



universität  
wien

# MASTERARBEIT/MASTER'S THESIS

Titel der Masterarbeit / Title of the Master's Thesis

## Beobachtung phänologischer Phasen aus dem All

verfasst von / submitted by

Hans Ressl, BSc

angestrebter akademischer Grad / in partial fulfilment of the requirements for the degree of

Master of Science (MSc)

Wien, 2019/ Vienna, 2019

Studienkennzahl lt. Studienblatt /  
degree programme code as it appears on  
the student record sheet:

A 066 614

Studienrichtung lt. Studienblatt /  
degree programme as it appears on  
the student record sheet:

Betreut von / Supervisor:

Masterstudium Meteorologie  
Priv.-Doz. Dr. Mag. Christoph Matulla



## Zusammenfassung

Diese Studie zielt darauf ab, einen Zusammenhang zwischen der satellitengestützten Landoberflächenphänologie (LSP) und den phänologischen Bodenbeobachtungen (GP) herzustellen, der es schließlich erlauben soll, phänologische Eintrittsdaten aus dem All zu bestimmen. Betrachtete Satellitenprodukte stammen aus der Sentinel-2-Mission, die 2015 mit dem Start von Sentinel-2A begonnen hat und 2017 mit Sentinel-2B fortgeführt wurde, sowie MODIS, auch aus zwei Satelliten bestehend, deren Daten bis 1999 bzw. 2002 zurückreichen. In dieser Arbeit werden die Jahre 2016 und 2017 betrachtet, in denen beide Produkte zur Verfügung stehen und miteinander verglichen werden können. Bodenbeobachtungen werden der europäischen phänologischen Datenbank PEP725 entnommen. Wir betrachten Eintrittstermine zweier phänologischer Phasen an verschiedenen Orten sowie die dort bis dahin beobachteten Verläufe des aus Satelliten-Daten abgeleiteten Normalized Difference Vegetation Index (NDVI) und bestimmen mit verschiedenen Ansätzen charakteristische Werte. Die Eignung dieser Ansätze bzw. der charakteristischen Werte wird durch den Vergleich von geschätzten mit beobachteten phänologischen Eintrittsterminen bewertet. Da uns zwei Jahre zur Verfügung stehen, wird ein Jahr zur Bestimmung der charakteristischen Werte herangezogen mit denen im anderen Jahr die Eintrittstermine geschätzt und mit den tatsächlich beobachteten verglichen werden (und vice versa). Neben der zeitlichen Validierung der Ansätze, evaluieren wir auch deren räumliche Abhängigkeit. Als phänologische Phasen betrachten wir den Laubaustrieb von Birke und Buche, da für diese Phasen die PEP725-Bodenphänologiedatenbank eine große Anzahl von Beobachtungen bereitstellt. Phänologische Beobachtungen haben in letzter Zeit viel Aufmerksamkeit erregt, indem sie als unabhängiger und zusätzlicher Beweis für den anthropogenen Klimawandel dienen. In den letzten fünf Dekaden haben sich die beiden betrachteten Laubaustriebsphasen um rund 10 Tage verfrüht. Die in dieser Arbeit durchgeführten und beschriebenen Analysen zeigen, dass zum gegenwärtigen Zeitpunkt eine physikalisch konsistente Bewertung der zur oben beschriebenen Kopplung zwischen LSP und GP verwendeten Ansätze nur auf Grundlage der MODIS-Daten erfolgen kann. Ergebnisse der zeitlichen Validierung zeigen eine ausgeprägte Abhängigkeit von der Region. Dieses Verhalten findet sich auch bei der räumlichen Leistungsbewertung wieder, wobei die Region in der die höchsten Werte der Gütemaße erreicht werden, auch jene ist, in der die zeitliche Validierung beste Ergebnisse liefert. In beiden Fällen wird die höchste Leistung mit demselben Kopplungsverfahren erzielt. Zusammenfassend gesehen bleiben die Ergebnisse großteils hinter den Erwartungen zurück. Dieses Verhalten hat mehrere Ursachen, wie z.B. den Mischpixeleffekt, der der Anlass für die gleichzeitige Betrachtung von Sentinel-2 und MODIS-Daten war, da die Hoffnung bestand, ihn durch die deutlich höhere räumliche Auflösung der Sentinel-2-Produkte reduzieren zu können. Andere sind: Fehler im Messvorgang und während der Datenprozessierung bei LSP, Beobachtungs- und Eingabefehler bei GP, Veränderungen in der Landnutzung, verschiedene zeitliche Auflösungen zwischen LSP und GP (day vs. composit period) und weitere in der Arbeit diskutierten. Bei den Sentinel-2-Daten hat die geringe zeitliche Auflösung, die einerseits durch den verspäteten Start von Sentinel-2B und andererseits von Wolkenfilterung sowie Fehlen von Satellitenbildern an Zeitpunkten mit vollständiger Bewölkung verursachten Datenlücken induziert ist, keine konsistenten Auswertungen und damit robusten Aussagen zugelassen. Dennoch deuten durchgeführte Analysen das in den Sentinel-2-Daten vorhandene Potential zur Verringerung des Mischpixeleffekts an, sobald eine höher zeitliche Auflösung erreicht ist und Datenlücken geschlossen werden können.



## Abstract

This thesis aims at analysing the potential of Sentinel-2 and MODIS Land Surface Phenology (LSP) to identify individual ground phenological (GP) phases. More specifically the effect of the considerably higher spatial resolution of the Sentinel data (10 m) compared to MODIS (250 m) on the quality of the LSP – GP relationship was to be quantified. Phenological observations gained lately much attention by serving as independent and additional evidence for the anthropogenic climate change. During the last five decades, phenological entry dates in spring advanced about 10 days towards earlier occurrences at mid to high latitudes. This investigation required satellite data from space as well as ground based phenological observations (GP), which are retrieved from the European phenological database PEP725. For this study the phenological phases “birch leaf unfolding” and “beech leaf unfolding” were selected as GP data and as LSP time series of the so-called Normalized Difference Vegetation Index (NDVI) available from satellite products. The temporal and spatial scope of the investigations was determined by the availability ground and satellite data sets. Sentinel-2 observations were available only for 2016 and 2017 and only for specific regions. The PEP725 data set was restricted to the existing stations. The conceptual approach through which we set out to accomplish the aforementioned objectives consists of two main steps. In the first step models simulating the linkage between LSP and GP are derived, while in the second step model-performances are assessed in sets of validation experiments, that systematically vary locations and periods used for model calibration and validation. Thereby it is possible to rank modelling approaches as well as to evaluate the suitability of Sentinel-2 and MODIS satellite data. Results based on the scope of data available at the time this thesis was conducted, reveal that sensible simulations of LSP-GP linkages require MODIS data. Validation experiments in both - spatial and temporal - modes show pronounced variations between the regions considered here. Furthermore, results of both modes match in terms of in which region and through which modeling approach highest performance is achieved. Asides from these results the main characteristic is an overall rather weak skill of the models simulating phenological occurrence dates from space. This, however, shall not come as a big surprise for several reasons amongst which the extremely short period of only two years, errors in locating GP observations, the considerable difference in temporal resolution between LSP (composite periods) and GP observations (days), the ‘mixed-pixel effect’ inherent to MODIS and the delayed launch of Sentinel’s second satellite impeding adequate observations are just a few of those discussed in the thesis. For the latter problem it was not feasible to demonstrate the reduction of the ‘mixed-pixel effect’ by Sentinel’s high spatial resolution. This, however, shall be possible as soon as a higher temporal resolution is reached and data gaps can be closed. The same applies to the new modelling approach of accumulating NDVI values. Its suitability, which is only hinted at in the analyses here, will soon become much clearer and add to the current state of the art.



# Inhaltsverzeichnis

<b>1 Einleitung</b>	<b>9</b>
1.1 Phänologie . . . . .	9
1.2 Motivation . . . . .	13
1.3 Stand der Wissenschaft . . . . .	15
1.4 Ziel . . . . .	17
<b>2 Daten</b>	<b>19</b>
2.1 Satellitendaten . . . . .	19
2.1.1 Normalized Difference Vegetation Index (NDVI) . . . . .	19
2.1.2 Sentinel-2 . . . . .	20
2.1.2.1 Sentinel-2 Prozessierung der ESA . . . . .	21
2.1.2.2 Sentinel-2-Datenquellen . . . . .	23
2.1.2.3 Problematik . . . . .	25
2.1.3 MODIS . . . . .	25
2.1.3.1 MODIS-Datenquelle . . . . .	25
2.1.3.2 MODIS-Prozessierung an der BOKU . . . . .	27
2.1.3.3 Problematik . . . . .	27
2.2 Landnutzungskataster . . . . .	28
2.2.1 Baumkronendichte . . . . .	28
2.2.2 Dominanter Blatttyp . . . . .	29
2.2.3 Problematik . . . . .	29
2.3 Bodenbeobachtungen . . . . .	29
2.3.1 Problematik . . . . .	29
2.3.2 Buche . . . . .	30
2.3.3 Birke . . . . .	32
2.3.4 Die phänologischen Jahre 2016 und 2017 . . . . .	33
<b>3 Methoden</b>	<b>37</b>
3.1 Datenbeschaffung und -aufbereitung . . . . .	37
3.2 Vergleich der Datensätze und Pixeldetektierung . . . . .	37
3.3 Zeitliche NDVI-Verläufe und Interpolation . . . . .	38
3.4 Bestimmung der Laubaustriebsphase . . . . .	39
3.4.1 Gaussian-Midpoint-Methode . . . . .	40
3.4.2 Spline-Midpoint-Methode . . . . .	40
3.4.3 Polyfit-Maximum-Methode . . . . .	40
3.4.4 Kumulativer NDVI . . . . .	41
3.5 Zeitliche und räumliche Validierung . . . . .	42
3.6 Durchführung mit Sentinel-2-Daten, Vergleich mit MODIS und Analyse der Satellitendaten . . . . .	43
<b>4 Resultate</b>	<b>44</b>
4.1 Zeitliche Validierung der Methodik . . . . .	44
4.2 Räumliche Validierung der Methodik . . . . .	54
4.3 Durchführung der Methodik mit Sentinel-2-Daten . . . . .	68
4.4 Analyse des MODIS- und Sentinel-2-NDVI . . . . .	71
4.5 Analyse der phänologischen Bodenbeobachtungen . . . . .	73
<b>5 Diskussion</b>	<b>77</b>

<b>6 Aussichten</b>	<b>81</b>
<b>7 Danksagung</b>	<b>82</b>
<b>Literatur</b>	<b>83</b>
<b>Appendix</b>	<b>91</b>

# 1 Einleitung

In den letzten Jahrzehnten hat die Phänologie, die Wissenschaft der periodisch im Jahresablauf wiederkehrenden Entwicklungsstadien von Flora und Fauna, in der Klimaforschung wie auch der Forst- und Landwirtschaft, deutlich an Signifikanz gewonnen (Rosenzweig et al., 2007). Natürliche Schwankungen aber auch anthropogenen aufgeprägte Trends haben unter anderem direkte Auswirkungen auf Wirtschaft, Gesundheit und Sozio-Ökonomie. Bei der Beschreibung derartiger Konsequenzen hat sich die Phänologie als besonders geeignet erwiesen, den Einfluss des menschengemachten Klimawandels abzubilden (Menzel et al., 2006; Schwartz et al., 2002).

## 1.1 Phänologie

Die Phänologie ist die Lehre von jahreszeitlichen Zyklen der Lebensphasen von Pflanzen und Tieren. Charakteristische Phasen in der Entwicklung von Wild- und Kulturpflanzen, wie Laubbaustrieb, Blüte, Blattverfärbung und Blattfall, aber auch von Tieren, wie im Frühjahr das erstmalige Auftauchen von Insekten und die Ankunft von Zugvögeln, gehören dazu. Die Beobachtungen dieser Phasen, deren Eintrittsdatum und Erscheinungsort, werden dazu in sogenannten phänologischen Karten festgehalten, welche Aussagen über räumliche Verhältnisse des lokalen Klimas, der Pflanzengeographie und der Länge der Vegetationszyklen liefern (Bammel et al., 2009; Zentralanstalt für Meteorologie und Geodynamik (ZAMG), 2018f).

Beobachtungen phänologischer Phasen besitzen eine jahrhundertealte Tradition. In Europa wurden 1957 die Internationalen Phänologischen Gärten (IPG) von E. Volkert und F. Schnelle gegründet. Um für ganz Europa vergleichbare phänologische Beobachtungsdaten aufzeichnen zu können, wurde ein Muttergarten errichtet, in welchem Zucht und Verteilung der Pflanzen abliefern. Bei vielen verschiedenen Einrichtungen und Institutionen wurden die IPG eingerichtet. Am Standort eines jeden Gartens gibt es eine offiziell betriebene Wetterstation. Das IPG-Beobachtungsnetz überdeckt 28 Längen- und 37 Breitengrade. Es reicht von Skandinavien bis Irland im Norden und Mazedonien bis Portugal im Süden (siehe Abbildung 1.1). Im Jahr 2010 beinhalteten die Internationalen Phänologischen Gärten 89 Stationen, welche verschiedenste Klimaregionen abdecken, und seit 2000 umfasst deren Beobachtungsprogramm 21 Pflanzenarten (Humboldt-Universität zu Berlin, 2017).

Pflanzen reagieren auf veränderte Umwelteinflüsse sehr empfindlich, womit auch der Klimawandel eine eindeutig sichtbare Wirkung auf phänologische Phasen hat. In Nordamerika und Europa zeigen lange phänologische Beobachtungsreihen seit Mitte des 20. Jahrhunderts Verschiebungen von Blühbeginn und Blattentfaltung um etwa 2.3 bis 5.2 Tage pro Jahrzehnt zu früheren Eintrittszeiten. Dazu treten Laubverfärbung und Laubfall hingegen immer später im Jahr ein (siehe Abb. 1.2), wodurch sich die Länge der Vegetationsperiode bis zu zwei Wochen verlängerte (Bammel et al., 2009; Zentralanstalt für Meteorologie und Geodynamik (ZAMG), 2018f).

Es zeigt sich, dass hauptsächlich in den mittleren und höheren Breiten Pflanzen deutlich auf Veränderungen in Temperatur und Niederschlag reagieren, besonders deren Fruchtreifephäsen während der warmen Jahreszeit. Dies ist in Abbildung 1.3 für Österreich einsehbar und zeigt damit eine Übereinstimmung der langfristigen Trends von Temperatur und Eintrittszeiten phänologischer Phasen (Bammel et al., 2009; Zentralanstalt für Meteorologie und Geodynamik (ZAMG), 2018f).

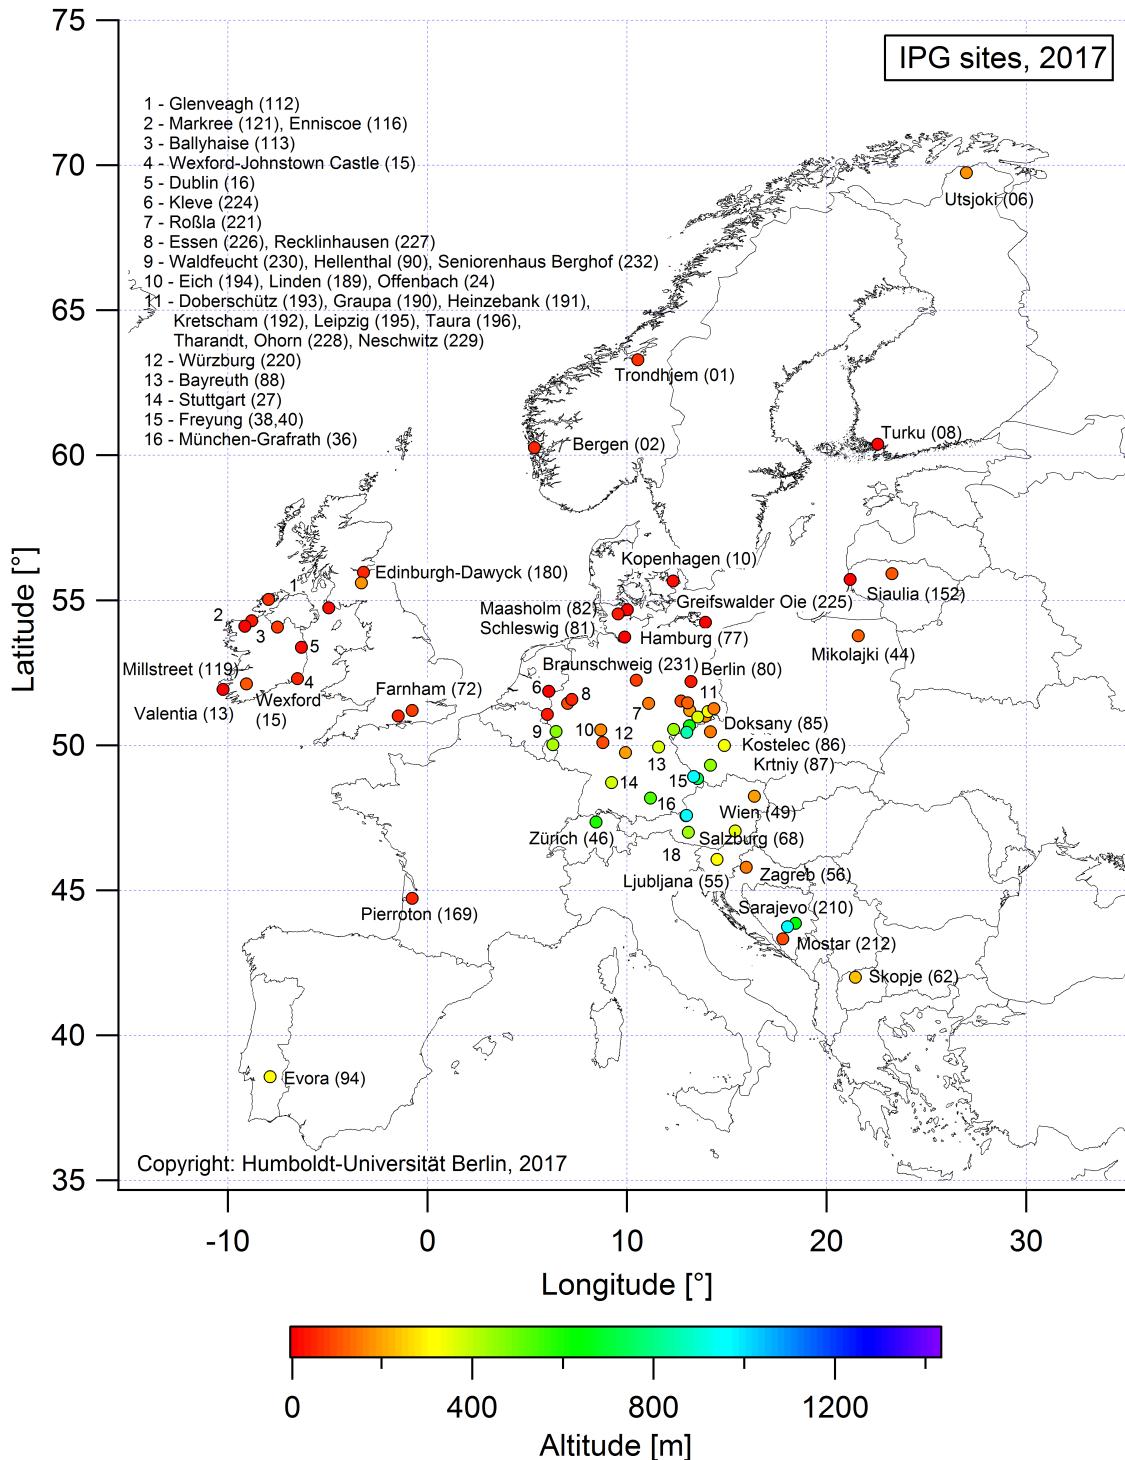


Abb. 1.1: Karte der Internationalen Phänologischen Gärten Europas. Das Beobachtungsnetz überdeckt 28 Längen- und 37 Breitengrade. Quelle: Humboldt-Universität zu Berlin, 2017

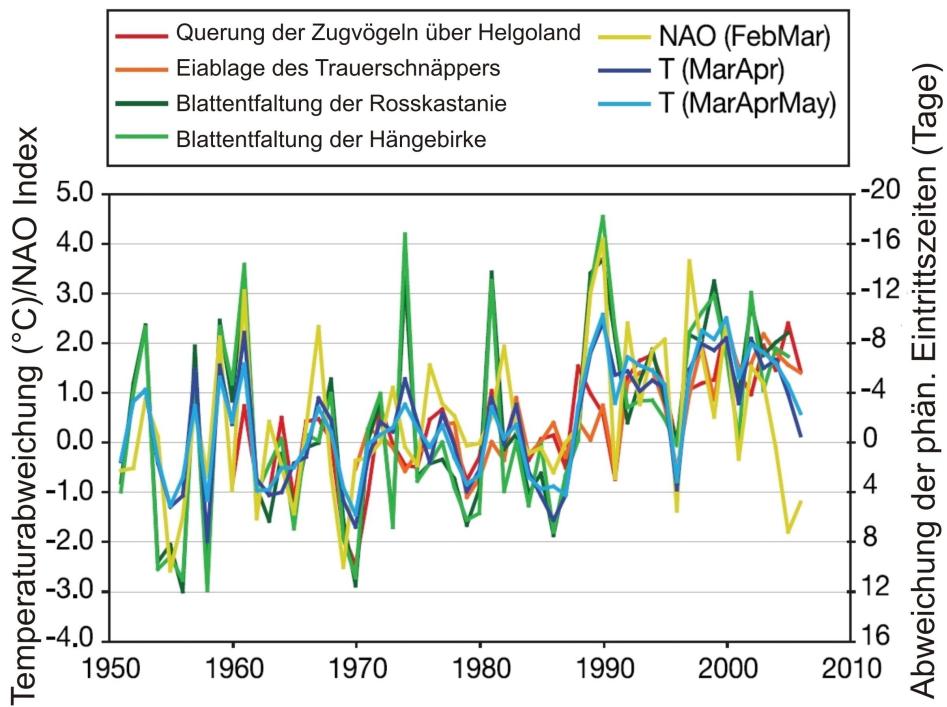


Abb. 1.2: Anomaliezeitreihen phänologischer Phasen von Pflanzen und Tieren in Deutschland, sowie der mittleren Frühlingstemperatur und des Nordatlantischen Oszillationsindex (NAO) in Bezug auf die Periode 1961-1990. Quelle: Parry et al., 2007

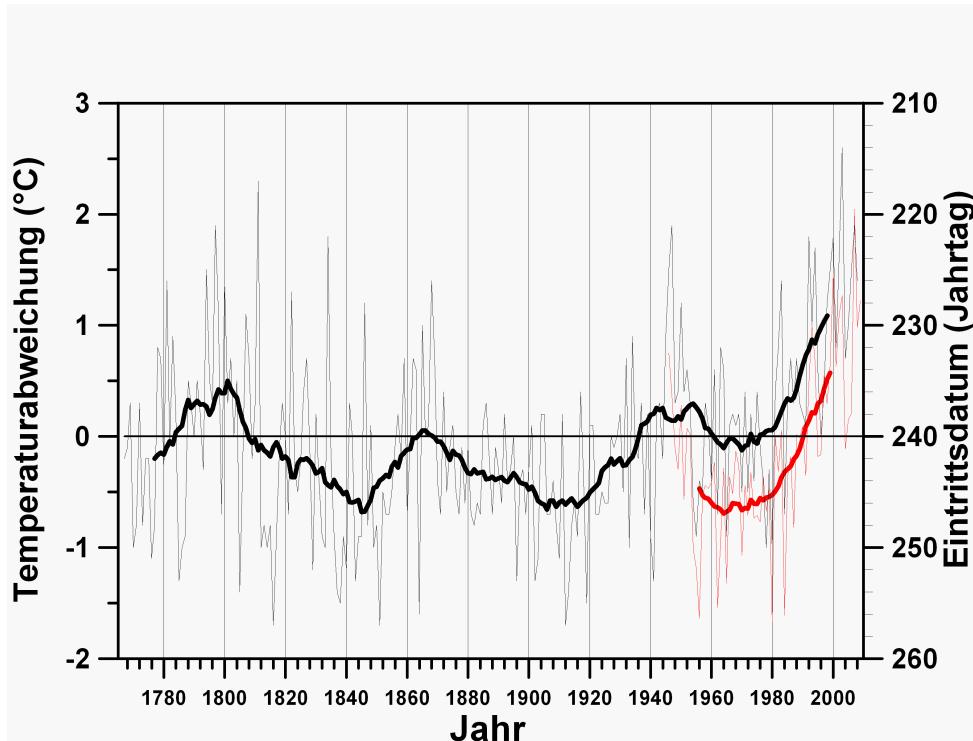


Abb. 1.3: Vergleich zwischen der mittleren Temperatur des Sommerhalbjahres in der nordöstlichen Alpenregion (schwarz) und dem Beginn der Fruchtreife des schwarzen Holunders (rot) – beides relativ zum Mittel der Periode 1901–2000. Dicke Linien entsprechen dem gleitenden Mittel über 21 Jahre. Quelle: Zentralanstalt für Meteorologie und Geodynamik (ZAMG), 2018f

Das phänologische Jahr ist in 10, auf Physiologie und Biologie der Pflanzen basierenden, Jahreszeiten unterteilt. Der Beginn einer Jahreszeit wird nicht durch ein bestimmtes Datum, sondern durch festgelegte Entwicklungsstadien ausgewählter Pflanzen, bestimmt (Bammel et al., 2009; Zentralanstalt für Meteorologie und Geodynamik (ZAMG), 2018d; Zimmermann et al., 2016):

- Wenn Haselnuss und Schneeglöckchen zu blühen beginnen, fängt der **Vorfrühling** an, die Natur erwacht mit dem Erblühen erster Holzpflanzen und Kräuter. Diese Phase endet mit der Blüte der Salweide. Im **Erstfrühling**, dessen Beginn die ersten Forsythienblüten markieren, starten bei vielen Holzpflanzen Blüten und Laubaustrieb. Alternativ kann die Blattentfaltung der Stachelbeere als Indikator herangezogen werden. Der phänologische Frühling endet mit dem Blattaustrieb der Stiel-Eiche und der Apfelblüte im **Vollfrühling**, die Blüte der meisten Gehölze und das Laub der Wälder sind voll entwickelt.
- Der **Frühsommer** setzt mit dem Blühbeginn der Robinie und des Schwarzen Holunders ein und endet mit dem Reifen ersten Beeren. Im **Hochsommer**, in dem Johannisbeeren und Linden blühen sowie Süßkirschen zu pflücken sind, und im **Spätsommer**, der durch die Fruchtreife der Vogelbeere (Eberesche) und des Frühpfels angezeigt wird, reifen die meisten Feld- und Gartenfrüchte völlig und werden geerntet.
- Wenn Hagebutten und Holunderbeeren ausreifen sowie die Herbstzeitlosen blühen, fängt der **Frühherbst** an. Brombeeren und Birnen werden geerntet. Im **Vollherbst** beginnt die Laubverfärbung, die Eicheln der Stieleiche und die Rosskastanie werden reif. Der phänologische Herbst endet mit dem **Spätherbst**, die Blätter der Rotbuche und der Stieleiche verfärbten sich und die Eberesche wirft ihr Laub ab.
- Das phänologische Jahr wird vom **Winter** abgeschlossen, der mit dem Laubfall von Stieleiche und spätreifenden Apfelsorten beginnt. Die Bäume haben ihr Laub verloren und es herrscht weitestgehend Vegetationsruhe. Um das spätere Keimen ihrer Samen gewährleisten zu können, benötigen etliche Wildpflanzen Frost.

Die phänologischen Jahreszeiten unterscheiden sich von den kalendarischen wesentlich in ihrer Länge. Im Zeitraum 1997 – 2016 bildete der phänologische Herbst mit etwa 70 bis 80 Tagen die kürzeste Jahreszeit, Winter und Frühling dauerten meist mehr als 100 Tage. Der Beginn des Herbstanfangs sowie des Winters unterliegt keinen großen Schwankungen, während im Gegensatz dazu der Eintritt des phänologischen Frühlings eine große Variabilität zeigt. Die Winterruhe bei Pflanzen endet hauptsächlich durch den Anstieg der Temperatur im Frühjahr. Vor allem die Witterung in den ersten Monaten des Jahres kann alljährlich stark variieren, womit ebenso die Pflanzenentwicklung während dieser Zeit großen Schwankungen unterworfen ist (Zimmermann et al., 2016).

## 1.2 Motivation

Der saisonalen Zyklus von Pflanzen und Tieren wird insbesondere in mittleren bis hohen Breitengraden von der Temperatur bestimmt. Daher wird die Phänologie als Mittel zur Dokumentation der Auswirkungen des Klimas auf die Ökosysteme verwendet (Menzel et al., 2006; Schwartz et al., 2002). Veränderungen im Auftreten phänologischer Phasen führen zu Änderungen der Länge von Vegetationsperioden und Pflanzenwachstumsphasen, was wiederum die Produktivität von Ökosystemen, die Wechselwirkungen zwischen Tieren und Pflanzen, den globalen und regionalen Kohlenstoffkreislauf sowie andere wesentliche Ökosystemprozesse beeinflusst. Untersuchungen der vielfältigen Zusammenhänge zwischen den sich verändernden Klimaantrieben und den durch die Phänologie festgehaltenen Reaktionen der Ökosysteme sind von herausragender Bedeutung hinsichtlich der Planung von Mitigations- und Adoptionsmaßnahmen, die zum Schutz von Gesellschaft, Flora und Fauna gegebenenfalls einzuleiten sind (Cleland et al., 2007; White et al., 2009).

Im Bereich der Fernerkundung wird die Phänologie als Bestandteil von Land-Surface-, Wettervorhersage- und Klima-Modellen zur Anwendung gebracht. Dabei dient die Entwicklung phänologischer Phasen im Vegetationszyklus unter anderem als Indikator für die Bodenfeuchte, welche in Folge den Energie- und Masse-Austausch zwischen Boden und Atmosphäre mitbestimmt. In diesem Zusammenhang sind Gräser optimale Zeiger für den Bodenwasserhaushalt. Abgesehen davon hat der Prozess des „Ergrünens“ von Pflanzen einen maßgeblichen Einfluss auf den latenten Wärmeaustausch bzw. Wärmefluss (Jolly et al., 2004; Le Roux et al., 1995; Menzel, 2002; Oliver et al., 1987). Wetter- und Klimamodelle benötigen, um die Strahlungs- und Energiebilanz korrekt modellieren zu können, die räumliche Verteilung des Bodens, der Vegetationsbedeckung und deren Zustand (Richardson et al., 2012). Es wurden Versuche durchgeführt, in Landoberflächenmodellen, die integraler Bestandteil von Klima- und Wettermodellen sind, den saisonalen Zyklus der Vegetation zu modellieren. Dabei wurde die Parametrisierung der Oberflächenalbedo auf Basis von LSP- und/oder GP-Datensätzen abgeleitet und in ein regionales sowie globales Klimamodell integriert (Rechid et al., 2009a; Rechid et al., 2009b; Song, 1999).

In der Grenzschichtmeteorologie hat der Zustand der Vegetation einen entscheidenden Einfluss auf die Rauigkeit der Erdoberfläche und den Energieaustausch. Refslund et al. (2014) zeigte mit Simulationen eines Wettervorhersagemodell während Hitzewellen und Dürren, bei denen die Vegetationsbedingungen und die Klimatologie voneinander abweichen, dass aktuelle Landoberflächeninformationen erforderlich sind. Derartige Informationen der Landoberfläche lassen sich aus dem Verhältnis des quadratischen Normalized Difference Vegetation Index (NDVI, siehe 2.1.1) zu den Grünflächenanteilen ableiten.

Eine zentrale Domäne der Phänologie ist die Land- und Forstwirtschaft. Dabei sind zwei Effekte im Vegetationszyklus von herausragender Bedeutung: (i) die Erwärmung im Frühjahr im Zusammenhang mit Spätfrostereignissen und (ii) das sogenannte „chilling“ im Herbst. Spätfrostereignisse steuern beispielsweise den Ernteeertrag im Obstbau, da sie die Entwicklung der Früchte schädigen oder ganz verhindern. Im Herbst, wenn die Tage kürzer werden und nachts tiefere Temperaturen vorherrschen, gehen die Pflanzen in die Winterruhe (auch Dormanz genannt) über, welche mit der Frostresistenz eng verknüpft ist. Während der Endodormanz (oder auch endogenen Dormanz) können Pflanzen selbst durch Erwärmung nicht stimuliert werden. Meist um die Wintersonnenwende, aufgrund längerer Tage und/oder wenn ein gewisses Kältebedürfnis<sup>1</sup> erreicht wurde („chilling“), wird dieses Stadium durchbrochen. Während der darauffolgenden exogenen Dormanz („quiescence“) können Pflanzen lediglich durch ungünstige Bedingungen

<sup>1</sup>Die reproduktive Entwicklung etlicher Pflanzen wird durch das Einwirken tiefer Temperaturen induziert oder unterstützt. Gassner entdeckte 1918 dieses „Kältebedürfnis“. (Lang et al., 1951)

Ende des Winters in ihrer Entwicklung beeinträchtigt werden. In dieser Zeit können sie auf höhere Temperaturen reagieren, ihre Entwicklungsrate steigt proportional mit der Temperatur („forcing“) (Menzel, 2007; Zimmermann et al., 2016). Wenn die Temperaturen weiter ansteigen, kann es sein, dass die Kältesummen, die für das „chilling“ notwendig sind, im Herbst nicht mehr erreicht werden. Das Auftreten der Kirschblüte im Frühling beispielsweise ist ein oft betrachteter Indikator für Klimaschwankungen. In Gegenden, wie Südafrika oder Australien, könnte die projiizierte weitere Erwärmung des Klimas zu einer Reduktion der möglichen Flächen führen, die für die Produktion von Kirschen geeignet sind (Darbyshire et al., 2011; Luedeling, 2012; Luedeling et al., 2013; Measham et al., 2014; Kapp, 2008).

Ein weiterer vom Klima gesteuerter Impact auf den Erfolg phänologischer Spezies liegt in der Begünstigung der Entwicklung von Schädlingen (z.B. Anzahl der im Vegetationszyklus ausbildbarer Generationen). Das bedeutet, dass die vom Klimawandel getriebene Entwicklung von Schädlingen berücksichtigt werden muss. Tatsächlich existiert eine Synchronisation zwischen der Vermehrung bzw. dem Auftreten von Schädlings-Generationen und phänologischen Phasen im Vegetationszyklus, die in Zukunft empfindlich gestört werden könnte. Dies würde weitreichende Konsequenzen, etwa in der Nahrungskette der Tierwelt, erzeugen. Raupen und Würmer ernähren sich von Knospen und Blättern, welche wiederum von Vögeln und anderen Tierarten gefressen werden, um nur ein Beispiel zu nennen (Scheifinger et al., 2007; Visser, 2008; Visser et al., 2012).

Auch sozio-ökonomische Aspekte der Phänologie können genannt werden, wie Alm-Auf- und Abtrieb, Saat und Ernte und der Reinigungsflug der Bienen im Bereich der Imkerei (Gorlier et al., 2012; Gounari, 2006; Pietzsch et al., 2016). Des Weiteren hat die Phänologie Auswirkungen auf die menschliche Gesundheit. Etwa 5 bis 30 % der Bevölkerung in den Industrieländern sind von allergischen Erkrankungen wie Asthma und Rhinitis<sup>2</sup> betroffen und der Prozentsatz steigt weiterhin an (Sofiev et al., 2013). Asthma ist eine nicht übertragbaren chronische Erkrankung der Atemwege der Lunge. Weltweit leiden rund 235 Millionen Menschen an Asthma, vor allem Kinder sind häufig davon betroffen (World Health Organization (WHO), 2018). Prognosen über den Beginn der Pollensaison und die Höhe der allergenen Pollenkonzentration in der Atmosphäre können neben der medizinischen Behandlung Allergikern helfen, vorbeugende Maßnahmen zu ergreifen, welche die negativen Auswirkungen allergischer Reaktionen vermindern können (Beggs, 2015; Zhang et al., 2015). Daher entwickelten die meisten europäische Wetterdienste numerische Pollenvorhersagemodelle (NPFDs), um die Pollenkonzentration in der unteren Atmosphäre über große Gebiete quantitativ vorherzusagen (Helbig et al., 2004; Pasken et al., 2005; Sofiev et al., 2006a; Sofiev et al., 2006b; Vogel et al., 2008; Zink et al., 2012). Diese NPFDs enthalten zur Simulation des Blühbeginns relevanter Spezies unter anderem ein phänologisches Modell, das mit langzeitigen phänologischen Beobachtungen abgeglichen ist (Scheifinger et al., 2013). Eine mögliche Anwendung von Echtzeit-LSP könnte das im NPFD enthaltene phänologische Modell stark unterstützen.

Umweltauswirkungen lassen sich auf Änderungen der phänologischen Phasen von Indikatorpflanzen zurückführen. Somit sind diese Veränderungen Zeiger für den Zustand der Umwelt. Phänophasen (Pollen) werden in der Paläoklimatologie benutzt um pre-instrumentelle Perioden in der Vergangenheit hinsichtlich deren Klimata zu beschreiben (Gosling et al., 2013; Grímsson et al., 2014).

---

<sup>2</sup>Rhinitis ist eine akute oder chronische Entzündung der Schleimhäute, hervorgerufen durch Infektionen und Allergien (Bousquet et al., 2008)

### 1.3 Stand der Wissenschaft

Untersuchungen von Vegetationsphänologie und deren Änderungen werden derzeit mit zwei verschiedenen Ansätzen durchgeführt: phänologische Bodenbeobachtungen (Ground Phenology, GP) und satellitengestützte Phänologie (Land Surface Phenology, LSP). In jüngerer Zeit wurden auch phänologische Beobachtungen der Vegetationsphänomene mit Hilfe von kontinuierlichen Aufnahmen von feststehenden Digitalkameras aufgenommen oder mit multispektralen und hyperspektralen Sensoren erstellt (Klosterman et al., 2014; Lange et al., 2017). Der erste Ansatz umfasst traditionelle *in situ*-Beobachtungen vor Ort. In Europa wurden zahlreiche bodenphänologische Untersuchungen durchgeführt (Ahas et al., 2002; Defila et al., 2001; Luterbacher et al., 2007; Menzel et al., 2006; Roetzer et al., 2000; Rutishauser et al., 2008; Scheifinger et al., 2002; Wolkovich et al., 2012). Diese phänologischen Studien haben den Vorteil der langen zeitlichen Abdeckung. Viele von diesen reichen in die frühen 1900er Jahre zurück. Die Überwachung der Phänologie am Boden einzelner Arten ist jedoch stark eingeschränkt, was vor allem auf (i) die Schwierigkeiten bei der Vereinheitlichung von Datensätzen über Pflanzenarten und phänologische Ereignisse zurückzuführen ist; (ii) die Schwierigkeit, die Daten mit Beobachtungen von Klimavariablen in Beziehung zu setzen; (iii) die zeitaufwändige Art der Beobachtung; (iv) die identifizierten phänologischen Phänomene, die repräsentativ für einzelne Arten und nicht für Populationen sind (Studer et al., 2007; White et al., 2009).

