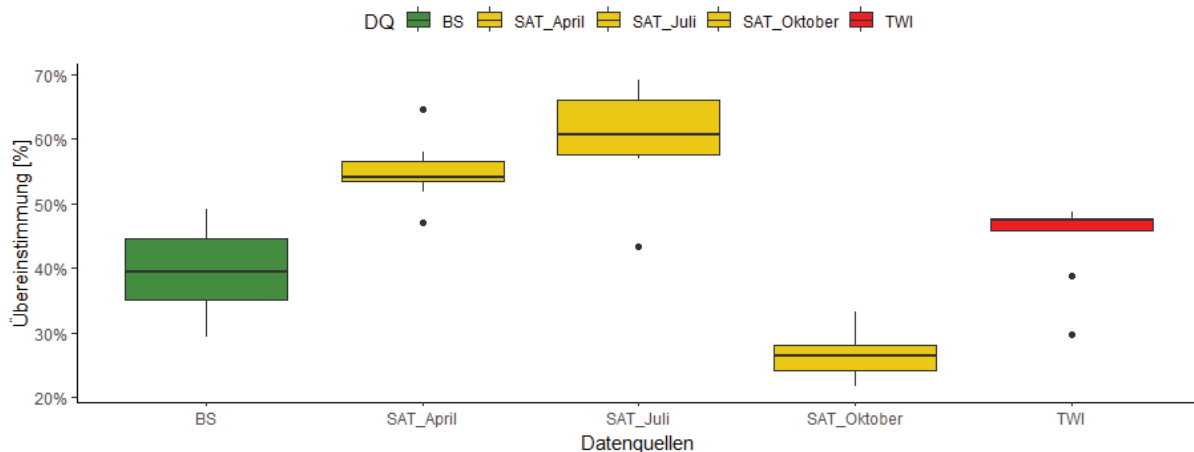
In der Abbildung 24 wird der große Einfluss der Zuweisung von Überzeugungswerten deutlich. Wird in einer Datenquelle jeweils nur eine Hypothese aktiv einem Pixel zugeordnet, ist die Zuweisung zu einer Hypothese allein davon abhängig, wie stark das Vertrauen des Anwenders in die Aussagekraft der Datenquelle insgesamt ist. Bei der Konstellation 8 beispielsweise ist der Nutzer von der SOE 1 und ihrer Hypothese  $\{g\}$  mit einem MOB von  $m=0,9$  überzeugt. Gleichzeitig ordnet er der SOE 2 mit ihrer Hypothese  $\{s\}$  den MOB  $m=0,8$  zu. Im Ergebnis fällt die Entscheidung auf die Zuordnung zur Hypothese  $\{g\}$ . Bei der Konstellation 10 ist der Nutzer von der SOE 1 nur mit einem Wert von  $m=0,8$  überzeugt, während er der SOE 2 mit dem MOB  $m=0,9$  geringfügig mehr Vertrauen zuspricht. Für die Zuordnung des Bildwerts zu einer Ergebnisklasse hat dies die Auswirkung, dass die Hypothese  $\{s\}$  aus der SOE 2 durchschlägt.

Die Mehrdimensionalität, die in den oben abgebildeten Grafiken die Verhältnisse der Aussagen verschiedener Datenquellen illustriert, ist nicht direkt in eine räumliche Karte übertragbar. So werden die Teilergebnisse für einen Punkt im Raum in jeweils unterschiedlichen Karten einer GIS-Anwendung dargestellt. In der Ergebniskarte, von welcher die Entscheidung über eine Zuordnung eines Pixels zu einer Zone abgeleitet wird, ist allein diejenige Hypothese ausschlaggebend, welche im Vergleich zu den anderen möglichen Hypothesen den höchsten

Wert der *belief function* aufweist. Abgelesen wird der höchste Funktionswert aller Hypothesenfunktionen an einer bestimmten Konstellationsnummer der x-Achse (Abbildung 24). Dieses Vorgehen erscheint dann problematisch, wenn sich - wie im oben erläuterten Beispiel ersichtlich – die *MOB*-Werte gegenteiliger Hypothesen nur geringfügig unterscheiden. Hier ist die Einbeziehung des *WOC* hilfreich bei der Einschätzung. Er ist das Maß für die Stärke des Widerspruchs, der besonders bei gleichhohen Überzeugungen von unterschiedlichen Hypothesen hohe Werte annimmt. Der *WOC* weist also auf ein wenig überzeugendes Ergebnis hin, obwohl von der Ergebniskarte eine eindeutige Entscheidung suggeriert wird. Aus diesem Grund wird ein erhebliches Maß an Mehrinformation erreicht, wenn gleichzeitig zur Ergebniskarte die Rasterkarte, in der der *WOC* für die stattgefundene Fusion ausgegeben wird, mitbetrachtet und in eine Entscheidungsfindung einbezogen wird.

Für die Parametrisierung des *TBM* zur Zonierung von Grünland bedeutet das, dass das Ergebnis stark von der Erfahrung des Nutzers und seiner Kenntnis der verwendeten Datenquellen abhängt. Schließlich ist eine der Realität entsprechende Einschätzung nur mit einer möglichst vollkommenen Abbildung der wahren Gegebenheiten auf der Fläche möglich (Schiewe, 2023). Deshalb werden bekannte Unsicherheitsfaktoren der Datenquellen (Alter, Maßstab, Aussagekraft im Hinblick auf die Fragestellung) gegeneinander abgewägt. Im Rahmen dieser Arbeit wurden Vorversuche durchgeführt, welche die Methode der Interpretation verschiedener Datenquellen in den Blick nehmen. So kann anhand der Übereinstimmungswerte aus der Kontingenzanalyse eine Aussage über eine angemessene Abstufung des jeweiligen Vertrauens in die betrachteten Datenquellen herbeigeführt werden. In Abbildung 25 ist die Übereinstimmung der fünf verglichenen Datenquellen bei der Kontingenzanalyse dargestellt. Insgesamt wurden immer drei Einteilungsmethoden der Validierungsdatenquelle und drei der geprüften Datenquelle ausgewertet. Deshalb setzen sich die abgebildeten Boxplots aus  $n=9$  Wiederholungen zusammen. Grün markiert die Bodenschätzung, die eine Übereinstimmung von durchschnittlich 40 % erreicht, ähnlich wie der rot dargestellte Topografische Feuchteindex, der im Mittel eine Übereinstimmung von etwa 47 % erzielt. Die Datenquelle TWI weist einen Chi-Quadrat-Wert unter 570 und ein Cramer's V von weniger als 0,3 auf. Es besteht somit lediglich ein mittlerer Zusammenhang zwischen der VD und dem TWI (Abbildung A-4). Die Auswertung der Satellitenbilddaten erscheint in der Grafik gelb. An den Terminen im April und Juli erreichen diese Daten eine deutlich höhere Übereinstimmung mit der Validierungsdatenquelle als die Bodenschätzung und der TWI. Auch der Chi-Quadrat-Wert von durchschnittlich 1186 (April) und 1713 (Juli) und der Cramer's V von 0,42 (April) und 0,51 (Juli) belegen einen starken Zusammenhang (Abbildung A-4). Es ist jedoch zu bedenken, dass der VD, ein Satellitenbild aus dem Sommer 2018, auf derselben Art der Bestandsaufnahme beruht und zudem in einem ähnlichen jahreszeitlichen Rahmen erstellt wurde, was eine hohe Korrelation erwar-

ten lässt. Dass das dritte Satellitenbild vom Oktober 2022 nur eine durchschnittliche Übereinstimmung mit dem VD von 26 % aufweist, unterstreicht wiederum den hohen Stellenwert des Aufnahmezeitpunkts bei Satellitenbildern. Mit den niedrigsten Durchschnittswerten für Chi-Quadrat (424) und Cramer's V (0,25) stimmt das Satellitenbild vom Oktober am wenigsten von allen fünf Datenquellen mit dem VD überein (Abbildung A-4).



**Abbildung 25:** *Flächenhafte Übereinstimmung der unterschiedlichen Datenquellen mit dem Validierungsdatensatz. Eigene Darstellung 2023.*

Werden die Ergebnisse der Kontingenzanalyse zusammengefasst und die Überlegungen zu den Sentinel-2 Satellitenbildern (Kapitel 3.2.2) mit einbezogen, so lässt sich für die Zuteilung der *reliability* folgende Abstufung ableiten:

1. Satellitenbild mit deutlich trennender Signatur und richtiger Reihenfolge der Hypothesenzuordnung
2. Satellitenbild mit schwach trennender Signatur und richtiger Reihenfolge der Hypothesenzuordnung
3. Topografischer Feuchteindex
4. Bodenschätzung
5. Satellitenbild mit falscher Reihenfolge der Hypothesenzuordnung

### 3.5 Datenverarbeitungsprozess

Der Verarbeitungsprozess, in dem das *Transferable Belief Model* für die Fusion von Geodaten angewandt wird, beinhaltet Faktoren, die vor der Anwendung definiert werden müssen. Grundlegende Parameter des *TBM* im GIS-kontext dieser Arbeit basieren auf den Publikationen von Dobers (2006, 2008). Dieser setzte sich intensiv mit der Umsetzung des Modells im bodenkundlichen und landwirtschaftlichen Kontext auseinander und definierte zu diesem Zweck allgemeingültige Rahmenbedingungen. Im Folgenden soll nun aus den Ergebnissen der Literaturrecherche, dem praktischen Methodenaneignungsprozess sowie den vorangestellten, eigenen Überlegungen und Analyseergebnissen ein Vorschlag zur Anwendung des *TBM* auf die

Erarbeitung von Biomasse-Zonenkarten im Grünland präsentiert werden. Dazu wird zunächst der Prozess der Datenverarbeitung dargelegt. Im Anschluss soll die angepasste Methode auf verschiedene Geodaten sets angewandt werden, um die Ergebnisse daraus vergleichen zu können. Dafür werden die ausgewählten Daten-Kombinationen dargestellt und eingeordnet. Zuletzt werden die Aufbereitung der Fusionsergebnisse, sowie der Validierungsprozess beschrieben.

Für die Fusion wurden zunächst die ausgewählten Datenquellen gesichtet und für die Verarbeitung in der gemeinsamen GIS-Umgebung der Software TerrSet vorbereitet (Clark Labs, 1987-2016). Die Datensichtung, einige Datenoperationen und die spätere Darstellung fand mit der *open source* Software QGIS statt (QGIS Development Team, 2023). Die verwendeten Bänder 04 und 08 der Satellitenbilder wurden dort zugeschnitten und bei Bedarf ins Koordinatenbezugssystem UTM 33-N projiziert. Die Bodenschätzung liegt im Idrisi-Vektorformat vor und wurde innerhalb von TerrSet in die Rasterdatenform überführt. Die TWI-Daten wurden vom Geodatenportal des Landes Brandenburg als freie Geodaten im 10 m Rasterformat bezogen (LGB, 2023c). Nachdem alle Ausgangsquellen als Rasterdateien in TerrSet geladen waren, konnte die Standardisierung der Daten beginnen. Dazu zählte die Angleichung der Rasterausdehnung und die Maskierung des Feldbereichs für alle verwendeten Datenquellen. Aus den Daten der Satellitenbilder mussten darüber hinaus die Werte des *NDVI* berechnet werden. Anschließend wurde das Interpretieren der Datenquellen durchgeführt. Bei diesem Schritt wurden die einzelnen Werte der Geodatenquellen mit den inhaltlich unterschiedlichen Daten in den *frame of discernment* umklassifiziert, sodass sie die vergleichbaren Hypothesen {s}, {m} und {g} enthielten. Die Zuteilung fand mit Interpretationstabellen statt, die für jede Datenquelle einzeln erarbeitet wurden (siehe Kapitel 3.3). Aus den numerischen wurden so kategoriale Datensätze mit gleichem inhaltlichem Maßstab, sodass diese untereinander vergleichbar sind. Jede Hypothese einer Datenquelle wurde in einer separaten Rasterdatei gespeichert, um weiterverarbeitet werden zu können.

Nach der Klassifizierung wurde durch die Anwendung der *fuzzy logic* die geometrische Unsicherheit an den Übergängen der Klassengrenzen modelliert. Dabei wurde die Breite des Übergangsbereichs sowie die Form des Funktionstyps definiert. In der vorliegenden Arbeit wurde eine lineare *membership function* gewählt. Die Rasterdatei mit den modellierten Klassengrenzen wurde in einen Punktvektor überführt, der dann als Textdatei exportiert wurde. Die Dateien, die einzelne Hypothesen enthalten, wurden anschließend im Programm „TBM v\_127“ wieder zu einer einzigen Datei aggregiert (Dobers, 2012). Um mehrere Quellen zu fusionieren, wurden alle Datenquellen wie beschrieben vorbereitet und dann nacheinander jeweils paarweise fusioniert. Das geschah mithilfe einer weiteren Schaltfläche der *TBM*-Software. An die-



ser Stelle des Verarbeitungsprozesses wurde den zur Kombination vorgesehenen Datenquellen die jeweilige *reliability* zugeordnet. In den Ergebnisdateien der Software sind Dateiformate vorhanden, die für die nächsthöhere Fusionsstufe weiterverwendet wurden. Der beschriebene Ablauf wiederholte sich so lange, bis alle geplanten Fusionen durchgeführt waren. Nach dem eigentlichen Fusionsprozess wurden die Ergebnisse zunächst in der Software QGIS dargestellt. Für die weitere Analyse der Ergebnisse wurden im QGIS Rasterlayer erzeugt. Diese konnten anschließend in der TerrSet-Software geladen werden. Dort wurden die Ergebnisse durch Rasteranalyseverfahren verglichen.

Die beschriebene Anwendungsmethode des *TBM* wurde bei verschiedenen Kombinationen von Geodaten durchgeführt. Dies passierte in zwei Stufen. Analysiert wurde im ersten Schritt der Einfluss der Auswahlmethode der Satellitenbilder, der Einfluss des Jahres, sowie der Wert der Integration der Bodenschätzungsdaten. Bei der Bildauswahlmethode wurde zwischen einer gezielten Auswahl von Zeitpunkten, in denen sich Standorte durch ihre *NDVI*-Werte deutlich voneinander trennen lassen, und einer Zufallsauswahl unterschieden. Bei jeder Methode wurden drei Bilder ausgewählt. Für die Repräsentation des Jahresfaktors wurde das Jahr 2021, welches ein eher feuchtes Jahr für die Region war, und das Jahr 2022, welches ein sehr trockenes Jahr darstellte, ausgewählt. Die beiden Vegetationsperioden unterschieden sich in ihrer Biomasseleistung deutlich. Im Jahr 2021 wurden in vier Schnitten 90 dt/ha TS geerntet, wogegen im Jahr 2022 nur 32 dt/ha TS in drei Schnitten geerntet wurden (Abbildung A-5). Der letzte Faktor nimmt die Daten der Bodenschätzung mit in den Blick. Bei den vier Faktorkombinationen aus Jahreseinfluss und Auswahlmethode wird die Bodenschätzung jeweils einmal ergänzt und mit der Faktorkombination, bei der auf die Bodenschätzung verzichtet wurde, verglichen. In Tabelle 4 sind die Faktorstufen und die sich daraus ergebenden Prüfglieder aufgeführt. Die Bezeichnung der Varianten setzt sich aus mehreren Bereichen zusammen. Der erste Teil drückt aus, aus welchem Jahr die verwendeten Satellitenbilder stammen („J21“ bzw. „J22“). Der folgende Buchstabe erklärt die Wahlmethode der Satellitenbilder. „A“ steht für die Auswahlmethode, wogegen „Z“ für die Zufallsmethode steht. Der letzte Teil der Bezeichnung sagt aus, ob die Bodenschätzung mit in die Fusion einbezogen wurde („1“) oder nicht („0“). Wird der TWI ergänzt so erhält die Varianten-Bezeichnung die Endung „\_TWI“



**Tabelle 4:** *Bezeichnungen und Faktoren des Variantensets 1 in Vorbereitung auf die Datenfusion mit dem TBM. Eigene Darstellung 2023*

ID	Bezeichnung	Jahr	Bildauswahl-Methode	Bodenschätzung
1	J21A_0	2021	3 x Bildauswahl FJ/SO	Nicht enthalten
2	J21A_1	2021	3 x Bildauswahl FJ/SO	Enthalten
3	J21Z_0	2021	3 x zufällige Bildauswahl	Nicht enthalten
4	J21Z_1	2021	3 x zufällige Bildauswahl	Enthalten
5	J22A_0	2022	3 x Bildauswahl FJ/SO	Nicht enthalten
6	J22A_1	2022	3 x Bildauswahl FJ/SO	Enthalten
7	J22Z_0	2022	3 x zufällige Bildauswahl	Nicht enthalten
8	J22Z_1	2022	3 x zufällige Bildauswahl	Enthalten

Im zweiten Teil des Methodentests wurde zusätzlich die Datenquelle des TWI mit verschiedenen Konstellationen fusioniert. Es wurde geprüft, inwieweit der TWI das vorhergegangene Ergebnis des am besten mit der Validierungsdatenquelle übereinstimmenden Faktorsets und das des am schlechtesten mit der Validierungsdatenquelle übereinstimmenden Faktorsets beeinflusst. Darüber hinaus wurde das Ergebnis der Fusion aus Bodenschätzung und TWI ergänzt (Tabelle 5).