Einige dieser Schwierigkeiten werden durch die Ableitung von LSP aus Satellitenbeobachtungen vermieden, so dass die Phänologie potenziell auf globaler Ebene abgebildet werden kann (White et al., 2005). Dieser zweite Ansatz besteht in der Verwendung des satellitenbasierten normalisierten Differenzvegetationsindex (NDVI). LSP ist jedoch nicht frei von Unsicherheiten, wie gemischte phänologische Signale mehrerer Landnutzungsformen („Mischpixeleffekt“), Rauschen in den Satellitensensordaten und Fehler in Verarbeitungsverfahren und Störungen durch den Menschen, wie Urbanisierung, politische und landwirtschaftliche Veränderungen (White et al., 2005). Der LSP-Ansatz kann nicht für das Monitoring einzelner Pflanzen oder Arten verwendet werden. Zudem liegen oft nur relativ kurze Zeitreihen von Daten vor (White et al., 2005). Darüber hinaus variieren die Ergebnisse erheblich, je nachdem, welcher Algorithmus verwendet wird, um das Datum des Einsetzens des Ergrünens oder des Beginns der Saison (SOS) aus der jährlichen NDVI-Zeitreihe zu extrahieren (White et al., 2009). So wurden zum Beispiel Unterschiede von mehr als 30 Tagen festgestellt, wenn verschiedene Methoden zur Extraktion der SOS-Daten im gemäßigten China angewendet wurden (Cong et al., 2012). Obwohl GP als auch LSP erfolgreich angewandt wurden, um die Frühlingsdynamik zu erfassen (Cleland et al., 2007), sind die Korrelation zwischen den beiden Methoden typischerweise schwach (Badeck et al., 2004; Cleland et al., 2007; Rodriguez-Galiano et al., 2015). Deshalb wird eine Kombination aus *situ*-Beobachtungen und NDVI-basierte Daten zur Beobachtung von Veränderungen in der Frühjahrsphänologie bevorzugt (Fu et al., 2014).

Es gibt einige Versuche, LSP und GP zu vergleichen (Badeck et al., 2004; Hamunyela et al., 2013; Maignan et al., 2008; Studer et al., 2007; White et al., 2009; Rodriguez-Galiano et al., 2015). Trotz der großen Herausforderungen Satelliten- und Bodenbeobachtung zu vergleichen, sollten sich beide Beobachtungsmethoden ergänzen. In einigen Situationen sind GP-Datensätze zur Interpretation der Satellitenphänologie erforderlich, in anderen LSP-Daten zur Hochskalierung von GP-Daten (Badeck et al., 2004; White et al., 2009). Beim Vergleich beider Beobachtungsmethoden gibt es zusätzlich zu den bereits beschriebenen spezifischen Problemen weitere Unsicherheiten (Hamunyela et al., 2013; Maignan et al., 2008; Studer et al., 2007; White et al., 2009): (i) unzureichende Anzahl an Beobachtungen oder räumliche Abdeckung; (ii) eine Einzelpunktbeobachtung ist möglicherweise nicht repräsentativ für die Gesamtpixelcharakteristiken

(Punkte versus Pixel); (iii) unterschiedliche zeitliche Auflösungen der Datensätze (day versus composite period); (iv) Messung verschiedene phänologische Phänomene; (v) unbekannte Messgenauigkeit und Fehler bei der Dateneingabe sowie (vi) nichtlineare Beziehung zwischen GP und LSP.

In Mitteldeutschland wurde eine Validierungsstelle für Sentinel-2-Produkte eingerichtet. NDVI-Werte von bodengestützten hyperspektralen und multispektralen Sensoren wurden mit NDVI-Produkten aus Sentinel-2A und Moderate-resolution Imaging Spectroradiometer (MODIS) in den Jahren 2015 und 2016 verglichen. Hohe Korrelationen und ähnliche phänologische Muster zwischen in-situ und satellitenbasierten NDVI-Zeitreihen für Laubwald zeigten die Zuverlässigkeit satellitenbasierter phänologischer Messungen, wobei Sentinel-2-basierte Metriken eine bessere Übereinstimmung mit in-situ Messungen als MODIS-basierte Messverfahren zeigten. Die hohe räumliche Auflösung von Sentinel-2 reduziert die in der Phänologieforschung allgegenwärtigen Mischpixeleffekte und bietet neue Möglichkeiten, Zusammenhänge zwischen Standortmessungen und Großprozessen zu verstehen, wie z.B. bei der Analyse von vegetationsabhängigen Prozessen in heterogenen Landschaften. Allerdings leiden die Sentinel-2-basierten Messungen durch die geringe zeitliche Auflösung, besonders bei Bewölkungen über mehrere Tage hinweg unter Datenlücken und daher unter zeitlichen Diskrepanzen zu den phänologischen Phasen (Lange et al., 2017).

Diese Arbeit versucht nun einerseits sich der Problematik des schwachen Zusammenhangs zwischen GP und LSP anzunehmen, in dem eine neue Methode zur Bestimmung verschiedener phänologischer Phasen angewendet wird, andererseits mit der Problematik des Mischpixeleffekts, die durch die Verwendung hochauflösender Satellitendaten minimiert bzw. gelöst werden soll. Wie bereits erwähnt, kann der LSP-Ansatz nicht für das Monitoring einzelner Pflanzen genutzt werden und bisherige Algorithmen können auch untereinander in ihren Ergebnissen variieren. Darum soll ein Ansatz gewählt werden, der LSP und GP direkt verknüpft. Hierfür wird die kumulative NDVI-Methode (näher in Abschnitt 3.4.4 beschrieben) verwendet, die ähnlich einem Temperatursummenmodell der Laubaustriebsphase von Birke und Buche eine bestimmte NDVI-Summe zuordnen soll, die bestenfalls rein von der Höhe und der geographischen Lage abhängig ist. Diese kumulative NDVI-Summe sollte robuster sein als ein bestimmter Schwellenwert, der bei bisherigen verwendeten Algorithmen angewandt wird. So könnte jeder phänologischen Phase eine bestimmte kumulative NDVI-Summe zugeordnet werden und damit einzelne Pflanzen und Arten beobachtet werden.

In digitalen Satellitenbildern sind kleine Fragmente der Vegetation schwierig zu erkennen, weil sie häufig kleiner als die Pixelgröße und mit anderen Landnutzungsklassen gemischt sind. In dieser Arbeit soll nun untersucht werden, ob hoch aufgelöste NDVI-Daten der neuen Sentinel-2 Satelliten diesen Mischpixeleffekt mindern oder sogar komplett lösen können. Durch die hohe räumliche Auflösung von 10 m sollten auch sehr kleine Strukturen erkannt und auch Grenzen zwischen verschiedenen Landnutzungsformen scharf dargestellt werden können.

## 1.4 Ziel

Die photosynthetische Aktivität der Pflanzendecke kann im Infrarotbereich aus dem All beobachtet werden, beispielsweise über den NDVI, dem Normalized Difference Vegetation Index, und weiteren ähnlichen Parametern. Die Aufgabe dieser Arbeit besteht darin, eine derartige Beziehung zwischen satellitengestützter Land Surface Phenology (LSP) und Ground Phenology (GP) herzustellen, sodass verschiedene phänologische Phasen im Vegetationszyklus über Europa (wie die Laubaustriebsphasen von Birke und Buche) aus dem All bestimmt werden können. Damit könnten räumliche und zeitliche Lücken, welche die phänologischen Bodenbeobachtungen nicht abdecken, mit Hilfe von Satellitendaten aufgefüllt werden. Zudem werden bisher verwendete MODIS-Satellitendaten, die eine räumliche Auflösung von 250 m besitzen, mit den hochauflösenden Daten der neuen Sentinel-2 Satelliten, mit einer räumlichen Auflösung von 10 m, verglichen. Betrachtet werden die Frühlingsphasen 2016 und 2017 in  $6 \times 100 \times 100 \text{ km}$  großen Gebieten, die Tirol und Süddeutschland, sowie das Mühl- und Waldviertel abdecken.

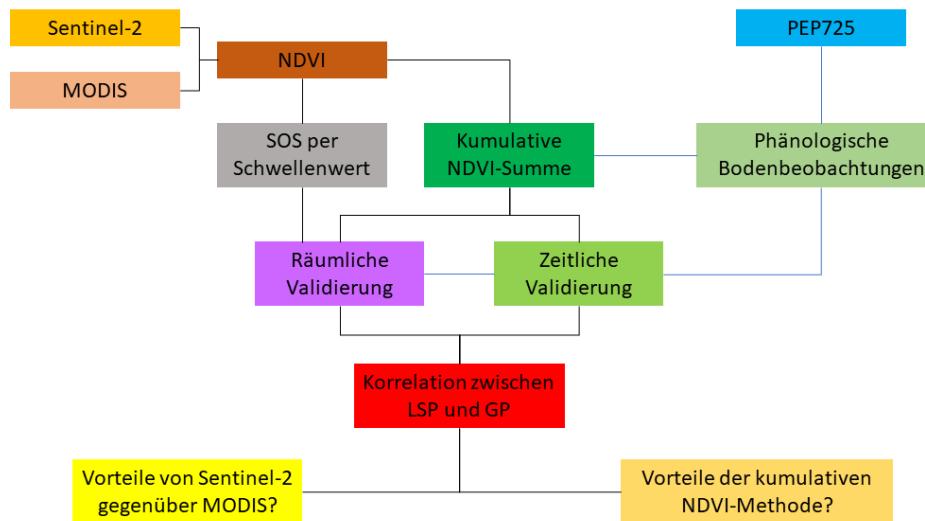


Abb. 1.4: Aufbau der Masterarbeit und Schritte zu ihrer Durchführung.

In diesem Kapitel wurde die Motivation hinter dieser Arbeit erläutert, das Themengebiet „Phänologie“ beleuchtet und der derzeitige Stand der Wissenschaft zu diesem Thema aufgezeigt.

Nach der Auswahl geeigneter Quellen für MODIS- und Sentinel-2-Daten für 2016 und 2017, die in Kapitel 2 ausführlich beschrieben sind, werden diese mit den phänologischen Bodenbeobachtungen über den kumulativen NDVI in Beziehung gesetzt, um die Laubaustriebsphasen von Birke und Buche ohne vorhandene Bodenbeobachtungen bestimmen zu können. Ein Hauptaugenmerk wurde dabei auf die Beschaffung von fertig prozessierten, wolkengefilterten und berechneten NDVI-Daten gerichtet, um den Fokus auf die Methodik zur Verbindung von LSP und GP richten zu können. Sämtliche genutzte Daten werden im nächsten Kapitel erklärt, sowie eine Beschreibung von Birke, Buche und den phänologischen Jahren 2016 und 2017 gegeben.

Im Kapitel 3 werden neben dem kumulativen NDVI auch bisherige etablierte Methoden zur Bestimmung von phänologischen Phasen direkt aus Satellitendaten beschrieben. Mit einer zeitlichen Validierung soll die Robustheit der kumulativen NDVI-Methode bestimmt und mit einer räumlichen Validierung der räumliche Zusammenhang zwischen GP und LSP analysiert werden.

Zuerst wird diese Methodik mit den MODIS-Daten durchgeführt, um die kumulative NDVI-Methode zu testen, im nächsten Schritt soll dies mit den Sentinel-2-Daten wiederholt werden, um etwaige Verbesserungen durch die höhere Auflösung erkennen zu können. Außerdem wird in diesem Kapitel die Be- und Verarbeitung der Satelliten- und phänologischen Beobachtungsdaten, sowie der Daten eines Landnutzungskatasters, welcher verwendet wird, um LSP und GP vergleichbar machen zu können, beschrieben.

Die Ergebnisse der beiden Validierungen werden in Kapitel 4 präsentiert. Es wird untersucht, ob mit MODIS eine befriedigende Korrelation zwischen satellitengestützter Land Surface Phenology und Ground Phenology hergestellt werden kann und diese mit Sentinel-2 zu verbessern ist. Sollten die, von den Jahren 2016 und 2017 zur Verfügung stehenden, Sentinel-2-Daten noch keine Verbesserungen bringen, oder für die kumulative NDVI-Methode noch nicht nutzbar sind, werden in Kapitel 6 Lösungsvorschläge unterbreitet bzw. wird erklärt, wie mit diesen neuen Daten zu verfahren ist, um die Brauchbarkeit zu verbessern. Zudem werden weitere und zukünftige Entwicklungen im Bereich der phänologischen Bodenbeobachtungen, Sentinel-2 und Landnutzungskataster gezeigt. In Abbildung 1.4 werden der Aufbau der Masterarbeit und die Schritte zu ihrer Durchführung schematisch dargestellt.

## 2 Daten

### 2.1 Satellitendaten

Für die satellitengestützte LSP werden Satellitendaten der Sentinel-2 Mission und MODIS verwendet.

#### 2.1.1 Normalized Difference Vegetation Index (NDVI)

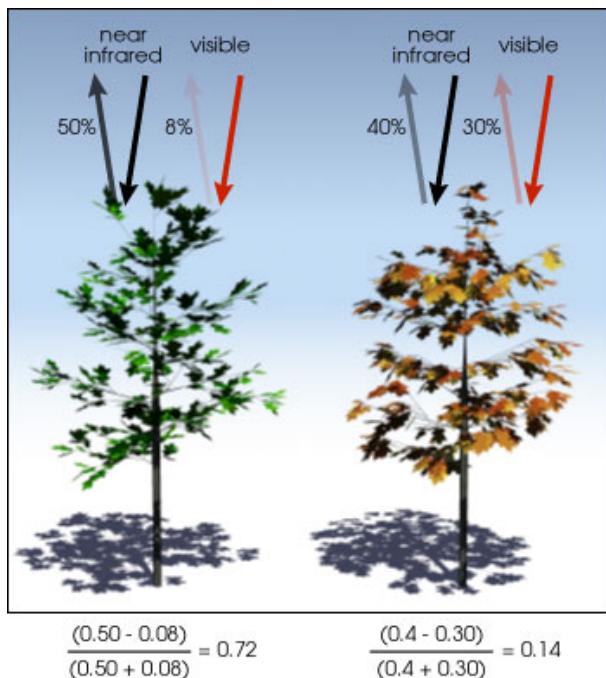


Abb. 2.1: Der NDVI beruht auf dem Unterschied der Reflexion des von Vegetation reflektierten sichtbaren Lichts und nahen Infrarotlichts. Grüne Vegetation (links) absorbiert den größten Teil sichtbaren Lichts, reflektiert dafür einen größeren Anteil des nahen Infrarot. Karge oder dürre Vegetation (rechts) absorbiert ähnlich viel des nahen Infrarotlichtanteils, wie es sichtbares Licht reflektiert. Die Zahlen entsprechen diesen Werten. Quelle: National Aeronautics and Space Administration (NASA), 2018

Die photosynthetische Aktivität der Pflanzendecke wird über den NDVI, dem Normalized Difference Vegetation Index, detektiert. Der Index beruht auf Unterschieden des Reflexionsgrades in verschiedenen Spektralbereichen. Gesunde bzw. grüne Vegetation reflektiert im roten sichtbaren Spektralbereich wenig, im Bereich des nahen Infrarot dagegen relativ viel Strahlung. Die Reflektivität von nahem Infrarot basiert auf dem Chlorophyllanteil der Vegetation und korreliert daher stark mit der Vitalität der Pflanzen. Je grüner die Pflanze, desto höher liegt der Reflexionsgrad in diesem Spektralbereich. Vegetationslose Oberflächen, wie Gestein, Erdboden aber auch abgestorbene Vegetation, zeigen keinen derartigen charakteristischen Unterschied im Reflexionsgrad (European Space Agency (ESA), 2017a; National Aeronautics and Space Administration (NASA), 2018; Wikipedia, 2017b).

Das NDVI-Verhältnis kann aus dem Beitrag des sichtbaren roten Lichtbereichs (*VIR*) und des nahen Infrarot-Bereichs (*NIR*) bestimmt werden (European Space Agency (ESA), 2017b):

$$\text{Normalized Difference Vegetation Index (NDVI)} = \frac{NIR - VIR}{NIR + VIR} \quad (2.1)$$

Ein Wert zwischen -0.1 und 0.1 lässt auf nahezu vegetationsfreie Flächen, wie Sand, oder Gestein, sowie Wolken oder Schneedeckung schließen. Niedrige Werte zwischen 0.2 und 0.4 bezeichnen Gras- und Strauchflächen. Hohe Vegetationsbedeckung mit grünen Pflanzen entspricht einem Wert nahe 1. Negative Werte werden von Wasserflächen verursacht (National Aeronautics and Space Administration (NASA), 2018; Sinergise, 2018).

Das NDVI-Verhältnis für SENTINEL-2 ist in Gleichung 2.2 dargestellt (European Space Agency (ESA), 2017b):

$$\text{Normalized Difference Vegetation Index (NDVI)} = \frac{\text{Band 8} - \text{Band 4}}{\text{Band 8} + \text{Band 4}} \quad (2.2)$$

Für die Berechnung des NDVI aus MODIS-Daten, werden Band 1 für VIR und Band 2 für NIR verwendet und in Gleichung 2.1 eingesetzt (National Aeronautics and Space Administration (NASA), 2017).

### 2.1.2 Sentinel-2

Die Raumfahrtmission Sentinel-2 besteht aus Sentinel-2A und Sentinel-2B, zwei baugleichen Satelliten, die in einer sonnensynchronen Umlaufbahn in einer mittleren Höhe von 786 km gleichzeitig und um 180° versetzt betrieben werden. Jeder Satellit nimmt dabei einen Streifen von 290 km Breite auf. Sentinel-2A startete am 23. Juni 2015, Sentinel-2B folgte am 7. März 2017. Sie gehören zum Copernicus-Programm der ESA und sind Teil der Sentinel-Satellitenreihe. Sentinel-2A und B sollen Informationen zur Landüberwachung, für den Klimaschutz als auch zum Krisen- und Katastrophenmanagement produzieren. Beide Satelliten sind mit einem Multispektralen Instrument (MSI) ausgerüstet, das nach dem Prinzip einer digitalen Zeilenkamera funktioniert. Die Beobachtungen werden in zehn Spektralkanälen mit einer räumlichen Auflösung von 10 oder 20 m pro Pixel aufgenommen. Zur Messung atmosphärischer Eigenschaften stehen zusätzlich drei schmalbandige Spektralkanäle mit 60 m räumlicher Auflösung zur Verfügung (Wikipedia, 2017c; European Space Agency (ESA), 2017b). Die einzelnen spektralen Kanäle von Sentinel-2A und B sind in Tabelle 2.1 und Abbildung 2.2 nachzulesen.

Der gesamte Planet kann von einem Satelliten innerhalb von 10 Tagen abgedeckt werden. Beide Satelliten benötigen 5 Tage bzw. 2-3 Tage um die mittleren Breiten abzudecken (European Space Agency (ESA), 2017b).

Die erste Vegetationsperiode, die von beiden Satelliten verfügbar ist, beginnt erst im Juni 2017. Daher werden in dieser Arbeit für die betrachteten Frühlingsphasen für 2016 und 2017 lediglich die Daten von Sentinel-2A verwendet.

Tabelle 2.1: Spektralkanäle von Sentinel 2 (European Space Agency (ESA), 2017b)

Band	S2A		S2B		Räumliche Auflösung (m)
	Mittlere Wellenlänge (nm)	Bandbreite (nm)	Mittlere Wellenlänge (nm)	Bandbreite (nm)	
1	442.7	21	442.2	21	60
2	492.4	66	492.1	66	10
3	559.8	36	559.0	36	10
4	664.6	31	664.9	31	10
5	704.1	15	703.8	16	20
6	740.5	15	739.1	15	20
7	782.8	20	779.7	20	20
8	832.8	106	832.9	106	10
8a	864.7	21	864.0	22	20
9	945.1	20	943.2	21	60
10	1373.5	31	1376.9	30	60
11	1613.7	91	1610.4	94	20
12	2202.4	175	2185.7	185	20

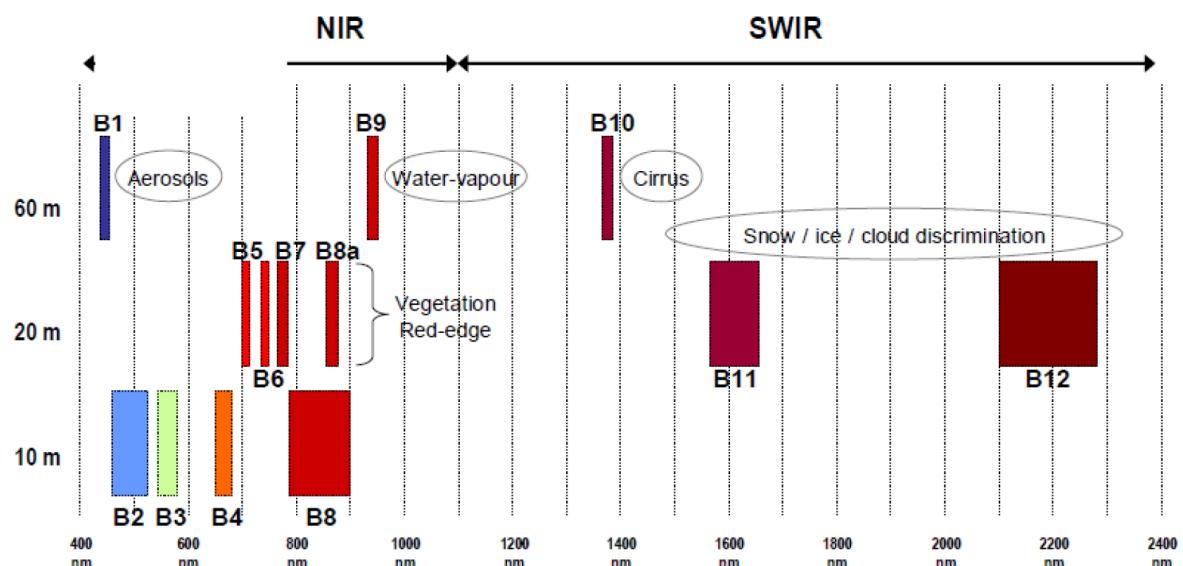


Abb. 2.2: Spektralkanäle von Sentinel 2 und deren Verwendungszweck. Wellenlängen sind auf der x-Achse, die Auflösung auf der y-Achse abgebildet. Quelle: European Space Agency (ESA), 2017c

### 2.1.2.1 Sentinel-2 Prozessierung der ESA

#### 2.1.2.1.1 Processing Levels

Um ein nutzbares Sentinel-2 Satellitenprodukt zu erhalten, müssen die Rohdaten der Satelliten einige Verarbeitungsschritte durchlaufen. Die Level-1A-Verarbeitung dient zur Dekomprimierung der Level-0-Produkte (komprimierte Rohbilddaten). Die Level-1B-Verarbeitung übernimmt das dekomprimierte Produkt und verrichtet erforderliche radiometrische Korrekturen. Darunter

sind die Dunkelsignalkorrektur, Korrektur ungleichförmiger Pixel, Identifizierung defekter Pixel und eine räumliche Filterung der 60-m-Spektralbänder. Die Level-1C-Verarbeitung führt radiometrische und geometrische Korrekturen durch, einschließlich einer Ortho-Rektifikation (Entfernung von geometrischen Verzerrungen) und der räumlichen Erfassung auf einem globalen Referenzsystem. Enthalten sind folgende Schritte (European Space Agency (ESA), 2017b):

- Kachelzuordnung: Auswahl von vordefinierten Kacheln.
- Raster-Resampling: Ermöglicht die Verknüpfung des nativen Geometriebildes mit dem Zielgeometriebild (orthogereichtet).
- Resampling jedes Spektralbandes in der Geometrie des Orthobildes unter Verwendung des Resampling-Rasters und eines Interpolationsfilters. In diesem Schritt erfolgt auch die Berechnung der Top-of-Atmosphere-Reflexionen.
- Berechnung der Wolken- und Land-/Wassermasken.

Die Level-2A-Verarbeitung beinhaltet eine Szenenklassifizierung und eine atmosphärische Korrektur, die auf die Level-1C Produkte angewandt wird. Ausgegeben wird ein Bottom-Of-Atmosphäre korrigiertes Reflexionsprodukt. Level-2A-Produkte bestehen aus  $100 \times 100 \text{ km}^2$  großen Kacheln (European Space Agency (ESA), 2017b).

Weiters werden eine Karte der Aerosolen Optischen Dicke (AOD), eine Wasserdampf-Karte (WD) und eine Szenenklassifizierungskarte mit Qualitätsindikatoren für Wolken- und Schneewahrscheinlichkeiten bei 60 m Auflösung ausgegeben. Level-2A-Produkte werden resampelt und mit gleicher räumlicher Auflösung für alle Bänder erzeugt, basierend auf der gewünschten Auflösung (10 m, 20 m oder 60 m). Ein Produkt mit einer Auflösung von 10 m enthält die Spektralbänder 2, 3, 4, 8 und eine AOD-Karte. Produkte mit einer Auflösung von 20 m enthalten die Bänder 2 - 7, die Bänder 8A, 11 und 12 sowie eine AOD- und WD-Karte. 60-m-Produkte enthalten alle Komponenten des 20-m-Produkts und zusätzlich die 60-m-Bänder 1 und 9. Das Zirrusband 10 entfällt, da es keine Oberflächeninformationen enthält.

Ein Szenenklassifizierung-Algorithmus ermöglicht die Erkennung von Wolken, Schnee und Wolkenschatten und die Erstellung einer Klassifikationskarte. Diese Karte beinhaltet vier verschiedenen Klassen für Wolken (einschließlich Zirrus) sowie sechs unterschiedliche Klassifikationen für Schatten, Wolkenschatten, Vegetation, Wasser und Schnee sowie Böden und Wüsten. Die Klassifikationskarte ist in Abbildung 2.3 dargestellt. Der dafür verwendete Algorithmus basiert auf einer Reihe von Schwellwerttests (European Space Agency (ESA), 2017a).

Diese Schwellenwerte werden aus Bandbreitenverhältnissen und Indizes, wie dem Normalised Difference Vegetation Index (NDVI) und dem Normalised Difference Snow and Ice Index (ND-SI), bestimmt. Der Algorithmus nutzt die reflektierenden Eigenschaften von Szenenmerkmalen, um das Vorhandensein oder Nichtvorhandensein von Wolken festzustellen. Diese Wolkenerfassung wird auf die Daten angewendet, um genaue atmosphärische und Oberflächenparameter zu erhalten, entweder als Input für die nachfolgenden oder für Verarbeitungsschritte höherer Ebenen (European Space Agency (ESA), 2017b).

Label	Classification
0	NO_DATA
1	SATURATED_OR_DEFECTIVE
2	DARK_AREA_PIXELS
3	CLOUD_SHADOWS
4	VEGETATION
5	BARE_SOILS
6	WATER
7	CLOUD_LOW_PROBABILITY
8	CLOUD_MEDIUM_PROBABILITY
9	CLOUD_HIGH_PROBABILITY
10	THIN_CIRRUS
11	SNOW

Abb. 2.3: Klassifizierungskarte der Level-2A Prozessierung. Quelle: European Space Agency (ESA), 2017b

### 2.1.2.2 Sentinel-2-Datenquellen

Vom Institut für Informations- und Kommunikationstechnologien am Joanneum Research Graz, in Person von DI Heinz Gallaun, wurden die Sentinel-2A NDVI-Daten für  $2 \times 100 \times 100$  km große Gebiete, die Tirol und Süddeutschland abdecken, für die Jahre 2016 und 2017 aus dem ECoLaSS-Projekt, sowie  $4 \times 100 \times 100$  km, die Süddeutschland abdecken, aus dem DIABOLO-Project zur Verfügung gestellt (siehe Abbildung 2.4). Das Horizon2020 Projekt „Evolution of Copernicus Land Services based on Sentinel data“ (ECoLaSS) zielt auf die Entwicklung innovativer Methoden, Algorithmen und Prototypen zur Verbesserung zukünftiger operationeller paneuropäischer und globaler Landüberwachungsdienste ab. Das Projekt wird von fünf Unternehmen/Institutionen durchgeführt: von der GAF AG, einem deutschen e-GEOS-Unternehmen; SIRS, einem französischen Anbieter von Erdbeobachtungsdiensten; dem Joanneum Research Graz; der Université Catholique de Louvain Belgien und dem Deutschen Zentrum für Luft- und Raumfahrt (DLR) (Deutsches Zentrum für Luft- und Raumfahrt e.V. (DLR), 2017). Das andere Horizon2020 Projekt „Distributed, Integrated and Harmonised Forest Information for Bioeconomy Outlooks“ (DIABOLO) soll bei den Herausforderungen einer Veränderung in der Forstpolitik auf verschiedenen Sektoren und Ebenen helfen. Hintergrund dafür ist der zunehmende Wettbewerb um die Waldressourcen, die steigende Nachfrage nach Biomasse sowie anderen Gütern und Dienstleistungen des Ökosystems. Diese neue Politik erfordert umfassende, zuverlässige und aktuelle Informationen. Dieses Projekt vereint 33 Partner aus wissenschaftlichen Einrichtungen in 25 europäischen Ländern. Darunter befinden sich Experten aus den Bereichen Politikwissenschaft, Waldinventur und Waldmodellierung, die in Verbindung zu europäischen politischen Institutionen und Interessenvertretern stehen um neue Methoden und Informationen für verschiedene Anwendungsgebiete bereitzustellen (Copernicus, 2018). Die Sentinel-2-Daten wurden mit den Algorithmen der ESA zur Atmosphären-, Wolken- und Schneefilterung Level 2A prozes-

siert. Daraus wurde der NDVI abgeleitet, wobei die Wolkenfilterung modifiziert wurde. Für die Wolkenmaske wurden geringfügige Verbesserungen, wie die Anwendung einer Füllschwelle von 30 Pixeln, einer minimalen Wolkengröße von 10 Pixeln und einer Dilatation zur Erweiterung der Wolkengrenzen um 10 Pixel, installiert. Die Wolken wurden mit einer Maske für hohe und mittlere Wolkenwahrscheinlichkeit (Label 8 und 9 in Abb. 2.3) entfernt. Wolken mit geringer Wahrscheinlichkeit, dünne Cirren und Wolkenschatten wurden nicht gefiltert. Diese Daten wurden in der Projektion WGS 84 (World Geodetic System 1984)/UTM zone 32N erstellt und als GeoTIFF gespeichert.

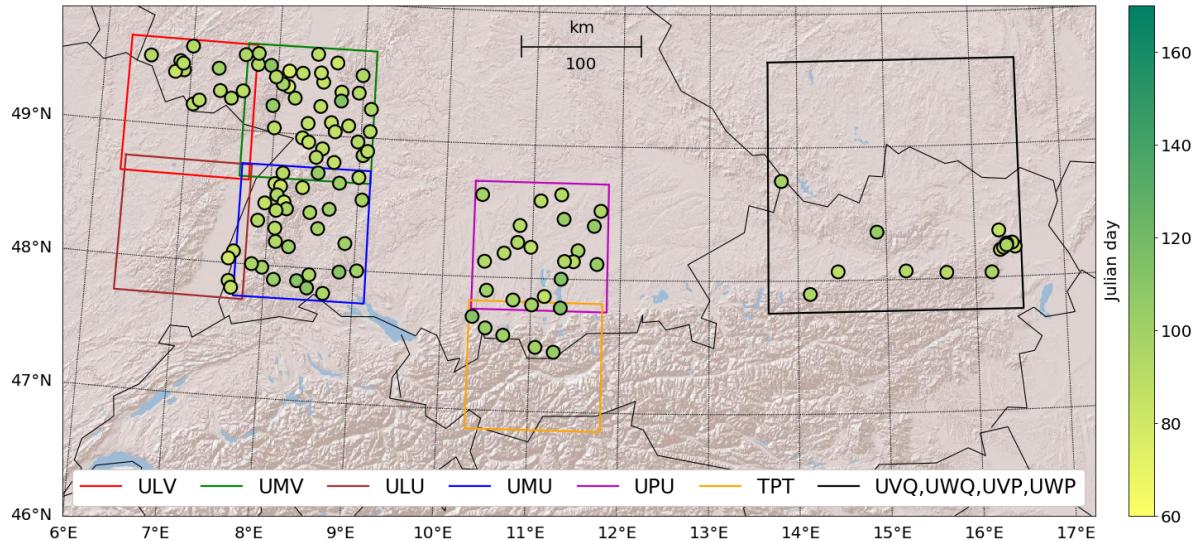


Abb. 2.4: Untersuchte Zielregionen (Datenanbieter: Joanneum Research Graz (links DIABOLO-Projekt und Mitte ECoLaSS-Projekt) und BFW/TU Wien (rechts)). Grenzen der Sentinel-Daten werden als farbige Rechtecke dargestellt (siehe Legende). Punkte zeigen phänologische Beobachtungsorte an und Farben die Eintrittsdaten der Blattentfaltung der Birken im Jahr 2017 (siehe Farbskala).

Das Institut für Waldinventur des Bundesamts für Wald (BFW) unter der Leitung von DI Dr. Klemens Schadauer lieferte in Person von Markus Löw Daten für Nieder- und Oberösterreich (siehe Abb. 2.4) für das Jahr 2017. Diese Daten wurden im Rahmen des Projekts „Ermittlung von Schäden durch Borkenkäfer - Beitrag der Fernerkundung Phase I“ der TU Wien im Auftrag des Bundesministeriums für Land- und Forstwirtschaft, Umwelt und Wasserwirtschaft, Sektion III/1 im Dezember 2017 erhoben. Projektleiter war Markus Hollaus, Departement für Geodäsie und Geoinformation, TU-Wien. Zum Projekt-Team gehören Bernhard Bauer-Marschallinger, Markus Hollaus und Prof. Wolfgang Wagner, alle drei ebenfalls Departement für Geodäsie und Geoinformation, TU-Wien (Department of Geodesy and Geoinformation, TU Wien, 2018).

Die Sentinel-2-Daten wurden ebenfalls mit den Algorithmen der ESA zur Atmosphären- und Wolkenfilterung prozessiert und daraus der NDVI abgeleitet. Wolkenschatten wurden mit Hilfe des NIR-Bandes (Nahes Infrarot) identifiziert und ausgeschlossen, ebenso Pixel, die in die Kategorien Schnee, keine oder beschädigte Daten, Dunkelbereiche, niedrige bis hohe Wahrscheinlichkeit für Bewölkung und Cirrus-Wolken fallen (d.h. Ausschluss von allen Klassen außer 4, 5 und 6 in Abbildung 2.3).

Diese Daten wurden in der Projektion WGS 84/UTM zone 33N erstellt und ebenfalls als GeoTIFF gespeichert.

### 2.1.2.3 Problematik

Für das Jahr 2016 und die erste Jahreshälfte 2017 standen lediglich Daten von Sentinel-2A zur Verfügung. Durch die daraus resultierende zeitliche Auflösung von bis zu 10 Tagen in Verbindung mit Bewölkung entstehen große Lücken in den Datensätzen. Zudem wurden auch die Datensätze beider Quellen unterschiedlich gefiltert, einmal mit einem modifizierten Wolken-, aber ohne Wolkenschatten- und Cirrenfilter, einmal mit beiden Filtern, aber ohne Modifizierung. Verfügbare Wolkenfilter-Algorithmen sind außerdem nicht so effektiv wie beispielsweise für Landsat (Sassen, 2018).

### 2.1.3 MODIS

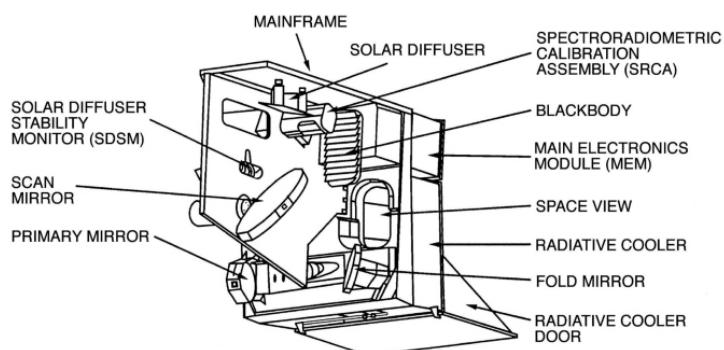


Abb. 2.5: Aufbau und Komponenten eines MODIS Messinstruments. Quelle: National Aeronautics and Space Administration (NASA), 2017

MODIS (Moderate Resolution Imaging Spectroradiometer) ist ein Messinstrument elektromagnetischer Strahlung an Bord der Terra (EOS AM-1) und Aqua (EOS PM-1) Satelliten. Terra wurde am 18. Dezember 1999, Aqua am 4. Mai 2002 gestartet. Die Umlaufbahn von Terra um die Erde ist zeitlich so bemessen, dass sie morgens von Norden nach Süden über den Äquator, Aqua überquert am Nachmittag von Süden nach Norden den Äquator. Die beiden MODIS Satelliten decken alle 1 bis 2 Tage die gesamte Erdoberfläche ab und erfassen dabei Daten in 36 Spektralbändern (National Aeronautics and Space Administration (NASA), 2017). In zwei Frequenzbändern erfolgt die Aufnahme mit 250 m, in 5 Bändern mit 500 m Auflösung und in den restlichen 29 Bändern mit einer Auflösung von einem Kilometer. Die einzelnen Spektralbänder sind in Tabelle 2.2 ausgezeichnet. In einer Umlaufbahn von 705 km Höhe wird mit einem  $\pm 55^\circ$ -Aufnahmemuster ein Streifen von 2330 km Breite erfasst (Wikipedia, 2017a).

Der MODIS-NDVI wird mit einer zeitlichen Auflösung von 7 Tagen und einer räumlichen von 250 m produziert (Klisch et al., 2016).

#### 2.1.3.1 MODIS-Datenquelle

Die MODIS-NDVI-Daten für die Jahre 2016 und 2017 wurden vom Institut für Vermessung, Fernerkundung und Landinformation (IVFL) an der Universität für Bodenkultur (BOKU) unter der Leitung von Univ.Prof. Dr. Clement Atzberger zur Verfügung gestellt.

Tabelle 2.2: Spektralkanäle von MODIS Terra und Aqua (National Aeronautics and Space Administration (NASA), 2017)

Hauptanwendung	Band	Wellenlänge (nm)
Land-/Wolken-/Aerosol-Grenzen	1	620 - 670
	2	841 - 876
Land-/Wolken-/Aerosol-Eigenschaften	3	459 - 479
	4	545 - 565
	5	1230 - 1250
	6	1628 - 1652
	7	2105 - 2155
	8	405 - 420
	9	438 - 448
Ozeanfarbe/Phytoplankton/Biogeochemie	10	483 - 493
	11	526 - 536
	12	546 - 556
	13	662 - 672
	14	673 - 683
	15	743 - 753
	16	862 - 877
Atmosphärischer Wasserdampf	17	890 - 920
	18	931 - 941
	19	915 - 965
Hauptanwendung	Band	Wellenlänge ( $\mu m$ )
Oberflächen-/Wolken-Temperaturen	20	3.660 – 3.840
	21	3.929 - 3.989
	22	3.929 - 3.989
	23	4.020 - 4.080
Temperatur der Atmosphäre	24	4.433 - 4.498
	25	4.482 - 4.549
Zirruswolken, Wasserdampf	26	1.360 - 1.390
	27	6.535 - 6.895
	28	7.175 - 7.475
Wolkeneigenschaften	29	8.400 - 8.700
Ozon	30	9.580 - 9.880
Oberflächen-/Wolken-Temperatur	31	10.780 - 11.280
	32	11.770 - 12.270
Höhe der Wolkenobergrenze	33	13.185 - 13.485
	34	13.485 - 13.785
	35	13.785 - 14.085
	36	14.085 - 14.385

### 2.1.3.2 MODIS-Prozessierung an der BOKU

Der Vegetationsindex wird aus MOD13Q1 und MYD13Q1 NDVI Collection 5 Produkten der MODIS Terra und Aqua Satelliten berechnet, die seit dem Jahr 2000 über den Online-Datenpool des NASA Land Processes Distributed Active Archive Center (LP DAAC) bezogen wurden. Diese Produkte liegen als Level-3-Gitterdaten mit 250 m räumlicher Auflösung in Sinusprojektion und zeitlicher Auflösung von 8 Tagen vor. Diese Level-3-Daten werden unter Anwendung des Composite-Verfahrens CV-MVC (Constrained View Angle-Maximum Value Composite) aus den Level-2G-Tagesreflexionsgitterdaten (MOD09- und MYD09-Serie) abgeleitet. Die MODIS-Daten werden heruntergeladen und unter Verwendung der „Nearest Neighbor Resampling“-Methode auf geographische Koordinaten (WGS84) mit einer räumlichen Auflösung von ca. 250 m (0,002232°) reprojiziert (Klisch et al., 2016).

Zur Minimierung möglicher Auswirkungen von unentdeckten Wolken und schlechten atmosphärischen Bedingungen, wird eine zeitliche Filterung der NDVI-Daten mittels eines standardisierten Verfahrens auf Grundlage von zwei unterschiedlichen Schritten, angewandt: (i) eine Offline-Glättung. Diese Glättung wird, wenn nötig, einmalig post hoc angewendet, um Zeitreihen zu interpolieren. Dabei wird ein Zustand, basierend auf Daten aus früheren und späteren Zeitpunkten, geschätzt. (ii) eine Near-real-time-Filterung (NRT-Filterung). Die Filterung wird wöchentlich wiederholt und beinhaltet die Schätzung eines bestimmten Zustands auf der Grundlage einer Teilsequenz von Eingaben (Klisch et al., 2016).

Der Offline-Glättungsschritt verwendet den Whittaker Smoother, der eine diskrete Reihe an diskrete Daten anpasst und die Rauigkeit der Kurve mit einer Gewichtung belegt. Die Daten des historischen Archivs (2001 bis 2012) werden damit geglättet und auf tägliche NDVI-Werte interpoliert (Klisch et al., 2016).

Von der Ausgabe der täglichen NDVI-Zeitreihe wird nur jedes siebte Bild, entsprechend „Montags“, gespeichert. Zusätzlich werden wöchentliche Statistiken aus den geglätteten „Montags“-Bildern berechnet, welche die typischen NDVI-Werte für einen bestimmten Ort und Zeit beschreiben („NDVI-Klimatologie“). Während der NRT-Filterung dient diese Information zur Begrenzung der Whittaker Glättung. Jedes Wochenende wird der NRT-Filterschritt, unter Verwendung der verfügbaren Beobachtungen der letzten 175 Tage, ausgeführt. Mindestens 10 MOD- und MYD-Beobachtungen sind innerhalb dieser 175 Tage erforderlich um mit unzureichenden Beobachtungen, beispielsweise mehrtägiger Bewölkung, fertig werden zu können. Ist diese empirisch definierte Bedingung nicht erfüllt, wird der Wert der „NDVI-Klimatologie“ als Gewichtung für die Filterung verwendet (Klisch et al., 2016).

Fehlende Einschränkungen in der NRT-Filterung, insbesondere zu Jahreszeiten, viele fehlende oder unzuverlässige Beobachtungen auftreten und/oder in denen schnelle NDVI-Änderungen stattfinden, können zu hohe oder niedrige Werten verursachen. Daher wird ein Einschränkungsverfahren angewandt, das Sprünge der NDVI-Werte zwischen aufeinanderfolgenden „Montagen“ entsprechend der „NDVI-Klimatologie“ begrenzt. Zusätzlich werden neben den „Montagsbildern“ eine Reihe von Metriken, welche bei jedem Schritt die jeweiligen Filterbedingungen charakterisieren, gespeichert. Diese erlauben eine spätere Modellierung der Unsicherheiten der geglätteten Ergebnisse (Klisch et al., 2016).

### 2.1.3.3 Problematik

NDVI-Daten aus MODIS haben durch ihre vergleichsweise grobe Auflösung von 250 m das bereits erwähnte Mischpixel-Problem, bei dem in einem Pixel verschiedene Landnutzungsformen vorkommen, was wiederum einen Einfluss auf den NDVI-Wert jenes Pixels hat. Daher können in den Satellitenbildern keine scharfen Ränder unterschiedlicher Landnutzung dargestellt werden.

## 2.2 Landnutzungskataster

Um die Satellitendaten von Sentinel-2A und MODIS mit den phänologischen Bodenbeobachtungen vergleichbar zu machen, wird ein Landnutzungskataster entsprechend der Auflösung der Sentinel Daten, benötigt. Dafür werden die „Copernicus High Resolution Layers“ (HLR) für Wald 2015, die eine räumliche Auflösung von 20 m besitzen, verwendet.

„Copernicus“ ist ein europäisches System zur Überwachung des Planeten. Die Daten werden von verschiedenen Quellen gesammelt, darunter Erdbeobachtungssatelliten und In-situ-Sensoren, aufbereitet und liefern aktuelle Informationen über sechs Themenbereiche: Meer, Land, Atmosphäre, Klimawandel, Sicherheit und Notfallmanagement. Das Thema Land gliedert sich wiederum in drei Hauptkomponenten: globale, paneuropäische und lokale Elemente.

Der paneuropäische Bestandteil wird von der Europäischen Umweltagentur (EEA) koordiniert und stellt Satellitenbild-Mosaiken sowie Informationen zur Landbedeckung und Landnutzung in den „CORINE Land Cover-Daten“ (CLC) und den „High Resolution Layers“ zur Verfügung. Die hochauflösenden paneuropäischen „High Resolution Layers“ sind orthorektifizierte Rastermosaiken. Diese werden aus Satellitenbildern von 39 Ländern, vornehmlich aus Sentinel-2A und Landsat 8 Daten, mit einer Auflösung von 20 m durch eine Kombination aus automatischer Verarbeitung und regelbasierte Klassifizierung, hergestellt. Bisher wurden fünf Themenbereiche eingeteilt, die mit den Hauptkomponenten von CLC übereinstimmen. Dazu zählen die Dichte der versiegelten Böden, die Dichte der Baumberdeckung, Waldarten, natürliche Graslandschaften, Feuchtgebiete und Gewässer (Copernicus, 2017).

Im Folgenden werden die verwendeten Produkte aus den Copernicus HRL für Wald beschrieben.

### 2.2.1 Baumkronendichte

Der Datensatz „Baumkronendichte“ (engl. „tree cover density“ (TCD)) gibt Auskunft über die prozentuale Baumkronenbedeckung pro Pixel. Diese Daten werden aus multispektralen HR-Satellitendaten (High Resolution) unter Verwendung von VHR-Satellitendaten (Very High Resolution) sowie Luft-Orthofotos als Referenzdaten erzeugt. Die Baumkronendichte wird anhand der VHR-Daten durch visuelle Interpretation beurteilt und anschließend durch eine lineare Funktion in die HR-Daten übertragen. Dieser Datensatz zeigt eine natürliche Empfindlichkeit gegenüber radiometrischen Einflüssen (z.B. Trübung) und der Phänologie. Daher sind Dichtewerte der Baumkronenbedeckung stark von der Qualität und Verfügbarkeit verwendeter Satelliten- und Referenzdaten abhängig (Copernicus, 2017).

In die Zuordnung der Baumberdeckung werden immergrüne, Laub- sowie Nadelbäume, Wälder, Obstgärten, Olivenhaine, Baumplantagen und Baumgruppen in städtischen Gebieten einbezogen, sofern sie auf den Satellitenbildern ersichtlich sind. Dagegen werden offene Flächen im Wald (wie vegetationsfreie Flächen, Straßen, Kahlschläge, verbrannte Flächen und andere schwere Waldschadensgebiete), Moore, Weinberge, Zwergkiefern im alpinen Bereich und Strauchland aus der Zuordnung ausgeschlossen (Copernicus, 2017).

Die Themenkarte mit dem Referenzjahr 2015 ( $\pm 1$  Jahr) liegt in räumlicher Auflösung von 20 m und monotonaler Abdeckung vor und zeigt die Baumkronendichte im Bereich von 1-100 % (Copernicus, 2017).

## 2.2.2 Dominanter Blattp

Der Datensatz „Dominante Blattp“ (engl. Dominant Leaf Type (DLT)) ist ein weiteres Produkt des HRL für Wald. Die Daten wurden aus multitemporalen Satellitenbilddaten abgeleitet und enthalten Informationen über den dominanten Blattp: Laubbaum/Laubblatt, Nadelbaum/Nadelblatt oder kein Baum/Blatt. Diese Themenkarte liegt ebenfalls in räumlicher Auflösung von 20 m und monatemperaler Abdeckung vor und ist in seinem Umfang identisch zum Produkt der Baumkronendichte (Copernicus, 2017).

Die beiden Produkte des HRL für Wald für das Referenzjahr 2015 ( $\pm 1$  Jahr) wurde im Europäischen Terrestrischen Referenzsystem 1989 (ETRS89) und in azimutaler flächentreuer Lambert-Projektion erstellt und als GeoTIFF gespeichert (Copernicus, 2017).

## 2.2.3 Problematik

Die HRL für Wald beinhalten Unterscheidungen nach Laub- oder Nadelbäume sowie kein Baumbewuchs, allerdings keine Unterscheidung nach verschiedenen Baumarten. Außerdem weisen auch die HLR für Wald mit einer räumlichen Auflösung von 20 m den Mischpixel-Effekt auf, was die Baumkronendichte zeigt. So weist zum Beispiel ein Laubbaumpixel mit 50 % Baumkronendichte zu einer Hälfte Laubbaum, zur anderen eine anderweitige nicht definierte Landnutzung auf.

## 2.3 Bodenbeobachtungen

Die Bodenbeobachtungen bzw. GP werden von der Zentralanstalt für Meteorologie und Geodynamik zur Verfügung gestellt. Abbildung 2.6 etwa zeigt die verfügbaren phänologischen Beobachtungen für den Laubaustrieb der Birke und Buche im Jahr 2017.

Die PEP725-Bodenphänologiedatenbank ist mit annähernd  $12 \times 10^6$  Datenpunkten eine der größten Sammlungen von phänologischen Bodenbeobachtungen in ganz Europa. Diese wurde in zahlreichen Studien zur Untersuchung der phänologischen Phasen der Vegetation in Verbindung mit dem Klimawandel verwendet. Von 32 europäischen meteorologischen Diensten und Projekt-partnern werden aus ganz Europa die von Freiwilligen von 1868 bis heute gesammelten Daten für die PEP725-Datenbank zusammengeführt und bereitgestellt. Diese Datenbank enthält Tausende von phänologischen Zeitreihen, die mehrere Standorte, Arten und phänologische Phasen repräsentieren (Cook et al., 2012; Lapenis et al., 2014; Menzel et al., 2006; Scheifinger et al., 2002; Templ et al., 2018; Wolkovich et al., 2012).

### 2.3.1 Problematik

Die PEP725-Bodenphänologiedatenbank hat einige Einschränkungen bezüglich des Vergleichs mit satellitengestützter LSP in ganz Europa, wie eine einseitige Verteilung der phänologischen Bodenstationen in Richtung der nord-zentraleuropäischen Region (insbesondere Deutschland,

Schweiz und Österreich) und enge Breitengradienten der Biodiversität<sup>1</sup>, wodurch das Artenspektrum des phänologischen Datensatzes beschränkt ist (Cook et al., 2012). Da die Wetterdienste und Institutionen, die Daten an PEP725 liefern, stark von freiwilligen Beobachtern abhängig sind, besteht eine hohe Ungenauigkeit in der Lokalisation der aufgezeichneten Beobachtungen. Zumeist werden nicht die Beobachtungsorte im Datensatz verknüpft, sondern die Orte der Eingabe durch den Beobachter, was meistens dessen Wohnort entspricht.

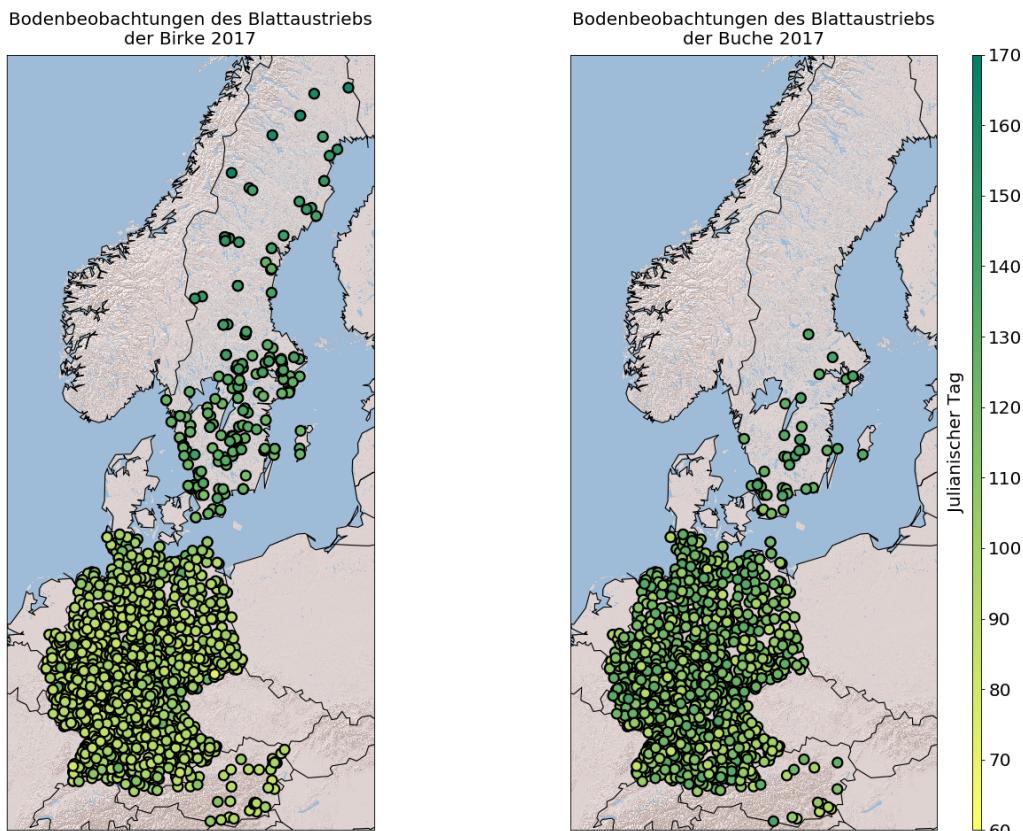


Abb. 2.6: Verfügbare phänologische Bodenbeobachtungen der Laubentfaltung der Birke (links) und Buche (rechts) für 2017. Die Farbskala zeigt den Jahrtag des Beginns der Laub austriebsphase.

### 2.3.2 Buche

Die Buche (*Fagus sylvatica*), oder auch Rotbuche, ist ein sommergrüner Laubbaum, der bis zu 35 m hoch werden kann. Sie zählt zu den Schattbaumarten und ist eine wichtige bestandsbildende Baumart (z.B. Buchenwälder im Wienerwald). Sie bevorzugt frische, nährstoffreiche und lockere Böden in sommerwarmen Lagen und kann bis in 1500 m Seehöhe vorkommen. Daher ist die Buche ein Baum der Ebenen und Mittelgebirge. Das Verbreitungsgebiet der Buche erstreckt sich in Nord-Süd-Richtung vom Süden Skandinaviens bis in den Norden Siziliens und in Ost-West-Richtung von der Nordküste Spaniens bis in die Westukraine (siehe Abb. 2.7) (Bundesforschungs- und Ausbildungszentrum für Wald, Naturgefahren und Landschaft (BFW), 2017a).

<sup>1</sup>Ein Breitengradient der Biodiversität ist die Änderung des Artenreichtums in Abhängigkeit vom Breitengrad. Die Artenvielfalt nimmt mit zunehmendem Breitengrad ab, in den Tropen ist sie am höchsten, in Richtung der Pole geht sie deutlich zurück (Wikipedia, 2018).

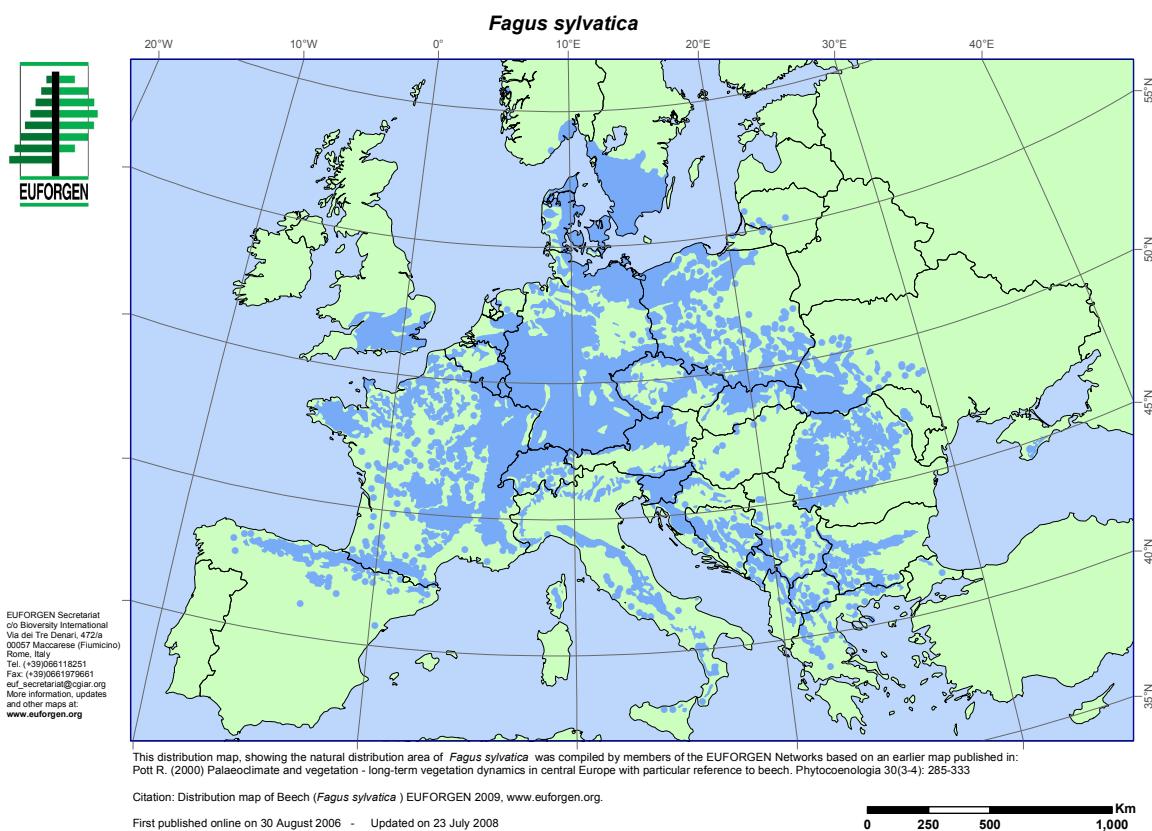


Abb. 2.7: Verbreitung der Buche in Europa (in Blau dargestellt). Quelle: European Forest Genetic Resources Programme (EUFORGEN), 2017

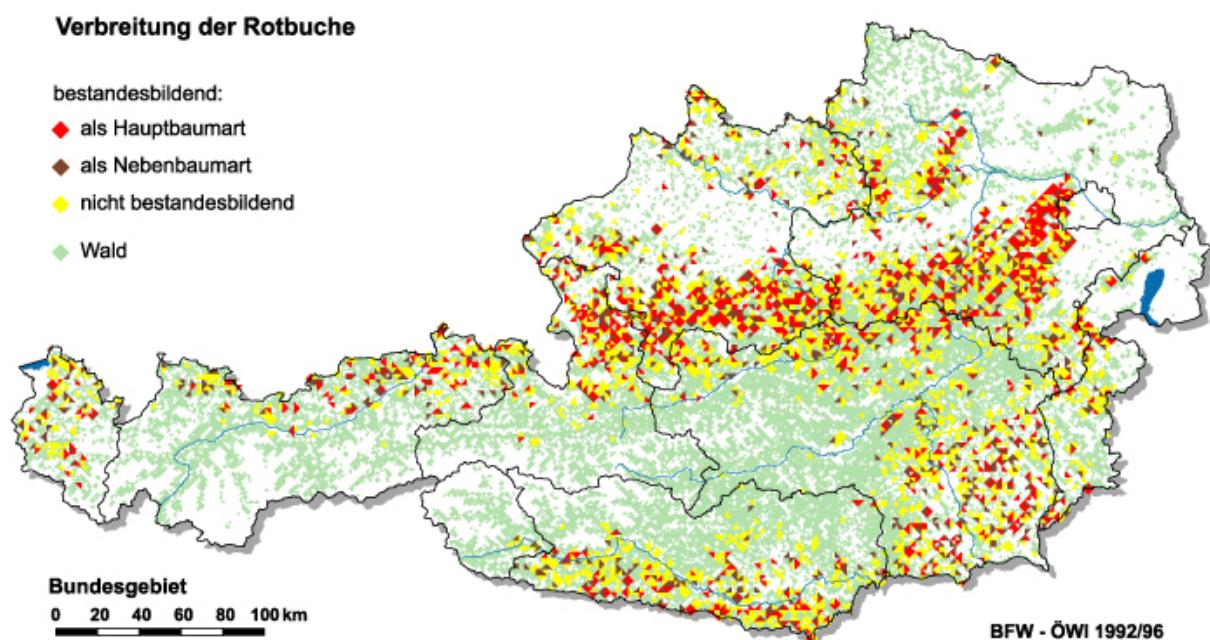


Abb. 2.8: Verbreitung der Buche in Österreich. Quelle: Bundesforschungs- und Ausbildungszentrum für Wald, Naturgefahren und Landschaft (BFW), 2017b

In Österreich zählt die Buche mit 10 % der Waldfläche zu den am häufigsten vorkommenden Laubbaumarten. Die Buche dominiert dabei die tieferen Lagen. 70 % ihres Vorkommens liegen zwischen 300 und 900 m, nur noch 6 % zwischen 1200 und 1500 m. In Deutschland beträgt der Anteil der Buche an der Waldfläche 15 % (Bundesforschungs- und Ausbildungszentrum für Wald, Naturgefahren und Landschaft (BFW), 2017c; Bundesministerium für Ernährung und Landwirtschaft, 2017). Abbildung 2.8 zeigt die Verbreitung der Buche in Österreich. Besonders im Wienerwald und dem südlichen Nieder- und Oberösterreich, dem Alpennordrand sowie im Süden von Kärnten und der Steiermark kommen Buchenwälder verbreitet vor.

### 2.3.3 Birke

Die Birke (*Betula pendula*), oder auch Sand- bzw. Weißbirke, ist ein sommergrüner Laubbaum, der bis zu 20 m hoch wird. Sie zählt zu den Lichtbaumarten und ist eine Pionierbaumart auf lichten, lockeren Rohböden. Daher wird sie zur Wiederbesiedlung kahler Flächen genutzt, wird mit der Zeit jedoch von konkurrenzstärkeren Baumarten verdrängt. Dank ihrer Kälteresistenz ist sie weniger anfällig auf Spätfrost. Sie bereitet den Boden für weniger robuste Arten vor und hindert, wegen der lichten Krone, andere Bäume nicht am Heranwachsen. Zusätzlich schützt sie den Boden auf baumlosen Hängen vor Erosion (Bundesforschungs- und Ausbildungszentrum für Wald, Naturgefahren und Landschaft (BFW), 2017a; Bundesforschungs- und Ausbildungszentrum für Wald, Naturgefahren und Landschaft (BFW), 2017c).

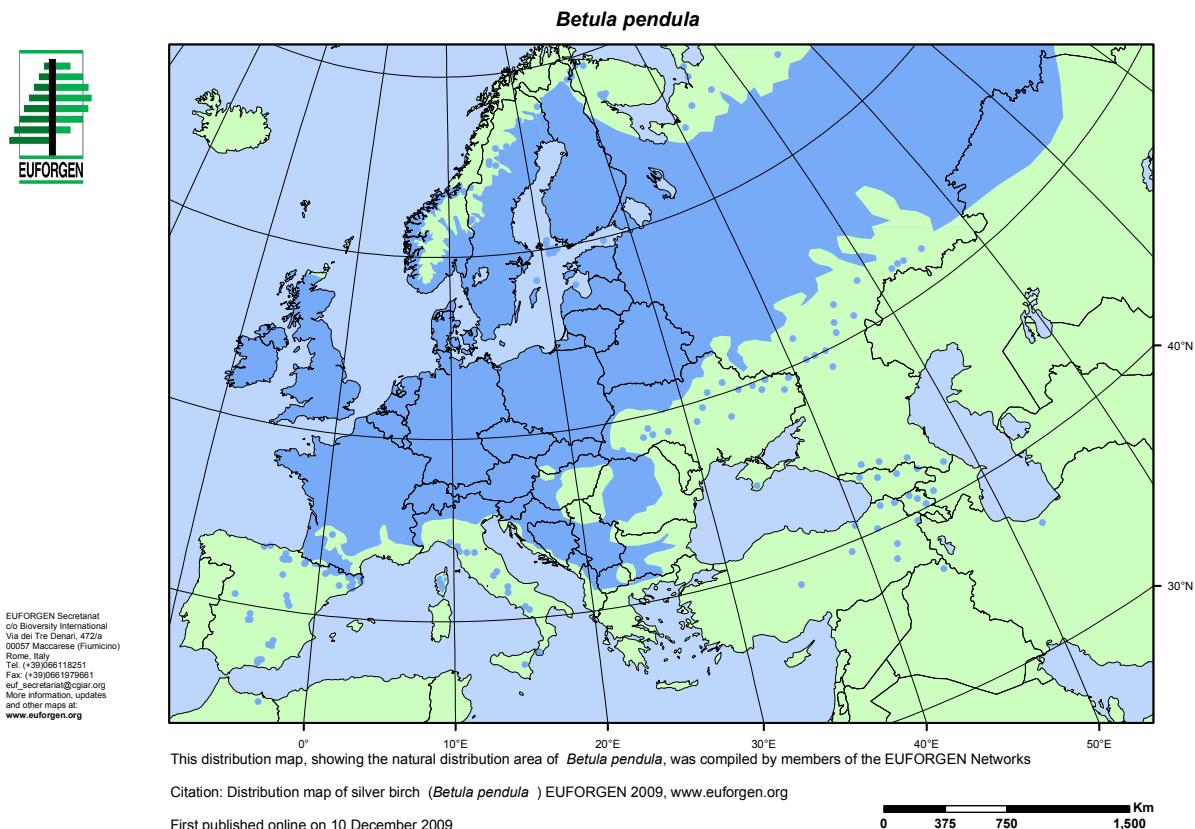


Abb. 2.9: Verbreitung der Birke in Europa (in Blau dargestellt). Quelle: European Forest Genetic Resources Programme (EUFORGEN), 2017

Vor gut 12.000 Jahren nach der letzten Eiszeit hat sie sich in den gemäßigten und kühlen Regionen der nördlichen Hemisphäre verbreitet. Die Birke ist fast überall in Europa heimisch, vor allem auf sandigen, nährstoffarmen und sauren Böden (siehe Abbildung 2.9) (Bundesforschungs- und Ausbildungszentrum für Wald, Naturgefahren und Landschaft (BFW), 2017a; Bundesforschungs- und Ausbildungszentrum für Wald, Naturgefahren und Landschaft (BFW), 2017c).

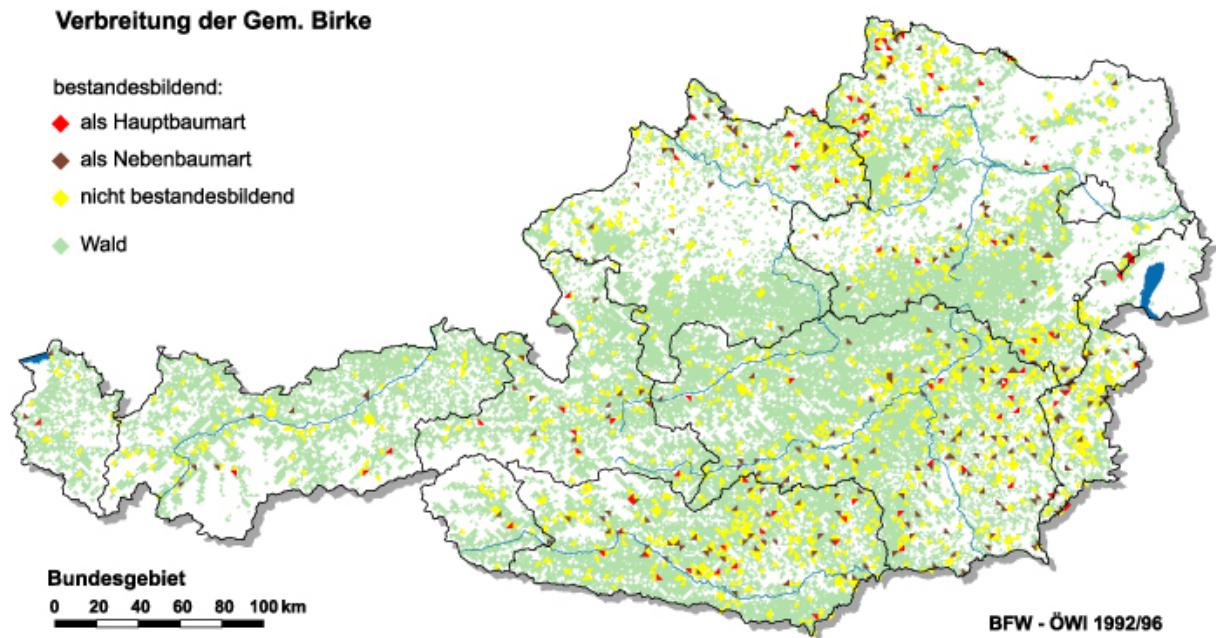


Abb. 2.10: Verbreitung der Birke in Österreich. Quelle: Bundesforschungs- und Ausbildungszentrum für Wald, Naturgefahren und Landschaft (BFW), 2017b

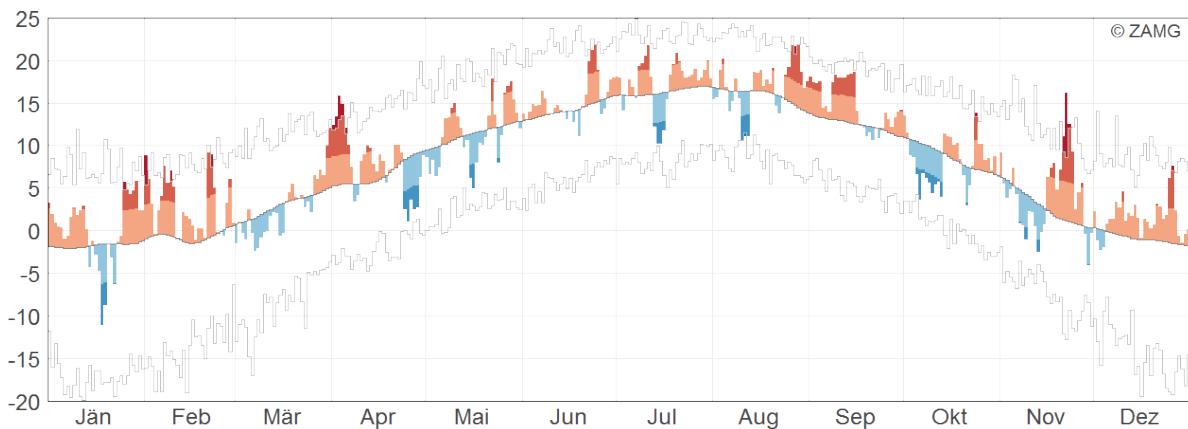
In Österreich ist die Birke besonders im Norden Österreichs, dem Mühl- und Waldviertel, sowie in Kärnten, im Südosten der Steiermark und dem südlichen Burgenland, verbreitet (siehe Abbildung 2.10).

### 2.3.4 Die phänologischen Jahre 2016 und 2017

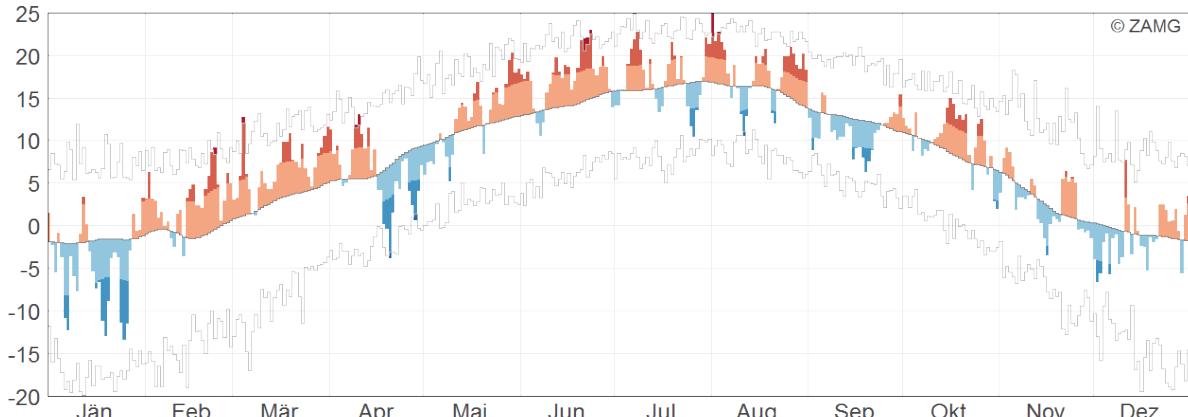
Ein sehr milder Winter 2015/2016 (siehe Abbildung 2.11) führte zu einem frühen Frühlingsbeginn des Jahres 2016. Im Westen Deutschlands blühten die ersten Haselsträucher bereits Anfang Dezember, womit dort der Beginn des meteorologischen Winters (1. Dezember) mit dem des phänologischen Vorfrühlings zusammenfiel. Im Mittel begann der Vorfrühling am 29. Januar 2016. Diese milde Winterperiode wurde durch einen Zustrom skandinavischer Kaltluft in der zweiten Januarhälfte unterbrochen, was Zwischenfruchtbestände abfrieren ließ. Januar und Februar waren im Mittel 1.3 bzw. 4.1 °C zu warm, jedoch bremsten Nachtfröste gepaart mit den schwankenden Temperaturen die Pflanzenentwicklung. Dadurch herrschte zu Beginn des meteorologischen Frühlings (1. März) immer noch der phänologische Vorfrühling. Im Vollfrühling verlief die Vegetationsentwicklung wieder relativ normal. Durch den frühen und langen Vorfrühling und den verlängerten Erstfrühling entwickelte sich der phänologische Frühling 2016 mit 119 Tagen zum längsten der letzten 20 Jahre. Im April sorgten Kaltluftvorstöße zum Monatsende hin für einstellige Höchsttemperaturen und Nachtfröste, in höheren Lagen fiel nochmals Schnee. Teilweise war es deutlich zu kalt, sowohl tagsüber als auch nachts, im Wein- und Obstbau kam es lokal zu erheblichen Ausfällen. Mit -12,5 °C wurde am 28. April in St. Michael im Lungau für

diesen Standort ein neuer Frostrekord aufgestellt (Messungen seit 1968) (Pietzsch et al., 2016; Zentralanstalt für Meteorologie und Geodynamik (ZAMG), 2018c; Zimmermann et al., 2016).

Sommer und Herbst verliefen ähnlich der letzten Jahre und zeigten allgemein deutlich geringere jährliche Schwankungen als im Frühjahr. Zu erwähnen ist noch die extrem warme 2. Novemberhälfte durch Föhnwetter in Süddeutschland und Österreich (siehe Abbildung 2.11). Die Laubentfaltung der Birke begann in Österreich und Süddeutschland Anfang April (gegen den 6. April, siehe Abbildung 2.12), die Buche folgte etwa eine Woche später (Pietzsch et al., 2016; Zentralanstalt für Meteorologie und Geodynamik (ZAMG), 2018c; Zimmermann et al., 2016).



(a) Tagesmittelwerte der Lufttemperatur für 2016



(b) Tagesmittelwerte der Lufttemperatur für 2017

Abb. 2.11: Tagesmittelwerte der Lufttemperatur für 2016 und 2017 in °C der Station Reutte im Nordwesten Tirols auf 842 m Seehöhe. Die dunkelgraue durchzogene Linie entspricht dem langjährigen Mittel 1961-1990, die hellgrauen Linien das bisherige Maximum und Minimum. Die Farben nach folgender Bedeutung: Dunkelrot: neues Maximum, Rot: zu warm für die Jahreszeit, Hellrot: der Jahreszeit entsprechend warm, Hellblau: der Jahreszeit entsprechend kalt, Blau: zu kalt für die Jahreszeit, Dunkelblau: neues Minimum. Quelle: Zentralanstalt für Meteorologie und Geodynamik (ZAMG), 2018a

Im Jahr 2017 traten die phänologischen Phasen der Pflanzen mehrheitlich früher ein als 2016. Lediglich der Vorfrühling begann deutlich später (siehe Abbildung 2.12). Ein überdurchschnittlicher Temperaturverlauf wurde von zwei ausgeprägten Kälteperioden unterbrochen. Nach einem unproblematischen Winter 2016 begann das Jahr mit einer Kälteperiode im Januar, welche zu einem durchschnittlichen Vorfrühlingsbeginn führte (Blühbeginn des Schneeglöckchens am 24.