**Tabelle 5:** *Bezeichnungen und Faktoren des Variantensets 2 in Vorbereitung auf die Datenfusion mit dem TBM. Eigene Darstellung 2023*

ID	Bezeichnung	Variante	TWI
9	J_x_	Kombination höchster Übereinstimmung	Nicht enthalten
10	J_x_TWI	Kombination geringster Übereinstimmung	Enthalten
11	J_x_	Kombination höchster Übereinstimmung	Nicht enthalten
12	J_x_TWI	Kombination geringste Übereinstimmung	Enthalten
13	TWI+BS	Topografischer Feuchteindex + Bodenschätzung	Enthalten

Bei der Durchführung der Fusionen wurden möglichst vergleichbare Rahmenbedingungen angestrebt. Alle erzeugten Karten und auch die Karten aus der Validierungsdatenquelle haben die gleiche Ausdehnung, das gleiche Koordinatenbezugssystem und demnach auch die gleiche Anzahl an Pixelwerten. Die Feldgrenzen wurden dabei großzügig nach innen versetzt. Mögliche Randeffekte, die besonders die Verwertbarkeit von Satellitenbildern, aber auch die Aussagekraft des TWI beeinflussen können, wurden dadurch reduziert. Die Interpretationsmethoden für die jeweiligen Datenquellen wurden entsprechend der vorangegangenen Analyse

standardisiert angewendet (vgl. Kapitel 3). Dabei wurden Satellitenbilder und TWI nach der Gruppenmethode und die Bodenschätzung anhand der Bodenzahlen eingeteilt. Zudem wurde bei der Interpretation der Datenquellen auch die Anzahl an Hypothesen einheitlich gehalten. So findet sich bei jeder Datenquelle die Unterscheidung zwischen {s}, {m} und {g}. Es wurde darauf verzichtet, Vereinigungsmengen aus den Hypothesen zu definieren (z.B. {s, m}), so dass auch in der Ergebniskarte nur die drei Ausprägungen der Pixelzuordnung auftauchen. Bei der Modellierung der Klassengrenzen wurden einheitliche Dimensionen der Übergangsbereiche zwischen diesen Grenzen gewählt. Satellitenbilder erhielten einen linear modellierten Übergangsbereich von 20 m, bei Bodenschätzung und TWI reicht der Grenzbereich 25 m in die angrenzende Klasse hinein. Die verwendeten Quellen wurden mit unterschiedlichen *reliabilities* versehen, jedoch wurden Quellen, bei denen eine vergleichbare Aussagekraft zu erwarten war, gleiche Überzeugungswerte zugeordnet. Am vertrauenswürdigsten wurden Satellitenbilder eingeschätzt, deren Standorte durch unterschiedliche *NDVI*-Werte deutlich trennbar sind (*reliability* = 0,9). Es folgen die Daten der Bodenschätzung und die des TWI mit einer *reliability* von 0,8. Satellitenbilder mit einer mittleren Trennbarkeit der Standorte aber richtiger Reihenfolge der Hypothesen erhielten eine *reliability* von 0,7. Satellitenbilder, die zwar eine Trennbarkeit von Standorten aufweisen, deren *NDVI*-Werte aber beispielsweise in inverser Reihenfolge die Standort-Hypothesen unterstützen, wurden mit einer *reliability* von 0,5 versehen.

Der erste Teil der Validierung der Ergebnisse erfolgte mit der Berechnung der Kontingenztafel zweier Rasterdateien. Die Ergebnisdatei mit den überzeugendsten Hypothesen (Entscheidungskarte) wurde wiederum mit dem VD verglichen, die bereits bei den Analysen zur Parametrisierung der Methode Verwendung fand (vgl. Kapitel 3.3.1). Analysiert wurden die Anteile der übereinstimmenden Flächenbereiche, die Anteile sich moderat unterscheidender Bereiche und die Anteile sich stark unterscheidender Bereiche. Übereinstimmende Flächenbereiche sind als diejenigen definiert, bei denen die Ergebnisdatei die gleiche Hypothese wie der VD enthält. Diese tauchen in der Ergebnisdarstellung als grüne Boxplots auf. Als gelbe Boxplots wurden die sich moderat unterscheidenden Flächenanteile visualisiert. Das sind die Areale, bei denen sich die Hypothesen um eine Klassenstufe unterscheiden. Bei den sich stark unterscheidenden Flächenanteilen handelt es sich um Konstellationen, bei denen eine Datenquelle die Hypothese {g} bestätigt, während die andere die Hypothese {s} stützt. Diese Flächenanteile wurden in Rot dargestellt. Im zweistufigen Verfahren wurden so zunächst alle Ergebnisse des ersten Variantensets verglichen. Die Datenkombination mit der durchschnittlich höchsten Übereinstimmung, sowie die mit der geringsten Übereinstimmung mit dem VD wurden ausgewählt, um anschließend exemplarisch einer weiteren Fusionsstufe im Rahmen des zweiten Variantensets zugeführt zu werden. Dabei wurde analysiert, ob die Ergänzung des TWI die Aussagekraft der Ergebniskarte verbessert. Um nähere Hinweise über den Einfluss

einzelner Parameter bei der Auswahl der Datenquellen zu erlangen, wurden Varianzanalysen durchgeführt. Für das Variantenset 1 wurden die Faktoren Jahr, Auswahlmethode und Ergänzung der Daten der Bodenschätzung untersucht. Dabei wurde eine Interaktion zwischen den Faktoren Jahr und Auswahlmethode mitbetrachtet. Im Variantenset 2 wurde die Auswirkung der Ergänzung des TWI betrachtet. Die Analysen wurden mithilfe der Statistiksoftware R durchgeführt.

Eine weitere wichtige Auswertungsrichtung betrachtet den *weight of conflict* genauer. Der Wert schätzt die Stärke des Widerspruchs bei jeder Fusionsstufe ein und wird durch die Darstellung im Raster in einen Raumbezug gesetzt (vgl. Kapitel 2.4, 3.5). Um die einzelnen Variantensets im Hinblick auf den enthaltenen Widerspruch zu analysieren, wurden in einem Vergleich zunächst die durchschnittlichen Widerspruchswerte jeder Fusionsstufe betrachtet und eingeordnet. Dazu wurde zunächst der Mittelwert des *WOC* jeder Fusionsstufe ermittelt. Anschließend wurden diese dann den Variantensets entsprechend zugeordnet und aufsummiert. Da bei den vergleichend betrachteten Varianten unterschiedlich viele Fusionen durchgeführt wurden, waren stark unterschiedliche Gesamtniveaus des Konfliktwerts zu erwarten. Um insgesamt die Vergleichbarkeit der Werte zu gewährleisten, wurden die aufsummierten *WOC*-Mittelwerte durch die jeweilige Anzahl der durchgeführten Fusionen geteilt. Zum einen wurden die Summen der *WOC*-Werte für das jeweilige Variantenset betrachtet. Zum anderen wurden, in Abhängigkeit von der Anzahl der Fusionen, die Konfliktwerte jedes Pixels innerhalb der unterschiedlichen Variantensets vergleichbar gemacht. In einem Diagramm wurden die aus den einzelnen Fusionen resultierenden, durchschnittlichen *WOC*-Werte in Form von Säulen dargestellt. Durch die übereinander gestapelten Säulen wurden die Durchschnittswerte der verschiedenen Fusionsstufen illustriert. Aus der Gliederung der Säulen wird ersichtlich, wie viele Fusionen pro Variante durchgeführt wurden. Die Fusionen der Satellitenbilder werden dabei in Grün, die der Bodenschätzung in Rot und die des TWI in Gelb dargestellt. Der gelbe Punkt, der am oberen Ende jeder Säule sitzt, markiert die Summe der durchschnittlichen Konfliktwerte jeder Variante. Die rote Linie markiert den standardisierten Konfliktwert, der über die Anzahl der Fusionen hinweg normalisiert wurde. Zur Beurteilung wurden weitere statistische Parameter wie Minimal- und Maximalwerte, sowie Modalwert und Median herangezogen. Darüber hinaus wurde ein visuell-qualitativer Ansatz der Bewertung des Konfliktwerts angestrebt, indem die Werte für jede Fusion im QGIS dargestellt wurden.










Um die Einschätzungen in die Bewertung der Ergebniskarte einzubeziehen, wurden die auf eine gleiche Fusionsanzahl normalisierten *WOC*-Werte in die Klassen „geringer Widerspruch“, „moderater Widerspruch“ und „starker Widerspruch“ eingeteilt (Tabelle 6). Die Klassifizierung der Einteilung richtet sich nach der Streuung der Konfliktwerte beider Konfliktkarten. Da die

Vergleichbarkeit der Widerspruchsstärke gegeben sein soll, wird die hier verwendete Einteilung auf beide Ergebniskarten angewandt.

**Tabelle 6:** *Klassifikations der Konfliktwerte für die Kombination mit der Ergebniskarte. Eigene Darstellung 2023.*

ID	Bezeichnung	Wertebereich des WOC
1	Geringer Widerspruch	0- 0,16
2	Moderater Widerspruch	0,16-0,32
4	Starker Widerspruch	0,32-0,5

Die visuelle Überlagerung der Konfliktkarte mit der Ergebniskarte ermöglicht die Einschätzung der Vertrauenswürdigkeit der sich ergebenden Kategorie-Zuweisungen. Die beiden Aussagen Hypothese der Ergebniskarte und Konfliktwert wurden kombiniert. Es entstanden bis zu neun neue Hypothesen-Klassen, die durch eine unterschiedliche Farbtintensität in der Ergebniskarte ablesbar sind (Abbildung 26). Geringe Widersprüche erscheinen in kräftigen Farben, starke Widersprüche dagegen in blassen Farben. Diese Methode wurde exemplarisch an ausgewählten Variantenkombinationen durchgeführt.

	1   1	Hypothese "schlecht" - geringer Widerspruch
	2   1	Hypothese "mittel" - geringer Widerspruch
	4   1	Hypothese "gut" - geringer Widerspruch
	1   2	Hypothese "schlecht" - moderater Widerspruch
	2   2	Hypothese "mittel" - moderater Widerspruch
	4   2	Hypothese "gut" - moderater Widerspruch
	1   4	Hypothese "schlecht" - starker Widerspruch
	2   4	Hypothese "mittel" - starker Widerspruch
	4   4	Hypothese "gut" - starker Widerspruch

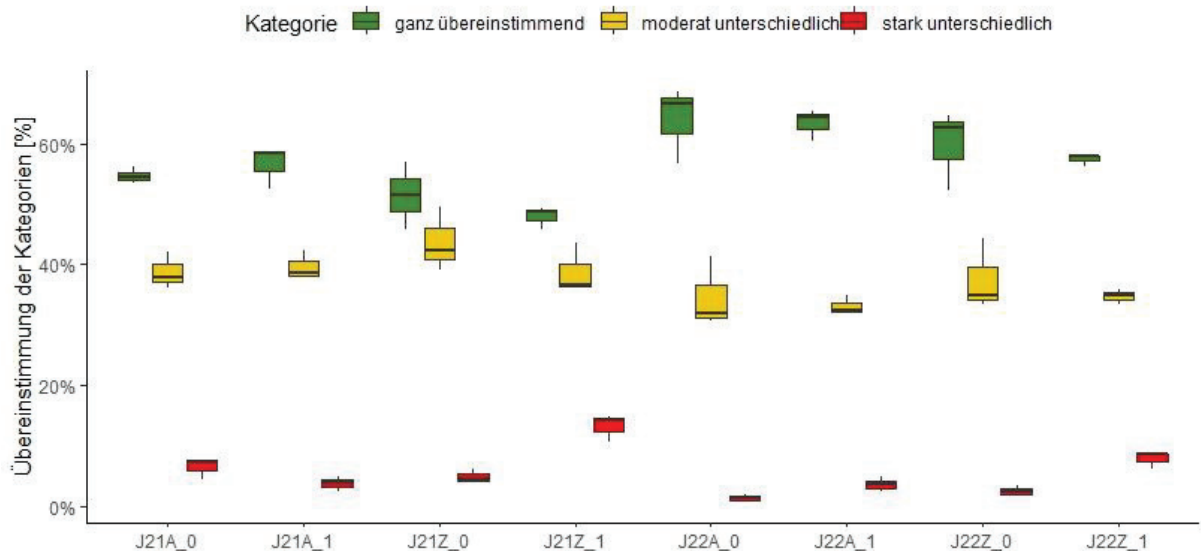
**Abbildung 26:** *Legende der Ergebniskarte mit integrierten Konfliktwerten. Eigene Darstellung 2023.*

## 4 Ergebnisse

Ausgehend von den folgenden Ergebnissen soll die Anwendungseignung des TBM für die Zonierung von Grünland hinsichtlich unterschiedlicher Biomasseleistung festgestellt werden.


### 4.1 Vergleich der Variantensets mit der Validierungsdatenquelle

Die Ergebnisse der Kontingenzanalyse des Variantensets 1 sind in Abbildung 27 grafisch zusammengefasst.



**Abbildung 27: Flächenhafte Übereinstimmung der TBM-basierten Datenfusion mit dem Validierungsdatensatz im Variantenset 1. Eigene Darstellung 2023.**

Die Varianten des ersten Sets zeigen eine Übereinstimmung von 45-70 % (grün). Die Bereiche mit moderater Übereinstimmung belaufen sich auf 30-50 % (gelb). Geringe Übereinstimmung tritt mit einer relativen Häufigkeit von 2-15 % auf (rot). Die höchste Übereinstimmung erreicht die Variante mit den gezielt ausgewählten Satellitenbild-Terminen aus dem Jahr 2022, bei der auf die Fusion mit den Daten der Bodenschätzung verzichtet wurde (J22A\_0). Zu den am wenigsten übereinstimmenden Flächenarealen führt die Fusion von zufällig gewählten Satellitenbild-Terminen aus dem Jahr 2021, bei der die Daten der Bodenschätzung ergänzt wurden (J21Z\_1). Bei dieser Fusion treten auch die meisten sich stark unterscheidenden Flächenanteile auf.



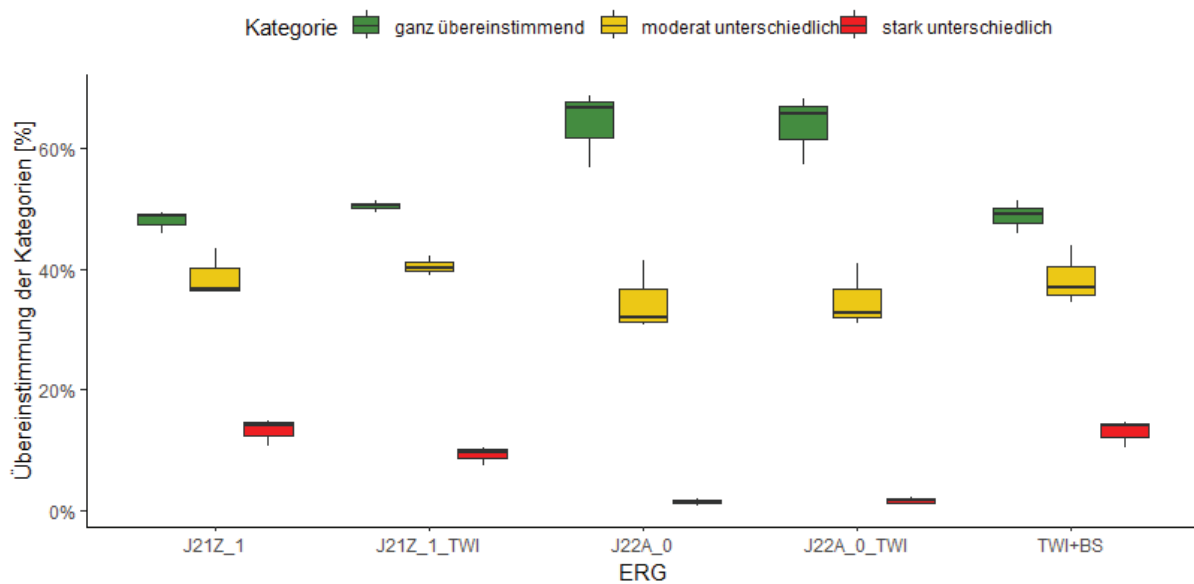
**Abbildung 28:** Einfluss des Jahres, der Wahlmethode für Satellitenbilder sowie der Integration von Bodenzahlen der Bodenschätzung auf die flächenhafte Übereinstimmung der TBM-basierten Datenfusion mit dem Validierungsdatensatz hinsichtlich Biomassewachstum. Faktoren des Variantensets 1, Eigene Darstellung 2023

Die ANOVA-Analyse der Einflussfaktoren Jahr, Auswahlmethode und Integration der Bodenschätzung ergab für das Variantenset 1, dass das für die Datenfusion verwendete Jahr den größten Einfluss auf die relative Häufigkeit übereinstimmender Pixel hatte ( $p < 0,001$ ) (Abbildung A-6). Bei den vorliegenden Varianten führen die Bilder aus dem Jahr 2022 zu deutlich höheren Übereinstimmungswerten (durchschnittlich 62 % gegenüber 53 % im Vorjahr). Die Auswahlmethode für Satellitenbilder zeigt ebenfalls einen signifikanten Einfluss ( $p < 0,05$ ). Eine gezielte Bildauswahl, die sich auf einen Aufnahmezeitraum beschränkt, bei dem sich Standorte deutlich trennen lassen, erreicht deutlich höhere Übereinstimmungswerte (durchschnittlich 58 %) als die Zufallsauswahl (durchschnittlich 54 %). In den Variantensets hatte weder die Hinzunahme noch der Verzicht auf Daten der Bodenschätzung signifikante Auswirkungen auf die Übereinstimmung mit dem Validierungsdatensatz. In der Abbildung A-6 ist ersichtlich, dass eine Interaktion der Faktoren Jahr und Auswahlmethode nicht nachgewiesen werden konnte. Die Stichprobengröße der jeweiligen Mittelwertvergleiche betrug  $n=24$ .

Weiterführende Analysen im Rahmen des Variantensets 2 wurden mit der Kombination J22A\_0, welche bei den vorangegangenen Analysen die höchste Übereinstimmung hervorbrachte und der Variante J21Z\_1, welche die geringste Übereinstimmung ergab, durchgeführt. Beide Varianten wurden um die Fusion mit dem TWI ergänzt (Abbildung 29). Eine weitere SOE-Kombination stellte die Fusion der Bodenschätzung und des TWI dar. Die Bereiche der Übereinstimmung bewegen sich auch hier zwischen 45 % und fast 70 %. Die moderate Unterscheidung liegt je nach Variante zwischen 30% und 45 %, Bereiche mit starker Unterscheidung treten mit einer relativen Häufigkeit von 2-15 % auf. Visuell sind nur sehr kleine Unterschiede zwischen den Sets zu erkennen, bei denen der TWI ergänzt wurde. Der Anteil der übereinstimmenden Pixel nahm beim Set J21Z\_1 durch den weiteren Fusionschritt leicht zu, bei der Variante J22A\_0 nahm er durch die TWI-Fusion minimal ab. Die Übereinstimmung der




Kombination aus TWI und Bodenschätzung mit der Validierungsdatenquelle erreicht Werte zwischen 45 und 50 % und liegt im Vergleich zu den Varianten J21Z\_1\_TWI, J22A\_0 und J22A\_0\_TWI zurück.



**Abbildung 29:** Flächenhafte Übereinstimmung der TBM-basierten Datenfusion mit dem Validierungsdatensatz im Variantenset 2. Eigene Darstellung 2023.

Beim Variantenset 2 wurde eine Faktoranalyse durchgeführt, die den Einfluss einer Ergänzung des TWI überprüft. Verglichen wurde der Datensatz ohne die Variante, bei der der TWI und die Bodenschätzung fusioniert wurden (Abbildung 30, links, n=12) und der Datensatz mit allen Kombinationen des Variantensets 2 (Abbildung 30, rechts, n=15). In beiden Fällen konnte kein signifikanter Einfluss der Ergänzung des TWI auf das Fusionsergebnis abgesichert werden.



**Abbildung 30:** Einfluss des TWI auf die Übereinstimmung der TBM-basierten Datenfusion mit dem Validierungsdatensatz für das Variantenset 2. Links: n=12 ohne Variante TWI+BS, rechts n=15 mit der Variante TWI+BS. Eigene Darstellung 2023.


## 4.2 Darstellung und Vergleich der Konfliktwerte

Bei jeder Fusion, die im Rahmen des Methodentests durchgeführt wurde, wurden für alle 3279 betrachteten Pixel die *weights of conflict* berechnet. Zur Erstellung der insgesamt elf verschiedenen Kombination-Varianten waren 15 Fusionen notwendig, bei denen jeweils Konflikte zur Einschätzung der Ergebniskarten verfügbar waren. In Tabelle 7 sind statistische Parameter aller Konfliktwerte aus den 12 Fusionen, die für die Erstellung des Variantensets 1 nötig waren, aufgeführt. Der Tabelle liegen die Konfliktwerte jeder einzelnen Fusion zugrunde. Fett markiert sind die Ergebnis-Varianten des Variantensets 1. Bei den statistischen Parametern fallen mehrfach hohe Mittelwerte auf. Außerdem sind einzelne hohe Modalwerte zu erwähnen (z. B. bei J21Z\_0 – SAT 1 und J22Z\_0 – SAT 1). Insgesamt zeigen die Werte zwischen Minimum und Maximum eine weite Spanne, die besonders bei den Fusionen J21A\_0 – SAT 2 und J22A\_0 – SAT 1 und SAT 2 auffällt, und einen maximalen Differenzwert von 0,72 erreicht. Die Varianten J21A\_0 – SAT 2, J21A\_1 – BS und J22A\_1-BS treten durch deutlich kleinere Modal- als Mittelwerte hervor. Bei den Varianten J21Z\_0 – SAT 1 und J22Z\_0 – SAT 1 zeigt sich das gegenteilige Verhältnis. Der Modalwert ist deutlich größer als der Mittelwert.

**Tabelle 7:** *Statistische Parameter des aus den einzelnen Fusionen resultierenden Konfliktwert-Datensatzes aus dem Variantenset 1. Fett markiert sind die Ergebnis-Varianten des Variantensets 1. Eigene Darstellung 2023*

Bezeichnung	J21A_0	J21A_0	J21A_1	J21Z_0	J21Z_0	J21Z_1	J22A_0	J22A_0	J22A_1	J22Z_0	J22Z_0	J22Z_1
Art der Fusion	SAT 1	SAT 2	BS	SAT 1	SAT 2	BS	SAT 1	SAT 2	BS	SAT 1	SAT 2	BS
Fusionsstufe	1	2	3	1	2	3	1	2	3	1	2	3
Mittelwert	0.15	0.26	0.24	0.26	0.12	0.22	0.17	0.15	0.27	0.17	0.22	0.25
Median	0.14	0.26	0.23	0.24	0.12	0.22	0.19	0.16	0.26	0.17	0.22	0.24
Modal	0.00	0.00	0.00	0.43	0.15	0.15	0.00	0.00	0.00	0.29	0.17	0.00
Minimum	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00
Maximum	0.43	0.67	0.54	0.43	0.21	0.44	0.72	0.70	0.54	0.29	0.46	0.52

In Abbildung 31 werden die mittleren Konfliktwerte des ersten Variantensets 1 näher behandelt. Deutlich erkennbar ist, dass durch jede Fusionsstufe die Gesamtsumme der Konfliktwerte steigt. Somit ist das Konfliktniveau der Varianten höher, bei denen die Bodenschätzung mit einbezogen wurde. Die Balken der Bodenschätzungs-Fusionen (gelb) zeigen mit durchschnittlich 0,24 einen größeren Konfliktwert an als die der Satellitenbild-Fusionen welche einen mittleren Konfliktwert von 0,18 aufweisen. Werden die normalisierten Konfliktwerte verglichen, so fällt auf, dass die Variante J22A\_0, die auch die größte Anzahl an mit dem VD übereinstimmenden Pixel hat, mit 0,16 den geringsten Konfliktwert aufweist. Den höchsten mittleren WOC besitzt die Variante J21A\_1 mit 0,22.



**Abbildung 31:** Mittlere Konfliktwerte jeder Fusionsstufe der Varianten aus dem Variantenset 1. Gelbe Punkte: Summe der mittleren Konfliktwerte, rote Linie: auf eine Fusion normalisierte Konfliktwerte jeder Variante. Eigene Darstellung 2023.

Werden anhand der Faktoren Jahreseinfluss, Auswahlmethode sowie Ergänzung der Bodenschätzung die Mittelwerte der durchschnittlichen WOC-Werte gebildet, zeichnen sich ähnliche Ergebnisse ab wie bei der Analyse der übereinstimmenden Areale mit dem VD (Tabelle 8, vgl. Kapitel 5.1). Wird der Mittelwert aus den Konfliktwerten in Abgrenzung der zwei verschiedenen Jahre gebildet, so ist der durchschnittliche WOC der Varianten im Jahr 2022 mit 0,25 leicht geringer als der des Jahres 2021 mit 0,27. Der Unterschied zwischen den Auswahlmethoden war noch weniger deutlich. Gezielt ausgewählten Terminen ist ein durchschnittlicher Konfliktwert von 0,26 zugeordnet, zufällig ausgewählten ein Wert von 0,27. Die mittleren Konfliktwerte bei Hinzunahme der Bodenuntersuchung liegen bei 0,27 und sind damit höher als bei Fusionen ohne Bodenschätzung (Tabelle 8).

**Tabelle 8:** Mittelwerte der weights of conflict nach Prüfgliedern der Faktoren Jahreseinfluss, Wahlmethode und Ergänzung der Bodenschätzung. Eigene Darstellung 2023

Jahr	2021	2022
		0.27
Wahlmethode	Zufallsmethode	Auswahlmethode
		0.27
Ergänzung Bodenschätzung	Enthalten	Nicht enthalten
		0.27

Tabelle 9 zeigt die statistischen Parameter der Fusionen, die im Zuge des Variantensets 2 durchgeführt wurden. Hervorzuheben ist, dass die Spannweite der Varianten in der Tabelle von links nach rechts abnimmt. Mittelwert und Median weisen dann, wenn sie aus Varianten mit einer Fusion des TWI resultieren mit durchschnittlich 0,18 ein geringeres Konfliktwert-Niveau auf als die Varianten des Variantensets 1. Die Fusionen zeigen alle einen geringeren Modalwert gegenüber dem Mittelwert. Dabei ist lediglich der Modalwert der Variante J22A\_0\_TWI deutlich größer als 0.

**Tabelle 9:** Statistische Parameter des aus den einzelnen Fusionen resultierenden Konfliktwert-Datensatzes aus dem Variantenset 2. Fett markiert sind die Ergebnis-Varianten des Variantensets 2. Eigene Darstellung 2023

Bezeichnung	<b>J22A_0</b>	<b>J22Z_1</b>	<b>J22A_0_TWI</b>	<b>J21Z_1_TWI</b>	<b>BS+TWI</b>
Art der Fusion	SAT 2	BS	TWI	TWI	TWI
Fusionsstufe	2	3	3	4	1
Mittelwert	0.15	0.25	0.18	0.18	0.17
Median	0.16	0.24	0.18	0.18	0.18
Min	0.00	0.00	0.00	0.00	0.00
Max	0.70	0.52	0.42	0.40	0.36
Modal	0.00	0.00	0.12	0.03	0.00

In Abbildung 32 sind die Konfliktwerte der einzelnen Fusionsstufen des Variantensets 2 dargestellt. Es werden Varianten mit einer sehr unterschiedlichen Anzahl von verwendeten Datenquellen verglichen. Die Kombination von zwei Datenquellen in der Variante BS+TWI steht mit einer Summe der mittleren Konfliktwerte von 0,17 der Kombination von fünf Datenquellen in der Variante J21Z\_1\_TWI mit einer Summe der mittleren Konfliktwert von 0,78 gegenüber. Die Fusionen mit dem TWI ergeben im Mittel Konfliktwerte von 0,18. Die normalisierten Konfliktwerte sind mit maximal 0,20 und minimal 0,16 insgesamt leicht niedriger als in den Varianten des Sets 1.


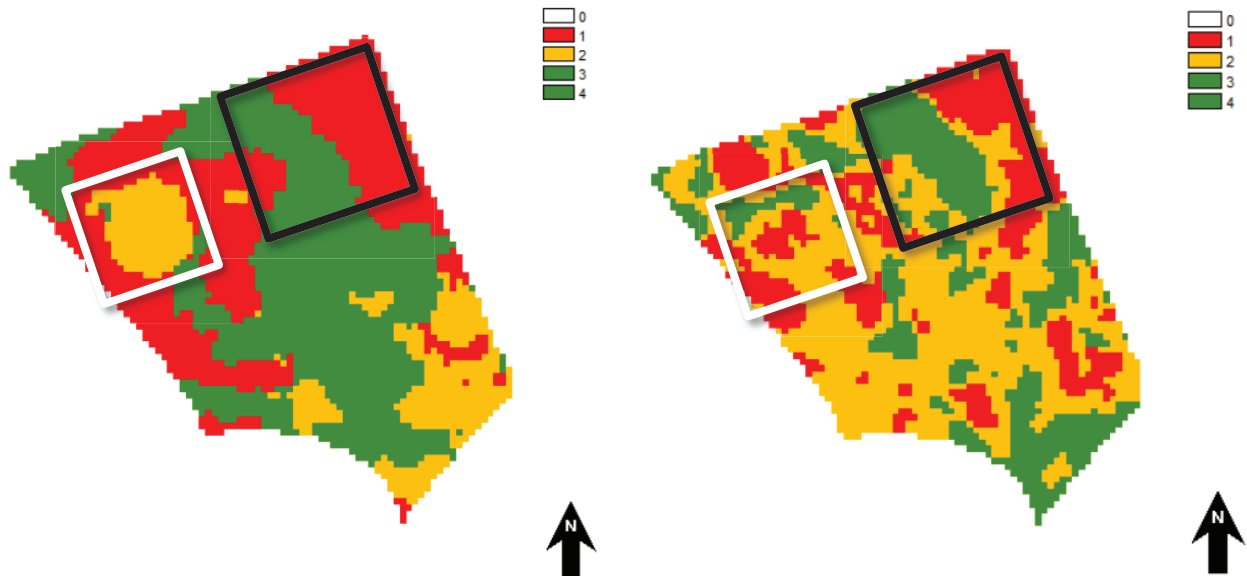


Abbildung 32: Mittlere Konfliktwerte jeder Fusionsstufe der Varianten aus dem Variantenset 2. Gelbe Punkte: Summe der mittleren Konfliktwerte, rote Linie: auf eine Fusion normalisierte Konfliktwerte jeder Variante. Eigene Darstellung 2023


### 4.3 Gegenüberstellung ausgewählter Ergebniskarten

Zur räumlichen Beurteilung der Analyseergebnisse sind in Abbildung 33 die Ergebniskarten der Varianten J21Z\_1 und J22A\_0 zu sehen. Diese stehen beispielhaft für alle durchgeführten und in Abbildung A- 7 dargestellten Varianten. Bei der Gegenüberstellung aller Ergebniskarten fällt auf, dass die Datenquellen, die mit höherer *reliability* ausgestattete Satellitenbild-Daten enthalten, heterogenere Areale zeigen. Sie erreichen auch höhere Übereinstimmungsniveaus (vgl. Kapitel 4.1). Bei den Ergebniskarten, deren Satellitenbild-Quellen aufgrund des Termins mit geringeren Überzeugungswerten ausgestattet waren, schlagen sich die Geodatenquellen Bodenschätzung bzw. TWI deutlicher in den Ergebnissen nieder, was an größeren, zusammenhängenden Zonen sichtbar ist. Auf der Untersuchungsfläche sind Bereiche vorhanden, die sich in jeder Ergebniskarte in etwa decken (schwarze Rahmen). Andere Bereiche hingegen zeigen deutlich unterschiedliche Ausprägungen, weil die Hypothesenzuweisungen sich deutlich unterscheiden (weiße Rahmen).



**Abbildung 33:** Gegenüberstellung der Ergebniskarten. Links: Ergebniskarte der Variante J21Z\_1, rechts: Ergebniskarte der Variante J22A\_0. Ähnliche Bereiche: schwarze Rahmen, unterschiedliche Bereiche: weiße Rahmen. Eigene Darstellung mit TerrSet 2023.

Bei der Betrachtung der Konfliktwerte auf der Untersuchungsfläche ist zum einen die Lage der Werte interessant, zum anderen ihre Spannweite. Die Lage gibt Auskunft darüber, an welchen Stellen sich Datenquellen in welcher Intensität widersprechen. Die Spannweite der Werte bzw. die Höhe der größten Konfliktwerte zeigt, inwieweit sich Hypothesen mit großer Überzeugung widersprechen. So wird an flächig hohen Widersprüchen ersichtlich, an welchen Stellen Konflikte zwischen Datenquellen, denen der Anwender starkes Vertrauen entgegenbringt, auftauchen (vgl. Kapitel 3.4.2).



**Abbildung 34:** Gegenüberstellung der Konfliktkarten. Links: Konfliktkarte der Variante J21Z\_1, rechts: Konfliktkarte der Variante J22A\_0. Schwarze Rahmen: unterschiedliche Lage und Stärke der Konfliktwerte, Eigene Darstellung mit TerrSet 2023.

In Abbildung 34 sind die durchschnittlichen Konfliktwerte der Varianten J21Z\_1 (links) und J22A\_0 (rechts) dargestellt. Die Konfliktkarten aller Fusionen sind wiederum in der Abbildung A-8 gelistet. In der linken Karte ist zu erkennen, dass die Konfliktwerte farblich nicht so deutlich

ausgeprägt sind wie in der rechten Karte. Durch die gleiche verwendete Skala wird die geringere Spannweite der Konfliktwerte in der linken Karte deutlich. Das bedeutet für rechts zwar mehr Bereiche mit moderaten *WOC-Werten*, dafür aber weniger hohe Widersprüche. Beim direkten Vergleich der beiden Karten werden auch Unterschiede in der Lage hoher und geringerer Konfliktwerte deutlich (schwarze Rahmen). Werden die Karten der Konfliktwerte im Zusammenhang mit den Ergebniskarten betrachtet, fällt auf, dass sich höhere Konfliktwerte, besonders in der Variante J22A\_0, oft in Grenzbereichen von zwei Klassen befinden. Dort wurden im Rahmen der Methode einerseits abnehmende Überzeugungen modelliert, andererseits werden in Übergangsbereichen die Hypothesen von Datenquelle zu Datenquelle etwas unterschiedlich zugewiesen. Dieser Effekt wird in der Variante J21Z\_1 weniger deutlich, da hier in den *SOEs* ganze Klassenflächen unterschiedlichen Hypothesen zugeordnet wurden und deshalb Konfliktwerte flächendeckender auftreten. Die Betrachtung der Histogramme beider Karten lässt weitere Einordnungen der Konfliktwerte zu. Aus der Abbildung 35 (unten) ist abzuleiten, dass die Werte der Variante J21Z\_1 einer Normalverteilung sehr nahekommen. Es gibt kaum Pixel ohne Widerspruchswert. Auffallend ist eine markante Häufung der Konfliktwerte rund um 0,24 und eine weitere, etwas weniger starke Häufung rund um den Wert 0,2. Die Spannweite liegt zwischen 0 und 0,32. Die Werte der Variante J22A\_0 zeigen sich unregelmäßiger verteilt und lassen keine Ähnlichkeit mit der Normalverteilung erkennen. Sie streuen stärker und liegen in einem Bereich zwischen 0 und 0,47 (Abbildung 35 oben). Der Modalwert liegt bei 0 und die weitere Verteilung setzt sich eher aus verschiedenen Häufungen an Einzelwerten zusammen. Die zweit- und dritthäufigsten Werte liegen dabei rund um 0,18 und 0,23.




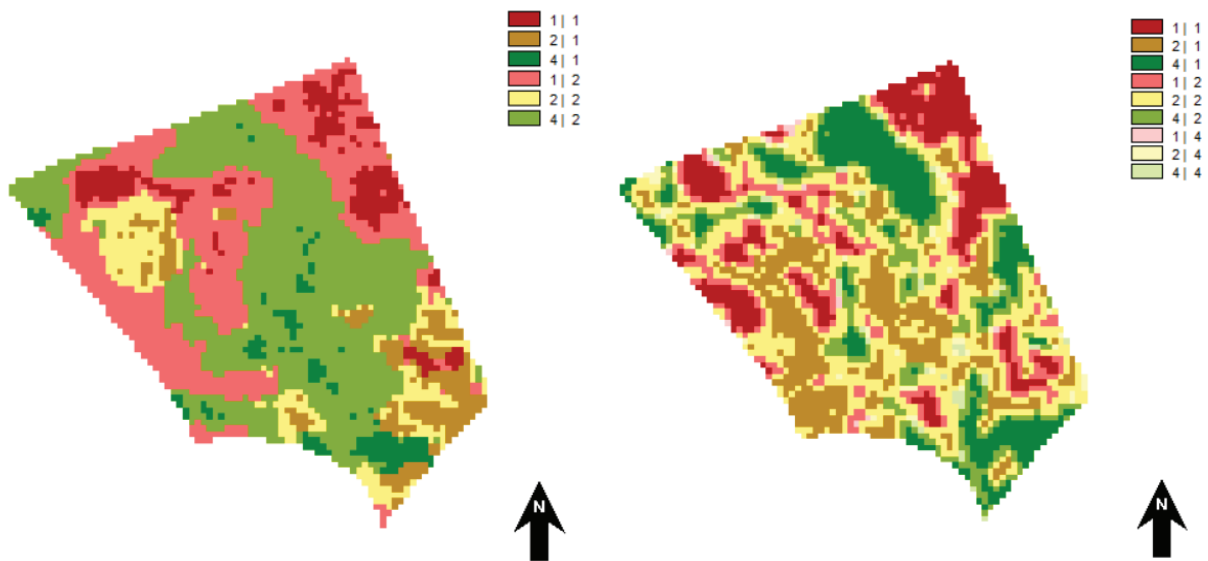


Abbildung 35: Histogramme der Konfliktwertkarten. Oben: Variante J22A\_0, unten: Variante J21Z\_1. Eigene Darstellung mit TerrSet 2023.

Abbildung 36 zeigt die Integration der Konfliktwerte in die Ergebniskarten. Der höhere Informationsgehalt, der durch die *WOC-Werte* vorhanden ist, wird dadurch abgebildet. Für die Variante J21Z\_0 ergab diese Verschneidung große Bereiche mit moderaten Widersprüchen und kleine Bereiche mit geringen Widersprüchen. Es kommen keine Bereiche vor, in denen starke Widersprüche auftreten. Die Karte der Variante J22A\_0 weist dagegen deutlich größere Areale auf, die geringe Widersprüche enthalten. Bereiche mit moderaten Widersprüchen treten besonders in Übergangsbereichen zwischen den zwei gegensätzlichen Hypothesen {g} und {s} auf. Vereinzelt kommen in der Datei auch Werte mit starken Widersprüchen vor.