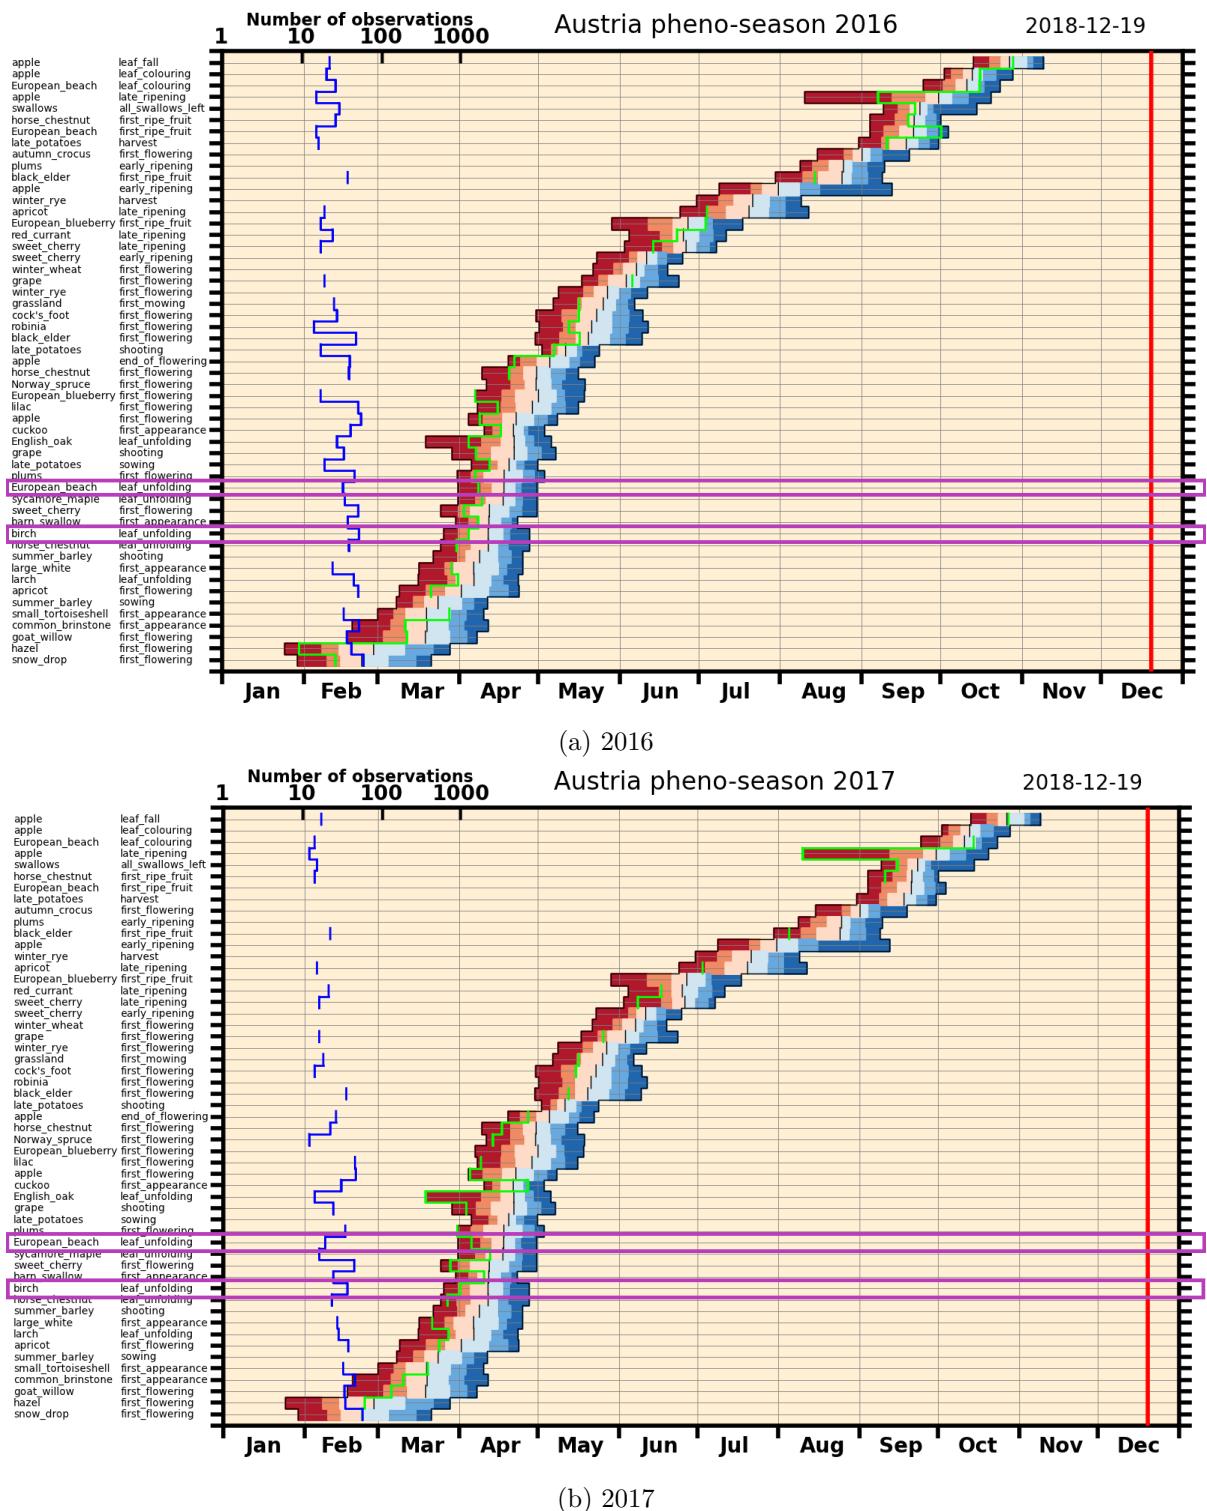


Abb. 2.12: Aufschlüsselung der phänologischen Phasen (vertikale Achse) im Jahreslauf (horizontale Achse) für die Vegetationsperiode 2016 (a) und 2017 (b) in Österreich. Blau eingezeichnet sind die Anzahl der zur Verfügung stehenden Beobachtungen, grün das Eintrittsdatum der jeweiligen Phase und die von Rot nach Blau verlaufenden Balken zeigen die Verteilung seit 1946. Dunkelrot und Dunkelblau zeigen dabei die Extremwerte, hellrot die 10 %-Perzentil und hellblau die 90 %-Perzentil, blass-rot die 25 %-Perzentil und blass-blau die 75 %-Perzentil, sowie in Schwarz der Median. Für diese Arbeit sind dabei die Blattentfaltung der Buche (european\_beach leaf\_unfolding) und der Birke (birch leaf\_unfolding) von Interesse (violett umrandet). Quelle: Zentralanstalt für Meteorologie und Geodynamik (ZAMG), 2018c

Februar). Eine äußerst warme Periode von Februar bis Mitte April (+ 2.9 bis 3.5 °C zum Mittel) trieb die Pflanzenentwicklung an und führte zu einem etwa 12 Tage früheren Einsetzen (Beginn der Blüte der Rosskastanie am 16. April). So war der wärmste in Deutschland gemessene März 3,7°C wärmer als das langjährige Mittel. Im Gegensatz zum Vorjahr und auch zum langjährigen Mittel, war der Frühling sonniger, wärmer und deutlich zu trocken. Eine Reihe von Kaltluftvorstößen unterbrach den warmen Frühling für circa drei Wochen, die zu verbreiteten Spätfrostschäden vor allem im Obst- und Weinbau führten (Janssen et al., 2017; Pietzsch et al., 2017; Scheifinger et al., 2017).

In den überdurchschnittlich warmen Monaten Mai und Juni wurde die Vegetationsentwicklung vorangetrieben, wodurch die Fruchtreife der Johannisbeere (am 17. Juni) etwa 10 Tage früher als im langjährigen Mittel einsetzte. Die phänologischen Phasen der ersten Jahreshälfte (Laubaustrieb, Blüte und frühe Reife) waren mit Ende Juni vollendet. In den Juli fallen nur wenige phänologische Phasen. Eine davon, die Reife der Marille, lag mit circa 11 Tagen vor dem langjährigen Mittel auf dem 11. Platz der 71-jährigen Reihe. Die Fruchtreife der Rosskastanie begann Ende des Sommers, fast zwei Wochen früher, als im langjährigen Mittel. Sie lag damit auf Platz 2 der 72-jährigen Reihe und setzte den Trend zu früheren Eintrittsterminen fort (Janssen et al., 2017; Pietzsch et al., 2017; Scheifinger et al., 2017).

Im Herbst hingegen fielen der Beginn der Laubverfärbung und des Laubfalls in den langjährigen Durchschnitt. Beide Phasen zeigten ein uneinheitliches Auftreten, in den letzten Jahrzehnte lässt sich allerdings ein Trend zur Verschiebung zu späteren Eintrittszeiten erkennen. An diese phänologischen Phasen im Herbst knüpft die Vegetationsruhe (auch Dormanzi genannt) an. Im Herbst und Winter wird diese durch einen ausreichenden Betrag an Kältesummen durchbrochen und bei gewissen Temperaturen im darauffolgenden Frühling kann erneut der Vegetationszyklus seinen Anfang nehmen. Die Laubentfaltung der Birke begann in Österreich und Süddeutschland etwa 5 Tage früher (gegen 1. April), die Buche folgte zur selben Zeit, wie die Birke 2016 (Janssen et al., 2017; Pietzsch et al., 2017; Scheifinger et al., 2017).

# 3 Methoden

## 3.1 Datenbeschaffung und -aufbereitung

Der erste Schritt bestand darin, geeignete Quellen für die Daten von Sentinel-2 und MODIS ausfindig zu machen. Im Fall von Sentinel-2 sind die Daten beider Satellitenpaare frei zugänglich, jedoch gab es keine fertig prozessierten und gefilterten NDVI-Zeitreihen zum Zeitpunkt der Datensammlung im Winter 2017/18. Level 1 prozessierte Daten, d.h. georeferenziert und Atmosphären-korrigiert, sind bei vielen Quellen zu finden, allerdings übersteigt deren Speicherbedarf für ein Gebiet von Österreich und Deutschland für zwei Jahre die für diese Arbeit zugänglichen Ressourcen, um sie selbst Level-2 zu prozessieren, filtern und den NDVI zu berechnen. Daher fiel die Wahl auf die in Kapitel 2 genannten Quellen. Im Falle der MODIS-Daten zeigt die BOKU eine ausgereifte Variante der Prozessierung, Filterung von Schnee und Wolken sowie Korrektur möglicher Fehler.

Da die verschiedenen Datensätze, ob Landnutzungskataster oder Satellitendaten, wie im Abschnitt 2 beschrieben, in unterschiedlichen Projektionen vorliegen und so nicht direkt miteinander vergleichbar sind, müssen diese auf eine gemeinsame Projektion gebracht werden. Um die hohe Genauigkeit der Sentinel-2-Daten zu bewahren, wurden die MODIS-NDVI-Daten, die HLR für Wald, als auch die NDVI-Daten von BFW/TU-Wien, da diese nur für ein Jahr vorliegen, auf die Projektion der Daten des Joanneum Research Graz gebracht (WGS 84/UTM zone 32N). Zur Reprojektion und Visualisierung der Daten wurde das Programm QGIS verwendet. Zusätzlich wurden die HLR für Wald zum einfacheren Vergleich mit den Sentinel-2-Daten von einer räumlichen Auflösung von 20 m auf 10 m gerechnet.

Die Satellitendaten aus den Projekten des Joanneum Graz liegen für einige der Kacheln nicht als fertig berechnete NDVI-Daten vor, weshalb der NDVI erst mit Hilfe der Standardformel 2.2 berechnet werden mussten. Diese Berechnung sowie das Auslesen der Satellitenbilder und der HLR für Wald wurden mit Python durchgeführt.

## 3.2 Vergleich der Datensätze und Pixeldetektierung

Im zweiten Schritt werden die Punktswerte der phänologischen Bodenbeobachtungen mit den LSP vergleichbar gemacht. In den „Copernicus High Resolution Layers“ für Wald werden dazu jene Pixel detektiert, die Laubwald aufweisen und Bodenbeobachtungspunkte umschließen bzw. sich in deren Umgebung befinden (siehe Abbildung 3.1). So wird versucht, das oben beschriebene Punkt vs. Pixel Problem zu umgehen und LSP und GP direkt vergleichbar zu machen, als auch die geringe räumliche Genauigkeit der GP-Daten zu berücksichtigen. Dazu wird das MODIS-Pixel detektiert, in dem ein Bodenbeobachtungspunkt liegt und in diesem und den Pixeln in einem Umkreis von 2 Pixel (entspricht einem Radius von ungefähr 500 m um die Beobachtung) jenes Pixel gesucht, das laut Landnutzungskataster den größten Anteil von Laubwald aufweist, d.h. die meisten HLR-Pixel, die Laubwald aufweisen, beinhaltet. Dies ist deswegen erforderlich, da die Pixel, in denen der GP Beobachtungsort liegt, oft keinen bis sehr geringen Anteil an Laubwald oder Wald im Allgemeinen, beinhaltet und somit der NDVI-Verlauf einer verbauten bzw. baumfreien Fläche analysiert werden würde. Anschließend werden die Sentinel-2 Pixel, die innerhalb des ausgewählten MODIS-Pixel liegen detektiert und nur jene zur Analyse verwendet, die laut

HLR Laubwald aufweisen, um so die Mischpixel-Problematik zu reduzieren, bestenfalls sogar zu lösen. Zusätzlich zur Information des Laubtyps wird auch die Information der Baumkronendichte verwendet, da auch die HLR für Wald mit einer räumlichen Auflösung von 20 m den Mischpixel-Effekt aufweist (siehe Abbildung 3.2). Was bedeutet, dass nicht nur der NDVI von Laubbäumen, sondern auch von Pflanzen, die unter oder neben dem Baum wachsen (wie beispielsweise Gräser, Moos und Sträucher), oder vom Untergrund des Baumes (Erd- oder felsiger Boden), gemessen werden. Aus den Kataster-Datensätzen werden der relative Laubbaum- und Nadelbaumanteil innerhalb eines MODIS-Pixels berechnet, indem die jeweiligen HLR-Pixel gezählt und durch die Anzahl der Pixel dividiert werden, die in ein MODIS-Pixel passen. Zusätzlich wird die Baumkronendichte der Laubbäume innerhalb eines MODIS-Pixels durch aufsummieren der Werte und Dividieren durch die Gesamtzahl an HLR-Pixel in einem MODIS-Pixel berechnet, als auch die Laubbaumkronendichte der verwendeten Sentinel-2 Pixel durch ein arithmetisches Mittel bestimmt.

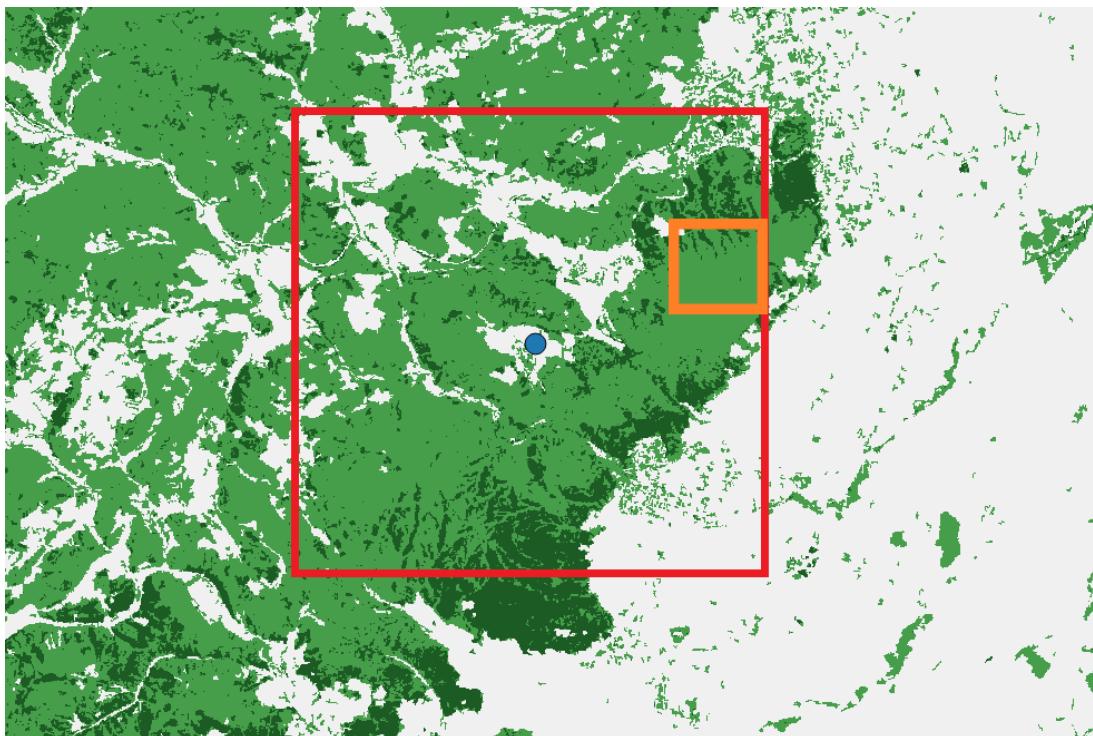


Abb. 3.1: „Copernicus High Resolution Layers“ (HLR) zur Detektion von bewaldeten Flächen innerhalb eines MODIS-Pixels, das für eine phänologische Beobachtungsstelle (blauer Punkt) repräsentativ ist. Innerhalb des rot umrandeten Bereiches, mit einer Seitenlänge von knapp einem Kilometer, wird jenes der 25 darin liegenden MODIS-Pixel gesucht, das laut HLR für Wald den größten Anteil an Laubbäumen aufweist, d.h. die meisten Laubbaum-Pixel beinhaltet. Das ausgewählte MODIS-Pixel ist in Orange angedeutet. Farbgebung: Dunkelgrün steht für Nadel-, Hellgrün für Laubbäume und Weiß steht für anderweitige Landnutzung

### 3.3 Zeitliche NDVI-Verläufe und Interpolation

Die ausgewählten Pixel bzw. Bereiche von Pixeln werden in den Satellitenbildern identifiziert und aus den einzelnen Bildern ein zeitlicher Verlauf des NDVI generiert. Im Fall von MODIS liegt ein NDVI-Verlauf mit einer zeitlichen Auflösung von 7 Tagen vor, für Sentinel-2 schwankt

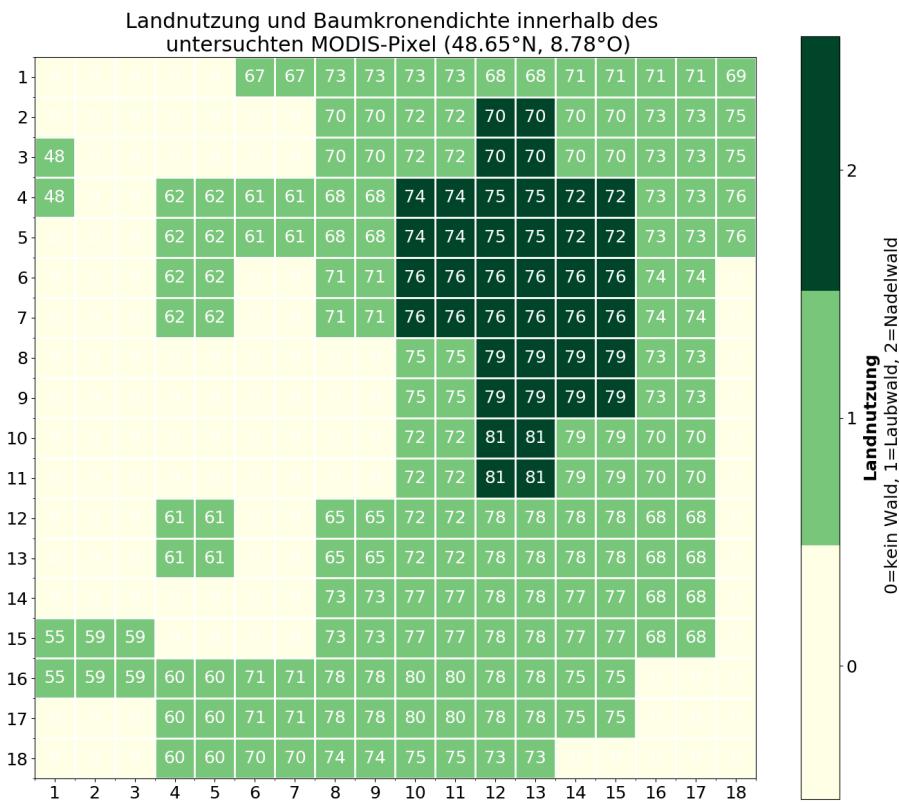


Abb. 3.2: Ein detektiertes MODIS-Pixel (nach Reprojektion mit ca. 175x175 m) mit den darin enthaltenen HLR-Pixel (nach Reprojektion mit 10x10 m). In kleinen Quadranten sind Laubbäume (hellgrün), Nadelbäume (dunkelgrün) und keinem Wald (blassgelb) mit deren Baumkronendichte in Prozent dargestellt. Innerhalb des MODIS-Pixel werden die Sentinel-2 Pixel (gleichbedeutend mit den HLR-Pixel) verwendet, die Laubwald aufweisen und nach Baumkronendichte in verschiedenen Klassen für die Analyse und dem Vergleich mit MODIS eingeteilt.

die zeitliche Auflösung zwischen 2 und 10 Tagen. Da in einem MODIS-Pixel je nach Laubbauanteil mehrere Sentinel-2 Pixel liegen, werden aus den NDVI-Werten jener Pixel Mittelwert sowie die 10 % und 90 % Perzentile berechnet und aus jedem dieser drei Werte ein NDVI-Verlauf gebildet. Mittels drei verschiedener Interpolationsverfahren werden NDVI-Verläufe mit täglicher Auflösung generiert: (i) Interpolation durch eine Gaußprozess-Regression, (ii) kubische Spline-Interpolation und (iii) Kurvenanpassung durch ein Polynom 6. Grades. Damit wurden nicht nur die NDVI-Verläufe auf eine eintägige Auflösung gebracht, sondern auch geglättet. Dieser und alle weiteren Schritte werden mit Python durchgeführt. Zur Interpolation mit einem Gauß-Prozess siehe ([http://scikit-learn.org/stable/modules/gaussian\\_process.html](http://scikit-learn.org/stable/modules/gaussian_process.html)), zur Kurvenanpassung durch ein Polynom siehe (<https://glowingpython.blogspot.com/2011/07/polynomial-curve-fitting.html>).

### 3.4 Bestimmung der Laubaustriebsphase

Im Bereich der Satellitenphänologie gibt es etablierte Methoden mit Schwellenwerten, den Beginn und den Offset des Ergrünens direkt aus Satellitendaten zu gewinnen (Cong et al., 2012; White

et al., 2009). Mit den bisherigen Schritten stehen nun alle Mittel zu Verfügung, um aus den generierten NDVI-Zeitreihen den Start des Ergrünens zu bestimmen. Der Schwellenwert, der diesen Start repräsentiert, wird in dieser Arbeit auf drei verschiedene Weisen detektiert:

#### 3.4.1 Gaussian-Midpoint-Methode

Die Gaussian-Midpoint-Methode verwendet zur Rekonstruktion der NDVI-Zeitreihe eine Gaußsche Kurve. Dabei wird dieselbe Gaußsche Interpolation verwendet, wie im Abschnitt 3.3 beschrieben. Diese Methode ist besonders für Vegetation geeignet, die eine einzelne Spitze in der NDVI-Zeitreihe aufweist (Cong et al., 2012). Für den gewählten Zeitraum wird ein NDVI-Verhältnis ( $NDVI_{ratio}$ ) berechnet und überschreitet dieses den Wert von 0,5, wird dieser Zeitpunkt als Beginn des Ergrünens definiert (Reed et al., 1994; White et al., 1997):

$$NDVI_{ratio}(t) = \frac{NDVI_t - NDVI_{min}}{NDVI_{max} - NDVI_{min}} \quad (3.1)$$

Dabei sind  $t$  der Jahrtag,  $NDVI_t$  der NDVI-Wert zum Zeitpunkt  $t$  und  $NDVI_{min}$  sowie  $NDVI_{max}$  sind die Minimum- und Maximumwerte der jährlichen NDVI-Kurve. Zu beachten sei allerdings, dass der satellitenbasierte Beginn des Ergrünens als Start aktiven Vegetationswachstums verstanden werden kann und somit üblicherweise später als der Blattaustrieb eintritt (Reed et al., 1994; White et al., 1997). Zusätzlich wird die Nebenbedingung eingeführt, dass das NDVI-Verhältnis zwischen dem Minimum und dem Maximum berechnet wird, also in jenem Intervall, in dem der NDVI am schnellsten ansteigt und auch das Ergrünens stattfindet (Atzberger et al., 2014).

#### 3.4.2 Spline-Midpoint-Methode

Die Spline-Midpoint-Methode verwendet für die Rekonstruktion der NDVI-Zeitreihe die Spline-Interpolation. Hier wird ein kubischer Spline, wie in Abschnitt 3.3 beschrieben, verwendet um die NDVI-Zeitreihe auf eine 1-Tages-Auflösung zu interpolieren. Dabei werden zwischen jedem der Datenpunkte eine Reihe von Polynomen 3. Grades eingepasst. Mit einem 7-tägigen gleitenden Mittel werden die interpolierten Zeitreihen geglättet. Zur Bestimmung des Beginns des Ergrünens wird dieselbe NDVI-Verhältnisberechnung wie bei der Gaussian-Midpoint-Methode (Formel 3.1) verwendet (Cong et al., 2012).

#### 3.4.3 Polyfit-Maximum-Methode

Bei der Polyfit-Maximum-Methode wird zur Rekonstruktion der NDVI-Zeitreihe ein Polynom 6. Grades angewandt. Dazu wird die Polynom-Kurvenanpassung an ein Polynom 6. Grades per Kleinster-Quadrate-Methode aus Abschnitt 3.3 verwendet. Im Gegensatz zu den beiden vorgenannten Methoden wird der NDVI-Schwellenwert in dieser Methode über folgendes NDVI-Verhältnis bestimmt (Cong et al., 2012; Piao et al., 2006):

$$NDVI_{ratio}(t) = \frac{NDVI(t+1) - NDVI(t)}{NDVI(t)} \quad (3.2)$$

Dabei sind  $NDVI_t$  der NDVI-Wert zum Zeitpunkt  $t$  und  $NDVI_{ratio}$  die berechnete relative Änderungsrate des NDVI zum Zeitpunkt  $t$ . Mit anderen Worten, der Maximalwert dieses NDVI-Verhältnisses ist die größte Änderung der NDVI-Zeitreihe. Die Zeit, die dem maximalen NDVI-Verhältnis entspricht, ist definiert als das Datum des Beginns des Ergrünens (Cong et al., 2012; Piao et al., 2006). Dies entspricht der 1. Ableitung des NDVI und der Zeitpunkt, an dem dessen Maximum liegt, gilt als Beginn. In Cong et al. (2012) enthält diese Methode außerdem die Temperatur als Hilfsindex, um die Eintrittszeitpunkte zu begrenzen. Dabei wird ein falsches Maximum des NDVI-Verhältnisses zu einem Zeitpunkt abgelehnt, an dem die lokale Temperatur unterhalb von 5°C liegt. In dieser Arbeit wird stattdessen das NDVI-Verhältnis erst ab dem 60. Tag des Jahres berechnet, da vor diesem Tag weder die Birke noch die Buche mit dem Austrieb der ersten Blätter beginnen.

Für weitere Details zu den drei Methoden siehe Cong et al. (2012).

#### 3.4.4 Kumulativer NDVI

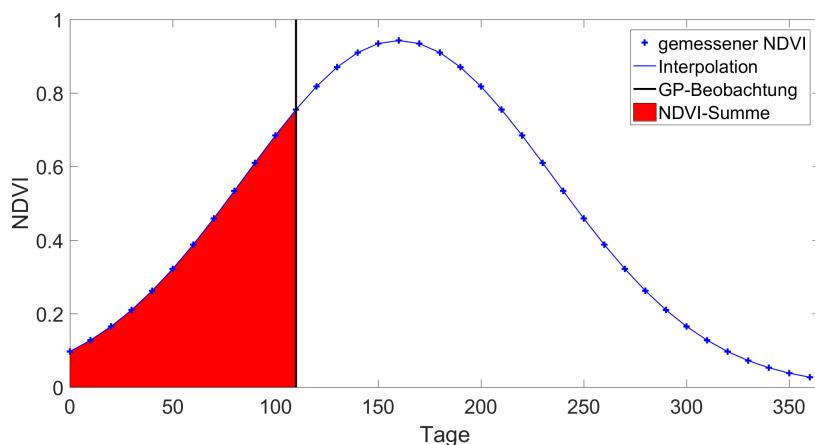


Abb. 3.3: Symbolischer Verlauf der NDVI-Werte (blaue Punkte) an einem Standort während eines Jahres, zur Verdeutlichung der beschriebenen Methode des kumulativen NDVI. Dazu wird die interpolierte NDVI-Kurve (blaue Kurve) am beobachteten Eintrittstermin der Blattentfaltung (schwarze vertikale Linie) abgeschnitten und das Integral bzw. die Summe der NDVI-Werte vom Anfang des Jahres bis dahin gebildet (rote Fläche).

Der kumulative NDVI ist die Summe der NDVI-Werte über die Zeit, z.B. eines Jahres, beziehungsweise die mit Integralen berechnete Fläche unter der NDVI-Kurve, und wird für Analysen der jährlichen Zyklen, der Produktivität, sowie der Änderungen der Vegetation oder auch Vegetationszyklen über mehrere Jahre verwendet (Gong et al., 2015; Hargrove et al., 2010; Rojas, 2007). In dieser Arbeit soll der kumulative NDVI dazu dienen, LSP und GP vergleichbar zu machen, indem beide Informationen verknüpft werden. Dazu wird der interpolierte NDVI-Verlauf zum Zeitpunkt der Bodenbeobachtung abgeschnitten und vom Anfang des Jahres bis zum beobachteten Phaseneintritt der kumulative NDVI berechnet (siehe Abbildung 3.3). Diese NDVI-Summe soll im Weiteren für eine zeitliche und räumliche Validierung verwendet werden, welche im nächsten Abschnitt beschrieben sind. Die Idee dafür stammt aus der Modellierung der

Eintrittszeitpunkte phänologischer Phasen mit Hilfe von Temperatursummen über bestimmten Schwellenwerten. Es wird eine NDVI-Summe mit dem Phaseneintritt in Verbindung gebracht und nicht ein bestimmter NDVI-Wert oder Prozentsatz des Maximalwertes. Hierbei ist anzunehmen, dass eine NDVI-Summe robuster ist, als ein fixer NDVI-Wert. Ein flacher Anstieg der NDVI-Kurve bedeutet einen späteren Phaseneintritt, als ein steiler Anstieg und eine rasche Akkumulation des NDVI. Mit diesem Ansatz soll dem Laubaustrieb von Birke und Buche eine bestimmte NDVI-Summe zugeordnet werden, die bestenfalls lediglich von der Höhe und der geographischen Lage abhängig ist.

## 3.5 Zeitliche und räumliche Validierung

Um die Robustheit der beschriebenen Methode des kumulativen NDVI zu bewerten, wird zuerst eine zeitliche Validierung durchgeführt. Dazu wird an einer Station mit der Information eines Jahres, das Eintrittsdatum des Laubaustriebs für das zweite Jahr modelliert. Dies bedeutet der kumulative NDVI wird für das Jahr 2016 berechnet und im Jahr 2017 der Zeitpunkt identifiziert, an dem dieser Wert erreicht ist. Dieser Zeitpunkt ist dann der simulierte Eintrittstermin. Derselbe Vorgang wird mit dem kumulativen NDVI des Jahres 2017 durchgeführt, um den Eintrittstermin für das Jahr 2016 zu simulieren. Beide Modelle werden abschließend mit den Bodenbeobachtungen verglichen. Des Weiteren wird validiert, welche zeitliche Interpolationsmethode (aus Abschnitt 3.3) die genaueste Simulation ermöglicht.

Als Nächstes wird untersucht, ob mit einer der bisher publizierten Methoden zur Ermittlung der Pflanzenaktivität eine Vorhersage für das darauffolgende Jahr möglich ist. Dabei wird bei der Polyfit-Maximum-Methode in einem Jahr der Wert der  $NDVI_{ratio}$  (Formel 3.2) am Eintrittstermin der Bodenbeobachtung bestimmt und im zweiten Jahr detektiert, an welchem Tag des Jahres (innerhalb von 175 Tagen) dieser Wert der  $NDVI_{ratio}$  des zweiten Jahres am ähnlichsten ist bzw. die Steigung der 1. Ableitung beider Jahre nahe beieinander liegen, also deren Differenz minimal ist.

Zusätzlich werden die beschriebenen Methoden mit einer Persistenz-Vorhersage, den Eintrittsterminen des jeweils anderen Jahres, verglichen.

Im nächsten Schritt wird eine räumliche Validierung durchgeführt. Hierfür werden einerseits die in Abschnitt 3.4 beschriebenen Methoden verwendet, um die Laubaustriebsphase direkt aus den Satellitendaten zu bestimmen, und mit den Bodenbeobachtungen verglichen. Dies soll zeigen, ob im Falle wegfallender Bodenbeobachtungen die Information aus den Satellitendaten ausreicht, um dadurch entstehende Lücken zu füllen. Andererseits wird eine Kreuzvalidierung zur Bestimmung der räumlichen Korrelation angewandt. Die Kreuzvalidierung wird folgendermaßen durchgeführt: ein Beobachtungspunkt wird ausgelassen, aus allen anderen wird eine NDVI-Summe gebildet und dann an dem ausgelassenen Beobachtungspunkt bestimmt, zu welchem Zeitpunkt diese Summe erreicht wird. Dies entspricht dann dem berechneten Eintrittstag. Sämtliche berechnete Zeitpunkte werden mit den beobachteten mittels Korrelation verglichen. Die NDVI-Summe aller nicht ausgelassener Stationen wird auf mehrere Weisen gebildet:

- i das arithmetisches Mittel der kumulativen NDVI-Summen der übrigen Stationen;
- ii ein einfaches lineares Regressionsmodell, bei der die NDVI-Summe aus der allgemeinen Höhenregression über alle übrigen Stationen berechnet wird;
- iii ein multiples lineares Regressionsmodell, bei dem die NDVI-Summe als lineare Kombination aus Höhe, Länge, Breite, Laubbaum-, Nadelbaumanteil und/oder Baumkronendichte gebildet wird;

iv ein Regressionsmodell, bei dem der Eintrittstag aus den geographischen Standortparametern der Bodenbeobachtungen verwendet wird, d.h. nur mit Informationen der GP.

### 3.6 Durchführung mit Sentinel-2-Daten, Vergleich mit MODIS und Analyse der Satellitendaten

Die beschriebenen Schritte werden zuerst mit den MODIS-Daten durchgeführt, danach auch mit den Sentinel-2-Daten, um zu ermitteln, ob durch eine höhere räumliche Auflösung bessere Ergebnisse erzielt und neue Erkenntnisse gewonnen werden können. Zudem werden die NDVI-Werte bzw. NDVI-Verläufe der beiden Satellitensysteme miteinander verglichen, um zu analysieren, ob und welche Unterschiede es gibt. Dazu werden die Werte/Verläufe gemeinsam dargestellt, um etwaige Einflüsse durch den Mischpixeleffekt, d.h. einen Einfluss von Laub- und Nadelbaumanteilen, zu zeigen. Auch werden die Werte in den verschiedenen Saisonen in Abhängigkeit des Laubbaumanteils und der Baumkronendichte miteinander verglichen, um mögliche Abweichungen durch die Jahreszeiten zu finden.

In Abbildung 3.4 ist die Durchführung der bisher beschriebenen Schritte, sowie der Dateninput und -output in einem Diagramm zusammengefasst.

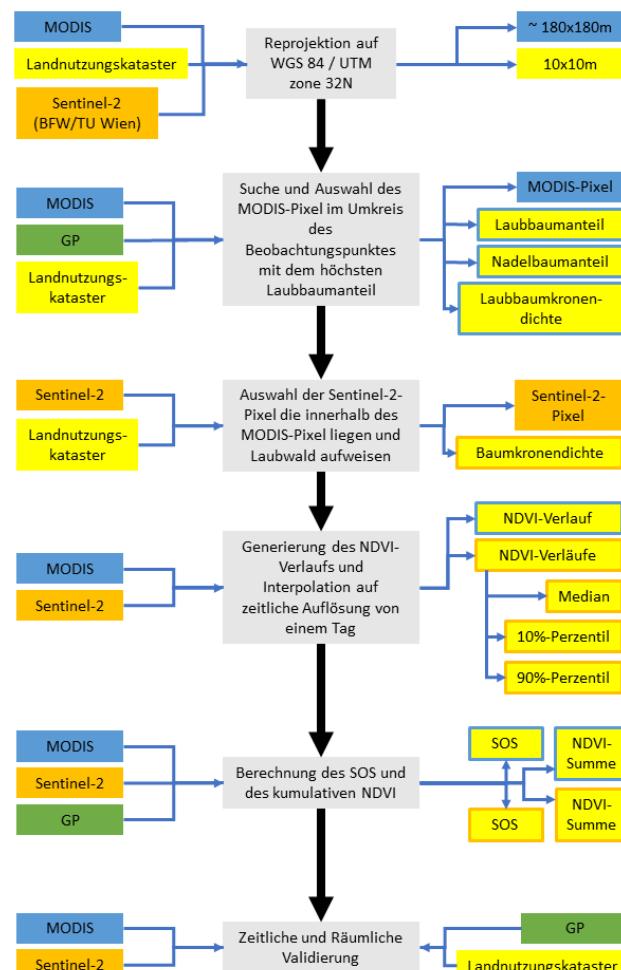


Abb. 3.4: Flussdiagramm der in dieser Arbeit durchzuführenden Module.

# 4 Resultate

Das zentrale Ziel dieser Masterarbeit besteht darin, zu bewerten, ob die räumliche Auflösung von 10 m und die zeitliche von 3-10 Tagen des aus den Sentinel-2-Daten berechneten NDVI ausreicht, um aus Satellitendaten die phänologischen Phasen bestimmter Pflanzengattungen zu bestimmen. Als erstes werden die Methoden auf MODIS-Daten angewandt, um zu untersuchen, wie gut die im vorherigen Kapitel beschriebenen Methoden mit Satellitendaten, mit einer räumlichen Auflösung von 250 m, funktionieren. Im zweiten Schritt werden die Methoden mit den Sentinel-Daten wiederholt, um zu zeigen, wie sich das Ergebnis mit Satellitendaten, die eine räumliche Auflösung von 10 m aufweisen, verbessern lassen.

## 4.1 Zeitliche Validierung der Methodik

Es wird eine zeitliche Validierung durchgeführt, um (wie in Abschnitt 3.5 beschrieben) die Robustheit der kumulativen NDVI-Methode sowie eine mögliche Verknüpfung der Polyfit-Maximum Methode mit den phänologischen Bodenbeobachtungen, zu testen. Dafür werden lediglich jene Stationen herangezogen, welche in den 6 Kacheln liegen und für die in beiden Jahren Sentinel-2-Daten zur Verfügung stehen (siehe Abschnitt 2.1.2). Das angegebene Jahr in den folgenden Abbildungen und Tabellen ist das Zieljahr, d.h. steht 2016, wurde die kumulative NDVI-Summe im Jahr 2017 gebildet und im Jahr 2016 der Tag gesucht, an dem diese Summe erreicht ist.

In Tabelle 4.1 der zeitlichen Validierung im Fall Birke sind statistische Maße zur Bestimmung der Güte der beiden Methoden und der verschiedenen zeitlichen Interpolationsmethoden, sowie zum Vergleich einer Persistenz, bei der die beobachteten Eintrittstermine der Blattentfaltung des anderen Jahres verwendet werden, aufgelistet. Die Ergebnisse der obere Hälfte der Tabelle sind für eine Interpolation der täglichen NDVI-Werte ab dem ersten gemeinsamen Startpunkt beider Jahre. Das Jahr 2016 beginnt mit dem ersten Satellitenbild am 4. Januar, das Jahr 2017 am 2. Januar. Daher wird die Interpolation und somit auch die Summenbildung des NDVI ab dem 4. Tag des Jahres gestartet. Dabei zeigt sich, dass die kumulative NDVI-Methode je nach zeitlicher Interpolationsmethode verglichen mit den Bodenbeobachtungen signifikante ( $p \leq 0.05$ ) Korrelationskoeffizienten von  $r = 0.55$  bzw.  $r = 0.56$ , eine mittlere Differenz von 16-17 Tagen sowie einen RMSE zwischen 19 und 20 für das Jahr 2016 aufweist. Für das Jahr 2017 zeigt sich eine Korrelation von  $r = 0.11 / 0.15 / 0.12$ , eine Differenz von 16-18 Tagen und ein RMSE von 20-21, allerdings ist der  $p$ -Wert  $\geq 0.05$ , womit die Korrelation nicht signifikant ist. Somit scheint die Methode für das Jahr 2016 deutlich besser zu funktionieren als für 2017.

Die modifizierte Polyfit-Maximum Methode zeigt im Jahr 2016 eine signifikante Korrelation mit den Bodenbeobachtungen von  $r = 0.19$ , eine mittlere Differenz von 23 Tagen und einen RMSE von 28.5. Für 2017 fällt die Korrelation auf  $r = -0.15$ , die mittlere Differenz zu den Beobachtungen und der RMSE bleiben annähernd gleich. Dies zeigt bereits, dass diese Methode weder geeignet für eine zeitliche Interpolation von Eintrittstagen ist, noch die Eintrittstage aus laufenden Messungen des NDVI via Satellit (real time) bestimmt werden können, allerdings ist sie auch nicht dafür gedacht.