**Abbildung 36:** Gegenüberstellung der Ergebniskarten mit integrierten Konfliktwerten. Links: Variante J21Z\_1, rechts: Variante J22A\_0. Kräftige Farben: hohe Überzeugung von den Hypothesen, blasser Farben: geringe Überzeugung von den Hypothesen. Eigene Darstellung mit TerrSet 2023.

## 5 Diskussion

Vor dem Hintergrund der Notwendigkeit einer effizienteren und umweltverträglicheren Grünlandnutzung wurde als zentrales Ziel dieser Arbeit die Einschätzung des Potenzials der Fusion von Geodaten mithilfe des Transferable Belief Models formuliert. Eine Optimierung im Grünland, die gleichzeitig ökonomischen und ökologischen Anforderungen gerecht wird, wird unter anderem in der standortspezifischen Ansprache der Fläche gesehen (Isselstein und Michaelis, 2015). Zwischen der meteregenauen Differenzierung von Standorten mithilfe von Geodaten und der Umsetzung von Management-Entscheidungen liegt jedoch die Schnittstelle der Interpretation der Geoinformationen. Diese erfolgt im Rahmen der Klassifizierung von Flächen, von der anschließend Entscheidungen abgeleitet werden. Um eine Klassifizierung zu erreichen, die den komplexen Systemen der Kulturlandschaft bestmöglich entspricht, ist die Betrachtung vielfältiger Einflussfaktoren, die durch unterschiedliche Messungen oder Kartierungen angesprochen werden, sinnvoll (Ahmad et al., 2022). Klassifikationsmethoden setzen dabei auf die Verarbeitung und Kombination großer Datenmengen. Viele Algorithmen basieren auf Methoden der künstlichen Intelligenz (KI) und des maschinellen Lernens. Diese Systeme sind auf die ausreichende Verfügbarkeit repräsentativer Daten zum Training ihrer Modelle angewiesen. Für landwirtschaftliche Anwendungen werden deshalb die Dateninfrastruktur im ländlichen Raum, sowie Vorbehalte seitens der Landwirte im Hinblick auf Datenschutz als limitierende Faktoren angesehen (Bosse et al., 2023). Das *TBM* könnte gerade für landwirtschaftliche Problemstellungen gut geeignet sein, da es bereits mit wenigen und nicht flächendeckend verfügbaren bzw. unvollkommenen Daten auskommt, dafür aber Erfahrungswissen des Nutzers mit einbezieht. So werden auf nachvollziehbare Weise Ergebnisse erzielt, die als Entscheidungsgrundlage dienen können. Das *TBM* kann dank seiner Flexibilität Unsicherheiten in Entscheidungsprozessen berücksichtigen, was im landwirtschaftlichen Kontext häufig erforderlich ist (Hanf, 1976; Vallentin et al., 2020). Das Modell ermöglicht es, potenziell jede verfügbare Informationsquelle unabhängig von ihrer Qualität zu nutzen, sofern eine plausible Interpretation der Inhalte erarbeitet werden kann. Das wird durch verschiedene Werkzeuge erreicht, durch die diese Unsicherheiten mithilfe von Expertenwissen eingeordnet werden (Ristic et al., 2020). Durch die Möglichkeit der Berücksichtigung langjähriger Erfahrungen und verschiedenster Datenquellen ist das Modell nicht zwingend auf eine Mindestmenge an Daten angewiesen. Inwieweit das *TBM* für die Anwendung auf Grünlandflächen geeignet ist, welche Faktoren auf eine erfolgreiche Anwendung Einfluss nehmen und wie der Konfliktwert interpretiert werden kann, wird im folgenden Abschnitt diskutiert.

## 5.1 Eignung des Transferable Belief Models zur Unterstützung einer teilautomatisierten Zonierung von Arealen unterschiedlichen Biomassewachstums im Grünland

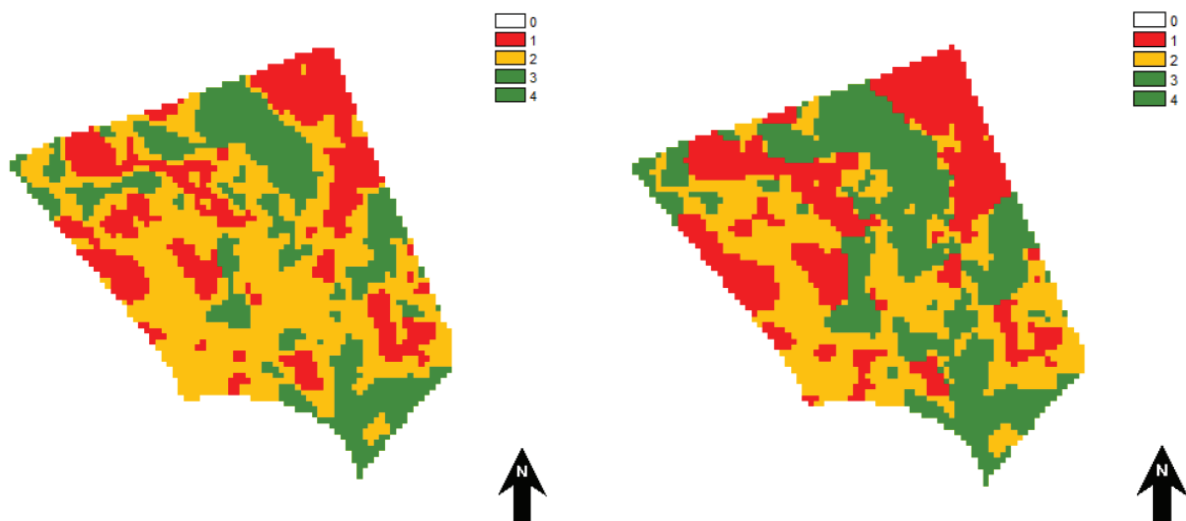
Nachdem in den Arbeiten der Autoren Dobers und Vallentin die Anwendung des TBM auf die Klassifizierung von Ackerflächen im Hinblick auf verschiedene pflanzenbauliche Fragestellungen gezeigt werden konnte, wird in der vorliegenden Arbeit die Übertragung auf Grünlandflächen thematisiert (Dobers, 2006, 2008; Vallentin et al., 2020). In Kapitel 3 wurde eine Anwendungsmethode des *TBM* im Rahmen der Ermittlung des Biomasseaufwuchses im Grünland erstellt. Eine Auswahl an Geodaten wurde anschließend aufbereitet, indem die enthaltenen Rohdaten durch eine Interpretation in Hypothesen klassifiziert wurden, die der Fragestellung entsprechen. Ziel war die Abgrenzung von Zonen des Biomassewachstums auf einer Grünlandfläche. Durch die Einschätzung einer erfahrenen Person wurden Interpretationsschemen für die vorhandenen Geodaten entwickelt, die auf Überzeugungswerten basieren. Die subjektive Einflussnahme des Anwenders auf die Rahmenbedingungen der Fusion lassen sich dabei in mehreren Schritten im Vorbereitungsprozess wiederfinden und sind transparent nachvollziehbar. Mit der Auswahl der zu verwendenden Datenquellen, der Festlegung der Interpretationstabelle für die Geodaten und der Zuordnung der *reliability* sind die zentralen Punkte für das Einfließen von Erfahrungswissen genannt. Die Modellierung der Übergänge zwischen Klassenflächen mit der *Fuzzy-Logic*, sowie die Anpassung der Außengrenzen durch den Maskenlayer sind bei der Arbeit mit Geodaten im landwirtschaftlichen Kontext als ergänzende Methoden der Quantifizierung von Unsicherheit anzusehen. Durch den teilautomatisierten Charakter der Zonierung von Arealen bleiben die Ergebnisse nachvollziehbar und lassen sich bei veränderten Gegebenheiten oder Erfahrungen leicht anpassen. Abgesehen von der Auswahl der Datenquellen wurden für die Vergleichbarkeit der Ergebnisse standardisierte Parameter zur Interpretation der Geodaten festgelegt. So wurden Satellitenbilder aus dem Sommer grundsätzlich mit der hohen *reliability* von 0,9 versehen und die Einteilungsmethode nach Gruppen wurde bei allen Satellitenbildern und dem TWI in gleicher Weise angewendet. In Kapitel vier wurden anschließend die Ergebnisse der Anwendung des *TBM* auf verschiedene Kombinationen von Geodaten präsentiert.

Grundsätzlich konnte mit der Arbeit eine Anwendung des *TBM* auf die Klassifizierung von Biomassezonen im Grünland gezeigt werden. Bereits im Rahmen der Vorbereitung der Fusion bietet das *TBM* die Möglichkeit, Geodaten auf der einfaktorischen Ebene durch Interpretationstabellen in Klassen einzuteilen. Die so entstehenden *SOEs* weisen für die jeweils betrachtete Ausgangsdatenquelle Hypothesen über die Lage der Biomassezonen aus, beinhalten jedoch noch keine Berücksichtigung von Unsicherheit. Damit wird in der Darstellung der klassifizierten Datenquellen durch die Schärfe der Abgrenzung der Klassen zunächst suggeriert, dass es sich bei der Zuweisung um unumstrittene Fakten handelt. Die Idee von mehrdimensionalen

Überzeugungen innerhalb einer Flächeneinheit wird erst durch die Zuordnung mehrerer Hypothesen zu einem Pixel mittels Verschneidung der Klassenflächen und die Ergänzung der *reliability* erreicht. Anschließend ermöglicht die eigentliche Fusion, bei der mehrere, das gleiche Objekt beschreibende Quellen für die Einteilung von Biomassezonen kombiniert werden, eine Betrachtung aus mehreren Perspektiven. Die Fusion kann bei übereinstimmenden Aussagen die Faktenlage an einem Ort stärken. Sich widersprechende Aussagen können die Mehrdeutigkeit einer in der Realität vorkommenden Situation beschreiben. So ist es dem Modell möglich, die Unsicherheit, mit der der Landwirt bei der Fällung von Entscheidungen konfrontiert ist, sichtbar zu machen. Die Nachahmung menschlicher Denkprozesse, die dem Modell zugeschrieben wird, findet dort statt, wo bei der Erstellung der Ergebniskarte die abgebildete Aussage über das betrachtete Areal ausgewählt wird (Ristic et al., 2020). In der Landwirtschaft ist die Abwägung vieler Faktoren, deren Ausprägungen nicht genau vorhersehbar sind, an der Tagesordnung. Die Entscheidungsfindung unter Einbeziehung des Faktors Unsicherheit wird vor allem im betriebswirtschaftlichen Kontext viel beschrieben und diskutiert (Hanf, 1976)

Die Vergleiche der Fusionen mehrerer Variantensets mithilfe der Berechnung von Kreuztabellen zeigen, dass durch den Prozess der Klassifizierung mit dem *TBM* in jedem Fall eine Übereinstimmung mit der Validierungsdatenquelle von ca. 45-70 % erreicht wird. Auch beim visuellen Vergleich aller Kombinationen lassen sich in ähnlichem Maß übereinstimmende Muster bei der Lage der jeweiligen Hypothesen wiederfinden (Abbildung A-7). Gleichzeitig wird die Bandbreite der Interpretationen deutlich, die sich bei der Frage der Einteilung einer Grünlandfläche nach Bereichen unterschiedlichen Biomasseertrags durch die Kombination verschiedener Geodaten ergibt. Die Ergebnisse der Variantensets J22A\_0, J22A\_1 und J22\_0\_TWI, bei denen mehrere Satellitenbilder aus dem trockenen Sommer 2022 fusioniert wurden, dokumentieren die höchsten Übereinstimmungen. Weil es sich bei der Validierungsdatenquelle ebenfalls um ein Satellitenbild handelt, welches im trockenheitsgeprägten Jahr 2018 aufgenommen wurde, ist zunächst nicht sicher differenzierbar, ob die hohe Übereinstimmung von der guten Wiedergabe der Biomassezonen durch die *TBM*-Fusion herrührt, oder eine Überbewertung der Variante aufgrund der Korrelation mit dem Validierungsdatensatz vorliegt (Abbildung A-9 bis A-12). Werden dann aber zur Beurteilung die stichprobenartigen Beobachtungen von Bodenverhältnissen und Pflanzenbestand auf der Fläche mit herangezogen, unterstützen diese die Hypothesen des Validierungsdatensatzes in den betrachteten Punkten (Abbildung A-1). Auch die Aussagen des Landwirts, der die Untersuchungsfläche bewirtschaftet, bestätigen die Einteilung des Validierungsdatensatzes (Frädrich, 2023). Bei der Begutachtung vor Ort wurde darüber hinaus deutlich, dass das Biomassewachstum des Grünlands auch kleinflächig variiert. Ein Beispiel dafür sind die humosen Senken in der nördlichen Mitte der Fläche. Diese Areale sind in trockenen Jahren, durch besseren Wasserhaushalt aufgrund der Lage im Relief

und der Nähe zum Grundwasser im Vergleich zur Restfläche sehr ertragreich. Bei feuchter Witterung kann es dort jedoch verstärkt zu Staunässe und schlechter Befahrbarkeit kommen, was sich gegebenenfalls negativ auf das Biomassewachstum auswirkt. Aus einigen Varianten ging kein Hinweis auf diese Gegebenheiten hervor. Bei den Varianten, die die Daten der Bodenschätzung enthalten, werden die Bereiche zwar der Hypothese {g} zugeordnet, in der Konfliktwertkarte tauchen jedoch erhöhte Werte auf (Abbildung 34 rechts). An diesem Beispiel wird die Bedeutung zusätzlicher Informationen durch die Kombination mehrerer Datenquellen verschiedenen Ursprungs ersichtlich. Deswegen ist beispielsweise die Variantenkombination J22A\_1, bei der zusätzlich die Bodenschätzung fusioniert wurde, gegenüber der Variante J22A\_0, bei der ausschließlich Satellitenbild-Daten fusioniert wurden, trotz der etwas geringeren Übereinstimmung mit dem Validierungsdatensatz, aufgrund ihres höheren Informationsgehaltes zu bevorzugen.



**Abbildung 37:** Gegenüberstellung der Ergebniskarten. Links: Ergebniskarte der Variante J22A\_0, rechts: Ergebniskarte der Variante J22A\_1. Eigene Darstellung 2023.

Die Ergänzung der Datenquelle TWI bringt eine weitere Perspektive in die Betrachtung der Fläche mit ein, auch wenn durch die Fusion der Übereinstimmungsgrad mit dem Validierungsdatensatz bei der Kombination J22A\_0 geringfügig zurückgeht. Ein deutlicher Effekt des Rückgangs von Übereinstimmungswerten tritt vermutlich erst bei einer größeren Anzahl von fusionierten Datenquellen auf (Vallentin et al., 2020).

Abschließend bleibt festzuhalten, dass es keine eindeutig beste Variantenkombination gibt. Um ein gutes Fusionsergebnis zu erreichen, sind somit mehrere Wege wählbar. Diese Erkenntnis trägt auch dem immer wieder thematisierten Umgang mit Unsicherheit in den Geodaten Rechnung. Im Laufe des Fusionsprozesses haben jedoch bestimmte Parameterausprägungen tendenziell Vorteile im Hinblick auf das Fusionsergebnis. Werden diese Vorteile konsequent genutzt und fortlaufend mit einer Fehlerbeurteilung kombiniert, bietet das *TBM* ein wertvolles Werkzeug zur teilautomatisierten Zonierung von Grünland. Die aus den Datenfusi-

onen erarbeiteten Ergebnisse stellen eine hochinformativ Quelle dar, die potenziell für landwirtschaftliche Anwendungen genutzt werden kann und trotzdem Raum lässt für die fachkundige Einschätzung des Nutzers.

## 5.2 Erarbeitung eines regional gültigen Prozessschemas

Für den Begriff Interpretationsschema kristallisierte sich während der Bearbeitung des Themas eine gewisse Bedeutungsverschiebung heraus. Schema meint hier nicht, dass feststehende, allgemeingültige Interpretationsparameter fixiert werden, sondern dass ein Prozessablauf für die Datenfusionen entwickelt wird. In der Arbeit wurden also Rahmenbedingungen für eine auf die Untersuchungsfläche zugeschnittene Vorgehensweise bei der Anwendung des *TBM* hergeleitet. Dazu wurden zunächst in Kapitel 3 die Methoden der Parametrisierung erörtert. Thematisiert wurden Klassifizierungsmethoden für Datenquellen, Einflüsse auf die Modellierung von Klassengrenzen, die Art und Weise der Zuteilung von *reliability* und die Auswahl von Geodaten. Aus diesen Vorüberlegungen wurde ein Vorgehen für die Durchführung der Fusion erarbeitet.