Die Persistenz zeigt eine signifikante Korrelation von  $r = 0.6$ , eine mittlere Differenz von ca. 10 Tagen und einen RMSE von 11.37 in den zwei Jahren. Dies bedeutet, dass, wenn sich die beiden Jahre sehr ähnlich sind, die Persistenz sehr gut funktioniert. Für die Jahre 2016 und 2017 funktioniert sie besser als die Methode des kumulativen NDVI, wobei die Korrelation 2016 nur

Tabelle 4.1: Ergebnis der zeitlichen Validierung der drei verwendeten Methoden im Fall der Birke. Bezuglich der Ergebnisse der kumulativen NDVI-Methode zeigt die obere Hälfte der Tabelle die Resultate mit der Aufsummierung des NDVI ab 4. Januar des jeweiligen Jahres, während die untere Hälfte der Aufsummierung ab 1. März entspricht. Fettgedruckte r Werte zeigen statistisch signifikante Korrelationen ( $p \leq 0.05$ ). Der Startzeitpunkt der kumulativen NDVI-Summe hat allerdings keinen Einfluss auf die 1. Ableitung des NDVI und der Persistenz, weshalb deren Maßzahlen oben und unten identisch sind.

Jahr	Maß	Methode				
		Kumulativer NDVI			1. Ableitung	Persistenz
		Gaußkurve	Cubic Spline	Poly. 6. Grades	Poly. 6. Grades	
2016	r	<b>0.56</b>	<b>0.55</b>	<b>0.56</b>	<b>0.19</b>	<b>0.6</b>
	$\bar{\Delta}$ [d]	16.17	16.27	16.72	22.35	9.75
	RMSE	19.7	19.21	20	28.28	11.37
2017	r	0.11	0.15	0.12	-0.15	<b>0.6</b>
	$\bar{\Delta}$ [d]	16.28	17.71	16.74	21.91	9.75
	RMSE	19.75	21.03	20.08	28.53	11.37
Bildung des kumulativen NDVI ab 1. März						
2016	r	<b>0.62</b>	<b>0.63</b>	<b>0.63</b>	<b>0.19</b>	<b>0.6</b>
	$\bar{\Delta}$ [d]	8.73	8.67	8.89	22.35	9.75
	RMSE	10.44	10.31	10.58	28.28	11.37
2017	r	<b>0.46</b>	<b>0.43</b>	<b>0.44</b>	-0.15	<b>0.6</b>
	$\bar{\Delta}$ [d]	9.59	9.47	9.74	21.91	9.75
	RMSE	11.66	11.29	11.71	28.53	11.37

ein wenig darunter liegt.

Bei der Interpolation der NDVI-Daten auf eine täglichen Verlauf zeigte sich, dass im Winter höhere NDVI-Werte als erwartet vorkommen bzw. ungewöhnliche Anstiege verzeichnet sind (wird in Kapitel 4.4 noch genauer untersucht). Um dieses Problem zu umgehen, wird im weiteren Schritt der Start der Interpolation, was dem Startpunkt der Bildung des kumulativen NDVI entspricht, auf den 1. März, der üblicherweise dem Start der Frühlingssaison auf der gemäßigten nördlichen Hemisphäre entspricht (White et al., 2009), verschoben. Dadurch lässt sich die Methode des kumulativen NDVI deutlich verbessern. Dies ist an der untere Hälfte der Tabelle 4.1 abzulesen, an der zu erkennen ist, dass besonders für 2017 deutlich bessere Ergebnisse resultieren. Die Korrelation steigt auf  $r = 0.46 / 0.43 / 0.44$ , der mittlere Fehler sinkt auf etwa 10 Tage, der RMSE auf etwa 12. Im Jahr 2016 schneidet die kumulative NDVI-Methode mit  $r = 0.62$  bzw. 0.63 nun besser ab als die Persistenz, die Differenz beträgt 9 Tage und der RMSE ca. 10.5. Für beide Jahre liegt nun eine statistisch signifikante Korrelation vor.

In Abbildung 4.1 sind die beschriebenen Methoden im Vergleich zu den Bodenbeobachtungen in beiden Jahren zu sehen. Auffällig sind dabei die teilweise späten berechneten Eintrittstage der modifizierten Polyfit-Maximum-Methode und die daraus resultierenden großen Differenzen zur Beobachtung. Grund dafür ist, dass der in einem Jahr bestimmte Wert der 1. Ableitung des NDVI im anderen Jahr nur annäherungsweise vorkommt. Daraus resultiert auch die bereits erwähnte geringe Korrelation und die hohe mittlere Differenz sowie der hohe RMSE. Die kumulative NDVI-Methode ergibt im Fall der drei zeitlichen Interpolationsmethoden nur geringe Unterschiede. So

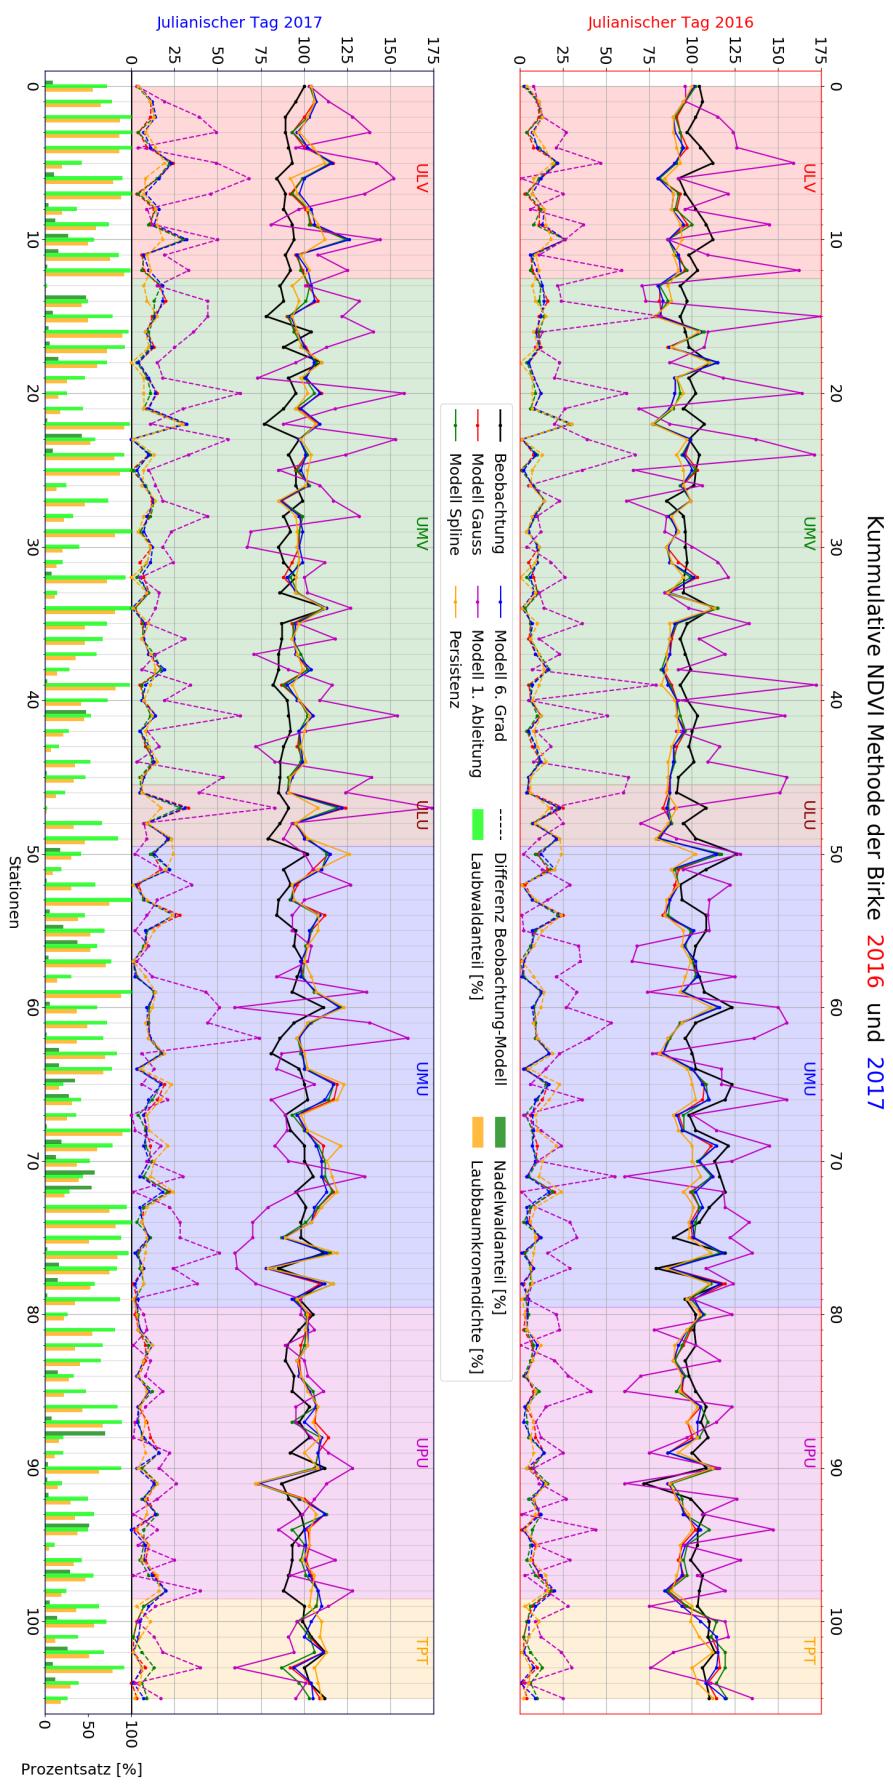


Abb. 4.1: Zeitliche Validierung mit Beobachtungen der Birke 2016 (oben) und 2017 (unten). In Schwarz sind die Bodenbeobachtungen, in Rot, Grün und Blau die kumulative NDVI-Methode mit den verschiedenen Interpolationsverfahren und in Pink die modifizierte Polyfit-Methode aufgetragen. Unterbrochene Linien zeigen die Differenzen der Beobachtungen zu den Schätzungen der jeweiligen Methode in der dazugehörigen Farbe. Hintergrundfarben entsprechen den Regionen in Abbildung 2.4. Darunter abgebildet sind die Werte für den Laubbaum-, den Nadelbaumanteil und der Laubbaumkronendichte des untersuchten, für die jeweilige Beobachtungsstation repräsentativen, MODIS-Pixels.

beträgt im Jahr 2016 die Differenz zu den Bodenbeobachtungen ca. 0 bis 25 Tage, 2017 bis etwa 30 Tage. Dabei ist kaum ein Unterschied in Abhängigkeit vom Laubwaldanteil (über und unter 80 %) in den Graphiken von Abbildung 4.3 zur erkennen. Ebenso gibt es nur geringe Unterschiede zwischen den Jahren 2016 und 2017 (Abbildung 4.4). Die Methode zeigt in beiden Laubwaldanteil-Klassen eine annähernd ähnliche Korrelation. Obwohl die Landnutzungsformen und somit der Laubwaldanteil über beide Jahre konstant bleiben sollte, zeigen beide Klassen für das Jahr 2016 höhere Korrelationskoeffizienten, weshalb der Mischpixeleffekt bei der zeitlichen Validierung wohl eine untergeordnete Rolle zu spielen scheint. Dennoch können in beiden Jahren Mischpixeleffekte zu einer allgemeinen Verringerung der Korrelationen beitragen, unabhängig vom Jahr.

Die Stationen zeigen 2016 in den Kacheln UMU und TPT, 2017 in den Kacheln ULV, ULU, UMU und UPU sogar eine bessere Korrelation als alle Stationen zusammen. Dies bestätigt auch die Abbildung 4.5, welche Streuplots von beobachteten gegen simulierten Eintrittstage der kumulativen NDVI-Methode mit der Interpolation mit einem Polynom 6. Grades aller bzw. der einzelnen Kacheln zeigt. Allerdings liegt die Korrelation der Kachel TPT 2016 knapp über dem Signifikanzniveau von 0.05, die der Regionen ULV und ULU 2017 deutlich darüber.

Untersucht man die erreichten NDVI-Summen zum beobachteten Eintrittstag der Blattentfaltung der Birke beider Jahre, so lässt sich zwar einen Unterschied in der Höhe der Summe der beiden Jahre erkennen, allerdings zeigt sich ein ähnlicher Verlauf, was sich wiederum in der Korrelation zwischen beiden Jahren widerspiegelt (siehe Abbildung 4.2). Dabei ist wiederum nur ein geringer Unterschied, zwischen den drei zeitlichen Interpolationsmethoden zu erkennen, allerdings zeigt die Interpolation via Kurvenannäherung mit einem Polynom 6. Grades hier und in den bisherigen Ergebnissen die höchste Korrelation.

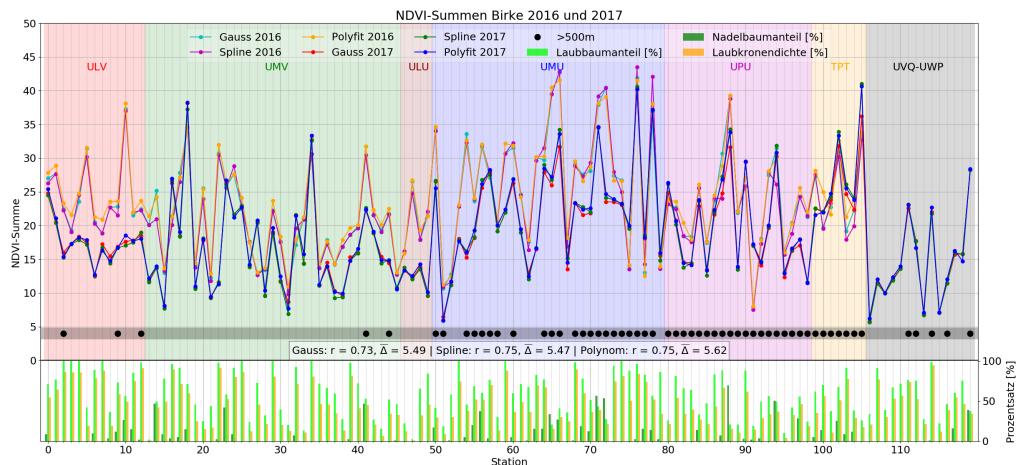


Abb. 4.2: Mit der kumulativen NDVI-Methode erhaltene NDVI-Summen der Birke beider Jahre. Die Farben unterscheiden die drei zeitlichen Interpolationsmethoden in beiden Jahren, wobei die helleren Farben für 2016 und die dunkleren für 2017 stehen. Angegeben sind die Korrelation zwischen den beiden Jahren und die mittlere Differenz. Hintergrundfarben entsprechen den Regionen in Abbildung 2.4. Darunter abgebildet sind die Werte für den Laubbaum-, den Nadelbaumanteil und der Laubbaumkronendichte des untersuchten, für die jeweilige Station repräsentative, MODIS-Pixels.

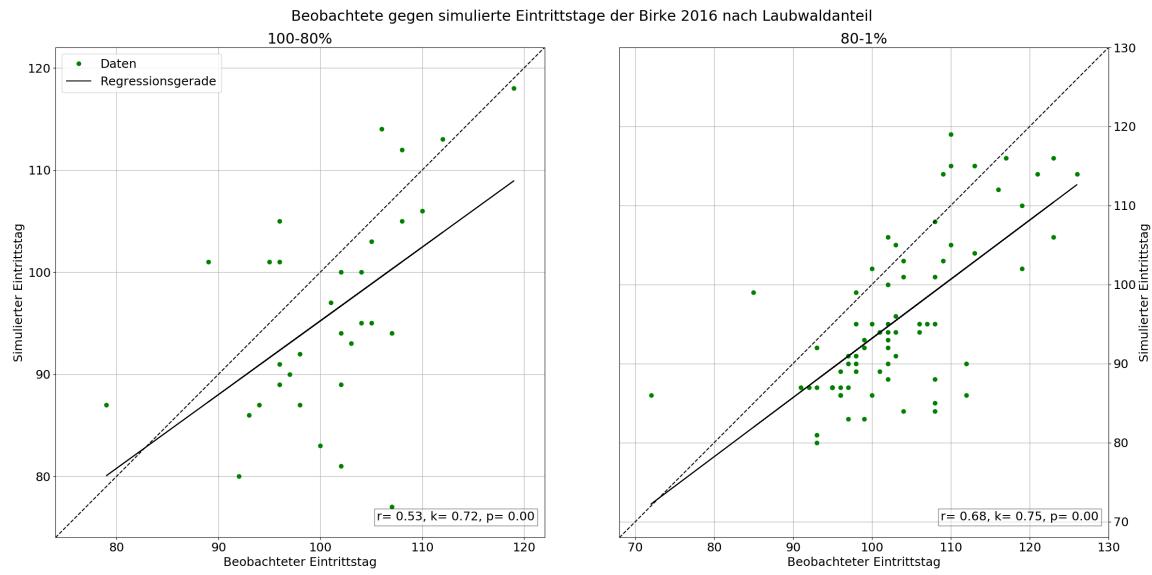


Abb. 4.3: Streuplots beobachtete gegen simulierte Eintrittstage des Laubaustriebs der Birke 2016 mit der Methode des kumulativen NDVI und der zeitlichen Interpolation mit einem Polynom 6. Grades unterschieden in zwei Klassen des Laubwaldanteils, über (links) und unter 80 % (rechts). Schwarze, durchgezogene Linien zeigen die tatsächlichen Regressionsgeraden. Gegebene Werte entsprechen dem Korrelationskoeffizienten und der Steigung der tatsächlichen Regressionsgeraden, sowie dem dazugehörigen p-Wert.

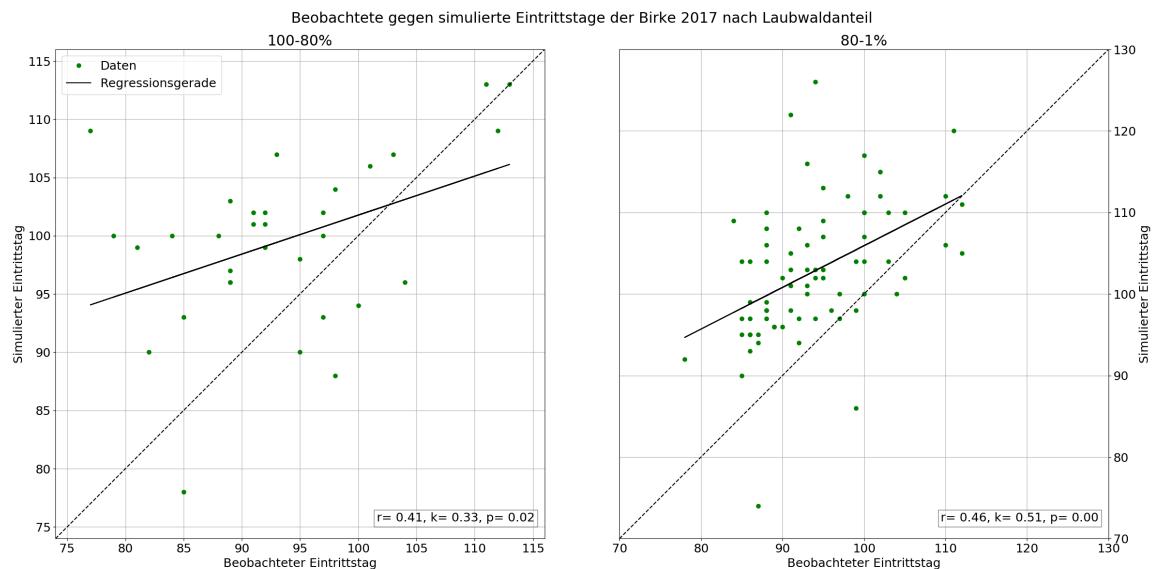
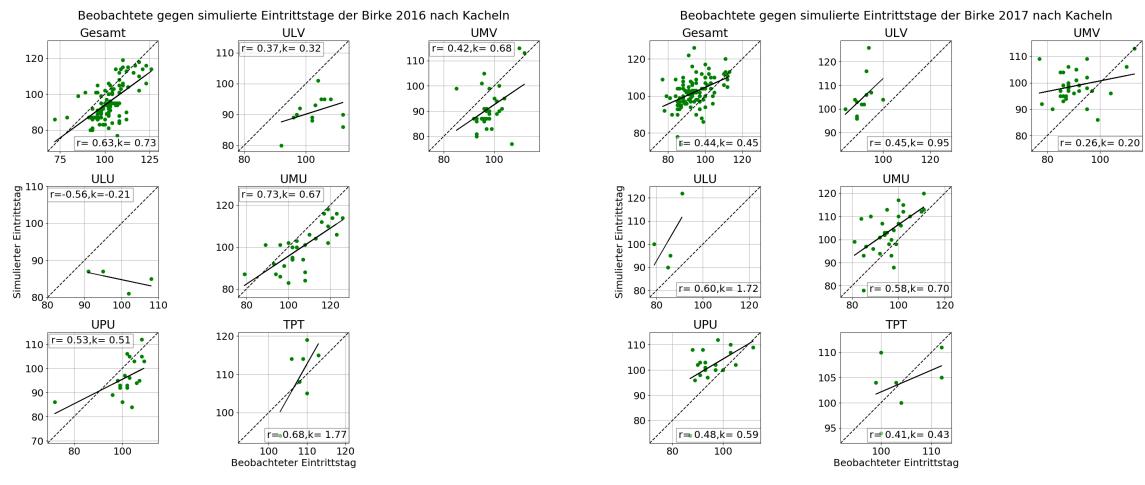


Abb. 4.4: Streuplots beobachtete gegen simulierte Eintrittstage des Laubaustriebs der Birke 2017 mit der Methode des kumulativen NDVI und der zeitlichen Interpolation mit einem Polynom 6. Grades unterschieden in zwei Klassen des Laubwaldanteils, über (links) und unter 80 % (rechts). Schwarze, durchgezogene Linien zeigen die tatsächlichen Regressionsgeraden. Gegebene Werte entsprechen dem Korrelationskoeffizienten und der Steigung der tatsächlichen Regressionsgeraden, sowie dem dazugehörigen p-Wert.



(a) Beobachtete gegen simulierte Eintrittstage der Birke 2016

(b) Beobachtete gegen simulierte Eintrittstage der Birke 2017

Abb. 4.5: Streuplots beobachtete gegen simulierte Eintrittstage des Laubaustriebs der Birke 2016 (a) und 2017 (b) bei der zeitlichen Validierung. Dabei wurde die Methode des kumulativen NDVI und die zeitliche Interpolation mit einem Polynom 6. Grades verwendet. Gezeigt werden sowohl alle Stationen (links oben), sowie die Stationen einzelner Kacheln. Sonstiger Aufbau wie Abbildung 4.4.

Tabelle 4.2: Ergebnis der zeitlichen Validierung der drei verwendeten Methoden im Fall der Buche. Bezuglich der Ergebnisse der kumulativen NDVI-Methode zeigt die obere Hälfte der Tabelle die Resultate mit dem Start der Summe des NDVI ab 4. Januar des jeweiligen Jahres, während die untere Hälfte der Aufsummierung ab 1. März entspricht. Fettgedruckte r Werte zeigen statistisch signifikante Korrelationen ( $p \leq 0.05$ ). Der Startzeitpunkt der kumulativen NDVI-Summe hat allerdings keinen Einfluss auf die 1. Ableitung des NDVI und die Persistenz, weshalb deren Maßzahlen oben wie unten identisch sind.

Jahr	Maß	Methode				
		Kumulativer NDVI			1. Ableitung Poly. 6. Grades	Persistenz
		Gaußkurve	Cubic Spline	Poly. 6. Grades		
2016	r	<b>0.39</b>	<b>0.37</b>	<b>0.39</b>	0.02	<b>0.47</b>
	$\bar{\Delta}$ [d]	13.29	13.18	13.38	28.14	8.91
	RMSE	17.68	17.51	17.76	34.59	11.27
2017	r	0.13	0.15	0.13	-0.01	<b>0.47</b>
	$\bar{\Delta}$ [d]	13.59	13.92	13.56	20.63	8.91
	RMSE	18.73	19.16	18.7	25.68	11.27

Bildung des kumulativen NDVI ab 1. März

2016	r	<b>0.49</b>	<b>0.5</b>	<b>0.5</b>	0.02	<b>0.47</b>
	$\bar{\Delta}$ [d]	10.13	10.34	10.25	28.14	8.91
	RMSE	13.11	13.18	13.15	34.59	11.27
2017	r	<b>0.23</b>	<b>0.19</b>	<b>0.25</b>	-0.01	<b>0.47</b>
	$\bar{\Delta}$ [d]	10.38	10.67	10.21	20.63	8.91
	RMSE	13.74	13.98	13.42	25.68	11.27

Betrachtet man den Fall der Blattentfaltung der Buche, so kann man in Tabelle 4.2 erkennen, dass die kumulative NDVI-Methode je nach zeitlicher Interpolationsmethode verglichen mit den Bodenbeobachtungen einen Korrelationskoeffizienten von  $r = 0.39$  bzw.  $r = 0.37$ , eine mittlere Differenz von etwa 14 Tagen und einen RMSE von ca. 18 für das Jahr 2016 aufweist. Für das Jahr 2017 liegt die Korrelation bei  $r = 0.13$  bzw. 0.15, die Differenz ebenfalls bei 14 Tagen und der RMSE um 19. Nach Verschiebung des Startpunktes der Summenbildung auf den 1. März zeigt die kumulative NDVI-Methode höhere und zudem signifikante Korrelationen in beiden Jahren. Der Korrelationskoeffizient steigt auf  $r = 0.49$  bzw. 0.5 im Jahr 2016, auf  $r = 0.23 / 0.19 / 0.25$  im Jahr 2017, in beiden Jahren reduziert sich die mittlere Differenz auf etwa 10-11 Tage und der RMSE auf 13-14. Somit scheint die Methode auch hier für das Jahr 2016 besser zu funktionieren als für 2017, allerdings werden niedrigere Korrelationen erreicht, als für die Laubaustriebsphase der Birke.

Die modifizierte Polyfit-Maximum Methode zeigt im Jahr 2016 eine nicht signifikante Korrelation mit den Bodenbeobachtungen von  $r = 0.02$ , eine mittlere Differenz von ungefähr 28 Tagen und einen RMSE von 35, für 2017 fällt die Korrelation auf  $r = -0.01$ , die mittlere Differenz zu den Beobachtungen beträgt 21 Tage und der RMSE 26. Auch in diesem Fall ist diese Methode für eine zeitliche Interpolation von Eintrittstagen genauso wenig geeignet, wie für die Bestimmung der Eintrittstage aus laufenden Messungen des NDVI via Satellit (real time).

Die Persistenz zeigt eine signifikante Korrelation von  $r = 0.47$ , eine mittlere Differenz von ca. 9 Tagen und einen RMSE von 11.27 in beiden Jahren. Im Gegensatz zum Laubaustrieb der Birke dürften sich die Phasen der Buche in den zwei Jahren stärker unterscheiden, denkbar wäre auch, dass Fehler in der Eingabe der Eintrittstage häufiger bzw. höher auftreten. Ebenfalls liegt die Korrelation der kumulativen NDVI-Methode vor dem Verschieben des Startpunktes für die Jahre 2016 und 2017 unter der Persistenz, durch die Verschiebung auf 1. März im Jahr 2016 knapp darüber.

In Abbildung 4.6 sind die beschriebenen Methoden im Vergleich zu den Bodenbeobachtungen in beiden Jahren zu sehen. Die kumulative NDVI-Methode zeigt unter den drei zeitlichen Interpolationsmethoden auch im Fall der Buche nur einen geringen Unterschied. Im Jahr 2016 liegt die Differenzen zu den Bodenbeobachtungen bei ca. 0 bis 30 Tagen, 2017 bis etwa 40 Tagen. Im Gegensatz zur Birke ist ein Unterschied nach hohen oder niedrigen Anteilen von Laubwald (über und unter 80 %) in Abbildung 4.8 für das Jahr 2016 zu erkennen. Die kumulative NDVI-Methode funktioniert bei hohen Laubwaldanteil besser als bei niedrigen. Dies gilt nicht nur für das Jahr 2016, sondern auch für 2017, da der Laubwaldanteil über beide Jahre konstant bleiben sollte. Allerdings kann bei einem Anteil von 80-100 % Laubwaldanteil eine deutlich höhere Korrelation erreicht werden als ohne Differenzierung (2016:  $r = 0.7$ ; 2017:  $r = 0.44$ ). Interessanterweise zeigen die simulierten Eintrittstage anders als bei einer Validierung von Modellen erwartet, eine größere Breite als die beobachteten. Die Stationen zeigen 2016 und 2017 in der Kachel UMU eine signifikant bessere Korrelation als alle Stationen zusammen. Auch in der Kachel ULV ist 2017 eine höhere Korrelation zu erkennen, diese ist jedoch nicht signifikant. Dies bestätigt wiederum die Abbildung 4.9, die Streuplots beobachteter gegen simulierter Eintrittstage der kumulativen NDVI-Methode mit der Interpolation mit einem Polynom 6. Grades aller bzw. der einzelnen Kacheln zeigt.

Betrachtet man die erreichten NDVI-Summen zum beobachteten Eintrittstag der Blattentfaltung der Buche in Abbildung 4.7, so erkennt man auch hier einen Unterschied in der Höhe der Summe der beiden Jahre, die Korrelation beträgt aber immer noch  $r = 0.57 - 0.6$ . Auch bei der Buche zeigt die Interpolation via Kurvenannäherung mit einem Polynom 6. Grades die höchsten Korrelationen.

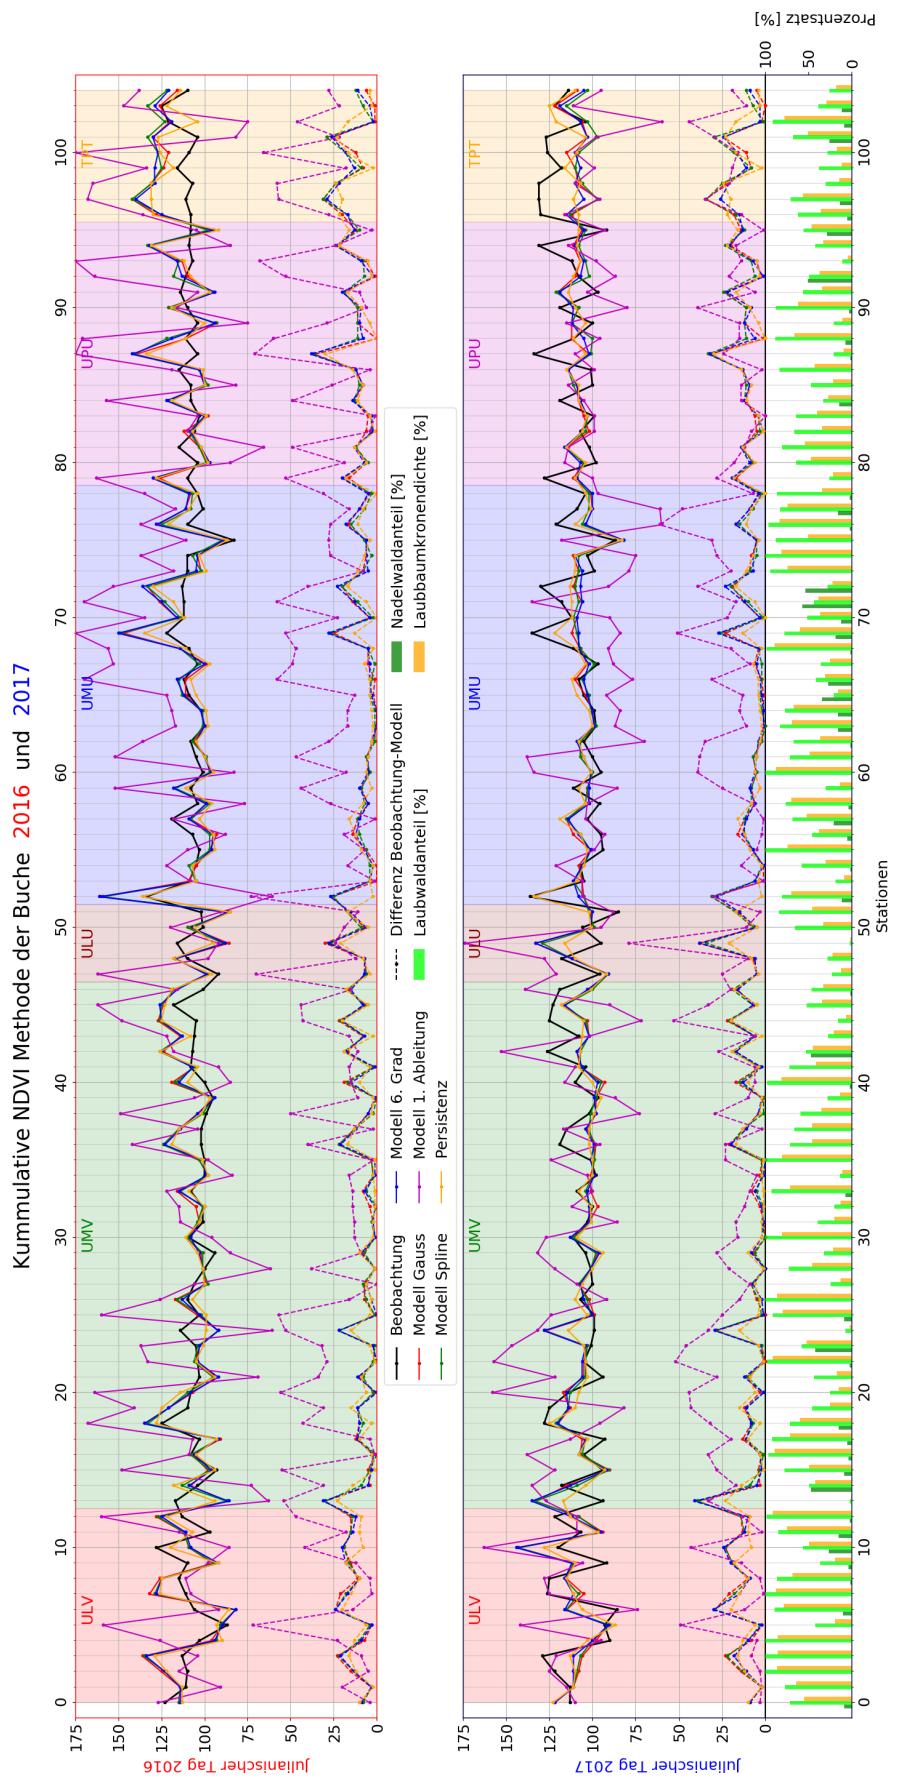


Abb. 4.6: Zeitliche Validierung mit Beobachtungen der Buche 2016 (oben) und 2017 (unten). In Schwarz sind die Bodenbeobachtungen, in Rot, Grün und Blau die kumulative NDVI-Methode mit den verschiedenen zeitlichen Interpolationsverfahren und in Pink die modifizierte Polyfit-Maximum-Methode aufgetragen. Unterbrochene Linien zeigen die Differenzen der Beobachtungen zu den Schätzungen der jeweiligen Methode in der dazugehörigen Farbe. Hintergrundfarben entsprechen den Regionen in Abbildung 2.4. Darunter abgebildet sind die Werte für den Laubbaum-, den Nadelbaum- und der Laubbaumkronendichte des untersuchten, für die jeweilige Station repräsentative, MODIS-Pixels.

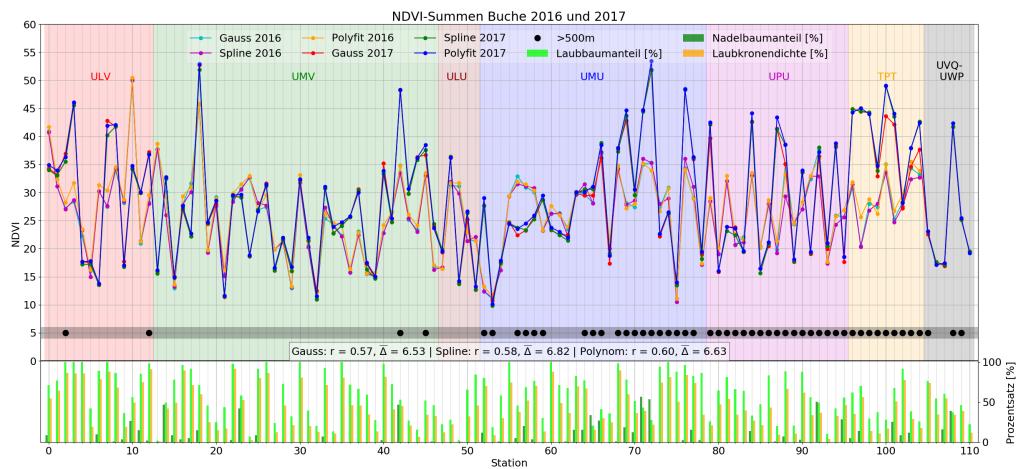


Abb. 4.7: Mit der kumulativen NDVI-Methode erhaltene NDVI-Summen der Buche beider Jahre. Die Farben unterscheiden die drei zeitlichen Interpolationsmethoden in beiden Jahren, wobei die helleren Farben für 2016 und die dunkleren für 2017 stehen. Zahlenwerte in der Mitte der Abbildung entsprechen der räumlichen Korrelation zwischen den beiden Jahren und der mittleren Differenz. Hintergrundfarben entsprechen den Regionen in Abbildung 2.4. Darunter abgebildet sind die Werte für den Laubbaum-, den Nadelbaumanteil und der Laubbaumkronendichte des untersuchten, für die jeweilige Station repräsentative, MODIS-Pixels.