Die intensive Auseinandersetzung mit der Auswahl und Interpretation von Geodatenquellen ergab, dass sich die Wahl der Datenquellen stark auf das Ergebnis des *TBM* auswirkt. Die Betrachtung und Einschätzung von Satellitenbildern nimmt dabei viel Raum ein, da diese Informationsquelle ein riesiges Potenzial an frei zugänglichen Geodaten bereithält. Die Aussagen, die von diesen Quellen abgeleitet werden können, sind jedoch sehr volatil. Deshalb wurden im Zusammenhang mit der Frage nach dem geeigneten Termin zur Auswahl von Satellitenbildern für die Grünlandinterpretation wichtige Auswahlkriterien erarbeitet. Im Verlauf eines Jahres zeigten sich nämlich extreme Unterschiede im Hinblick auf die Aussagekraft des berechneten Biomasseindex *NDVI* über den Standort, was die folgende Beobachtung beispielhaft darlegt. Ursprünglich wurde bezüglich der Entwicklung der Vegetation erwartet, dass sich bei Wachstumsbeginn zunächst zum jährlichen Gesamtwachstum der Biomasse inverse Signaturen des Index zeigen, da sich leichte Standorte schneller erwärmen (Klapp, 1971). Im weiteren Jahresverlauf wurde unmittelbar vor der Ernte des jeweiligen Grasbestandes die am deutlichsten sichtbare Trennung verschiedenen Biomassewachstums im Satellitenbild erwartet, da zu den Schnittterminen die höchsten Biomassemengen auf dem Grünland vorzufinden sind. Die Analysen zeigen jedoch deutlich andere Ergebnisse. Die inverse Ausprägung der Standorte zu Beginn der Vegetation war im betrachteten Zeitraum nicht signifikant. Auch war das Niveau der Werte vor der Ernte der Biomasse nicht signifikant nach Standorten differenzierbar. Eine signifikante und in erwarteter Reihenfolge der Werte auftretende Trennung der Standorte ist erst nach dem ersten Schnitt zu beobachten, wenn zum zweiten Schnitt hin neue Biomasse gebildet wird. Das Phänomen trat im trockenen Jahr 2022 länger auf als im feuchten



Vorjahr. 2021 war der Effekt wegen der schon bald auf den ersten Schnitt folgenden Regenfälle schnell nicht mehr erkennbar, da die schwachen Standorte in der Biomassebildung aufholten. Im weiteren Jahresverlauf traten nur noch uneindeutige Ausprägungen der *NDVI*-Werte auf. Eine mögliche Erklärung bietet die hohe vertikale Bestandsdichten im Grünland (Dierschke und Briemle, 2008). Diese äußern sich in hohen Werten für den Blattflächenindex, insbesondere an Terminen üppigen Wachstums. Inwieweit der Biomasseaufwuchs über das gesamte Jahr hinweg mit dem *NDVI* in Zusammenhang gebracht werden kann, ist deshalb in Frage zu stellen. Die Autoren Reddersen et al. (2014) fanden nur einen geringen Zusammenhang zwischen Biomasse und verschiedenen Vegetationsindizes im Grünland (Bestimmtheitsmaß 0,3). Erst durch die gemeinsame Betrachtung von Vegetationsindizes und Blattflächenindex konnte ein Wert des Bestimmtheitsmaßes von 0,78 erreicht werden. Auch aus dem Bereich der Ackerkulturen ist eine abnehmende Sensitivität des *NDVI*-Wertes bei zunehmenden Blattflächenindizes bekannt (Lilienthal, 2014). Aus diesen Forschungsarbeiten, die sich mit den Erkenntnissen der vorliegenden Arbeit decken, kann zur regionalen Grünland-Klassifizierung auf Flächen mit Silagenutzung abgeleitet werden, dass sich besonders Satellitenbilder aus dem Zeitraum nach dem ersten Schnitt bzw. aus dem Frühsommer zur Differenzierung von Standorten eignen, da in anderen Zeiträumen womöglich keine starke Beziehung zwischen aufwachsender Biomasse und *NDVI* besteht.

Von der Faktoranalyse, die im Rahmen der Anwendung des *TBM* durchgeführt wurde, lassen sich Hinweise auf eine günstige Ausprägung der gewählten Datenquellen ableiten. Die Satellitenbilder des Jahres 2022 führten gegenüber denen aus dem Jahr 2021 in allen Kombinationsvarianten zu signifikant höherer Übereinstimmung mit dem Validierungsdatensatz. Bereits in der *NDVI*-Analyse (vgl. Kapitel 3.2.2) deutete sich das an, da die drei Hypothesen {s}, {m} und {g} im Jahr 2022 an acht Terminen in drei Gruppen signifikant zu trennen waren, während dies im Jahr 2021 nur an drei Terminen der Fall war. Als Grund für die deutlichere Standortdifferenzierung im *NDVI* kann eine ausgeprägtere Trockenheit im Jahr 2022 angeführt werden. Einen weiteren Prüffaktor stellte die Wahlmethode der Satellitenbilder dar. Durch gezielte Auswahl bestimmter Bilder aus dem Frühsommer wurde gegenüber der Zufallsauswahl eine signifikant höhere Übereinstimmung mit der Validierungsdatenquelle erreicht, wenngleich der Effekt der Wahlmethode der Satellitenbilder geringer ausfiel als bei der Wahl des Jahres. Die Erkenntnis aus der Faktoranalyse, dass eine gezielte Auswahl von Geodaten die Fusionsergebnisse verbessert, wurde auch durch die Autoren Vallentin et al. (2020) bereits belegt und beschrieben. Bei der Integration der Bodenschätzung und des TWI in die Datenfusion zeigte die Varianzanalyse bei keiner der beiden zusätzlichen Datenquellen eine signifikante Verbesserung bzw. Verschlechterung der Übereinstimmung mit der Validierungsdatenquelle. Auffällig ist jedoch, dass besonders bei einer ungünstigen Satellitenbildauswahl durch die Hinzunahme von Bodenschätzung oder TWI eine größere Übereinstimmung mit dem VD generiert werden

konnte. Allerdings bleibt grundsätzlich offen, ob die höheren Übereinstimmungswerte zwischen Fusionen mit Satellitenbildern und dem VD durch besonders gut beschriebene, tatsächlich vorherrschende Gegebenheiten hervorgerufen wird, oder dem Umstand geschuldet ist, dass es sich sowohl bei der Fusionierungs- als auch bei der Validierungsquelle um ein Satellitenbild handelt.

Weiterhin ergeben sich aus den Betrachtungen in Kapitel 3 Ergebnisse für die Klassifizierung der ausgewählten Datenquellen. Die Bodenschätzung enthält Daten mit festgelegten Wertebereichen. Da die Bodenschätzung aus Teildatensätzen mit Attributen besteht, wurde ein Vergleich zwischen verschiedenen Interpretationsansätzen angestrebt. Die alleinige Verwendung der Bodenzahl erzielte gegenüber der Bodenart, aber auch gegenüber der Kombination zwischen Kulturart und Bodenzahl die höchsten Übereinstimmungen mit der Validierungsdatenquelle. Bei der Bodenzahl handelt es sich bereits um ein Attribut, das durch die Betrachtung mehrerer Faktoren mithilfe des Grünland- bzw. Ackerschätzrahmens erstellt wurde. Mit der Weiterentwicklung der digitalisierten Landwirtschaft etablierte sich die Bodenschätzung zu einer zunehmend wichtigen Quelle in der Beschreibung von Bodenfunktionen (Herche, 2019).

Im Vergleich zur Bodenschätzung stellen die relativskalierten Daten der Satellitenbilder und des TWI den Nutzer vor deutlich größere Schwierigkeiten bei der Einteilung im Rahmen der Datenfusion. Für diese Daten eine standardisierte Parametrisierung für das *TBM* festzulegen, ist anspruchsvoll, da sich die Verteilungen der Werte von Quelle zu Quelle unterscheiden. Die *NDVI*-Werte haben über die Saison hinweg variierende Wertebereiche und Verteilungsformen. Besonders bei Terminen, die ein insgesamt hohes *NDVI*-Niveau aufweisen, tritt bei der Darstellung im Histogramm eine starke Stauchung und Linksschiefe der Werte auf (Abbildung A-13 und A-14). Um eine Teilautomatisierung der Klassifizierung zu erreichen, wurden insgesamt drei einfache Methoden verglichen, die Einteilung nach immer gleichen Intervallen, nach gleich großen Quantilen und nach Gruppen. Bei einer Verteilungsform, die der Normalverteilung ähnelt, führen die beiden erstgenannten Methoden zu annehmbaren Klassifizierungsergebnissen. Die Intervallmethode kommt jedoch bei einer gewissen Stauchung und Schiefe der Verteilungsform zu schlechteren Einteilungsergebnissen. Der Nachteil der Quantilmethode dagegen ist die implizierte Annahme, dass jede Datenquelle flächenmäßig immer gleich große Hypothesenareale aufweist. Bei der dritten Methode wurde ein qualitativer Einteilungsansatz gewählt, bei dem anhand der Betrachtung des Histogramms Gruppen zugeteilt wurden. Diese Einteilungsmethode erreicht tendenziell die höchsten Übereinstimmungswerte, dicht gefolgt von der Quantilmethode. Mit größerem Abstand folgt die Intervallmethode. Da die Unterschiede zwischen der Einteilungsmethode nach Gruppen und der nach Quantilen nicht bedeutend sind, ist es legitim, für eine einfache teilautomatisierte Anwendung die Quantilmethode zu verwenden, da diese einfacher maschinell umsetzbar ist. Der Einfluss der Einteilungsmethode war geringer und insgesamt weniger bedeutend als die Auswahl der Geodaten. Darüber

hinaus bleibt zu prüfen, ob komplexere Klassifizierungsmethoden, zum Beispiel aus dem Bereich der unüberwachten Klassifizierung, einen Mehrwert für die Datenfusion mit dem *TBM* bringen (Segl et al., 2018; Tso und Mather, 2001).

Neben der Wahl der Datenquelle und der Einteilungsmethode der Daten ist die Einschätzung von Unsicherheit bedeutend für das Fusionsergebnis. Diese fließt einerseits ein in die Modellierung der Übergänge von Klassengrenzen nach der Klassifizierung von Rohdaten, andererseits wird sie durch die *reliability* ausgedrückt, welche die gesamte Datenquelle nach der Überzeugung des Nutzers einordnet. Die *reliability* hat besonders großen Einfluss, wenn sich zwei Datenquellen widersprechen und gleichzeitig in beiden *SOEs* keine Übergangsbereiche zwischen Klassengrenzen vorliegen. In diesem Fall wird zunächst der mass of belief der leeren Menge angenommen, der anschließend einer Hypothese aus dem *frame of discernment* ( $\{g\}$ ,  $\{m\}$ ,  $\{s\}$  oder  $\{\Omega\}$ ) zugeteilt wird. Die zugehörigen *masses of belief* werden ausschließlich von der Höhe der *reliability* bestimmt, die der gesamten Datenquelle zugeteilt ist. Im Ergebnis überwiegt die Hypothese derjenigen Datenquelle, der die höchste *reliability* zugeordnet wurde. Auch innerhalb einer vertrauenswürdigeren Datenquelle können ambivalente und vage Bereiche vorliegen, die sich weniger sicher einer Klasse zuordnen lassen als andere. Aus diesem Grund ist die Auseinandersetzung mit der Modellierung von Unsicherheiten an Klassengrenzen entscheidend für eine erfolgreiche Zonierung.

Durch die detaillierte Auseinandersetzung mit der Auswahl von Datenquellen, deren Einteilungsmethoden und dem Umgang mit Unsicherheiten konnte eine regional gültige Parametrisierung für die Geodatenfusion mit dem *TBM* auf dem vorliegenden Grünlandstandort erarbeitet werden. So wird die Interpretation der hier betrachteten Geodaten möglich.

### 5.3 Relevanz der Konfliktwerte

Der Konfliktwert ist zentraler Bestandteil der Datenfusion mit dem *TBM* und erweitert die Ergebnisse um die wichtige Information der Vertrauenswürdigkeit der Klassen in der Ergebniskarte. Er wird beim Transfer der Fusionsergebnisse auf die pignistische Ebene berechnet und liefert zu einer Karte, die auf den ersten Blick scharfe Klassengrenzen suggeriert, eine Einschätzung zur Sicherheit der ausgewiesenen Pixelzuordnung. Die Konfliktwerte geben Auskunft über Bereiche, an denen Unsicherheiten in den Ergebniskarten auftreten. Dabei kann auf die Lage der Unsicherheiten, ihre Stärke, aber auch auf die Art der Unsicherheit geschlossen werden. Auch können daraus Rückschlüsse auf die Parametrisierung des Modells und damit die Einschätzung des Nutzers gezogen werden.

Anhand des Vergleichs zweier Konfliktkarten wurden diese Ausprägungen des *WOC* illustriert. Lage und Stärke der Unsicherheiten sind in den Beispielen durch die Pixel in farblicher Abstufung wiedergegeben. Die Art der Unsicherheit lässt sich durch das Muster der Konfliktwerte nachvollziehen. Liegen zusammenhängende Bereiche mit gleich hohen *WOC*-Werten vor, so

lässt sich auf eine inhaltliche Unsicherheit schließen. Bei der Einteilung der Geodaten wurden dort dem gleichen Ort in zwei unterschiedlichen Datenquellen verschiedene Hypothesen zugeordnet (vgl. Abbildung 34 rechts). Liegen die Widerspruchswerte besonders an den Übergängen der Klassengrenzen und weisen kleinräumige Unterschiede auf, so kennzeichnet dies die Vagheit bzw. Ambivalenz in den Übergangsbereichen zweier Klassen. Diese erhöhten Konfliktwerte kommen durch die gleichzeitige Überzeugung von mindestens drei verschiedenen Hypothesen an einem Punkt zustande. Durch die Modellierung nach der *fuzzy logic* werden Pixeln in einem gewissen Grenzbereich die Hypothesen der beiden angrenzenden Klassen in einem bestimmten Verhältnis zugeordnet. Die Hypothese  $\{\Omega\}$  wird durch die Zuordnung der *reliability* ergänzt und stellt die dritte Hypothese dar.

Die Betrachtung statistischer Parameter des Konfliktwert-Datensatzes gibt Auskunft über die Parametrisierung des Modells. Ein hoher Maximalwert bedeutet, dass die widersprüchlichen Hypothesen aus fusionierten Datenquellen stammen, die mit hohen Überzeugungswerten versehen wurden (vgl. Abbildung 24 rechts). Der Minimalwert, bzw. das häufige Auftreten kleiner Werte lässt Rückschlüsse auf das Ausmaß übereinstimmender Bereiche zu, da dort geringe Konfliktwerte zu erwarten sind (vgl. Abbildung 34 links). Das Verhältnis zwischen Median und Mittelwert ermöglicht wiederum eine Einschätzung der gesamten Ergebnis-Konflikte. Ist der Mittelwert höher als der Median, deutet das auf eine höhere Anzahl stärkerer Konfliktwerte hin. Umgekehrt zeigt ein Mittelwert, der geringer ist als der Median eine höhere Anzahl niedriger Konfliktwerte an.

Die Inhalte der Ergebniskarte und der Konfliktkarte gleichermaßen zu erfassen und zu verbinden, stellt aufgrund der hohen Komplexität der beiden Informationsträger ein Problem dar. Wird die Ergebniskarte ohne Berücksichtigung der Konflikte verwendet, suggeriert sie einen höheren Informationsgehalt, als sie aufgrund der Unsicherheiten, die in der Konfliktwertkarte ablesbar sind, hat. Die Darstellung der Unsicherheit in Ergebniskarten ist jedoch schwierig, wenn man deren Übersichtlichkeit und Verständlichkeit erhalten will (Kinkeldey et al., 2014). Die in Kapitel 4.4 erarbeitete Darstellung stellt einen Ansatz dar, die Hypothesenzuweisung und gleichzeitig die dazugehörigen Konfliktwerte zu erfassen. Durch die Abstufung der Farbtintensität können die Bereiche, in denen die Hypothese sehr überzeugend ist, von den Bereichen unterschieden werden, in denen die Hypothese nicht mit großer Sicherheit zugewiesen werden konnte. Die Darstellung trägt der Tatsache Rechnung, dass die Zuweisungen auf Überzeugungswerten beruhen, die auf der Basis unvollkommener Informationen über die Fläche entstanden. Darüber hinaus wird illustriert, dass die Verarbeitung der Daten mit dem *TBM* an einigen Stellen zu Einschätzungen mit hoher Überzeugung führt, dass aber auch Bereiche existieren, für die ergänzende Informationen nötig wären, um eine höhere Überzeugung von der Klassifizierung zu erreichen. Diese Karte könnte die Grundlage für die Optimierung von

---

Grünland darstellen. Areale mit hohen Konfliktwerten können dann gezielt begutachtet werden, um die tatsächlich vorherrschende Situation einzuschätzen. Neu gewonnene Daten können wiederum in das Modell implementiert werden, um so den tatsächlich vorherrschenden Bedingungen auf der Fläche näher zu kommen. Bei bestimmten Anwendungen wie zum Beispiel der Planung einer Bodenprobenahme können Kernareale mit geringen Widerspruchswerten zur Beprobung festgelegt werden. Dagegen sollten Bereiche mit hohen Widersprüchen zur Vermeidung von Mischproben gemieden werden. Weitere Einsatzmöglichkeiten einer kombinierten Zonierungs- und Konfliktkarte ergeben sich sicherlich im Laufe einer späteren Praxisanwendung, wobei für die Integration von Konfliktwerten in Ergebniskarten verschiedene Darstellungsformen denkbar sind. Welche Form der grafischen Aufbereitung die Unsicherheiten und Konflikte am besten repräsentiert, bleibt zu diskutieren.

## 6 Fazit und Ausblick

Das Transferable Belief Model fusioniert in einem mehrstufigen Prozess verschiedene Geodaten vor dem Hintergrund einer übergeordneten Fragestellung. Die vorliegende Arbeit thematisiert die Nutzung des *TBM* bei der Zonierung von Grünland im Hinblick auf Biomassewachstum. Das *TBM* ist durch seine Flexibilität im Hinblick auf die Berücksichtigung der zur Verfügung stehenden Geodaten und die mögliche Einbindung von Erfahrungswerten gut für landwirtschaftliche Anwendungen geeignet. Besonders bei Änderungen von Klima- und Witterungsverhältnissen sowie Management-Anpassungen kann durch neu gewonnene, mittels *TBM* fusionierte Daten die Klassifizierung von Flächen im Laufe der Jahre ständig aktualisiert und in ihrer Genauigkeit verbessert werden. Es konnte gezeigt werden, dass durch die Verwendung von einfach verfügbaren Geodaten eine Klassifizierung möglich ist. Sie beinhaltet auch eine Einschätzung zur Sicherheit der Zuteilung, die durch den Konfliktwert ausgedrückt wird. Inwieweit durch die Verarbeitung von Geodaten eine Annäherung an die Realität gelingt, ist maßgeblich abhängig von dem Datensatz, mit dem die Ergebnisse zu Kontrollzwecken verglichen werden. Ein Validierungsdatensatz enthält dabei wiederum nur Daten, die bestenfalls durch eine andere Erhebungsmethode bzw. durch eine höhere Auflösung sicherere Aussagen über die tatsächlichen Gegebenheiten an einem Standort zulassen als die zu prüfenden Datenquellen. Diese Daten werden „wahre Werte“ (eng. „*ground truth*“) genannt, stellen aber wiederum nur ein Modell der Wirklichkeit dar (vgl. Schiewe, 2023). Der in dieser Arbeit verwendete Validierungsdatensatz basiert auf einem Satellitenbild, das zwar dank seines optimalen Aufnahmezeitpunkts eine deutliche Standortheterogenität zeigt, aber weder einen genaueren Maßstab noch eine alternative Erhebungsmethode bietet. Jedoch ist im Zusammenhang mit der Validierung von Karten nicht nur die Genauigkeit des zur Verfügung stehenden Validierungsdatensatzes entscheidend, sondern auch das Verhältnis zu den Anforderungen einer bestimmten Fragestellung (Schiewe, 2023). Da die vorliegende Arbeit die Eignung des *TBM* für die Unterscheidung von Zonen verschiedenen Biomassewachstum im Grünland bestätigt, ohne die Genauigkeit dieser Zuordnung zu thematisieren, ist die Aussagekraft des Validierungsdatensatzes als ausreichend anzusehen.

Im Laufe der Forschungsarbeit wurde deutlich, dass bestimmte Parameter des *TBM* die Ergebnisse der Fusion entscheidender beeinflussen als andere. Hier ist vor allem die zielgerichtete Auswahl von geeigneten Datenquellen zu nennen. Darüber hinaus wird die Wiederholbarkeit der Ergebnisse deutlich von der Einteilungsmethode der ursprünglichen Datenquellen beeinflusst. So wurden weniger stark streuende Ergebnisse erzielt, wenn die Datenquellen nach der Gruppen- oder der Quantilmethode und nicht nach der Intervallmethode eingeteilt wurden. Ob durch die Datenquellen Bodenschätzung und TWI, die deutlich andere Inhalte und Maßstäbe haben als Satellitenbilder, ein Mehrwert für die Fusion entsteht, konnte nicht eindeutig gezeigt werden. In der Theorie ist dieser Mehrwert jedoch vorhanden, da durch die Integration



dieser Datenquellen die Klassifizierung zusätzlich mit weiteren Attributen gekoppelt wird, wodurch eine Hypothese durch mehrere Perspektiven gestützt werden kann. Die Relevanz von Bodenschätzung und TWI als Fusionsinhalte müssten eventuell in weiteren Arbeiten untersucht werden. Dazu ist gegebenenfalls eine Überarbeitung der Testmethoden, die Steigerung der Wiederholungen und der Abgleich mit einem anderen Validierungsdatensatz notwendig. Unabhängig von der Aussagekraft einer zusätzlichen Fusion des TWI und der Bodenschätzung ist auf jeden Fall eine regional gültige Parametrisierung für die Geodatenfusion mit dem *TBM* auf dem vorliegenden Grünlandstandort gelungen. Das erarbeitete Prozessschema legt damit den Rahmen für eine Interpretation fest.

In dieser Arbeit konnte darüber hinaus gezeigt werden, dass die Integration von Konfliktwerten einen Mehrwert bedeutet, weil so die Vertrauenswürdigkeit der Ergebnisse mit abzulesen ist. Konfliktwerte geben Auskunft über die Lage und Stärke von Unsicherheiten in der Klassifizierung. Um diese bei der Entscheidung berücksichtigen zu können, müssen Wege der gemeinsamen Darstellung von Ergebnishypothese und zugeordnetem Konfliktwert in der Ergebniskarte gefunden werden. Die vorliegende Arbeit operiert mit Abstufungen in der Farbintensität. Eine derartige Visualisierung kann die weitere Verarbeitung der *TBM*-Ergebnisse, etwa zur Erstellung einer Bewirtschaftungskarte in Form einer Vektordatei, erleichtern, da sie weniger hohe Anforderungen an die genaue Position der Polygongrenzen stellt. Weiterhin können beispielsweise bei der Planung für eine Bodenprobenahme gezielt Bereiche mit hohen Widerspruchswerten gemieden werden, um Mischproben zu vermeiden. Grundsätzlich erscheinen Zonierungskarten mit integriertem Konfliktwert, der Unsicherheiten in der Klassifizierung abbildet, hilfreich für eine differenzierte Standortansprache.

Die gesamte Parametrisierung des *TBM* ergab für die Untersuchungsfläche in der Prignitz nicht die eine endgültige Ergebniskarte, sondern mehrere ähnliche, jeweils plausible mit Konfliktwerten hinterlegte Zonierungskarten. Ihre hohe Informationsdichte und Aussagekraft macht sie für die landwirtschaftliche Anwendung in der Praxis interessant. Daraus ergeben sich jedoch Folgethemen, die zuvor in weiteren Studien untersucht werden müssen. Die Sicherheit der Ergebnisse könnte durch Tests mit höher Wiederholungszahl und einem genaueren Validierungsdatensatz gesteigert werden. Darüber hinaus müssen im Hinblick auf die Parametrisierung der Methode andere Standorte mit möglichst unterschiedlichen Eigenschaften betrachtet werden, um eine Übertragbarkeit der Methodik zu überprüfen. Die Erweiterung auf mehrere Kulturen und Interpretationsfragestellungen scheint naheliegend. Ein nächstes Forschungsstadium könnte die weitere Automatisierung und Vereinfachung der Anwendung darstellen, bis hin zur automatischen Ableitung von Bewirtschaftungskarten. Sobald sich eine Praxisreife des Modells abzeichnet, erscheint die Vereinfachung des Konzepts zusammen mit



einer verständlichen Vermittlung an die praktischen Anwender wichtig, um eine hohe Akzeptanz gegenüber den Ergebnissen des Werkzeuges *TBM* zu generieren.

## 7 Literaturverzeichnis

- Abdalla, Z. F., & El-Ramady, H. (2022). Applications and Challenges of Smart Farming for Developing Sustainable Agriculture. *Environment, Biodiversity and Soil Security*, 6(2022), 81-90.
- Ahmad, U., Nasirahmadi, A., Hensel, O., & Marino, S. (2022). Technology and data fusion methods to enhance site-specific crop monitoring. *Agronomy*, 12(3), 555.
- Amelung, W., Blume, H.-P., Fleige, H., Horn, R., Kandeler, E., Kögel-Knabner, I., Kretzschmar, R., Stahr, K., & Wilke, B.-M. (2018). Bodenbewertung und Bodenschutz. In *Scheffer/Schachtschabel Lehrbuch der Bodenkunde* (pp. 687-718). Springer Berlin Heidelberg. [https://doi.org/10.1007/978-3-662-55871-3\\_11](https://doi.org/10.1007/978-3-662-55871-3_11)
- Baeumer, K. (1992). Ertragsbildende Prozesse und ertragsbegrenzende Faktoren. In *Allgemeiner Pflanzenbau* (Vol. 3, pp. 20-109).
- Barbedo, J. G. A. (2022). Data Fusion in Agriculture: Resolving Ambiguities and Closing Data Gaps. *Sensors*, 22(6), 2285.
- BGR. (2023). *Geoportal der Bundesanstalt für Geowissenschaften und Rohstoffe* Zuletzt aufgerufen am: 23.04.2023 from <https://geoportal.bgr.de/mapapps/resources/apps/geoportal/index.html?lang=de#/geoviewer>
- Blaschka, M. A. (2003). Fernerkundung und GIS-Zukunftsperspektiven in der Landwirtschaft. *Ber. über das 9. Alpenländische Expertenforum.*, 53.
- Bosse, S., Berns, K., Bosch, J., Dörr, J., Eichhorn, F. C., Eisert, P., Fischer, C., Gassen, E., Gerstenberger, M., & Gerighausen, H. (2023). Nachhaltige Landwirtschaft mittels Künstlicher Intelligenz—ein plattformbasierter Ansatz für Forschung und Industrie. 43. *GIL-Jahrestagung, Resiliente Agri-Food-Systeme*.
- Buck, O., Rühl, J., Schroiff, A., Münch, D., Wiede, S., Bicsan, A., Müller, S., Klink, A., Hinterlang, D., & Mütterthies, A. (2018). Der Einsatz von Fernerkundung im FFH-Monitoring am Beispiel der Anwendung FELM. *NATUR UND LANDSCHAFT*, 93(5).
- Buck, O. K., Luca, Biscan, Alexandra; Müller, Sönke; Völker, Andreas; Haub, Carsten (2020). *Landnutzungsänderungen in Natura 2000-Gebieten: Methodenvergleich und Anwendungsbeispiele* (BfN Skripten 566, Issue).
- Clark Labs. (1987-2016). *TerrSet*. In (Version 18.20) Clark University.
- DATAtab. (2023). *DATAtab: Online Statistics Calculator*. DATAtab e. U. Zuletzt aufgerufen am: 29.04.2023 from <https://datatab.de/tutorial/tabelle-chi-quadrat>
- Dierschke, H., & Briemle, G. (2008). Ökologische Bedingungen in Graslandökosystemen. In *Kulturgrasland* (pp. 67-87).
- Dobers, E. S. (2002). *Methoden der Standorterkundung als Grundlage der DGPS-gestützten Ackerbaus* [Dissertation, Göttingen].
- Dobers, E. S. (2006). Anwendung des Transferable Belief Model in der computergestützten Bodenkartierung. Geographisches Kolloquium, Universität Göttingen.
- Dobers, E. S. (2008). *Generation on new soil information by combination of data sources of different content and scale using GIS and belief structures* (12).
- Dobers. (2012). *TBM\_v127*. In (Version 1.3.0)
- DSV. (2023). *Country Feldgras 2052*. Zuletzt aufgerufen am: 27.04.2023 from <https://www.dsv-saaten.de/sorte/1317>
- DWD. (2023). *Deutscher Wetterdienst - Wetter und Klima aus einer Hand*. Zuletzt aufgerufen am: 25.04.2023 from <https://www.dwd.de/DE/leistungen/klimakartendeutschland/klimakartendeutschland.html?nn=480164>
- Eckelmann, W., Sponagel, H., & Grotenthaler, W. (2005). *Bodenkundliche Kartieranleitung. - 5. verbesserte und erweiterte-Auflage*.
- ESA. (2023). *Sentinel-2 - Colour vision for Copernicus*. Zuletzt aufgerufen am: 29.04.2023 from [https://www.esa.int/Applications/Observing\\_the\\_Earth/Copernicus/Sentinel-2](https://www.esa.int/Applications/Observing_the_Earth/Copernicus/Sentinel-2)
- FLF-JKI. (2023). *Topografischer Feuchteindex*. Forschungszentrum für landwirtschaftliche Fernerkundung - Julius Kühn Institut. Zuletzt aufgerufen am: 22.03.2023 from

- <https://flf.julius-kuehn.de/webdienste/webdienste-des-flf/topographischer-feuchteindex.html>
- Frädrieh, T. (2023). Feldbegehung der Fläche Kombinat mit dem Betriebsleiter Herrn Tim Frädrieh - 21.03.2023. In.
- Fritsch, D., Glemser, M., Klein, U., Sester, M., & Strunz, G. (1998). Zur Integration von Unsicherheit bei Vektor- und Rasterdaten. *Geo-Informationssysteme*, 1998(4), 26-35.
- GISGeography. (2023, 30.05.2022). *What is NDVI (Normalized Difference Vegetation Index)?* Zuletzt aufgerufen am: 29.04.2023 from <https://gisgeography.com/ndvi-normalized-difference-vegetation-index/>
- Hanf, C.-H. (1976). Die Elemente rationaler Entscheidungen unter Unsicherheit. Proceedings "Schriften der Gesellschaft für Wirtschafts- und Sozialwissenschaften des Landbaues eV",
- Hannemann, J. (2010). *Die Berücksichtigung inhaltlicher und räumlicher Unschärfe bei der GIS-gestützten Erstellung von Bodenkarten* Universitaet Bayreuth (Germany)].
- Heiß, A., Paraforos, D. S., Sharipov, G. M., & Griepentrog, H. W. (2020). Fuzzy Farmer-optimierte Stickstoffdüngung durch mehrparametrische Datenfusion und präzise Applikation in Echtzeit. *40. GIL-Jahrestagung, Digitalisierung für Mensch, Umwelt und Tier*.
- Henrich, V., Krauss, G., Götze, C., & Sandow, C. (2011). *The IndexDatabase* <https://www.indexdatabase.de/>
- Herche, V. (2019). Bodenschätzung in Deutschland-Möglichkeiten und Grenzen der Nutzung.
- Hopkins, A., & Holz, B. (2006). Grassland for agriculture and nature conservation: production, quality and multi-functionality. *Agronomy research*, 4(1), 3-20.
- Huang, S., Tang, L., Hupy, J. P., Wang, Y., & Shao, G. (2021). A commentary review on the use of normalized difference vegetation index (NDVI) in the era of popular remote sensing. *Journal of Forestry Research*, 32(1), 1-6.
- Isselstein, J., & Michaelis, T. (2015). *Fachforum Grünland - Grünland innovativ nutzen und Ressourcen schützen*
- Ittershagen, M. M., Corinne; Stoll, Jonas; Jozwiak, Andrea; Weyers, Anette; Sophia, Köhler; Örtl, Elke. (2023). *Grünlandumbruch*. Umweltbundesamt. Zuletzt aufgerufen am: 26.04.2023 from <https://www.umweltbundesamt.de/daten/land-forstwirtschaft/gruenlandumbruch#gefahrderung-des-grunlands>
- Jana, S., & Mahanta, J. (2022). Boundary of a fuzzy set and its application in GIS: a review. *Artificial Intelligence Review*. <https://doi.org/10.1007/s10462-022-10331-0>
- Joos, G. (2001). Modellierung von Unschärfe in GIS.
- Kaivosoja, J. (2019). Role of spatial data uncertainty in executions of precision farming operations.
- Kinkeldey, C., MacEachren, A. M., & Schiewe, J. (2014). How to assess visual communication of uncertainty? A systematic review of geospatial uncertainty visualisation user studies. *The Cartographic Journal*, 51(4), 372-386.
- Klapp, E. (1971). *Wiesen und Weiden: eine Gründlandlehre*. Parey.
- Klaus, F. (1999). Einführung in Techniken und Methoden der Multisensor-Datenfusion.
- Kok, Z. H., Shariff, A. R. M., Alfatni, M. S. M., & Khairunniza-Bejo, S. (2021). Support vector machine in precision agriculture: a review. *Computers and Electronics in Agriculture*, 191, 106546.
- Kühn, D., & Müller, H. (2009). Probleme der Interpretation der Bodenschätzung bei der Kartierung in Brandenburg.
- Landesamt für Digitalisierung, B. u. V. (2011). *Datenbeschreibung der Bodenschätzung im Format Shape*. <https://www.adbv-guenzburg.de/file/pdf/2519/Kundeninformation%20Bodensch%C3%A4tzung%20Shape.pdf>
- Legros, J.-P. (2006). *Mapping of the Soil*. Science Publishers, .
- LGB. (2023a). *ALKIS Brandenburg (WMS)*. Zuletzt aufgerufen am: 23.04.2023 from <https://geobroker.geobasis->

- [bb.de/gbss.php?MODE=GetProductPreview&PRODUCTID=31591bca-bb40-4d8a-98ad-35efc37524c9](https://bb.de/gbss.php?MODE=GetProductPreview&PRODUCTID=31591bca-bb40-4d8a-98ad-35efc37524c9)
- LGB. (2023b). *Geobroker - Der Internetshop der LGB*. Zuletzt aufgerufen am: 27.04.2023 from <https://geobroker.geobasis-bb.de/>
- LGB, L. u. G. B. (2023c). Digitales Geländemodell Gitterweite 10m Brandenburg mit Berlin. In.
- Liedtke, H., & Marcinek, J. (2003). Das Relief der Jung-und Altmoränenlandschaften. *Institut für Länderkunde (Hrsg.). Nationalatlas Bundesrepublik Deutschland, Relief, Boden und Wasser*, S, 68-69.
- Lilienthal, H. (2014). Optical sensors in agriculture: principles and concepts. *Journal für Kulturpflanzen*, 66(2), 34-41.
- Microsoft Corporation. (2021). *Microsoft Excel*. In (Version 16.0) <https://office.microsoft.com/excel>
- Nedeljkovic, I. (2004). Image classification based on fuzzy logic. *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, 34(30), 3-7.
- PBK. (2023). *PBK*. Zuletzt aufgerufen am: 27.04.2023 from <https://www.pbk-pritzwalk.de/>
- QGIS Development Team. (2023). *QGIS Geographic Information System*. In *Białowieża* (Version 3.22.14) Open Source Geospatial Foundation. <https://qgis.org/de/site>
- R Core Team. (2023). *R: A language and environment for statistical computing* In R Foundation for Statistical Computing. <https://www.R-project.org/>
- Reddersen, B., Fricke, T., & Wachendorf, M. (2014). Ein Multisensorischer Ansatz mit Blattflächenindex, Ultraschall-Distanzmessung und Vegetationsindices zur Abschätzung von Biomasseertrag im extensiven Grünland. *VDI-MEG*, 302.
- Ristic, B., Gilliam, C., Byrne, M., & Benavoli, A. (2020). A tutorial on uncertainty modeling for machine reasoning. *Information Fusion*, 55, 30-44.
- Ruser, H., & León, F. P. (2007). Informationsfusion—Eine Übersicht (Information Fusion—An Overview). *tm-Technisches Messen*, 74(3), 93-102.
- Ruser, H., & León, P. (2006). F. Methoden der informationsfusion—Überblick und taxonomie. *Informationsfusion in der Mess-und Sensortechnik; Universitätsverlag Karlsruhe: Karlsruhe, Germany*, 1-20.
- Schauppenlehner, T., & Muhar, A. (2004). *Analysen der Zusammenhänge zwischen Kleinrelief und landwirtschaftlichen Ertragsdaten in einer alluvialen Landschaft zur Erstellung verbesserter Bodenkarten*.
- Schiewe, J. (2023). Unsicherheiten von Geodaten. In *Kartographie: Visualisierung georäumlicher Daten* (pp. 129-137). Springer.
- Schmidt, T., Schuster, C., Kleinschmit, B., & Förster, M. (2014). Evaluating an intra-annual time series for grassland classification—how many acquisitions and what seasonal origin are optimal? *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 7(8), 3428-3439.
- Schmitz, T., & Müller, D. (2020). *Digitale Karte der Bodenwertzahlen für Brandenburg*.
- Schwarz, J., & Kohler, F. (2023). *Pearson-Chi-Quadrat-Test (Kontingenzanalyse)*. Hochschule Luzern. Zuletzt aufgerufen am: 28.03.2023 from <https://www.empirical-methods.hslu.ch/entscheidbaum/zusammenhaenge/pearson-chi-quadrat/>
- Segl, K., Bohn, N., Chabrillat, S., Neumann, C., Roessner, S., Ward, K., & Wolanin, A. (2018). Maschinelles Lernen bei der Auswertung von Fernerkundungsdaten. *System Erde*, 8(1), 18-25.
- Shen, M., Chen, J., Zhu, X., & Tang, Y. (2009). Yellow flowers can decrease NDVI and EVI values: Evidence from a field experiment in an alpine meadow. *Canadian Journal of Remote Sensing*, 35(2), 99-106.
- Smets, P. (1994a). What is Dempster-Shafer's model. *Advances in the Dempster-Shafer theory of evidence*, 34.
- Smets, P. (2000a). Data fusion in the transferable belief model. Proceedings of the third international conference on information fusion,
- Smets, P. (2000b). The transferable belief model and other interpretations of Dempster-Shafer's model. <https://doi.org/10.48550/arxiv.1304.1120>

- Smets, P. (2005). Decision making in the TBM: the necessity of the pignistic transformation. *International journal of approximate reasoning*, 38(2), 133-147.
- Smets, P. K., Robert. (1994b). The transferable belief model. *Artificial Intelligence* (66), No. 2.
- Sörensen, R., Zinko, U., & Seibert, J. (2006). On the calculation of the topographic wetness index: evaluation of different methods based on field observations. *Hydrology and Earth System Sciences*, 10(1), 101-112.
- Sulik, J. J., & Long, D. S. (2015). Spectral indices for yellow canola flowers. *International Journal of Remote Sensing*, 36(10), 2751-2765.
- Tso, B., & Mather, P. M. (2001). Multisource Classification. In *Classification Methods for Remotely Sensed Data*. Taylor & Francis.
- Vallentin, C., Dobers, E. S., Itzerott, S., Kleinschmit, B., & Spengler, D. (2020). Delineation of management zones with spatial data fusion and belief theory. *Precision agriculture*, 21(4), 802-830. <https://doi.org/10.1007/s11119-019-09696-0>
- von Wardenburg, E. (2023). *Smart Farming & Offroad*. Fraunhofer-Institut für Kognitive Systeme (IKS). Zuletzt aufgerufen am: 26.04.2023 from <https://www.iks.fraunhofer.de/de/themen/smart-farming.html>
- Wald, L. (1999). Some terms of reference in data fusion. *IEEE Transactions on geoscience and remote sensing*, 37(3), 1190-1193.
- Walsh, M., Hary, I., & Schwartz, H. (1997). *Einsatz von geographischen Informationssystemen (GIS) und Methoden zur Verarbeitung unsicheren Wissens zur Beurteilung von Optionen des Ressourcenmanagements in pastoralen Systemen*. Ressourcenknappheit und Erhaltung der Lebensgrundlage - die Herausforderung für die Zukunft, Berlin.
- Wolfert, S., Ge, L., Verdouw, C., & Bogaardt, M.-J. (2017). Big data in smart farming—a review. *Agricultural systems*, 153, 69-80.
- Wu, D. (2012). Twelve considerations in choosing between Gaussian and trapezoidal membership functions in interval type-2 fuzzy logic controllers. 2012 IEEE International conference on fuzzy systems,
- Xue, J., & Su, B. (2017). Significant remote sensing vegetation indices: A review of developments and applications. *Journal of sensors*, 2017.
- Zadeh, L. A. (1965). Fuzzy sets. *Information and control*, 8(3), 338-353.