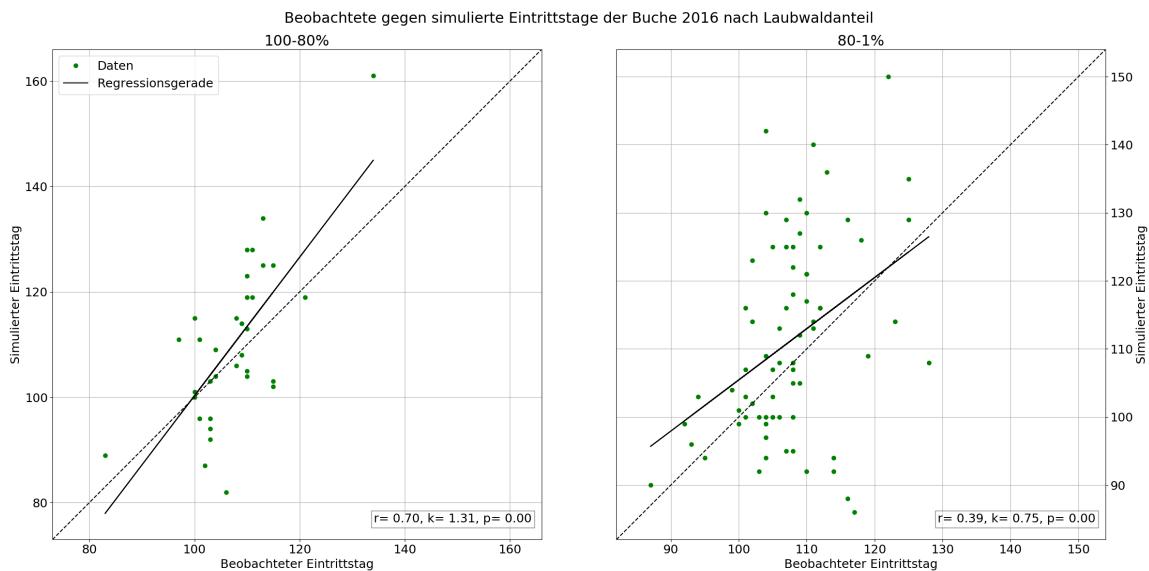
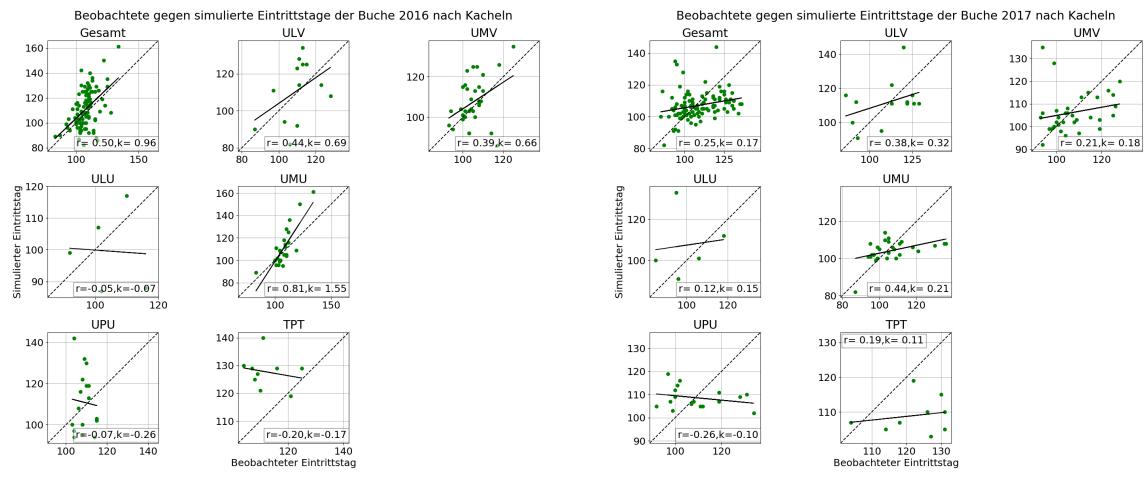


Abb. 4.8: Streuplots beobachtete gegen simulierte Eintrittstage des Laubauabtriebs der Buche 2016 mit der Methode des kumulativen NDVI und der zeitlichen Interpolation mit einem Polynom 6. Grades unterschieden in zwei Klassen des Laubwaldanteils, über (links) und unter 80 % (rechts). Schwarze, durchgezogene Linien zeigen die tatsächlichen Regressionsgeraden. Gegebene Werte entsprechen dem Korrelationskoeffizienten und der Steigung der tatsächlichen Regressionsgeraden, sowie dem dazugehörigen p-Wert.



(a) Beobachtete gegen simulierte Eintrittstage  
der Buche 2016

(b) Beobachtete gegen simulierte Eintrittstage  
der Buche 2017

Abb. 4.9: Streuplots beobachteter gegen simulierter Eintrittstage des Laubaustriebs der Buche 2016 (a) und 2017 (b) bei zeitlicher Validierung. Dabei wurde die Methode des kumulativen NDVI und der Interpolation mit einem Polynom 6. Grades verwendet. Gezeigt werden sowohl alle Stationen (links oben), sowie die Stationen einzelner Kacheln. Sonstiger Aufbau wie Abbildung 4.4.

Beim Laubaustrieb sowohl der Birke, als auch der Buche zeigt die Methode des kumulativen NDVI für die Simulation der Eintrittstage von 2017 für 2016 die höhere Korrelation als die von 2016 für 2017, wobei sie im Fall der Birke bessere Ergebnisse liefert.

## 4.2 Räumliche Validierung der Methodik

Im vorherigen Abschnitt konnte gezeigt werden, dass die kumulative NDVI-Methode teilweise leistungsstärker als eine Persistenz und auch robuster ist als die Verknüpfung der Polyfit-Maximum Methode mit den phänologischen Bodenbeobachtungen. Nun wird dieselbe Methode in einer Kreuzvalidierung untersucht, um eine räumliche Korrelation zwischen GP und LSP herzustellen und zu bewerten. Zusätzlich werden etablierte Methoden des LSP-Ansatzes betrachtet, welche nicht exakt dieselben phänologischen Ereignisse beobachten wie der GP-Ansatz (Rodriguez-Galiano et al., 2015). Im Grunde wird nicht explizit der Blattaustrieb der Birke und Buche, sondern die SOS des jeweiligen Pixels, errechnet. Damit soll gezeigt werden, dass diese, wie in Abschnitt 1.3 bereits erwähnt, üblicherweise eine schwache Korrelation zu den Bodenbeobachtungen aufweisen.

Abbildung 4.10 zeigt den Vergleich zwischen den verschiedenen Ansätzen:

1. das arithmetisches Mittel der kumulativen NDVI-Summen der nicht ausgelassenen Stationen, mit dem an der ausgelassenen Station detektiert wird, an welchem Tag diese Summe erreicht wird. Diese entspricht dann dem Eintrittstag
2. ein einfaches lineares Regressionsmodell, bei der die NDVI-Summe aus der allgemeinen Höhenregression über alle übrigen Stationen berechnet und damit wie vorher das Eintrittsdatum bestimmt wird
3. ein multiples lineares Regressionsmodell (MLRM), das im Weiteren genauer beschrieben wird
4. die etablierten Methoden

Dabei wurde wieder die NDVI-Summe ab dem 1. März gebildet. Außerdem ist deren Differenz zu den Bodenbeobachtungen für die Beobachtungen der Birke im Jahr 2016 eingezeichnet. Zusätzlich wird erneut der Anteil an Laub- und Nadelbäumen sowie die Baumkronendichte des jeweiligen, für die Station repräsentativen MODIS-Pixels in Prozent abgebildet. Tabelle 4.3 zeigt die Ergebnisse mit der zeitlichen Interpolationsmethode einer Kurvenannäherung mit Polynom 6. Grades. Diese erreicht, wie bei der zeitlichen Validierung, die höchsten Korrelationen. Im Weiteren sind die Ergebnisse für die Summenbildung ab 4. Januar ersichtlich, welche wiederum höhere Korrelationen zeigen, wenn am 1. März gestartet wird. Dabei erreicht ein einfaches arithmetisches Mittel im Jahr 2016 eine schwache negative Korrelationen ( $r = -0.05$ ), das lineare Regressionsmodell schon eine Korrelation von  $r = 0.21$  und das multiple lineare Regressionsmodell  $r = 0.41$ . Allerdings zeigt sich nun eine stärkere Höhenabhängigkeit. Auch die mittlere Differenz sinkt von ca. 10 Tagen mit dem arithmetischen Mittel auf 7.6 Tage mit dem MLRM. Die etablierten Methoden zur Bestimmung des SOS zeigen wie bereits erwartet schwächere Korrelationen mit den Bodenbeobachtungen, der Korrelationskoeffizient liegt zwischen  $r = -0.3$  und  $r = -0.14$ , die mittlere Differenz zwischen 17 und 28 Tagen und der RMSE zwischen 23 und 37. Für das Jahr 2017 sinkt die Korrelation der verwendeten Methoden ebenfalls wie bei der zeitlichen Validierung. Während das arithmetische Mittel nun einen negativen Korrelationskoeffizienten von  $r = -0.31$  aufweist, sinkt die Korrelation des linearen Regressionsmodells auf  $r = 0.11$  und des MLRM auf  $r = 0.25$ . Mittlere Differenz und RMSE bleiben dagegen annähernd unverändert.

Tabelle 4.3: Verschiedene Maße, die in der räumlichen Validierung verwendeten Methoden, im Fall der Birke. Als zeitliche Interpolationsmethode für den kumulativen NDVI wurde eine Kurvenannäherung mit Polynom 6. Grades verwendet. Beziiglich der Ergebnisse der kumulativen NDVI-Methode zeigt die obere Hälfte der Tabelle die Resultate mit dem Start der Summe des NDVI ab 4. Januar des jeweiligen Jahres, während die untere Hälfte der Aufsummierung ab 1. März entspricht. Fettgedruckte r Werte zeigen statistisch signifikante Korrelationen ( $p \leq 0.05$ ). Der Startzeitpunkt der kumulativen NDVI-Summe hat allerdings keinen Einfluss auf die LSP-Methoden, weshalb die Maßzahlen oben und unten identisch sind.

Jahr	Maß	Methode					
		Kumulativer NDVI			LSP		
		Mittel	Lin. Reg.	MLRM	Gaussian-Midp.	Spline-Midp.	Polyfit-Max.
2016	r	0.08	0.1	<b>0.26</b>	<b>-0.3</b>	-0.14	<b>-0.2</b>
	$\bar{\Delta}$ [d]	16.54	16.76	12.0	17.97	17.22	27.53
	RMSE	22.15	22.23	16.07	23.19	24.63	36.59
2017	r	<b>-0.19</b>	-0.04	0.1	-0.05	0.07	<b>-0.22</b>
	$\bar{\Delta}$ [d]	19.15	18.52	11.98	17.03	20.14	27.51
	RMSE	25.84	24.56	15.44	22.86	26.74	30.51
Bildung des kumulativen NDVI ab 1. März							
2016	r	-0.05	<b>0.21</b>	<b>0.41</b>	<b>-0.3</b>	-0.14	<b>-0.2</b>
	$\bar{\Delta}$ [d]	10.05	9.36	7.59	17.97	17.22	27.53
	RMSE	13.13	12.06	9.64	23.19	24.63	36.59
2017	r	<b>-0.31</b>	0.11	<b>0.25</b>	-0.05	0.07	<b>-0.22</b>
	$\bar{\Delta}$ [d]	10.85	8.68	7.08	17.03	20.14	27.51
	RMSE	14.15	11.72	9.21	22.86	26.74	30.51

Das leistungsstärkste multiple lineare Regressionsmodell wurde anhand eines Vergleichs von Modellen mit unterschiedlichen Prädiktoren bestimmt (in Abbildung 4.11 dargestellt). Dabei wurde die NDVI-Summe der nicht ausgelassenen Stationen in Abhängigkeit zu den verschiedenen Parameter der MODIS-Pixel gesetzt, die Koeffizienten der MLRM bestimmt, die Parameter an der ausgelassenen Station eingesetzt und damit deren NDVI-Summe berechnet. Anhand des NDVI-Verlaufes der ausgelassenen Station wird wieder der Tag bestimmt, an dem diese Summe erreicht ist. Die NDVI-Summe wird dabei als lineare Kombination aus Höhe, Länge, Breite, Laubbaum- und Nadelbaumanteil sowie Baumkronendichte in verschiedenen Variationen gebildet. Formal dargestellt ergibt sich für die MLRM mit allen Parametern:

$$\Sigma NDVI_R = a_0 + a_1 \cdot h_R + a_2 \cdot \lambda_R + a_3 \cdot \phi_R + a_4 \cdot LWA_R + a_5 \cdot NWA_R + a_6 \cdot TCD_R \quad (4.1)$$

Dabei bedeuten  $\Sigma NDVI_R$  die kumulative NDVI-Summe,  $h_R$  die Höhe,  $\lambda_R$  die Länge,  $\phi_R$  die Breite,  $LWA_R$  den Laubwald-,  $NWA_R$  den Nadelwaldanteil und  $TCD_R$  die Laubbaumkronendichte aller anderen Stationen.  $a_0$  bis  $a_6$  sind die zu schätzenden Regressionsparameter.

Mit den geschätzten Regressionsparametern kann nun eine kumulative NDVI-Summe für die ausgelassene Station gebildet werden:

$$\Sigma NDVI_O = a_0 + a_1 \cdot h_O + a_2 \cdot \lambda_O + a_3 \cdot \phi_O + a_4 \cdot LWA_O + a_5 \cdot NWA_O + a_6 \cdot TCD_O \quad (4.2)$$

Darin sind wieder dieselben Größen wie in Gleichung 4.1 verwendet worden, allerdings von der ausgelassenen Station, wofür der Index  $O$  steht.

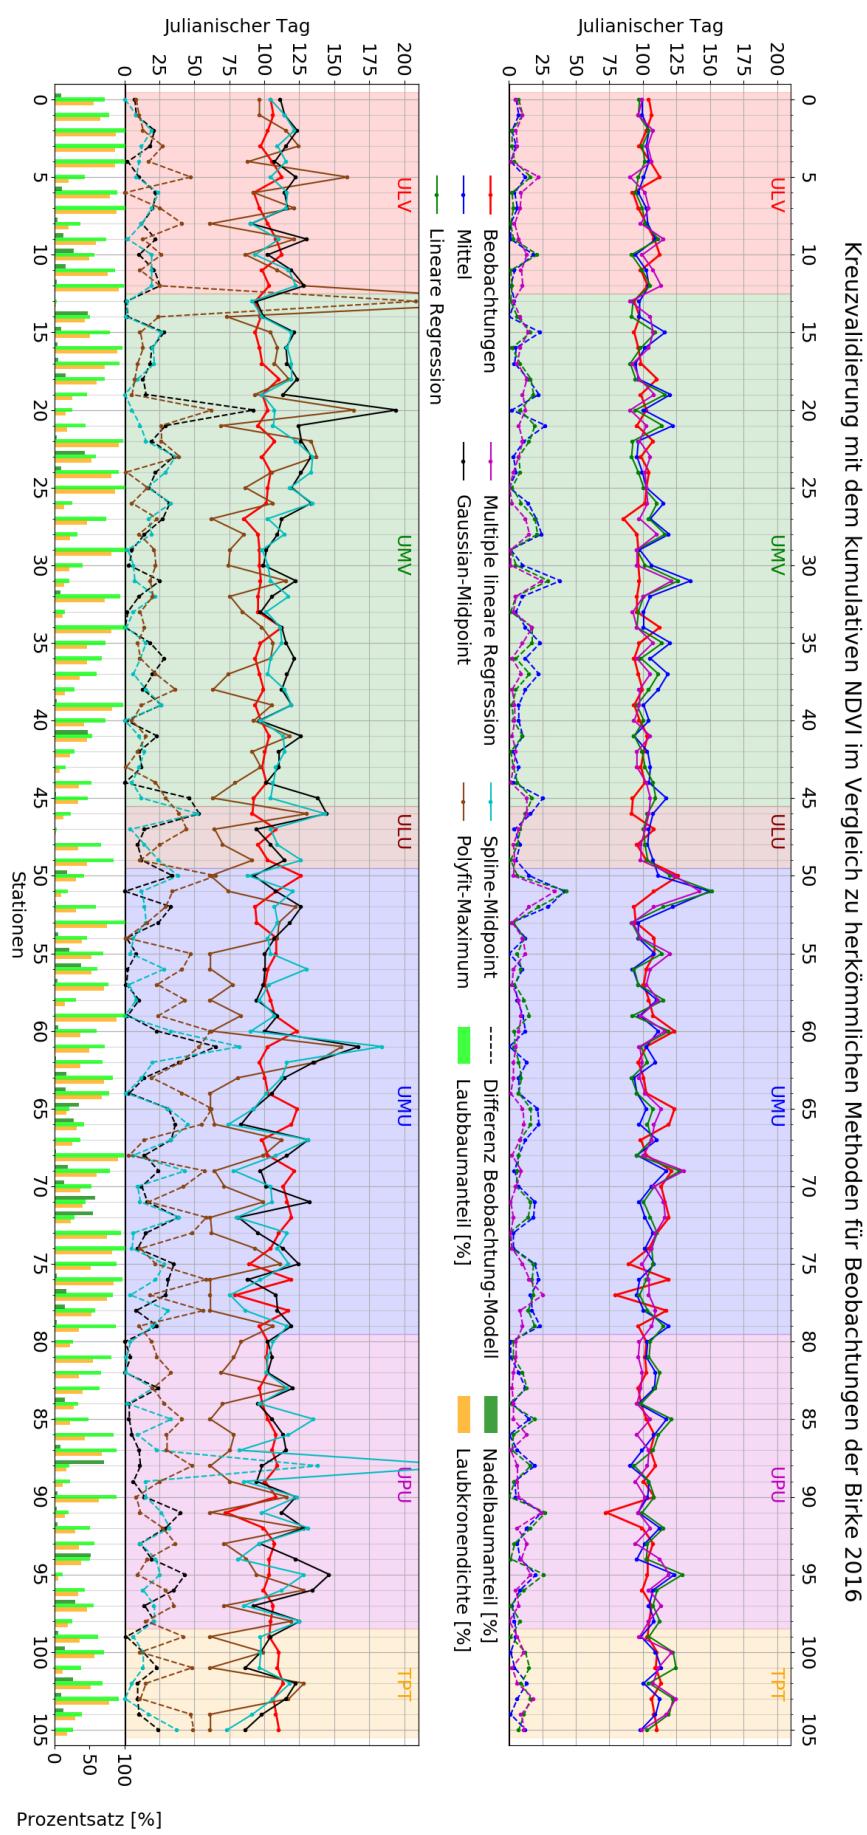


Abb. 4.10: Räumliche Validierung mit Beobachtungen der Birke 2016. Oben sind verschiedene Methoden abgebildet, um mittels kumulative NDVI-Methode eine räumliche Korrelation zwischen LSP und GP herzustellen. Darunter sind die drei etablierten Methoden zur Bestimmung des SOS dargestellt. In Rot sind die Bodenbeobachtungen, in Pink, Grün und Blau die kumulative NDVI-Methode mit den verschiedenen Verfahren zur räumlichen Interpolation, in Schwarz die Gaussian-, in Türkis die Spline-Midpoint- und in Braun die Polyfit-Methode aufgetragen. Die NDVI-Summe wurde ab dem 1. März gebildet. Unterbrochene Linien zeigen die Differenzen der Beobachtungen zu den Schätzungen der jeweiligen Methode in der dazugehörigen Farbe. Hintergrundfarben entsprechen den Regionen in Abbildung 2.4. Darunter abgebildet sind die Werte für den Laubbaum-, den Nadelbaumanteil und der Laubbaumkronendichte des untersuchten, für die jeweilige Beobachtungsstation repräsentativen, MODIS-Pixels.

Tabelle 4.4: Vergleich multipler linearer Regressionsmodelle in der räumlichen Validierung im Fall der Birke. LA steht für Laubwald-, NA für Nadelwaldanteil und TCD für Laubbaumkronendichte. Als zeitliche Interpolationsmethode für den kumulativen NDVI wurde eine Kurvenannäherung mit Polynom 6. Grades verwendet. Fettgedruckte r Werte zeigen statistisch signifikante Korrelationen ( $p \leq 0.05$ ).

(a) 2016			(b) 2017		
Parameter und Gütemaße			Parameter und Gütemaße		
r	$\bar{\Delta}$	RMSE	r	$\bar{\Delta}$	RMSE
Höhe, Länge, Breite					
<b>0.30</b>	9.18	11.54	0.13	8.36	11.17
Höhe, Länge, Breite, LA, NA, TCD					
<b>0.41</b>	7.59	9.64	<b>0.25</b>	7.08	9.21
Höhe, Länge, Breite, TCD					
<b>0.3</b>	9.07	11.24	<b>0.20</b>	7.58	9.92
Höhe, Länge, Breite, LA, TCD					
<b>0.34</b>	8.09	10.62	<b>0.20</b>	7.48	9.89
Höhe, Länge, Breite, LA					
<b>0.29</b>	9.27	11.57	<b>0.18</b>	7.93	10.35
Höhe, Länge, Breite, NA, TCD					
<b>0.41</b>	7.84	9.82	<b>0.27</b>	6.87	9.16
Höhe, Länge, Breite, NA					
<b>0.39</b>	8.03	10.27	0.16	7.88	10.54
Höhe, Länge, Breite, LA, NA					
<b>0.38</b>	8.09	10.15	<b>0.25</b>	7.1	9.4
LA, NA, TCD					
<b>0.22</b>	7.96	10.3	-0.16	8.57	11.28
Tag = Höhe, Länge, Breite					
<b>0.61</b>	4.92	6.88	<b>0.56</b>	4.75	6.31

Daraus kann dann der Eintrittstag bestimmt werden:

$$\Sigma NDVI_O - \sum_{i=0}^t NDVI_{O_i} = \min \quad (4.3)$$

Wobei  $\Sigma NDVI_O$  wieder die kumulative NDVI-Summe,  $NDVI_{O_i}$  der NDVI zum Zeitpunkt  $i$  der ausgelassenen Station und  $t$  der gesuchte Zeitpunkt ist, an dem die Gleichung erfüllt wird. Dieser Zeitpunkt  $t$  entspricht dem Eintrittstag.

Tabelle 4.4 zeigt dabei die Korrelationskoeffizienten, die mittlere Differenz zu den Bodenbeobachtungen und den RMSE beider Jahre für die multiplen linearen Regressionsmodelle mit verschiedenen Parametern. Setzt man etwa als Prädiktoren die geographischen Standortparameter (Höhe, Länge, Breite) des beobachteten Pixels, wird bereits im Jahr 2016 eine Korrelation von  $r = 0.3$  erreicht, wobei die Höhe einen großen Anteil an der erklärten Varianz hat. Dies deckt sich mit dem Ergebnis der linearen Regression, bei welcher rein die Höhe als Prädiktor verwendet wird. Im Jahr 2017 geht dieser Einfluss ein wenig zurück, hier wird ein Korrelationskoeffizient von  $r = 0.13$  erreicht, das Ergebnis ist jedoch nicht signifikant ( $p = 0.16$ ). Werden jene Parameter, welche den Mischpixeleffekt beschreiben, also Laubwald-, Nadelwaldanteil und Baumkronendichte, als Prädiktoren eingesetzt, so erhält man  $r = 0.22$  für 2016 und  $r = -0.16$

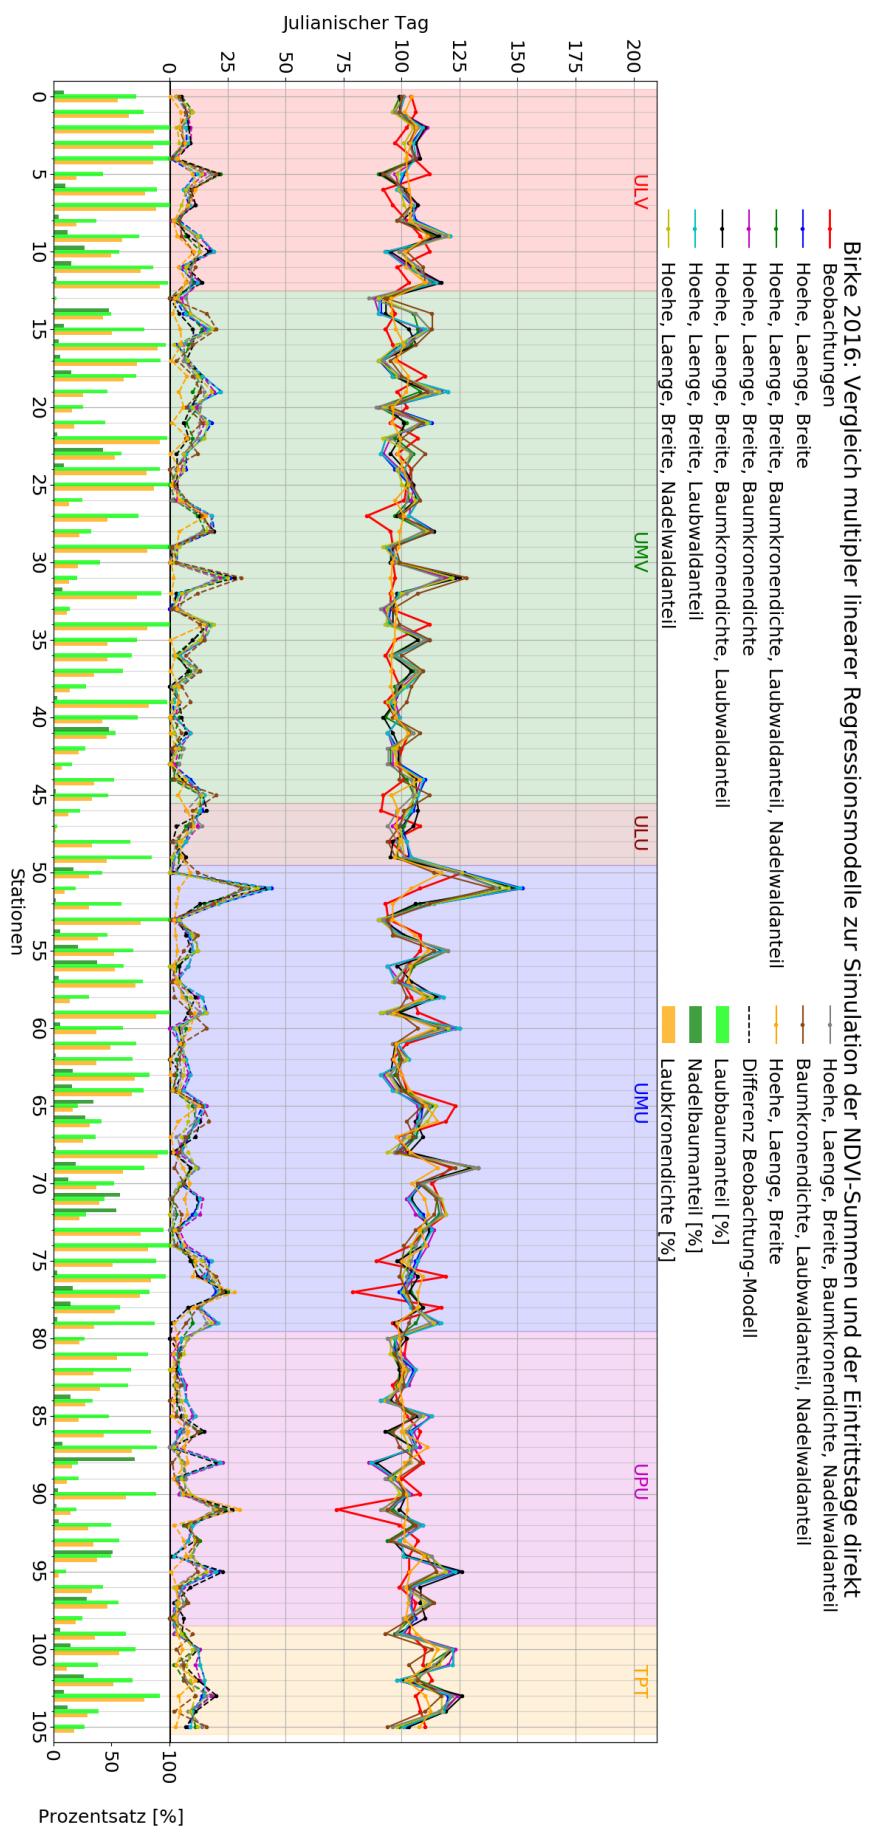


Abb. 4.11: Räumliche Validierung mit dem Vergleich multipler linearer Regressionsmodelle mit verschiedenen Parametern als Prädiktoren (abzulesen in der Legende) zur Simulation der Eintrittstage des Laubbaustriebs der Birke an den Beobachtungspunkten im Vergleich zu den Beobachtungen 2016. Unterbrochene Linien zeigen die Differenzen der Beobachtungen zu den Schätzungen der jeweiligen Methode in der dazugehörigen Farbe. Hintergrundfarben entsprechen den Regionen in Abbildung 2.4. Darunter abgebildet sind die Werte für den Laubbaum-, den Nadelbaumanteil und der Laubbaumkronendichte des untersuchten, für die jeweilige Beobachtungsstation repräsentativen, MODIS-Pixels.

für 2017. Es zeigt sich, dass der Mischpixeleffekt ebenfalls einen Einfluss auf die räumliche Korrelation zwischen LSP und GP hat. Die stärkste Korrelation wird erreicht, wenn sowohl die geographischen Standortparameter als auch Parameter, die den Mischpixeleffekt beschreiben, kombiniert werden. Hierbei werden Höhe, Länge, Breite, Laubwald-, Nadelwaldanteil und Laubbaumkronendichte als Parameter eingesetzt. Dabei wird eine signifikante Korrelation von  $r = 0.41$  für 2016 und  $r = 0.25$  für 2017 erreicht, wobei der Nadelbaumanteil am meisten, der Laubwaldanteil deutlich weniger Anteil an der erklärten Varianz hat. Wird der Laubwaldanteil bei der Birke bei der Berechnung für 2017 ausgeschlossen, so steigt die Korrelation auf  $r = 0.27$ . Da dies als spezifischer Fall angesehen werden kann, zeigt sich, dass das MLRM mit allen Parametern das geeignete Modell darstellt. Die stärkste Korrelation wird erreicht, wenn rein die Informationen der GP verwendet werden und der Eintrittstag der Laubentfaltung direkt als lineare Kombination aus Höhe, Länge und Breite der Beobachtung bildet wird. Dabei wird eine signifikante Korrelation von  $r = 0.61$  für 2016 und  $r = 0.56$  für 2017 erreicht. Die einzelnen Gebiete unterscheiden sich ebenfalls bei der räumlichen Validierung in ihrer Korrelation zwischen den mit dem besten MLRM simulierten und den beobachteten Eintrittstagen des Laubaustriebs der Birke. In Abbildung 4.12 sind in Streuplots die verschiedenen Kacheln dargestellt. Im Jahr 2016 zeigt z.B. die Region, die der Kachel UMU entspricht, eine signifikant höhere Korrelation ( $r = 0.53$ ) als das gesamte Untersuchungsgebiet, 2017 hat die Kachel ULU eine deutlich höhere Korrelation ( $r = 0.7$ ), allerdings keine statistisch signifikante.

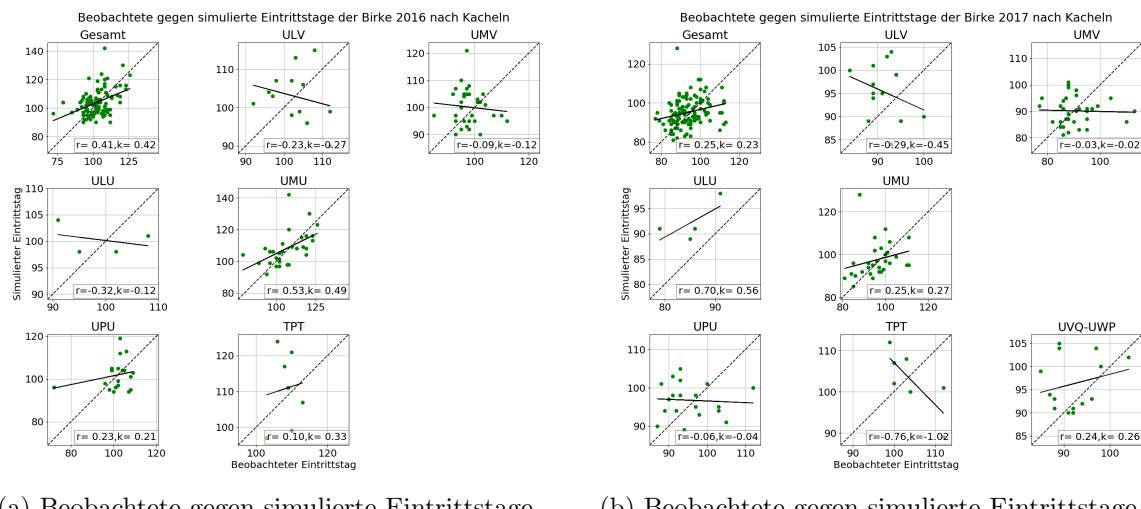


Abb. 4.12: Streuplots von beobachteten gegen simulierten Eintrittstagen des Laubaustriebs der Birke 2016 (a) und 2017 (b) mit der Methode des kumulativen NDVI, der zeitlichen Interpolation mit einem Polynom 6. Grades und der räumlichen Interpolation mit dem geeigneten multiplen linearen Regressionsmodell. Gezeigt werden sowohl alle Stationen (links oben), sowie die Stationen einzelner Kacheln. Schwarze, durchgezogene Linien zeigen die tatsächlichen Regressionsgeraden. Gegebene Werte entsprechen dem Korrelationskoeffizienten und der Steigung der tatsächlichen Regressionsgeraden.

Anschließend werden die Ergebnisse des Laubaustriebs der Buche näher beschrieben. In Tabelle 4.6 sind die Gütemaße der unterschiedlichen verwendeten Methoden zur Bildung einer räumlichen Korrelation zwischen GP und LSP für die Jahre 2016 & 2017 aufgelistet und in Abbildung 4.13 grafisch dargestellt. Die obere Hälfte der Tabelle zeigt die Ergebnisse für den Start der NDVI-Summenbildung am 4. Januar, die untere Hälfte am 1. März. Ebenso können die Korrelationen durch ein Verschieben des Startzeitpunktes verbessert werden, weshalb nun-

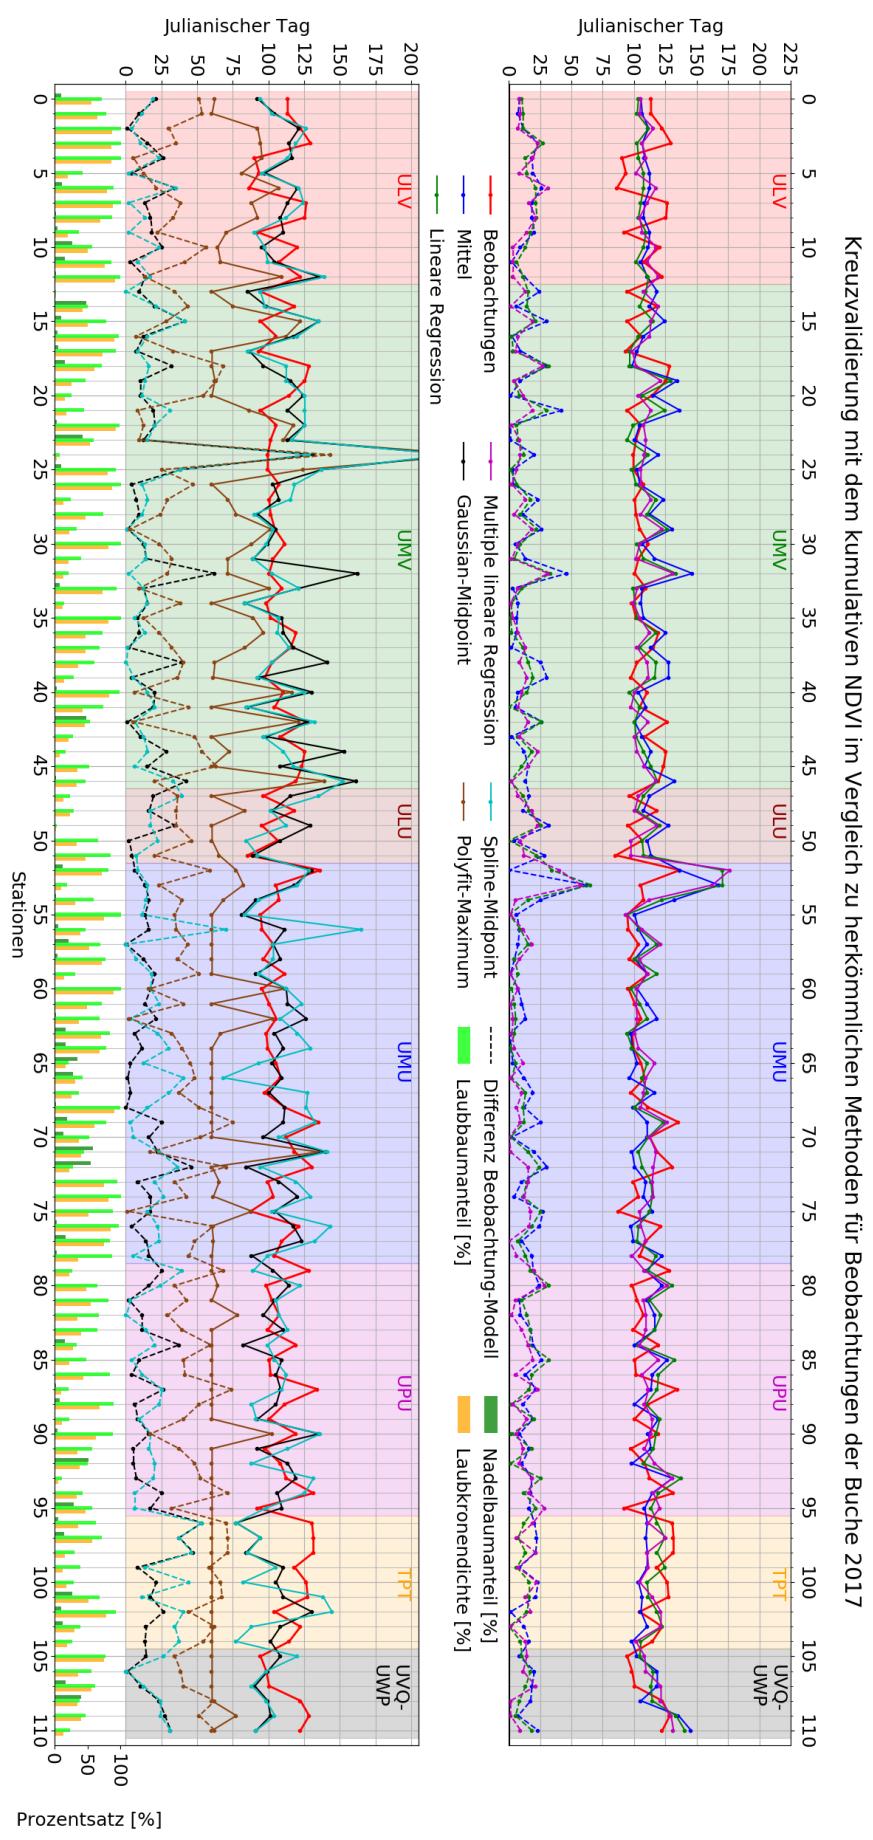


Abb. 4.13: Räumliche Validierung mit den Beobachtungen der Buche 2016. Oben sind verschiedene Methoden abgebildet, um mittels kumulativer NDVI-Methode eine räumliche Korrelation zwischen LSP und GP herzustellen. Darunter sind die drei etablierten Methoden zur Bestimmung des SOS dargestellt. In Rot sind die Bodenbeobachtungen, in Pink, Grün und Blau die kumulative NDVI-Methode mit den verschiedenen Verfahren zur räumlichen Interpolation, in Schwarz die Gaussian-, in Türkis die Spline-Midpoint- und in Braun die Polyfit-Methode aufgetragen. Die NDVI-Summe wurde ab dem 1. März gebildet. Unterbrochene Linien zeigen die Differenzen der Beobachtungen zu den Schätzungen der jeweiligen Methode in der dazugehörigen Farbe. Hintergrundfarben entsprechen den Regionen in Abbildung 2.4. Darunter abgebildet sind die Werte für den Laubbaum-, den Nadelbaumanteil und der Laubbaumkronendichte des untersuchten, für die jeweilige Beobachtungsstation repräsentativen, MODIS-Pixels.

mehr auf die untere Hälfte der Tabelle eingegangen wird. Ähnlich wie bei der Birke zeigt ein Flächenmittel der NDVI-Summen eine schwache Korrelation zu den Bodenbeobachtungen in beiden Jahren. Ein lineares Regressionsmodell mit der Höhe als Prädiktor erreicht  $r = 0.12$  und  $r = 0.2$  und ein multiples lineares Regressionsmodell erzielt eine Korrelation von  $r = 0.23$  und  $r = 0.28$  in beiden Jahren. Wiederum kann bei den etablierten Methoden (Gaussian-, Spline-Midpoint- und Polyfit-Maximum-Methode) ein schwacher räumlicher Zusammenhang zu den Bodenbeobachtungen hergestellt werden. Der Korrelationskoeffizient liegt im Jahr 2017 bei allen drei Methoden nahe an Null, im Jahr 2016 zwischen -0.23 und -0.11 je nach Methode. Somit konnten die bisherigen Ergebnisse in der Literatur in Abschnitt 1.3, dass nur eine spärliche Korrelation zwischen GP und LSP vorhanden ist, auch für den Blattaustrieb der Buche bestätigt werden.

Tabelle 4.6: Verschiedene Maße der in der räumlichen Validierung verwendeten Methoden im Fall der Buche. Als zeitliche Interpolationsmethode für den kumulativen NDVI wurde eine Kurvenannäherung mit Polynom 6. Grades verwendet. Bezüglich der Ergebnisse der kumulativen NDVI-Methode zeigt die obere Hälfte der Tabelle die Resultate mit dem Start der Summe des NDVI ab 4. Januar des jeweiligen Jahres, während die untere Hälfte der Aufsummierung ab 1. März entspricht. Fettgedruckte r Werte zeigen statistisch signifikante Korrelationen ( $p \leq 0.05$ ). Der Startzeitpunkt der kumulativen NDVI-Summe hat allerdings keinen Einfluss auf die LSP-Methoden, weshalb die Maßzahlen oben und unten identisch sind.

Jahr	Maß	Methode					
		Kumulativer NDVI			LSP		
		Mittel	Lin. Reg.	MLRM	Gaussian-Midp.	Spline-Midp.	Polyfit-Max.
2016	r	0.04	-0.01	0.1	<b>-0.23</b>	-0.17	-0.11
	$\bar{\Delta}$ [d]	17.23	17.33	14.08	15.66	14.66	29.07
	RMSE	23.24	23.59	19.30	20.43	19.31	37.18
2017	r	0.03	0.12	<b>0.23</b>	-0.01	0	-0.06
	$\bar{\Delta}$ [d]	20.40	19.87	14.00	17.08	18.51	39.84
	RMSE	26.42	25.85	18.98	23.55	24.79	44.93
Bildung des kumulativen NDVI ab 1. März							
2016	r	0.02	0.12	<b>0.23</b>	<b>-0.23</b>	-0.17	-0.11
	$\bar{\Delta}$ [d]	9.88	9.67	8.54	15.66	14.66	29.07
	RMSE	13.44	13.34	11.93	20.43	19.31	37.18
2017	r	-0.05	<b>0.2</b>	<b>0.28</b>	-0.01	0	-0.06
	$\bar{\Delta}$ [d]	14.54	12.93	11.34	17.08	18.51	39.84
	RMSE	17.89	16.14	14.55	23.55	24.79	44.93

In Tabelle 4.7 sind die MLRM mit verschiedenen Parametern als Prädiktoren für beide Jahre abzulesen. In Abbildung 4.14 sind diese simulierten Eintrittstage des Blattaustriebs der Buche im Vergleich zu den Bodenbeobachtungen im Jahr 2017 grafisch dargestellt. Dabei zeigt sich, wie bei der Birke, in beiden Jahren eine Abhängigkeit besonders von der Höhe, dem Nadelwaldanteil und der Laubbaumkronendichte. Im Jahr 2017 zeigen die verbliebenen Parameter einen stärkeren Anteil an der erklärten Varianz als 2016. Auch hier wird die stärkste Korrelation mit allen zur Verfügung stehenden Parametern, welche sowohl die Lage der untersuchten Pixel als auch den Mischpixeleffekt beschreiben, erzielt. Dabei wird 2016 eine Korrelation zur GP von  $r = 0.23$  erreicht, im Jahr 2017 steigt diese auf  $r = 0.28$ .

Tabelle 4.7: Vergleich multipler linearer Regressionsmodelle in der räumlichen Validierung im Fall der Buche. LA steht für Laubwald-, NA für Nadelwaldanteil und TCD für Laubbaumkronendichte. Als zeitliche Interpolationsmethode für den kumulativen NDVI wurde eine Kurvenannäherung mit Polynom 6. Grades verwendet. Fettgedruckte r Werte zeigen statistisch signifikante Korrelationen ( $p \leq 0.05$ ).

(a) 2016			(b) 2017		
Parameter und Gütemaße			Parameter und Gütemaße		
r	$\bar{\Delta}$	RMSE	r	$\bar{\Delta}$	RMSE
Höhe, Länge, Breite			Höhe, Länge, Breite		
0.16	9.47	13.52	<b>0.19</b>	12.78	16.17
Höhe, Länge, Breite, LA, NA, TCD			Höhe, Länge, Breite, LA, NA, TCD		
<b>0.23</b>	8.54	11.93	<b>0.28</b>	11.34	14.55
Höhe, Länge, Breite, TCD			Höhe, Länge, Breite, TCD		
0.17	9.24	12.97	<b>0.20</b>	12.14	15.46
Höhe, Länge, Breite, LA, TCD			Höhe, Länge, Breite, LA, TCD		
<b>0.23</b>	8.86	12.39	<b>0.26</b>	11.69	15.1
Höhe, Länge, Breite, LA			Höhe, Länge, Breite, LA		
0.15	9.53	13.48	0.18	12.65	15.95
Höhe, Länge, Breite, NA, TCD			Höhe, Länge, Breite, NA, TCD		
0.18	8.72	12.25	<b>0.25</b>	11.49	14.62
Höhe, Länge, Breite, NA			Höhe, Länge, Breite, NA		
0.18	9.21	12.79	<b>0.23</b>	12.02	15.29
Höhe, Länge, Breite, LA, NA			Höhe, Länge, Breite, LA, NA		
0.16	9.19	12.8	<b>0.25</b>	11.58	15.14
LA, NA, TCD			LA, NA, TCD		
0.18	8.29	11.49	0.1	12.38	15.34
Tag = Höhe, Länge, Breite			Tag = Höhe, Länge, Breite		
<b>0.54</b>	4.54	6.55	<b>0.45</b>	9.47	11.28

Der stärkste signifikante Korrelationskoeffizient ( $r = 0.54$  für 2016 und  $r = 0.45$  für 2017) wird allerdings beim MLRM erreicht, bei der nur Informationen aus der Bodenbeobachtung eingehen (Eintrittstag abhängig von den geographischen Standortparametern der Beobachtung). Auffällig ist, dass für den Laubaustrieb der Buche 2017 mit Informationen rein aus der GP (MLRM „Tag = Höhe, Länge, Breite“) eine niedrigere Korrelation erreicht wird, was in Kapitel 4.5 näher beschrieben wird.

Die einzelnen Gebiete unterscheiden sich auch bei der räumlichen Validierung in ihrer Korrelation zwischen den, mit dem stärksten MLRM, simulierten und den beobachteten Eintrittstagen des Laubaustriebs der Buche. In Abbildung 4.15 sind in Streuplots die verschiedenen Kacheln dargestellt. Im Jahr 2016 zeigt die Region, die der Kachel UMU entspricht, eine deutlich höhere signifikante Korrelation ( $r = 0.66$ ) als das gesamte Untersuchungsgebiet, genau so im Jahr 2017 ( $r = 0.55$ ). Die Kachel TPT erzielt 2016 ebenfalls eine höhere Korrelation, wegen der geringen Anzahl an Stationen allerdings keine statistisch signifikante ( $r = 0.59$ ). Die Region UVQ-UWP, bei der, aufgrund der Verfügbarkeit von Sentinel-2-Daten, nur das Jahr 2017 betrachtet wird und die eine niedrige Anzahl an Stationen beinhaltet, zeigt eine signifikante Korrelation von  $r = 0.86$ . Dies entspricht 74 % der erklärten Varianz.

Buche 2017: Vergleich multipler linearer Regressionsmodelle zur Simulation der NDVI-Summen und der Eintrittstage direkt

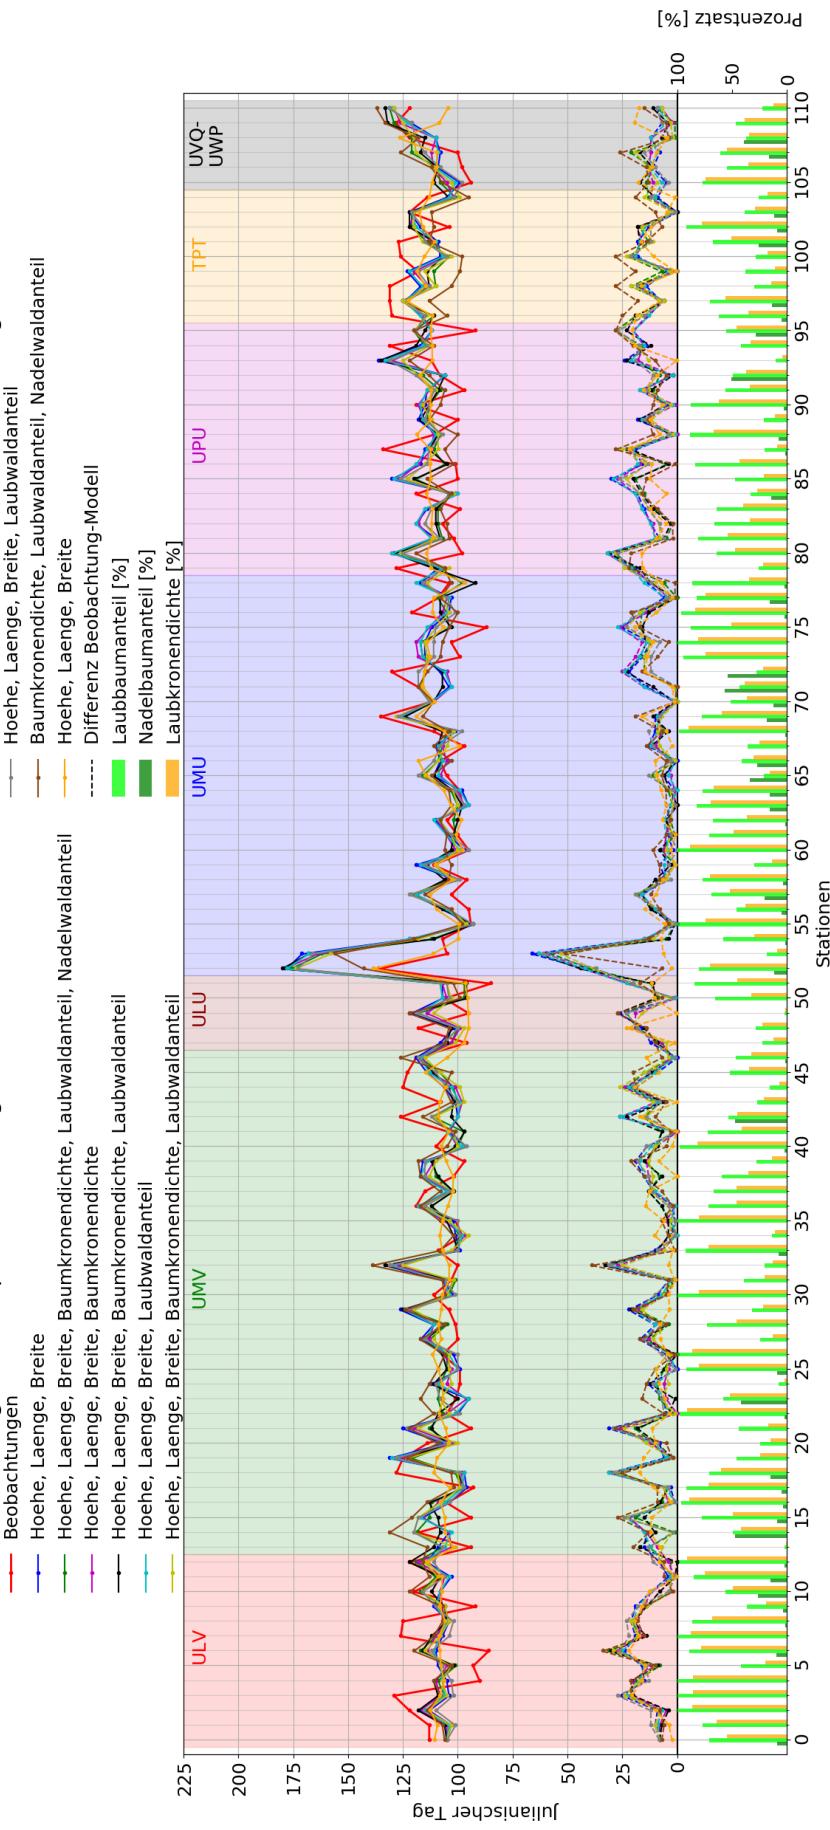


Abb. 4.14: Räumliche Validierung mit dem Vergleich multipler linearer Regressionsmodelle mit verschiedenen Parametern als Prädiktoren (abzulesen in der Legende) zur Simulation der Eintrittstage des Laubbaustriebs der Buche an den Beobachtungspunkten im Vergleich zu den Beobachtungen 2017. Unterbrochene Linien zeigen die Differenzen der Beobachtungen zu den Schätzungen der jeweiligen Modelle in der dazugehörigen Farbe. Hintergrundfarben entsprechen den Regionen in Abbildung 2.4. Darunter abgebildet sind die Werte für den Laubbau-, den Nadelbaumanteil und der Laubkronendichte des untersuchten, für die jeweilige Beobachtungsstation repräsentativen, MODIS-Pixels

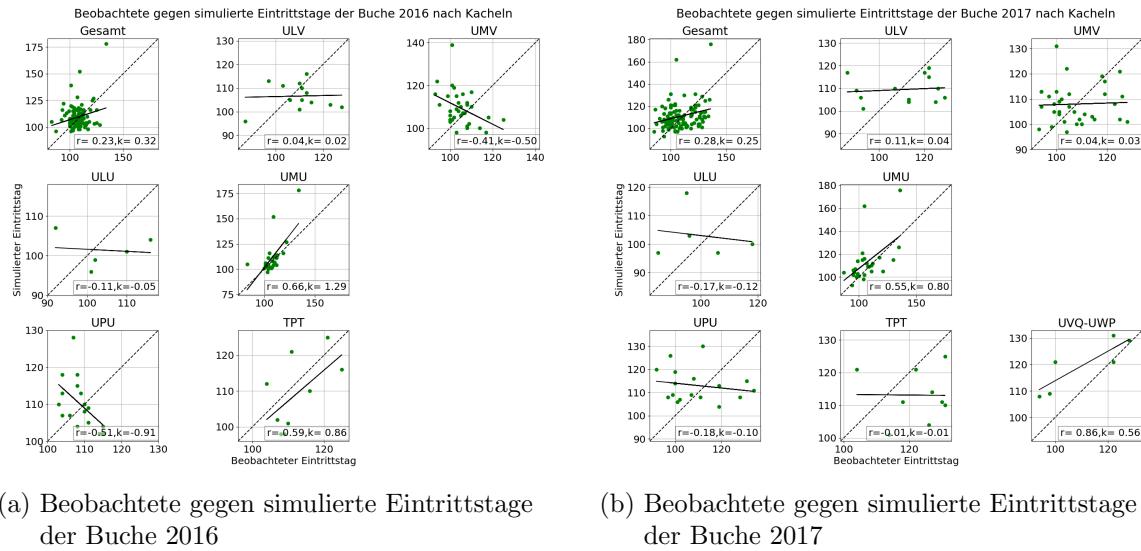


Abb. 4.15: Streuplots beobachteter gegen simulierter Eintrittstage des Laubaustriebs der Buche 2016 (a) und 2017 (b) mit der Methode des kumulativen NDVI, der zeitlichen Interpolation mit einem Polynom 6. Grades und der räumlichen Interpolation mit dem besten multiplen linearen Regressionsmodell. Gezeigt werden sowohl alle Stationen (links oben), sowie die Stationen einzelner Kacheln. Sonstiger Aufbau wie Abbildung 4.12.

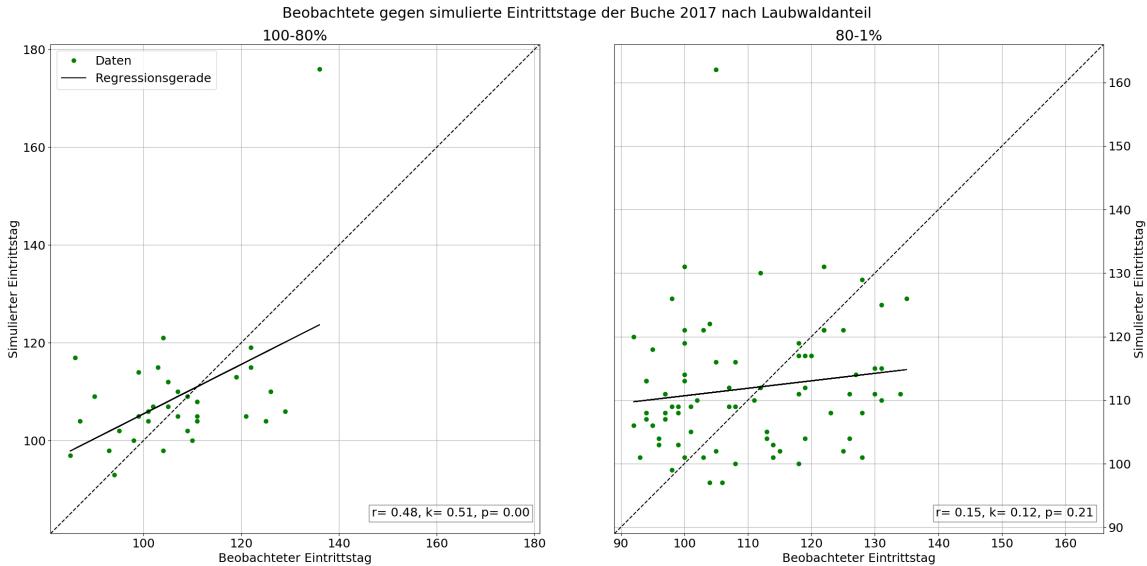


Abb. 4.16: Streuplots beobachteter gegen simulierter Eintrittstage des Laubaustriebs der Buche 2017 mit der Methode des kumulativen NDVI, der zeitlichen Interpolation mit einem Polynom 6. Grades und der räumlichen Interpolation mit dem besten multiplen linearen Regressionsmodell unterschieden in zwei Klassen des Laubwaldanteils, über (links) und unter 80 % (rechts). Schwarze, durchgezogene Linien zeigen die tatsächlichen Regressionsgeraden. Gegebene Werte entsprechen dem Korrelationskoeffizienten und der Steigung der tatsächlichen Regressionsgeraden, sowie dem dazugehörigen p-Wert.

Abbildung 4.16 zeigt ebenfalls den Einfluss des Mischpixeleffekts. In diesem Streuplot werden die simulierten gegen die beobachteten Eintrittstage aufgetragen, allerdings in zwei Klassen des Laubwaldanteils (über und unter 80 %). Die simulierten Punkte sind mit dem stärksten MLRM modelliert worden. Die Korrelation in der Klasse mit hohem Laubwaldanteil ist ( $r = 0.48$ ) deutlich stärker als in der Klasse mit niedrigem Anteil ( $r = 0.15$ ) und in der Gesamtheit aller Beobachtungspunkte ( $r = 0.28$ ).

Abschließend wird der räumliche Zusammenhang zwischen GP und LSP für den Laubaustrieb von Birke und Buche ohne Kreuzvalidierung analysiert. Hierfür werden die NDVI-Verläufe in verschiedenen Klassen betrachtet: das Vorhandensein von Laub- oder Mischwald im repräsentativen Pixel, nach Laubwaldanteil, verschiedene Höhenstufen und weitere Klassen. Dazu werden die mit der kumulativen NDVI-Methode berechneten NDVI-Summen gegen die verschiedenen Parameter aufgetragen.

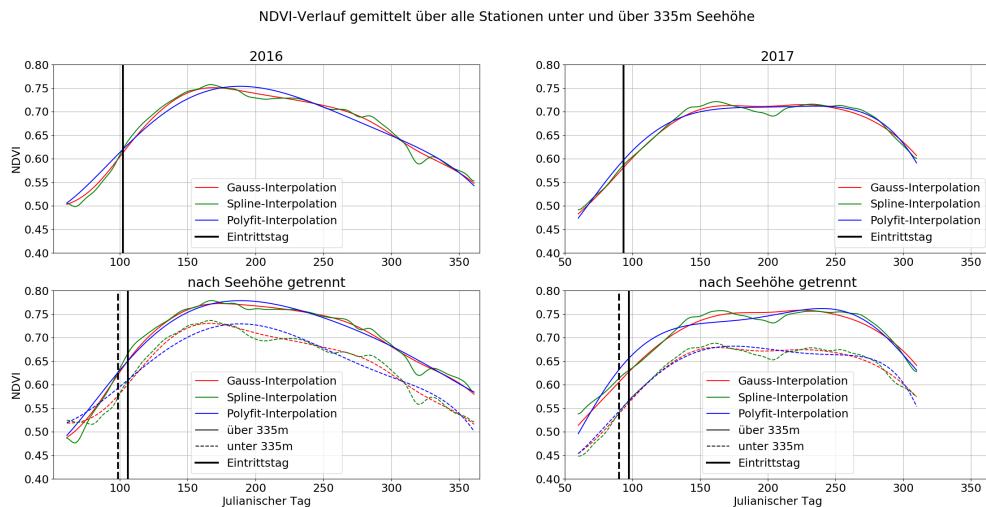


Abb. 4.17: NDVI-Werte im Laufe des Jahres 2016 (links) und 2017 (rechts) gemittelt über alle verwendeten Stationen (oben) und in zwei Höhenniveaus getrennt (unten). Vertikale Linien entsprechen den Eintrittsterminen (ebenfalls stationsgemittelt).

In Abbildung 4.17 werden die über alle Stationen gemittelten NDVI-Verläufe beider Jahre der Birke und getrennt in zwei Höhenniveaus dargestellt. Die Darstellung wird bei einer Seehöhe von 335 m getrennt, damit beide Klassen dieselbe Anzahl an Stationen enthält. Der gemittelte NDVI-Verlauf von Stationen über 335 m Seehöhe zeigt eine höher liegende NDVI-Kurve als der von Stationen unterhalb. Dies kann einerseits damit erklärt werden, dass bei niedrig gelegenen Stationen eher NDVI dämpfende Landnutzungsformen (wie Felder und verbaute Flächen) zum Mischpixeleffekt beitragen, welche in höheren Lagen seltener vorkommen. Andererseits zeigt der NDVI laut Literatur eine Höhenabhängigkeit, wodurch mit steigender Seehöhe höhere NDVI-Werte verbunden sind (Matsushita et al., 2007; Mokarram et al., 2015; Zhan et al., 2012). Auch die stationsgemittelten beobachteten Eintrittstage liegen je nach Höhenklasse etwa 10 Tage auseinander, sie treten unter 335 m früher auf als darüber. Die Höhenabhängigkeit der Eintrittstermine war zu erwarten, da diese nicht nur in der Literatur belegt wurde (Defila, 2007; Rötzer et al., 2001; Vitasse et al., 2009), sondern auch selbst zu beobachten ist. Besonders in Gebirgsregionen ist eine starke Höhenabhängigkeit zu erkennen. Betrachtet man einen Berg im Frühling, so kann man im Laufe der Zeit gut beobachten, dass die Bäume am Fuße des Berges als erstes zu ergrünern beginnen, danach in höheren Lagen und zuletzt ergrünern schließlich die Bäume am Gipfel. In anderen Worten, die Entfaltung der Blätter breitet sich über die Zeit von unten nach oben hin aus.

Trennt man die stationsgemittelten NDVI-Summen auch noch in Klassen von reinem Laubwald und Mischwald und zusätzlich nach Laubwaldanteil über und unter 80 %, so zeigt sich, dass die NDVI-Kurve bei hohem Laubwaldanteil höher liegt als bei geringem. Besonders bei reinem Laubwald ist ein Unterschied von bis zu 0.2 im NDVI-Wert zu erkennen (siehe Abbildung 4.18).

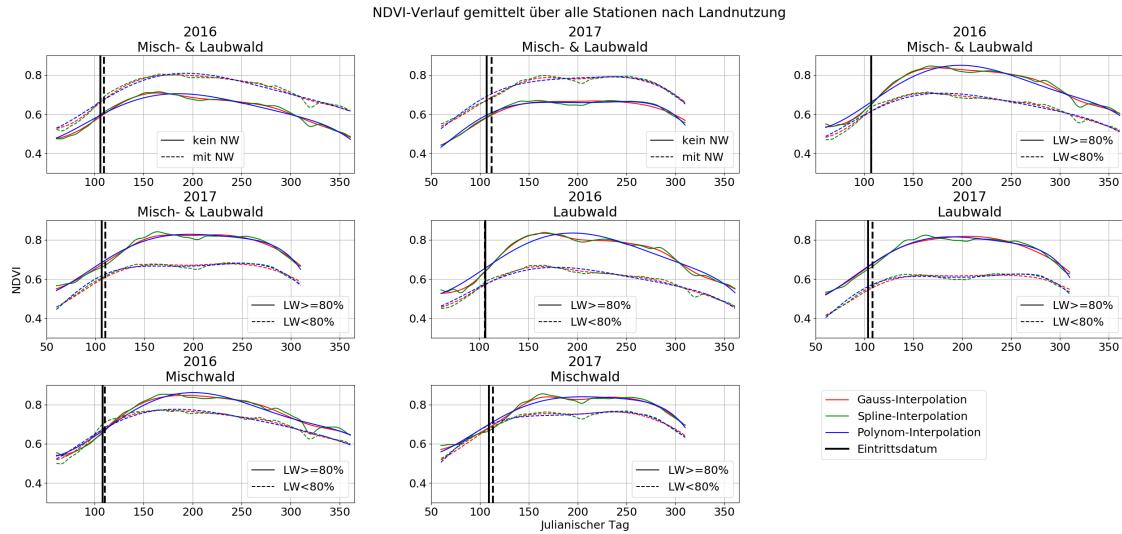


Abb. 4.18: NDVI-Werte im Laufe des Jahres 2016 (links) und 2017 (rechts) gemittelt über alle verwendeten Stationen getrennt nach reinem Laubwald, Mischwald und jeweils in zwei Klassen des Laubwaldanteils, über und unter 80 %. Vertikale Linien entsprechen den Eintrittsterminen, ebenfalls stationsgemittelt.

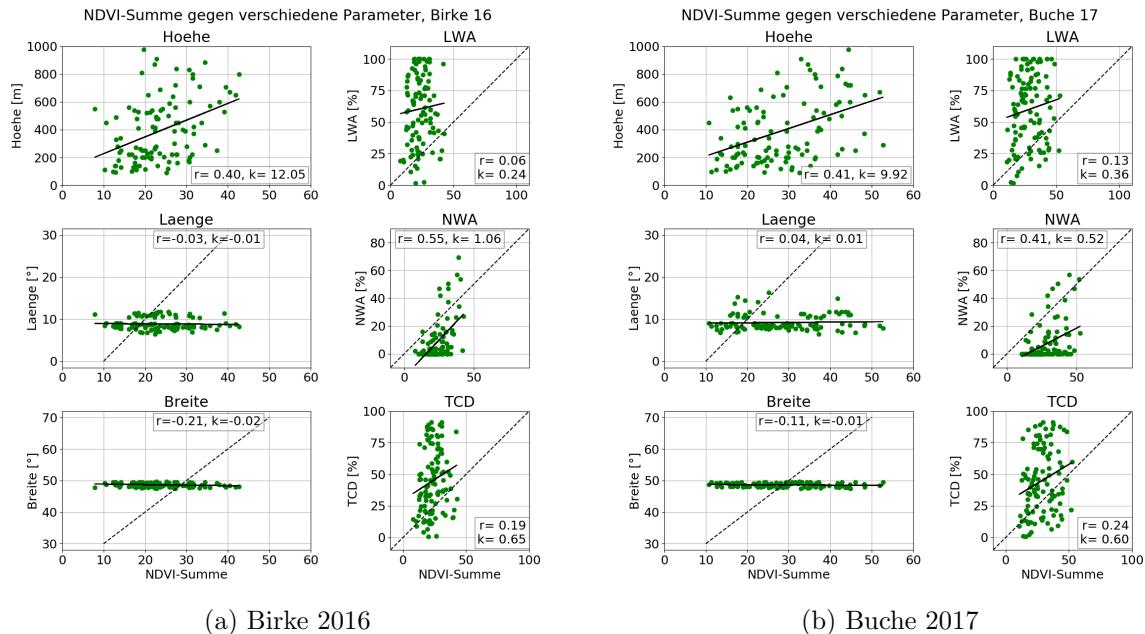


Abb. 4.19: Kumulative NDVI-Summe des Laubaustriebs der Birke 2016 (a) und Buche 2017 (b) mit zeitlicher Gauß-Interpolation gegen die Parameter (Teilbilder) der, für die jeweilige Station repräsentativen, MODIS-Pixel. Sonstiger Aufbau wie Abbildung 4.12.

Trägt man die mit der kumulativen NDVI-Methode berechneten NDVI-Summen gegen die verschiedenen Parameter in Streudiagrammen auf, erkennt man in Abbildung 4.19 für die erreichten NDVI-Summen der Birke 2016 und Buche 2017 den bereits bei der Kreuzvalidierung erwähnten Zusammenhang zwischen NDVI-Summe und Höhe ( $r = 0.4$ ), Baumkronendichte ( $r = 0.19$  bzw.  $0.24$ ) und besonders dem Nadelwaldanteil ( $r = 0.55$  bzw.  $0.41$ ). Wie bereits erwähnt, zeigt der NDVI eine Höhenabhängigkeit. Dieser Umstand dürfte daher auch Auswirkungen auf die kumulative NDVI-Summe haben, da höhere Werte zu höheren Summen führen.

Es zeigt sich, dass in beiden Jahren und für beide Phasen ein multiples lineares Regressionsmodell mit allen verfügbaren Parametern die geeignetere Lösung darstellt, um eine räumliche Korrelation zwischen LSP und GP herzustellen. Allerdings zeigt der starke Einfluss des Mischpixeleffekts, repräsentiert durch Laubbaum-, Nadelbaumanteil und Baumkronendichte, die Notwendigkeit für Satellitensysteme mit deutlich höherer räumlicher Auflösung als 250 Meter.

Im nächsten Abschnitt wird die Methodik mit Sentinel-2-Daten durchgeführt und näher betrachtet. Es wird erwartet, dass der Mischpixeleffekt durch die hohe räumliche Auflösung von 10 m weniger oder sogar keinen Einfluss auf die Ergebnisse hat.

### 4.3 Durchführung der Methodik mit Sentinel-2-Daten

In diesem Abschnitt wird nun untersucht, ob mit den räumlich höher aufgelösten Sentinel-2-Daten bessere Ergebnisse erzielt werden können. Kleinere Pixel lassen sich leichter zur Gänze einer Landnutzungsklasse zuordnen, als große. Daher können in den Satellitenbildern auch Grenzen zwischen verschiedenen Landbedeckungen und Landnutzungsformen deutlich erkannt werden, wie beispielsweise Ränder von Wäldern, Flüssen und Seen.

Allerdings zeigte sich bereits beim Einlesen der Satellitenbilder, dass eine Interpolation der NDVI-Werte auf einen NDVI-Verlauf mit eintägiger zeitlicher Auflösung, aufgrund zu großer Datenlücken nicht möglich ist. Die zeitliche Auflösung von Sentinel-2A liegt bei 3-10 Tagen, durch die Wolkenfilterung entstehen zusätzliche Lücken in den Satellitenbildern, sowie bei vollständiger Bewölkung zum Aufnahmezeitraum stehen keine Bilder zur Verfügung. Daher ist für die Jahre 2016 und 2017 weder eine Generierung der NDVI-Verläufe, noch eine vernünftige Interpolation dieser auf Eintagesbasis, möglich. Zudem stehen Anfang Frühling, also jenem Zeitraum in dem der Laubaustrieb von Birke und Buche auftritt, die wenigsten Daten im Vergleich zum Gesamtjahr zur Verfügung. Ab der zweiten Jahreshälfte 2017, in der auch Daten von Sentinel-2B zur Verfügung stehen, erkennt man eine deutlich höhere zeitliche Auflösung und weniger Lücken.

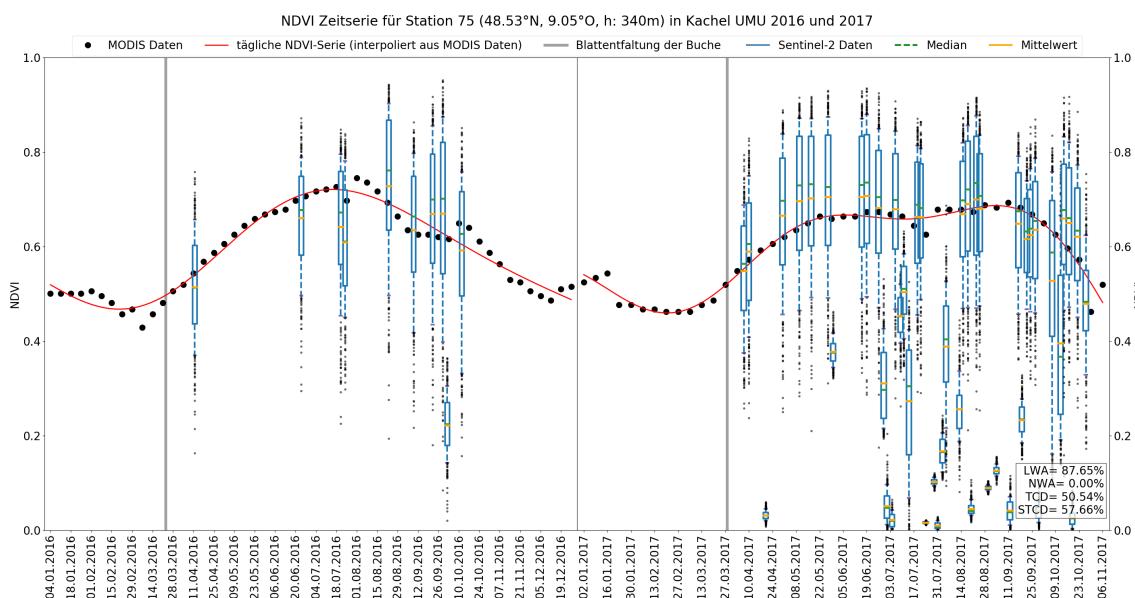


Abb. 4.20: Verlauf der NDVI-Werte der Station 75 in Kachel UMU für die Jahre 2016 und 2017 von MODIS (schwarze Punkte). Die rote Kurve entspricht der Gauß-Interpolation dieser Werte. Die Boxplots charakterisieren die Verteilung der in diesem MODIS-Pixel liegenden Sentinel-Werte. Die Boxplots zeigen Median und Mittelwert, die 25er und 75er Quantile, sowie die Whiskers (die 10 % und 90 % Perzentile). Werte rechts unten entsprechen dem Laubbaumanteil (LWA), dem Nadelbaumanteil (NWA) und der Laubbaumkronendichte (TCD) des untersuchten MODIS-Pixels sowie der Laubbaumkronendichte (STCD) der Sentinel-Pixel. Graue horizontale Striche zeigen den Eintrittstermin des Laubaustriebs der Buche.

In Abbildung 4.20 werden zum Vergleich die NDVI-Werte von MODIS für die Jahre 2016 und 2017, der daraus mit der Gauß-Näherung interpolierte NDVI-Verlauf und die Werte, der im untersuchten MODIS-Pixel liegenden Sentinel-Pixel, als Boxplots dargestellt. An der großen Streuung und den Werten nahe Null lässt sich erkennen, dass (wie bereits in der Problematik zu den Sentinel-2-Daten im Abschnitt 2.1.2 erwähnt) nicht in allen Daten Wolkenschatten gefiltert werden und die Filterung der Wolken weiterer Verbesserung bedarf. Möglicherweise werden Pixel mit einer geringen Baumkronendichte sowie der Landnutzungskataster mit seiner räumlichen Auflösung von ursprünglich 20 m, weiterhin durch die Mischpixel-Problematik beeinflusst. Achtet man auf Median und Mittelwert der Boxplots, so kann man einen den MODIS-Daten ähnlichen NDVI-Verlauf erahnen. Dies liegt einerseits daran, dass der Laubwaldanteil in diesem Pixel relativ hoch ist, wodurch der Mischpixeleffekt weniger Einfluss hat. Andererseits zeigen die detektierten Sentinel-Pixel eine geringe Baumkronendichte von etwas über 50 %, wodurch diese einen Mischpixeleffekt aufweisen. Der Median liegt dabei etwas höher, da dieser weniger sensibel auf Ausreißer reagiert.

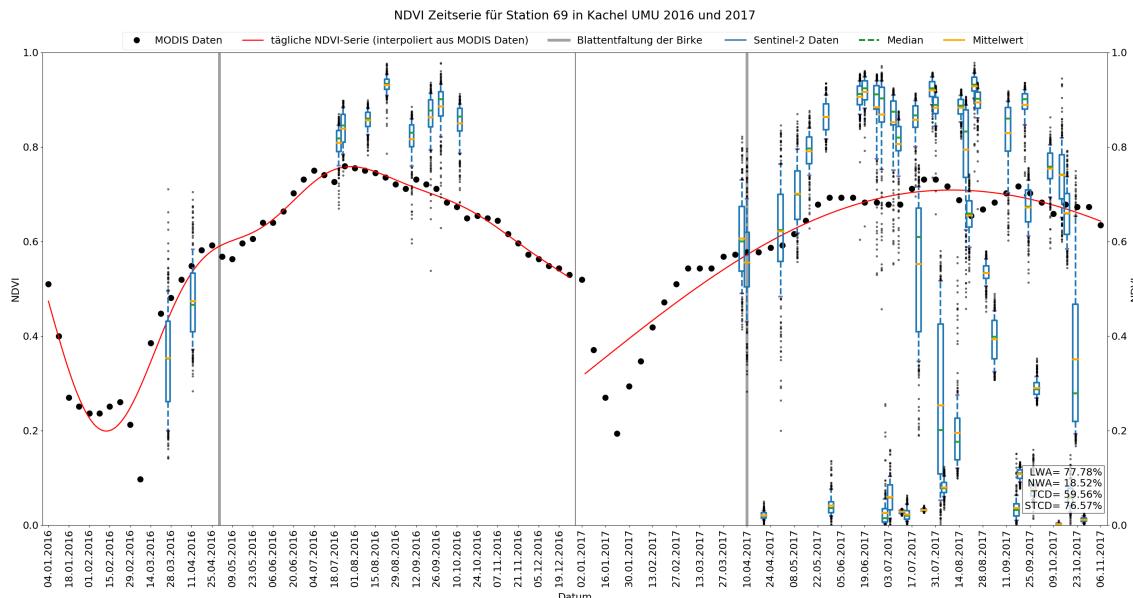


Abb. 4.21: Verlauf der NDVI-Werte der Station 69 in Kachel UMU für die Jahre 2016 und 2017 von MODIS (schwarze Punkte). Die rote Kurve entspricht der Gauß-Interpolation dieser Werte. Die Boxplots charakterisieren die Verteilung der in diesem MODIS-Pixel liegenden Sentinel-Werte. Die Boxplots zeigen Median und Mittelwert, die 25er und 75er Quantile, sowie die Whiskers (die 10 % und 90 % Perzentile). Werte rechts unten entsprechen dem Laubbaumanteil (LWA), dem Nadelbaumanteil (NWA) und der Laubbaumkronendichte (TCD) des untersuchten MODIS-Pixels sowie der Laubbaumkronendichte (STCD) der Sentinel-Pixel. Graue horizontale Striche zeigen den Eintrittstermin des Laubaustriebs der Birke.