## A Anhang

Abbildung A- 1: Protokoll der Flächenbegehung am 21.03.2023

Betrieb: PBK Pritzwalk

Ort: Schönhagen, Fläche „Kombinat“

Datum: 21.03.2023

Thema: Beurteilung unterschiedlicher Grünlandstandorte

Grobe Bodenansprache mit Bodensonde und wenig Erfahrung

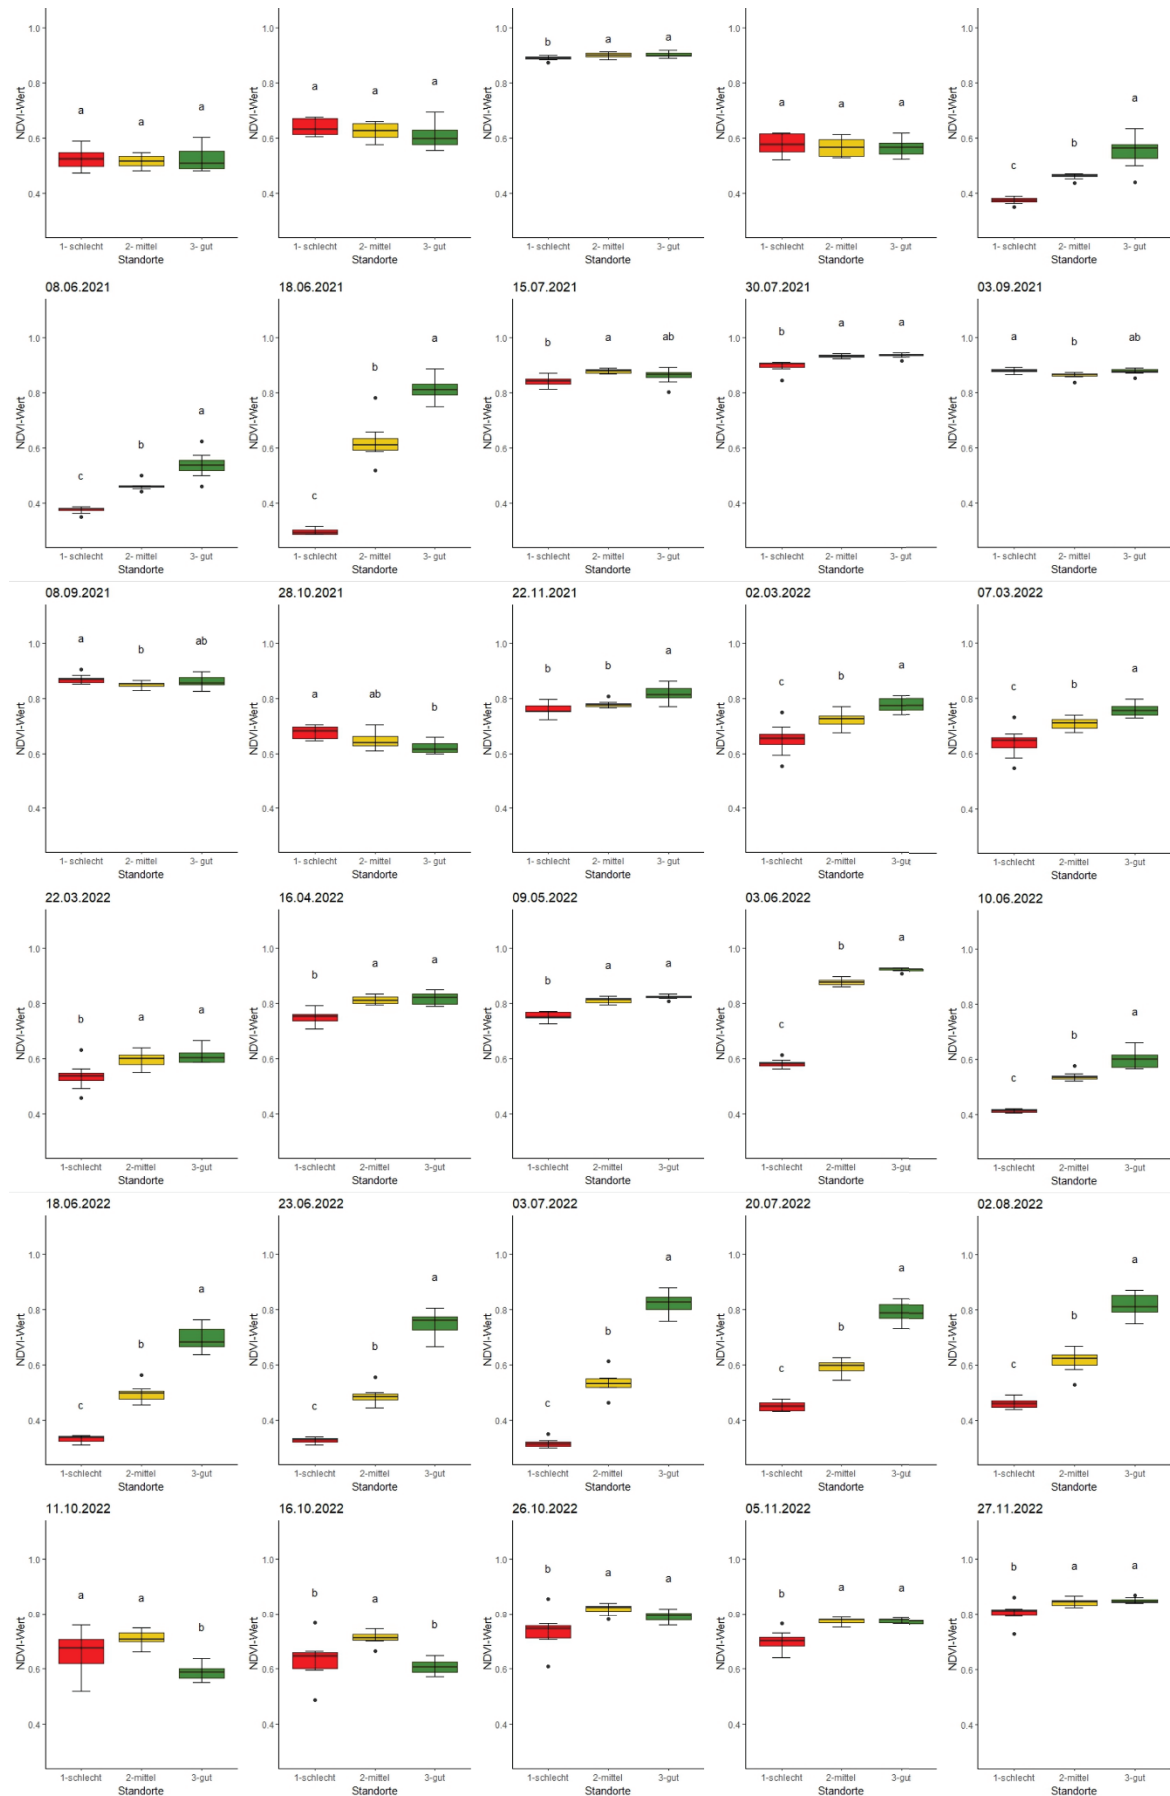
Siehe QGIS-Projekt: PBK\_Vor\_Ort\_Termin



Allgemeine Beobachtungen: Fläche stärker kupert als erwartet, sehr heterogen, vereinzelt Verunkrautung mit Vogelmiere, Taubnessel, Storchschnabel – winterannuelle Ackerunkrautflora?

1. Scharfer Übergang zu besserem Grasbestand, mehr Weidelgras, 10:90 Unkraut: Grünland  
35/40 ApAh -> Verdichtung, kein Substratwechsel (vermutetes Substrat: sandiger Lehm)
2. Flechten, Moose; 80:20 Unkraut:Grünland, starke Verunkrautung  
-35/40 ApAh mineralisch, kein tieferes Durchkommen, vermutl. Grobsand anstehend
3. auffällige Verunkrautung; vereinzelt Moose und Flechten 30:70 Unkraut:Grünland  
-40 anmooriger A-Horizont (kein kratzendes Geräusch), -50 Verdichtung, -90 Grobsand
4. anmooriger Oberboden -> deutlich dunkler, bindiger Boden, hohe Feuchtigkeit,  
5:95 Unkraut:Gras, -30 humoser/anmooriger A-Horizont, -50 mA/gS, -90 gS; Floppt beim Rausziehen (-> Wasser steht an?)
5. abfälliges Gelände, 40:60 Unkraut:Gras,  
-35 Ap/Ah sL? (hoher Feinsand bzw. Tonanteil), -50 IS (dichtlagernd), -80 IS, -90 gS
6. Kuppe, 70:30 Unkraut:Gras  
-35-40 gS (Verdichtung) -90 fS

**Abbildung A- 2:** Grafische Darstellung der Trennbarkeit der NDVI-Werte an vordefinierten Standorten. Eigene Darstellung 2023.





**Abbildung A- 3:** *Ergebnisse der Varianzanalysen und der Tukey HSD-Tests im Rahmen der Analyse der NDVI-Werte an vordefinierten Standorten. Jahre 2021 und 2022. Eigene Darstellung 2023.*

Ergebnisse Zeitreihenanalyse 2021								
		Mögliche Hypothesensets						
Datum	sign. A-NOVA	{g}	{m}	{s}	{g, m}	{m, s}	{g, s}	{g, m, s}
25.02.2021								a
22.03.2021								a
09.05.2021	*			b	a			
31.05.2021								a
05.06.2021	***	a	b	c				
08.06.2021	***	a	b	c				
18.06.2021	***	a	b	c				
15.07.2021								a
30.07.2021	***			b	a			
03.09.2021								a
08.09.2021								a
28.10.2021	***	ab*	b	a				
22.11.2021	***	b	ab*	a				
02.03.2022	***	a				b		
07.03.2022	***	a	b	c				
22.03.2022	***	a	b	c				
16.04.2022	***			b	a			
09.05.2022	***			b	a			
03.06.2022	***			b	a			
10.06.2022	***	a	b	c				
18.06.2022	***	a	b	c				
23.06.2022	***	a	b	c				
03.07.2022	***	a	b	c				
20.07.2022	***	a	b	c				
02.08.2022	***	a	b	c				
11.10.2022	*	a	b	c				
16.10.2022		a				b		
26.10.2022	*			b	a			
05.11.2022	***			b	a			
27.11.2022	**			b	a			

\*Signifikanzniveau sagt aus, dass Wertebereich nicht von anderen Gruppen abzugrenzen ist  
 \*Pixel in dieser Gruppe würden Hypothesenset {g, m, s} zugeordnet

**Abbildung A- 4:** *Chi-Quadrat-Wert und Cramer's V aus der Kontingenzanalyse der Einteilungsmethoden verschiedener Geodatenquellen. Eigene Darstellung 2023.*

Datenquelle	Datum	Einteilungsmethode	Chi-Quadrat-Wert	Cramer's V
TWI		I	407	0.25
TWI		Q	522	0.28
TWI		G	570	0.29
SAT	16.04.2022	I	1283	0.44
SAT	16.04.2022	Q	1093	0.41
SAT	16.04.2022	G	1184	0.42
SAT	30.07.2022	I	1529	0.48
SAT	30.07.2022	Q	1675	0.50
SAT	30.07.2022	G	1936	0.54
SAT	11.10.2022	I	396	0.24
SAT	11.10.2022	Q	443	0.26
SAT	11.10.2022	G	434	0.25

Abbildung A- 5: *Biomasse-Erntemengen der Jahre 2020, 2021 und 2022 auf der Fläche Kombinat.*  
 Quelle: PBK Pritzwalk, 2023.

<u>Ertragsübersicht GL</u>		1. Schnitt		2. Schnitt		3. Schnitt		4. Schnitt		Gesamt	Gesamtertrag im Feldblock in dt TS
Erntejahr	Fläche	TS Ertrag dt/ha	TS Gehalt %	TS Ertrag dt/ha	TS Gehalt %	TS Ertrag dt/ha	TS Gehalt %	TS Ertrag dt/ha	TS Gehalt %	TS Ertrag dt/ha	
2020	Kombinat Rinderzucht	23.35	38.00	17.70	85.00	6.30	38.00	8.47	30.00	47.34	2.211.33
2021	Kombinat Rinderzucht	46.53	50.00	8.45	38.00	30.93	32.00	4.80	30.00	85.92	3.594.28
2022	Kombinat Rinderzucht	19.65	41.00	6.14	40.00	6.07	30.00			31.86	1.262.13

Abbildung A- 6: *Ergebnisse der Varianzanalysen bzw. Post-Hoc-Tests (TukeyHSD) für die Faktoren der Variantensets 1 und 2. Erstellt mit R. Eigene Darstellung 2023.*

```
# Varianzanalyse mit anschließendem Tuckey-HSD-Test
# Faktor Jahr (Variantenset 1)

              Df Sum Sq Mean Sq F value Pr(>F)
df.ergA$Jahr  1 0.04344 0.04344   19.18 0.000239 ***
Residuals    22 0.04983 0.00227
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
  Tukey multiple comparisons of means
    95% family-wise confidence level

Fit: aov(formula = df.ergA$rel.Hfk ~ df.ergA$Jahr)

$`df.ergA$Jahr`
              diff              lwr              upr              p adj
2022-2021 0.08508333 0.04478732 0.1253793 0.0002391
```

```
# Varianzanalyse mit anschließendem Tuckey-HSD-Test
# Faktor Wahlmethode (Variantenset 1)

              Df Sum Sq Mean Sq F value Pr(>F)
df.ergA$Auswahl  1 0.01810 0.018095   5.296 0.0312 *
Residuals        22 0.07517 0.003417
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
  Tukey multiple comparisons of means
    95% family-wise confidence level

Fit: aov(formula = df.ergA$rel.Hfk ~ df.ergA$Auswahl)

$`df.ergA$Auswahl`
              diff              lwr              upr              p adj
Termin - Zufall-Termin - Auswahl -0.05491667 -0.1044083 -0.005425048 0.0312292
```

```
# Zweifaktorielle Varianzanalyse mit anschließendem Tuckey-HSD-Test
# Faktoren Jahr:Wahlmethode (Variantenset 1)

      Df Sum Sq Mean Sq F value Pr(>F)
Jahr   1 0.04344 0.04344  27.471 3.96e-05 ***
Auswahl 1 0.01810 0.01810  11.444 0.00296 **
Jahr:Auswahl 1 0.00012 0.00012  0.074 0.78836
Residuals 20 0.03162 0.00158
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
  Tukey multiple comparisons of means
    95% family-wise confidence level

Fit: aov(formula = rel.Hfk ~ Jahr + Auswahl + Jahr * Auswahl, data = df.ergA)

$Jahr
      diff      lwr      upr    p adj
2022-2021 0.08508333 0.05122103 0.1189456 3.96e-05

$Auswahl
      diff      lwr      upr    p adj
Termin - Zufall-Termin - Auswahl -0.05491667 -0.08877897 -0.02105437 0.0029553

$`Jahr:Auswahl`
      diff      lwr      upr    p adj
2022:Termin - Auswahl-2021:Termin - Auswahl 0.08066667 0.01641006 0.144923269 0.0107982
2021:Termin - Zufall-2021:Termin - Auswahl -0.05933333 -0.12358994 0.004923269 0.0768175
2022:Termin - Zufall-2021:Termin - Auswahl 0.03016667 -0.03408994 0.094423269 0.5650573
2021:Termin - Zufall-2022:Termin - Auswahl -0.14000000 -0.20425660 -0.075743398 0.0000324
2022:Termin - Zufall-2022:Termin - Auswahl -0.05050000 -0.11475660 0.013756602 0.1574742
2022:Termin - Zufall-2021:Termin - Zufall 0.08950000 0.02524340 0.153756602 0.0045514
```

```
# Varianzanalyse des Faktors Bodenschätzung (Variantenset 1)
```

```
      Df Sum Sq Mean Sq F value Pr(>F)
df.ergA$BS  1 0.00085 0.000852  0.203 0.657
Residuals  22 0.09242 0.004201
```

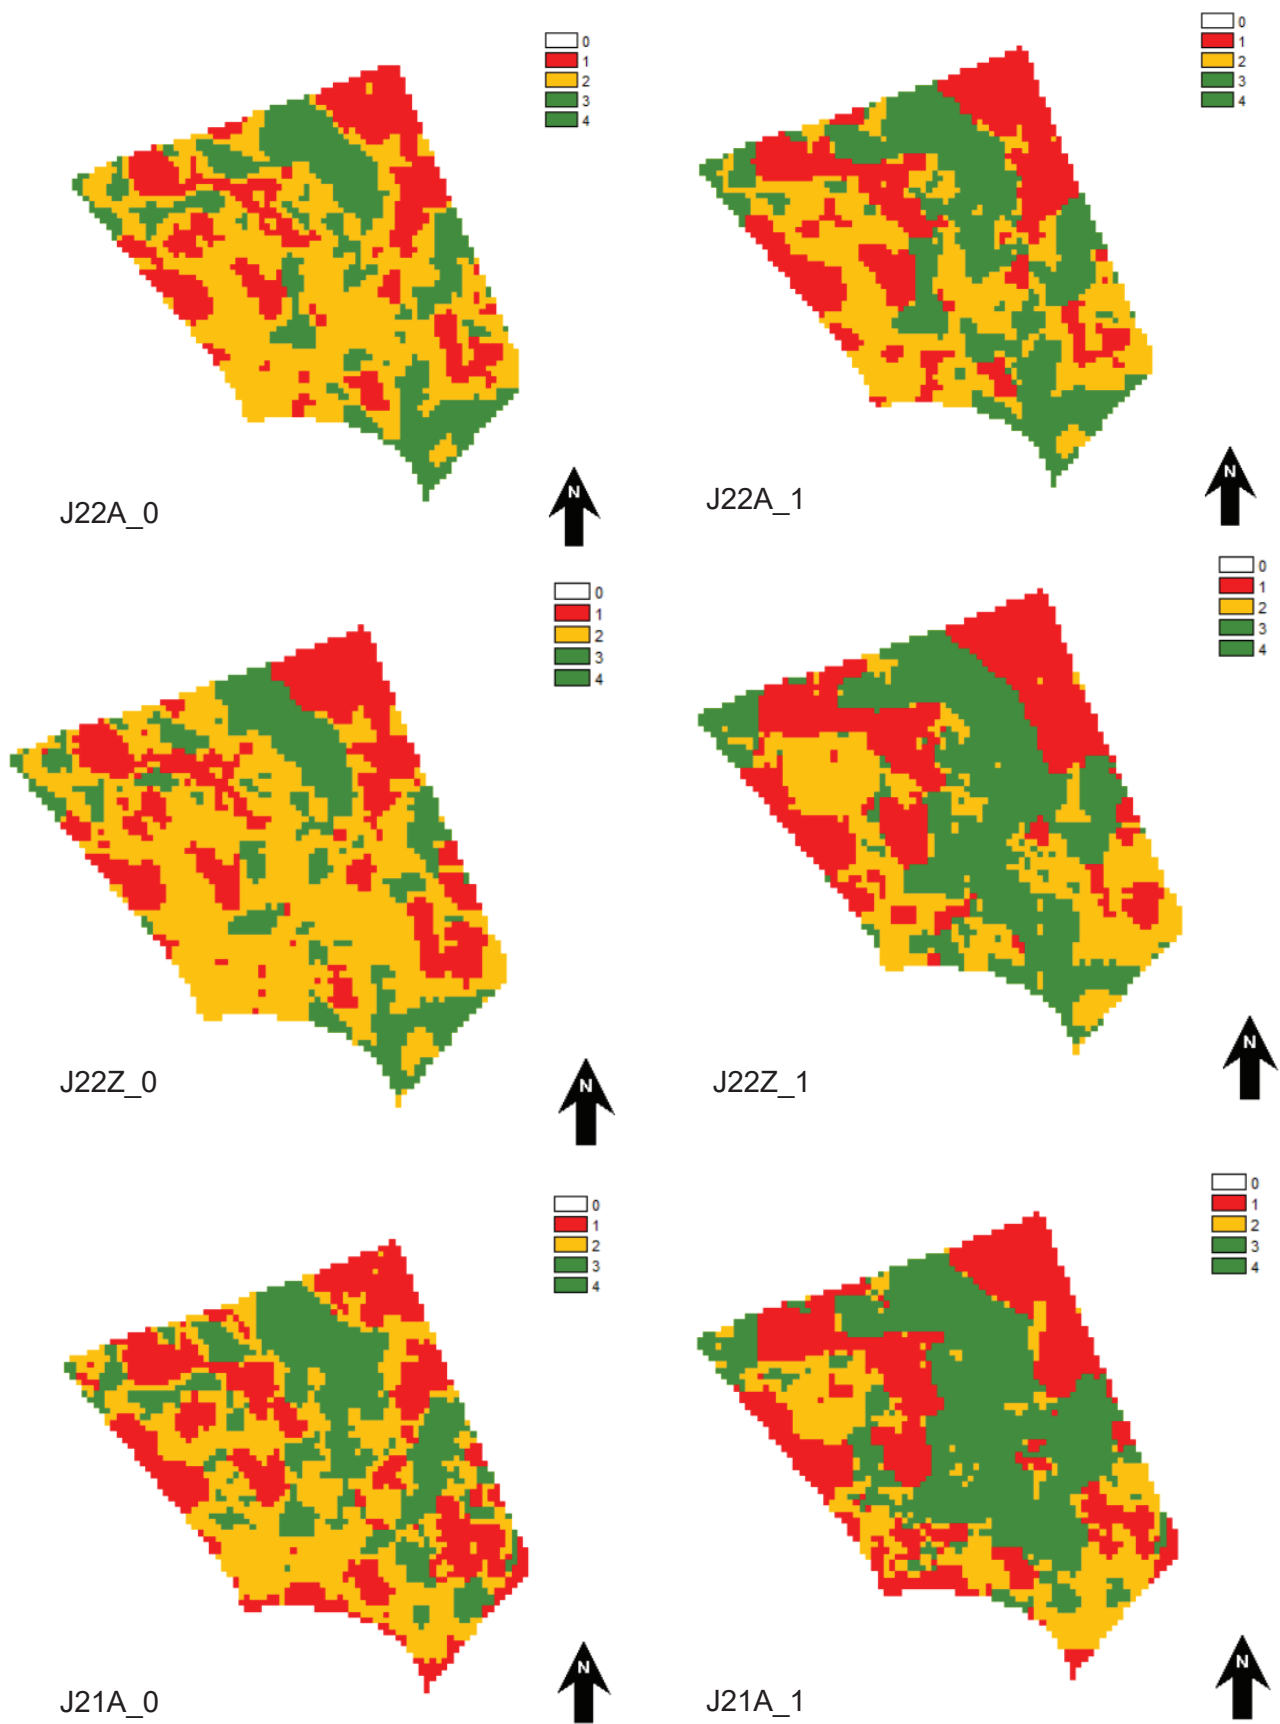
```
# Varianzanalyse des Faktors TWI (Variantenset 2, n=15)
```

```
      Df Sum Sq Mean Sq F value Pr(>F)
TWI    1 0.00109 0.001088  0.147 0.708
Residuals 13 0.09638 0.007414
```

```
# Varianzanalyse des Faktors TWI (Variantenset 2, n=12)
```

```
      Df Sum Sq Mean Sq F value Pr(>F)
TWI    1 0.00032 0.000323  0.04 0.846
Residuals 10 0.08108 0.008108
```

Abbildung A- 7: Ergebniskarten der Variantensets 1 und 2. Eigene Darstellung 2023








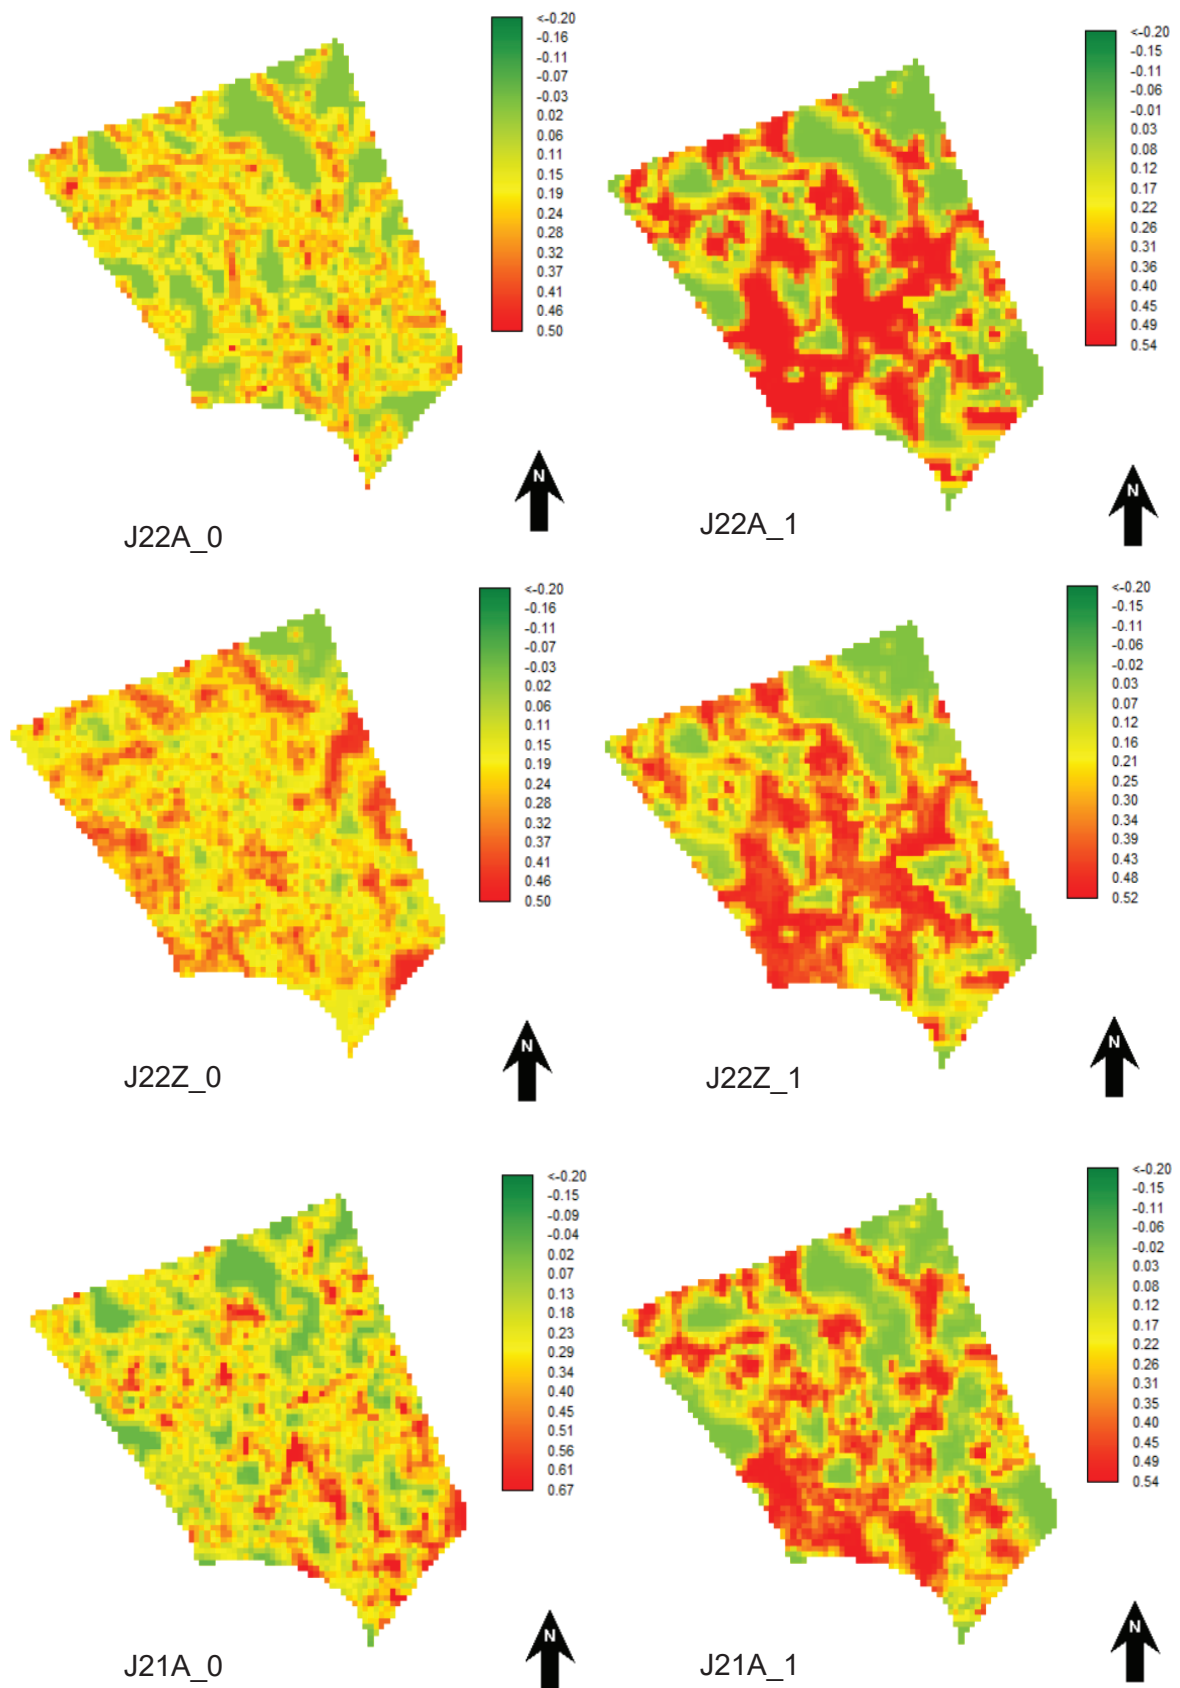







Abbildung A- 8: Konfliktkarten der Variantensets 1 und 2. Eigene Darstellung mit TerrSet 2023.









J21Z\_0





J21Z\_1




J22A\_0\_TWI




J21Z\_1\_TWI



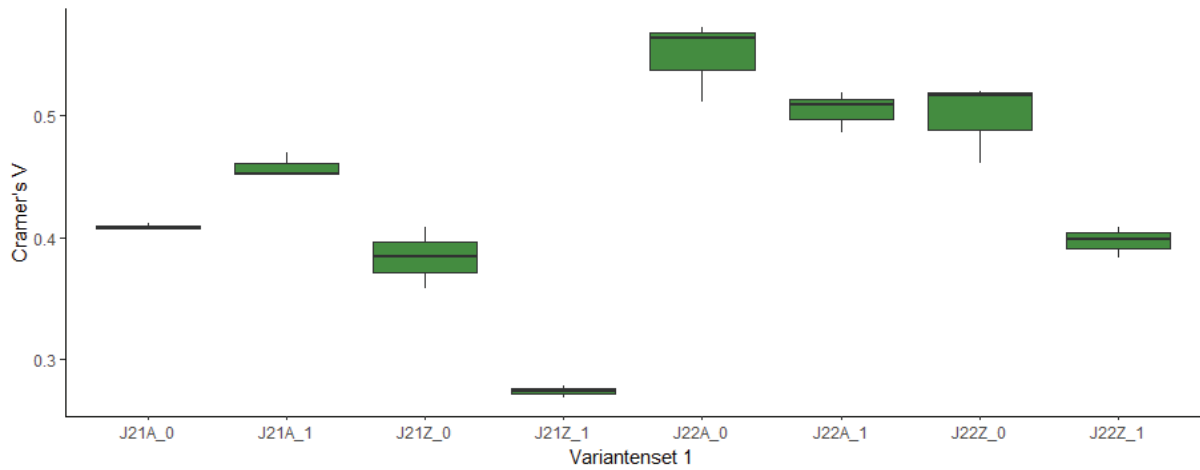
TWI+BS




**Abbildung A- 9:** *Chi-Quadrat-Wert der Varianten des Variantensets 1 in Gegenüberstellung mit dem Validierungsdatensatz. Eigene Darstellung 2023.*




**Abbildung A- 10:** *Cramer's V der Varianten des Variantensets 1 in Gegenüberstellung mit dem Validierungsdatensatz. Eigene Darstellung 2023.*




**Abbildung A- 11:** *Chi-Quadrat-Wert der Varianten des Variantensets 2 in Gegenüberstellung mit dem Validierungsdatensatz. Eigene Darstellung 2023.*




**Abbildung A- 12:** *Cramer's V der Varianten des Variantensets 2 in Gegenüberstellung mit dem Validierungsdatensatz, Eigene Darstellung, 2023.*



**Abbildung A- 13:** *Histogramm der NDVI-Werte des Satellitenbilds vom 30.07.2021, Standort: Kombinat, PBK Pritzwalk. Eigene Darstellung 2023.*



**Abbildung A- 14:** *Histogramm der NDVI-Werte des Satellitenbilds vom 03.07.2022, Standort Kombinat, PBK Pritzwalk. Eigene Darstellung 2023.*



**Danksagung**

Besonders Danken möchte ich dem Ideengeber, Betreuer und großen Förderer der vorliegenden Arbeit Herrn Professor Dr. Eike Stefan Dobers. Er stellte mir viele seiner eigenen Entwicklungen und Konzepte zur Verfügung und nahm sich immer Zeit für meine endlosen Fragen. Er war zuerst Lehrender auf einem langen Verständnisprozess und später kritischer und fordernder Diskussionspartner, weshalb ich auf eine sehr lehrreiche und prägende Zeit zurückblicken darf. Bei meiner Zweitbetreuerin Frau Professorin Dr. Becke Strehlow möchte ich mich für ihre Unterstützung und das Interesse an dem Thema meiner Arbeit bedanken. Herrn Tim Frädrich, dem Geschäftsführer der PBK Pritzwalk, danke ich für die Unterstützung bei der Umsetzung meiner Arbeit auf der Untersuchungsfläche Kombinat. Herr Frädrich zeigte große Bereitschaft, sich Zeit zu nehmen, Daten weiterzugeben und ausführliche, wertschätzende Gespräche zu führen, was den Erstellungsprozess meiner Arbeit sehr bereichert hat. Darüber hinaus ist die Unterstützung bei der Korrektur hervorzuheben, die ich durch Frau Renate Hanrieder bekommen habe. Sie war es, die meine Texte auf Verständlichkeit hin überprüft, und sie damit sehr verbessert hat. Für die liebevolle, manchmal fordernde aber immer bedingungslose Unterstützung meiner Familie und meines Partners bei all meinen Projekten und Ideen bin ich sehr dankbar.

## **Eidesstattliche Erklärung**

Ich, Linda Lechner, erkläre hiermit eidesstattlich, dass ich die vorliegende Bachelor-Arbeit/Master-Thesis mit dem Thema „Parametrisierung des Transferable Belief Models zur teilautomatisierten Zonierung von Grünland zum Zwecke der Ansprache von Standorten mit verschiedener Biomasseleistung auf einem Praxisbetrieb in der Prignitz“ selbständig und ohne Benutzung anderer als angegebenen Hilfsmittel angefertigt habe; die aus fremden Quellen direkt oder indirekt übernommenen Gedanken sind als solche kenntlich gemacht. Die Arbeit wurde bisher in gleicher und ähnlicher Form keiner anderen Prüfungsbehörde vorgelegt und auch noch nicht veröffentlicht.

Neubrandenburg, den 04.05.2023