Im Gegensatz dazu ist in Abbildung 4.21 der NDVI-Verlauf eines MODIS-Pixels, mit etwas niedrigerem Laubwaldanteil ( 78 %), dafür Nadelwaldanteil ( 19 %) und den darin enthaltenen Sentinel-2-Pixel mit einer höheren mittleren Baumkronendichte ( 77 %) dargestellt. Wieder sind die Lücken in den Sentinel-2-Daten zu erkennen, besonders im Winter und Frühling. Auch die große Streuung und die NDVI-Werte nahe Null sind erkennbar. Median und Mittelwert der Boxplots lassen hier im Sommer einen NDVI-Verlauf mit deutlich höheren Werten erahnen als die MODIS-Daten zeigen. Das liegt einerseits daran, dass der Laubwaldanteil in diesem Pixel doch

niedriger ist, als in der vorherigen Abbildung und dadurch der Mischpixeleffekt mehr Einfluss hat. Andererseits zeigen die detektierten Sentinel-Pixel eine höhere Baumkronendichte von etwas über 75 %, wodurch die Dämpfung durch andere Landnutzungsformen geringer ausfällt. Im April zeigen Median und Mittelwert ähnliche NDVI-Werte wie MODIS. Darüber hinaus sind ab Juli 2017 auch Daten von Sentinel-2B enthalten, wodurch sich die zeitliche Auflösung augenscheinlich verbessert. Damit kann in Zukunft mit einer höheren Brauchbarkeit von Sentinel-2-Daten gerechnet werden.

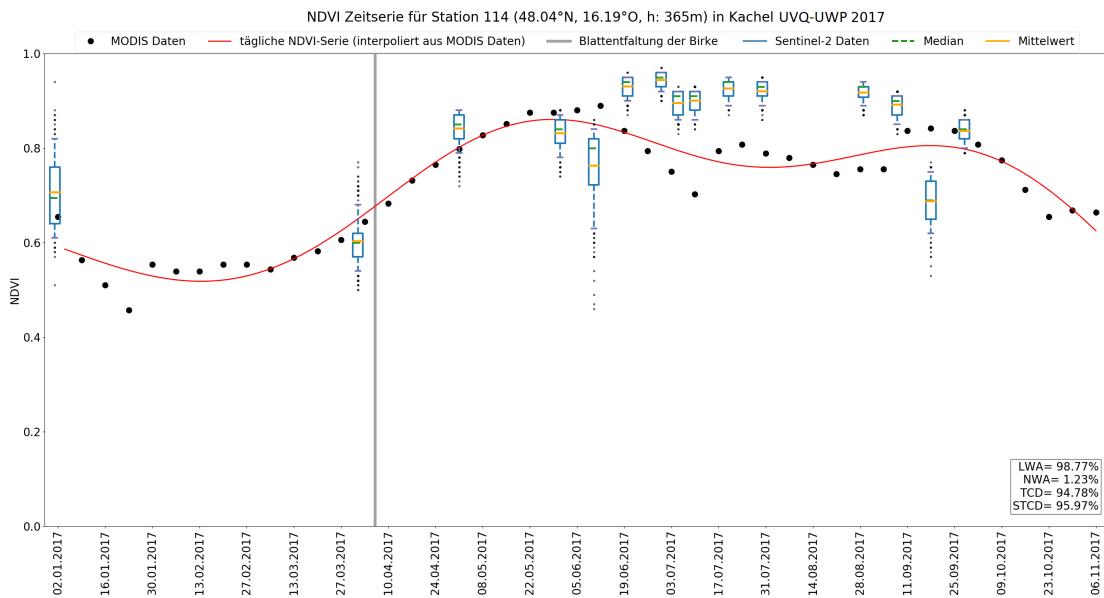


Abb. 4.22: Verlauf der NDVI-Werte der Station 114 in Kachel UVQ-UWP für das Jahr 2017 von MODIS (schwarze Punkte). Die rote Kurve entspricht der Gauß-Interpolation dieser Werte. Die Boxplots charakterisieren die Verteilung der in diesem MODIS-Pixel liegenden Sentinel-Werte. Die Boxplots zeigen Median und Mittelwert, die 25er und 75er Quantile, sowie die Whiskers (die 10 % und 90 % Perzentile). Werte rechts unten entsprechen dem Laubbaumanteil (LWA), dem Nadelbaumanteil (NWA) und der Laubbaumkronendichte (TCD) des untersuchten MODIS-Pixels sowie der Laubbaumkronendichte (STCD) der Sentinel-Pixel. Graue horizontale Striche zeigen den Eintrittstermin des Laubaustriebs der Birke.

In Abbildung 4.22 wird der NDVI-Verlauf der Region UVQ-UWP, welche Ober- und Niederösterreich entspricht, dargestellt. In diesen Daten, welche rein für das Jahr 2017 vorliegen, wurden Wolken mit geringer Wahrscheinlichkeit, Cirren und Wolkenschatten gefiltert. Da kaum Werte nahe 0 vorliegen und Dämpfungen durch Bewölkung nur Mitte Juni und Ende September zu erkennen sind, kann daraus geschlossen werden, dass die Filterung einen deutlichen Effekt aufweist. Gründe für die Streuung können Pixel mit niedriger Baumkronendichte oder auch die etwas niedrigere Auflösung des Landnutzungskatasters sein, wodurch ein Mischpixeleffekt nicht auszuschließen ist.

## 4.4 Analyse des MODIS- und Sentinel-2-NDVI

Durch die Prozessierung und Interpolation von Datenlücken an der BOKU stehen für den Zeitraum von 4. Januar 2016 bis 6. November 2017 NDVI-Werte lückenlos alle 7 Tage zur Verfügung. Für die Analyse dieser Daten werden die NDVI-Werte für beide Jahre zusammengefasst und nach Saison sowie Laubwaldanteil bzw. Baumkronendichte der Pixel aufgeteilt. Bereits bei der Interpolation der NDVI-Werte auf 1-Tages Auflösung zeigten einige Pixel unerwartet hohe Werte oder Anstiege des NDVI im Winter. Aus der Literatur sind NDVI-Werte gegen 0.5 oder darunter zu erwarten (Atzberger et al., 2014; Garonna et al., 2014; Jin et al., 2014; White et al., 1997), welche jedoch überschritten werden. Laut Delbart et al. (2005) zeigt der NDVI eine Sensibilität auf Schnee, da dieser nicht nur mit dem Ergrünen steigt, sondern auch während der Schneeschmelze. Eine weitere mögliche Erklärung wären andere Landnutzungsformen bzw. Vegetation rund um und unter den Bäumen, welche sich aufgrund des Mischpixeleffekts auf den gemessenen NDVI auswirken können. Diese Vegetation können Gras oder immergrüne Pflanzen sein, die im Winter höhere Werte als Laubbäume aufweisen. Ein weiterer Grund ist nach Lange et al. (2017) eine durch die Überflugzeit von MODIS-Terra gegen 10:30 Uhr mögliche Auswirkungen von Beleuchtungsgeometrien auf das Signal.

Die NDVI-Werte beider Jahre für alle ausgewählten Pixel, an denen Beobachtungen der Birke vorliegen, werden in Abbildung 4.23 dargestellt. Hier werden die NDVI-Werte der Stationen in den einzelnen Kacheln nach Jahreszeiten zusammengefasst und in verschiedene Klassen des Laubwaldanteils eingeteilt. Auffällig sind dabei die bereits erwähnten hohen Werte im Winter, welche sogar proportional zum Laubwaldanteil steigen. Somit scheint die Erklärung von Auswirkungen von Beleuchtungsgeometrien durch die Überflugszeit als äußerst plausibel. Um diesen Effekt auszuschließen, wurde für die Berechnung des kumulativen NDVI erst ab dem 1. März des jeweiligen Jahres mit der Summenbildung begonnen. Betrachtet man die NDVI-Werte beider Jahre im Frühling, so zeigen sich teilweise ähnlich hohe Werte in allen Klassen, teilweise erhöhen sich die Werte in Klassen höheren Laubwaldanteils im Mittel um bis zu 0.2. Im Sommer liegen die NDVI-Werte im Mittel in allen Gebieten in den Klassen höheren Laubwaldanteils höher, ebenfalls um bis zu 0.2, sofern dort Pixel mit entsprechendem Laubwaldanteil detektiert werden konnten. Diese Werte entsprechen eher der Erwartung und zeigen deutlich den Mischpixeleffekt und die Dämpfung des NDVI durch anderweitige Landnutzungsformen in Klassen mit niedrigerem Laubwaldanteil.

Für einen Vergleich mit MODIS wollen werden nun die von Sentinel-2 gemessenen NDVI-Werte in den verschiedenen Saisonen und Kacheln beider Jahre betrachtet. Da im Gegensatz zu MODIS nur Pixel verwendet wurden, die laut Landnutzungskataster Laubwald beinhalteten, werden in Abbildung 4.24 die verschiedenen Klassen nicht nach Laubwaldanteil, sondern nach Laubbaumkronendichte eingeteilt und zusätzlich mit den Werten von MODIS verglichen.

Wie bereits im vorherigen Abschnitt beschrieben, zeigen die Sentinel-2-NDVI-Werte eine deutlich größere Streuung im Vergleich mit MODIS. So sind beispielsweise im Sommer Werte zwischen 0 und 1 vertreten, erwartungsgemäß sollten diese nahe 1 liegen. Dies liegt einerseits an den bereits beschriebenen Problemen mit der, je nach Quelle verschiedenen, Wolkenfilterung. So zeigt sich großteils die Streuung unabhängig von der Klasseneinteilung. Andererseits zeigen manche Klassen mit hoher Baumkronendichte eine deutlich geringere Streuung (wie in der Kachel TPT in allen 4 Saisonen), was auf die ursprünglich größere Auflösung des Landnutzungskatasters von 20 m zurückzuführen ist und wodurch auch bei Sentinel-2 Mischpixeleffekte auftreten. Zeigt ein Pixel des Landnutzungskatasters eine Baumkronendichte von 75 % an, so bedeutet das, dass von den vier Sentinel-Pixel, die darin liegen (abhängig von der Lage des Baumes innerhalb des

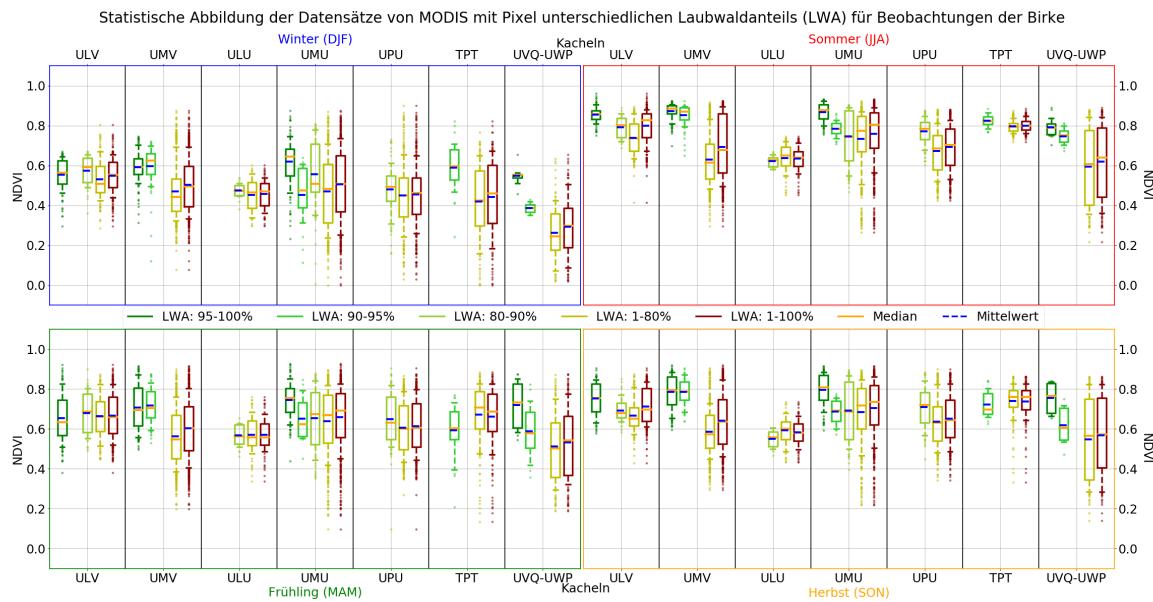


Abb. 4.23: NDVI-Werte von MODIS beider Jahre für alle ausgewählten Pixel, an denen Beobachtungen der Birke vorliegen, der einzelnen Kacheln nach Jahreszeiten zusammengefasst und in verschiedene Klassen des Laubwaldanteils eingeteilt. Diese Klassen sind je nach Laubwaldanteil (LWA) in 100-95 % (dunkelgrün), 95-90 % (grün), 90-80 % (hellgrün), < 80 % (gelb) eingeteilt und den NDVI-Werten ohne Klasseneinteilung (rot) gegenübergestellt. Orange ist der Median und Blau der Mittelwert.

Pixels), vielleicht nur drei tatsächlich den NDVI eines Laubbaumes, oder alle vier auch andere Landnutzungsformen messen. Bei einer Baumkronendichte von 50 % könnten nur zwei Sentinel-Pixel den NDVI eines Laubbaumes messen, bei 25 % sogar nur eines.

Unabhängig davon sollen nun die mittleren NDVI-Werte nach Saison und Kachel der einzelnen Klassen näher betrachtet werden. Im Winter zeigt sich erneut die Problematik der Datenlücken. So ist in den Kacheln ULU und UMU in den drei Wintermonaten beider Jahre keine einzige Messung in den detektierten Pixeln vorhanden. Des Weiteren lassen sich auch hier die zu hohen NDVI-Werte ausmachen, welche schon bei MODIS zu sehen waren. Lange et al. (2017) deutete bereits an, dass auch bei Sentinel-2A, der eine ähnliche Überflugzeit wie MODIS-Terra aufweist, mögliche Auswirkungen von Beleuchtungsgeometrien auf das Signal im Winter auftreten können. In Zukunft wird sich zeigen, ob durch die Verfügbarkeit der Daten von Sentinel-2B und somit von beiden Satelliten, dieses Problem bestehen bleibt oder gelöst werden kann. Im Sommer liegen in allen Kacheln die Mittelwerte etwas höher als bei MODIS und wiederum zeigen die Klassen mit höherer Baumkronendichte höhere Werte als jene mit geringerer. Dies lässt vermuten, dass sowohl der Mischpixel- als auch der dämpfende Effekt anderweitiger Landnutzungsformen weniger Auswirkung haben. Im Herbst verhält sich der NDVI ähnlich, im Frühling dafür je nach Kachel verschieden. Teilweise sinkt der NDVI mit der Baumkronendichte, teilweise liegt er je nach Klasse verschieden hoch (in der Klasse mit der höchsten Dichte in etwa so niedrig wie bei < 80 %) und in der Kachel ULU ist der NDVI in allen vier Klassen dem von MODIS sehr ähnlich. In der Kachel UVQ-UWP lässt sich ebenfalls eine starke Streuung der NDVI-Werte in den Saisonen erkennen. In diesen Daten wurden auch Wolken mit geringer Wahrscheinlichkeit, Cirren und Wolkenschatten gefiltert, wodurch diese Streuung entweder auf die großteils niedrige Baumkronendichte zurückgeführt werden kann, oder auf die etwas niedrigere Auflösung des Landnutzungskatasters, wodurch ebenfalls ein Mischpixeleffekt auftreten kann und eine Dämpfung durch Bewölkung nur zeitweise und nicht so ausgeprägt auftritt.

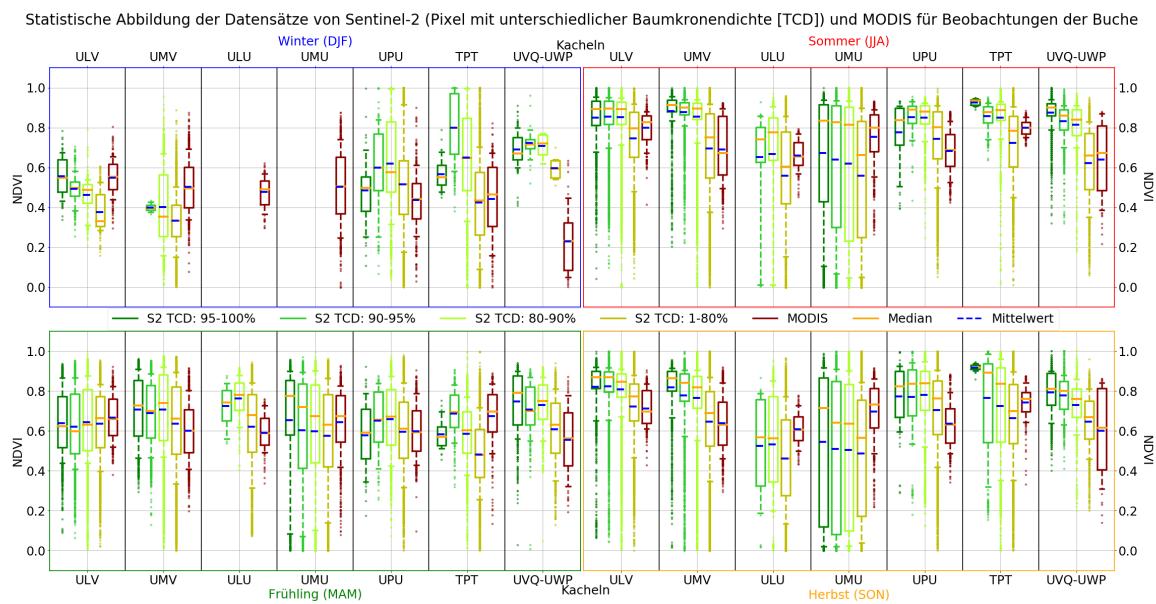


Abb. 4.24: NDVI-Werte von Sentinel-2 beider Jahre für alle ausgewählten Pixel, an denen Beobachtungen der Buche vorliegen, der einzelnen Kacheln nach Jahreszeiten zusammengefasst und in verschiedene Klassen der Laubbaumkronendichte (TCD) eingeteilt. Diese Klassen sind je nach Laubbaumkronendichte (TCD) in 100-95 % (dunkelgrün), 95-90 % (grün), 90-80 % (hellgrün), < 80 % (gelb) eingeteilt und den NDVI-Werten von MODIS ohne Klasseneinteilung (rot) gegenübergestellt. Orange ist der Median und Blau der Mittelwert.

## 4.5 Analyse der phänologischen Bodenbeobachtungen

Birke und Buche sind die Baumarten mit den meisten Beobachtungen zu „Beginn des Laubaustriebs“ in der PEP725 Datenbank. Stellvertretend für beide Baumarten steht der Laubwald im Landnutzungskataster, da diese, aber besonders die Buche, am verbreitetsten in Laubwäldern vertreten sind. Zudem gibt es kaum reine Birkenwälder, reine Buchenwälder (z.B. im Wienerwald) kommen häufiger vor (Bundesforschungs- und Ausbildungszentrum für Wald, Naturgefahren und Landschaft (BFW), 2017b). Die Birke beginnt in Österreich ab Ende März mit dem Austreiben erster Blätter, dargestellt in Abbildung 2.12 in Abschnitt 2.3.4. Je höher die geografische Breite, desto später tritt die Laubeintrittsphase auf, so beginnt diese im Norden von Schweden etwa erst ab Mitte Mai. Anfang April erfolgt auch das Ergrünen der Buche in Mitteleuropa, in Süd-Schweden ab Ende April.

Beobachtungen zu der phänologischen Phase „Blattentfaltung“ bei Buche und Birke reichen bis zum Ende des Zweiten Weltkriegs zurück. Frühere Beobachtungen wurden in Berlin zusammen mit vielen anderen Dokumenten der ZAMG zerstört, die dort im Reichswetterdienst archiviert wurden (Zentralanstalt für Meteorologie und Geodynamik (ZAMG), 2018e). Abbildung 4.25 zeigt die zeitliche Entwicklung dieser Phasen, die sowohl deutlich zunehmende Verzögerungen bei den Phaseneintrittsdaten bis in die 1980er Jahre als auch seither stark voranschreitende Erscheinungstermine aufweisen. Seit 1949 zeigt der Zeitverlauf des Laubaustriebes in Österreich für die Birke einen Trend zu früherem Einsetzen von 10 bis 15 Tagen, für die Buche ein früheres Einsetzen um etwa 5 - 10 Tage. Dies ist in der Tat ein weiterer, unabhängiger Hinweis für den anthropogenen Klimawandel, da er auf phänologischen Beobachtungen und nicht auf der Lufttemperatur beruht, die in erster Linie in diesem Zusammenhang verwendet wird.

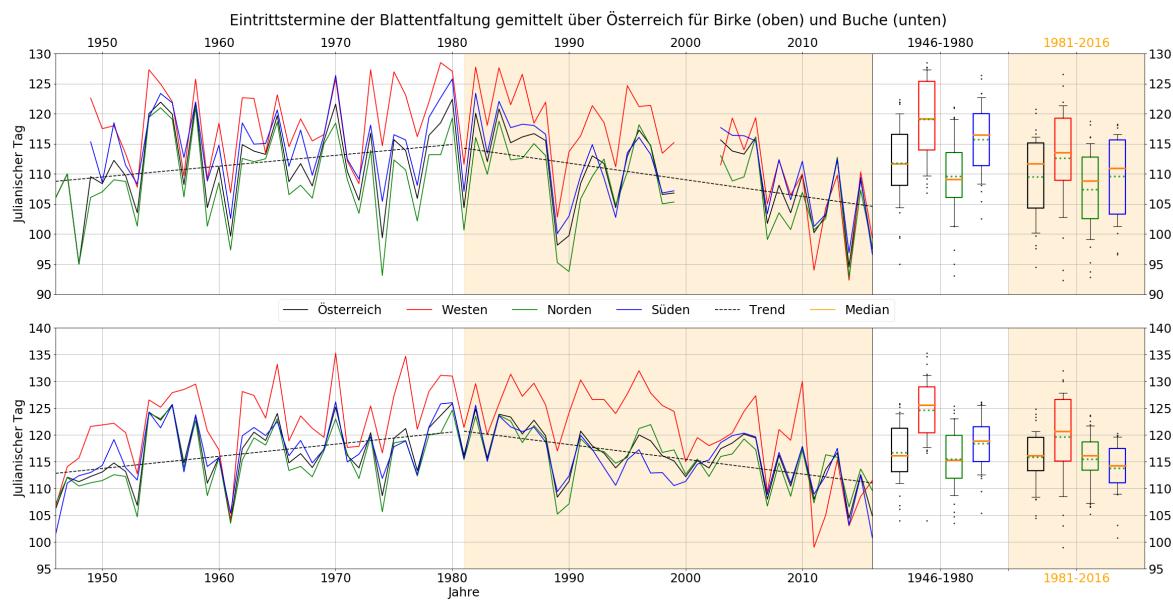


Abb. 4.25: Verlauf des Eintrittsdatums der Blattentfaltung für Birke (oben) und Buche (unten) in Österreich. Mittelwert über ganz Österreich (schwarz), den Westen (rot), den Norden (grün) und den Süden Österreichs (blau).

Nachfolgend werden die in dieser Arbeit verwendeten phänologischen Bodenbeobachtungen, welche im Untersuchungsgebiet liegen, für Birke und Buche in den Jahren 2016 und 2017 betrachtet. Zuerst werden die beobachteten Eintrittstermine mit einem multiplen linearen Regressionsmodell, wobei der Eintrittstag abhängig von Höhe, Länge und Breite ist, abgebildet. Es zeigt sich, dass in beiden Jahren im Fall der Birke und der Buche, die Varianz deutlich durch das Regressionsmodell gedämpft wird, was etwaige Ausreißer und somit fehlerhafte Beobachtungen ausschließen kann. So werden durch das Modell für die Eintrittstage der Blattentfaltung der Birke im Jahr 2016 etwa 41 % der gesamt auftretenden Varianz erklärt, im Jahr 2017 ca. 35 %. Für die Eintrittstage der Blattentfaltung der Buche erklärt das Modell 2016 etwa 34 %, 2017 ungefähr 26 % der Varianz. Dies zeigt einerseits, wie bereits in den vorherigen Abschnitten erwähnt, dass die Bodenbeobachtungen 2017 besonders für die Buche fehlerhafter sein könnten. Andererseits könnte dies auch bedeuten, dass durch ein multiples lineares Regressionsmodell mit der Höhe, Länge und Breite als Prädiktoren kein höherer Anteil der auftretenden Varianz erklärt werden kann.

Abschließend werden die Eintrittstermine von Birke und Buche beider Jahre in den einzelnen Kacheln im Vergleich zu den simulierten Terminen aus der zeitlichen und räumlichen Validierung als Boxplots betrachtet. Der Blattaustrieb der Birke zeigt im Jahr 2017 in allen Kacheln ein früheres Eintreten als 2016. Dabei zeigt die Kachel UMU im Jahr 2016 sowohl eine größere Variabilität der, als auch die spätesten Eintrittstermine dieses Jahres, was wohl an der Topographie (dem Schwarzwald und der Schwäbischen Alp) in dieser Region liegt. Die Kachel TPT zeigt 2016 und 2017, durch die Lage im Alpenvorland, im Durchschnitt spätere Eintrittstermine als in den übrigen Gebieten. Was bereits in den beiden Kapiteln zu den Ergebnissen der zeitlichen und räumlichen Validierung beschrieben wurde, wird in der Abbildung 4.26 zusammengefasst dargestellt. Die modellierten Eintrittstermine aus der zeitlichen Validierung tendieren 2016 zu früheren Eintrittstagen als die beobachteten, 2017 zu späteren. Dies resultiert aus den späteren Eintrittsterminen 2016 als 2017. Bei den Ergebnissen der räumlichen Validierung ist ein einheitlicher Trend zu früheren Eintrittsterminen 2017 erkennbar, da das räumliche Modell nicht von den Beobachtungen des Jahres 2016 abhängig ist. In einigen Regionen und Jahren liegt der

Mittelwert der simulierte Eintrittstag sehr nahe am beobachteten, in anderen der Median. Auch zeigen die simulierten Termine sowohl eine größere als auch eine kleinere Variabilität als die Beobachtungen.

Der Blattaustrieb der Buche zeigt keine einheitliche Tendenz zu früheren Eintrittsterminen 2017. Da die Buche kälteempfindlicher ist als die Birke (Bundesforschungs- und Ausbildungszentrum für Wald, Naturgefahren und Landschaft (BFW), 2017c), dürften Spätfröste ab Mitte April 2017 regional zu einem späteren Eintritt des Laubaustriebs geführt haben als 2016. Somit ist auch bei den simulierten Eintrittstagen der zeitlichen Validierung kein einheitlicher Trend zu früheren oder späteren Terminen erkennbar. Das Modell der räumlichen Validierung zeigen ebenfalls keinen Trend zu früheren Eintrittstagen 2017.

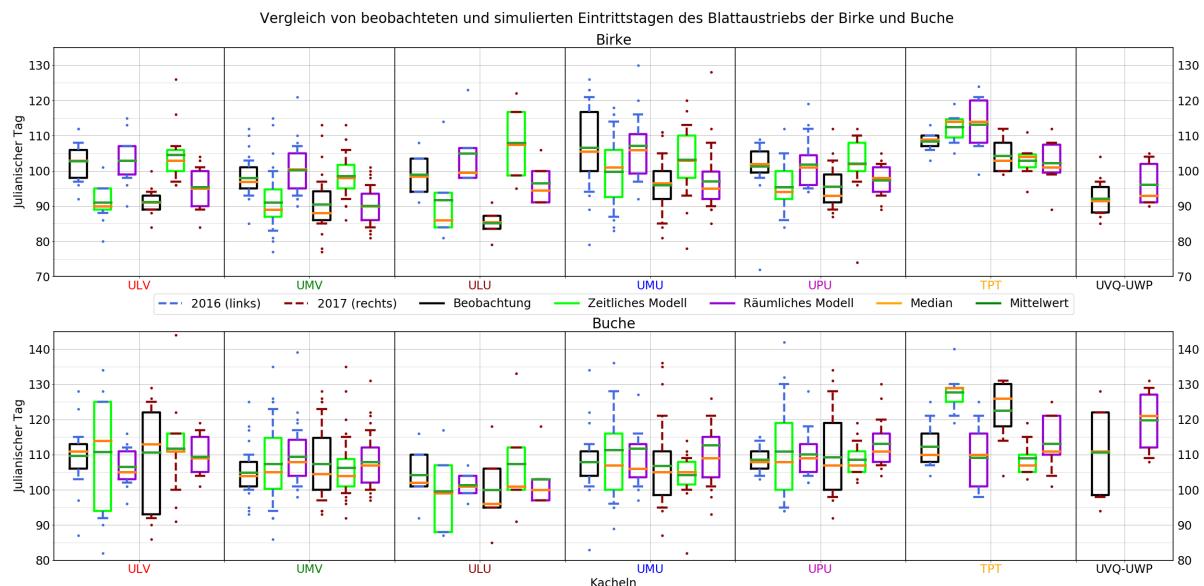


Abb. 4.26: Beobachtete Eintrittstermine der Birke und Buche für die Jahre 2016 (jeweils links, Whiskers und Ausreißer Blau) und 2017 (jeweils rechts, Whiskers und Ausreißer Rot) innerhalb der untersuchten Kacheln. Dazu die bei der zeitlichen und räumlichen Validierung mit der kumulativen NDVI-Methode aus den MODIS-Daten modellierten Eintrittstermine in Hellgrün und Violett. Orange zeigt den Median, Grün den Mittelwert.

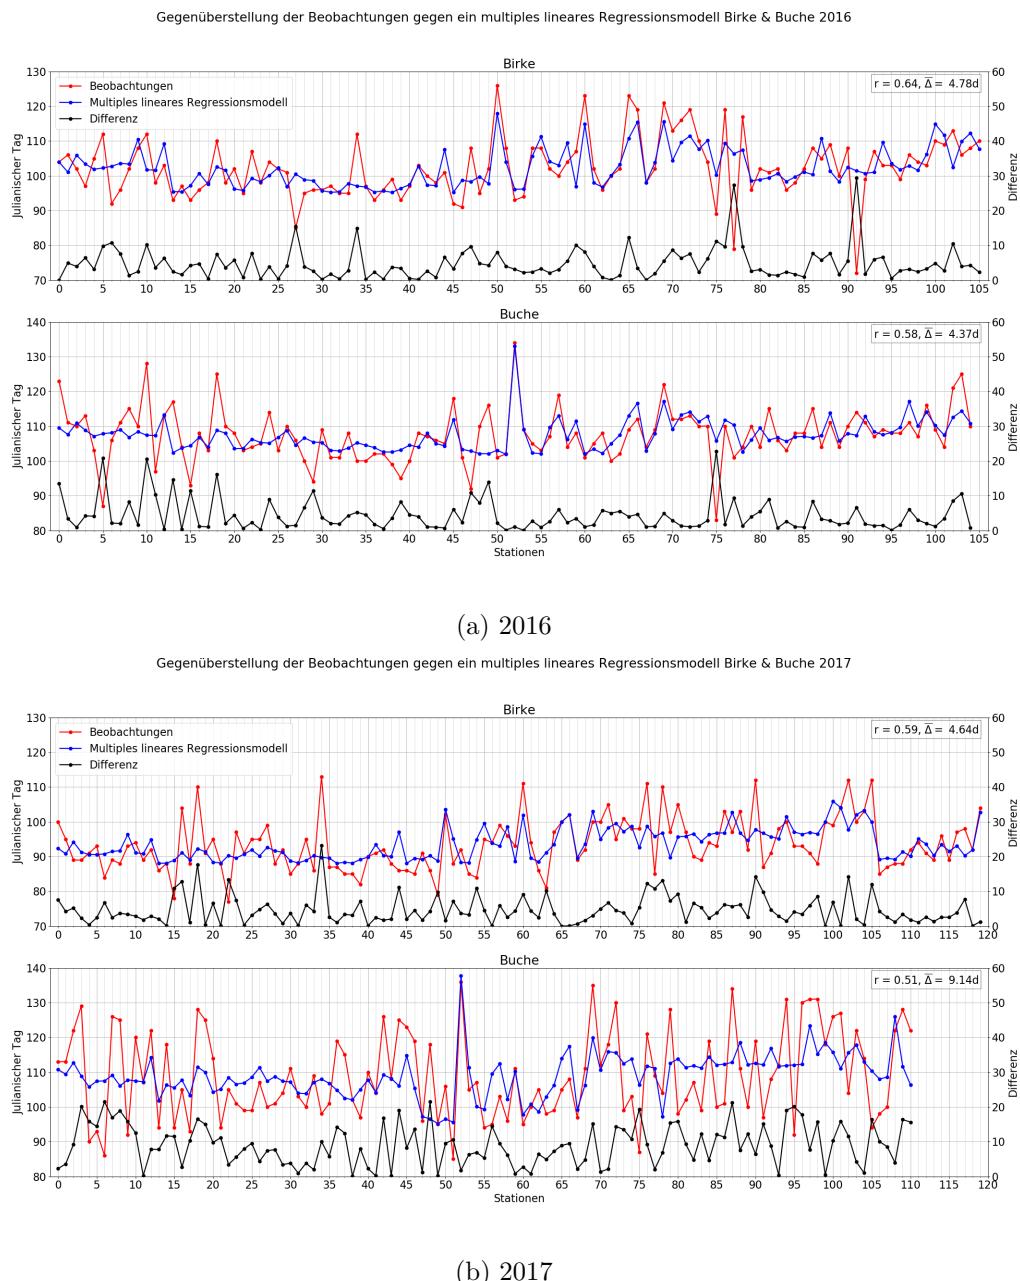


Abb. 4.27: Beobachtete Eintrittstermine der Birke und Buche für die Jahre 2016 (a) und 2017 (b) in Rot. Dazu die mit Hilfe einer multiplen linearen Regression modellierten Eintrittstermine in Blau und deren Differenz in Schwarz. Angegeben ist zusätzlich der Korrelationskoeffizient zwischen Beobachtung und Modell sowie die mittlere Abweichung. Die Birke ist jeweils oben, die Buche unten abgebildet.

## 5 Diskussion

Das Ziel dieser Arbeit ist die Bewertung des, mit Sentinel-2 und MODIS Satelliten verfügbar gemachten, Datenmaterials in Hinblick auf die Simulation phänologischer Eintrittstermine aus dem All. Dabei sollen insbesondere die Vorteile, welche die neuen, gegenüber den MODIS-Beobachtungen, räumlich viel höher aufgelösten Sentinel-2-Daten mit sich bringen, analysiert werden.

So klar sich Ziel und Aufgabe darstellen, so sehr zeigten sich im Laufe der Arbeit zunehmend Probleme, die mit der Daten-Beschaffung und -Aufbereitung (vor allem hinsichtlich der neuen Sentinel-2 Produkte) einhergingen. Eigene Förderprogramme, Tagungen und Workshops, auf denen zahlreiche Projekte vorgestellt wurden, deuteten jedoch einen reichhaltigen Pool aufbereiteter Datensätze an. Probleme im Zusammenhang mit Satellitendaten waren daher anfangs nicht zu erwarten.

Da die Eintrittstermine phänologischer Phasen im Verlauf des Vegetationszyklus von einer zunehmenden Zahl von Faktoren beeinflusst werden, lag der Fokus dieser Arbeit auf Frühjahresphasen, deren Auftreten noch verhältnismäßig wenigen störenden Einflüssen ausgesetzt ist. Der Start von Sentinel-2A am 23. Juni 2015 und die folglich erst für die 2. Jahreshälfte verfügbaren Daten, reduzierten die Analyseperiode durch den Wegfall von 2015 von drei Jahren auf zwei: 2016 und 2017.

Die Beschaffung (aus Sentinel-2-Produkten nach Wolken- und Schneefilterung) prozessierter NDVI-Daten für die zwei verbliebenen Jahre stellte sich, entgegen den Erwartungen, als erhebliche Hürde dar. Die zur Zeit der Datenbeschaffung, von Herbst 2017 bis Anfang 2018, der Öffentlichkeit zugänglichen Quellen für Sentinel-2-Daten verfügten über keine zufriedenstellenden NDVI-Daten. Prozessierung und Filterungen hätten größtenteils selbst vorgenommen werden müssen. Diese Arbeitsschritte erfordern profunde Kenntnisse sowie erhebliche Computer-Ressourcen in Bezug auf Leistung und Speicherplatz. Prozessierte Datensätze zeigten hinsichtlich Nützlichkeit und Verfügbarkeit oft signifikante Limitierungen. Die Nutzbarmachung prozessierter NDVI-Daten stellte sich also wesentlich komplizierter dar als präsentiert. Nach aufwendiger und zeitintensiver Suche konnten letztendlich Institutionen gefunden werden, deren Knowhow und Expertise die zur Generierung der (in Abschnitt 2.1.2 beschriebenen) Datensätze erforderliche Prozessierung und Filterung der zu diesem Zeitpunkt noch sehr neuen Sentinel-2-Daten erlaubte. Die Beschaffung der verhältnismäßig lange in die Vergangenheit zurückreichenden MODIS-Daten war, wegen der über die Jahre vielerorts etablierten Expertise, vergleichsweise einfach.

Besonders problemlos verlief die Bereitstellung der über viele Dekaden in die Vergangenheit zurückreichenden Beobachtungen phänologischer Eintrittstermine. Dafür stand die 2005 im Rahmen einer COST Aktion (COST725) begründete Europäische Bodenphänologie-Datenbank „PEP725“ zur Verfügung. PEP725 wird an der ZAMG gepflegt und steht dort seit 2010 der wissenschaftlichen Gemeinschaft frei zur Verfügung.

Da sich die durchzuführenden Analysen rein auf die von allen Datensätzen abgedeckten Gebiete und Zeitabschnitte erstrecken können, waren die Sentinel-2-Daten – die den Durchschnitt definierten – für diese Arbeit limitierend.

Bei der Simulation phänologischer Eintrittstermine aus Satelliten-Beobachtungen wurde neben aus der Literatur bekannten Verfahren (beruhen auf dem stärksten Anstieg der NDVI-Werte

bzw. auf dem Überschreiten eines Schwellwert dieser) eine neue Methodik (Überschreitung von Schwellwerten akkumulierter NDVI-Summen) zur Anwendung gebracht. Mit diesen Ansätzen wurden erreichte Leistungen in Validierungsexperimenten (in Raum und Zeit) analysiert und miteinander verglichen. Darauf basierend erfolgte die Bewertung der mit gegenwärtig vorliegenden (auf den von Sentinel-2 definierten raum-zeitlichen Ausschnitten beschränkten) Satellitenprodukten erzielbaren Leistungen bei der Simulation von Eintrittsterminen phänologischer Phasen und damit deren momentane Eignung.

Sowohl die zeitliche als auch die räumliche Validierung zeigten bessere Ergebnisse, wenn man die Summenbildung des kumulativen NDVI erst ab 1. März des jeweiligen Jahres beginnt, da so Unregelmäßigkeiten im NDVI-Verlauf im Winter (hervorgerufen durch Schneedeckung oder Beleuchtungsgeometrien) keinen Einfluss zeigen und in dieser Arbeit nur die Vegetationsperiode von Interesse ist.

In der zeitlichen Validierung zeigt sich die Methode des kumulativen NDVI als durchaus robust. Im Fall der Blattentfaltung der Birke kann für das Jahr 2016 eine signifikante Korrelation von  $r = 0.63$  über alle Kacheln bzw. Regionen gezeigt werden und damit ist diese Methode sogar leistungsstärker als eine Persistenz, also eine Verwendung der Beobachtungsdaten vom jeweils anderen Jahr. In der Region UMU wird sogar ein Korrelationskoeffizient von  $r = 0.73$  erreicht, mit  $RSQ = 53\%$  erklärter Varianz. Auch im Fall der Buche zeigt das Jahr 2016 eine signifikante Korrelation von  $r = 0.5$  über alle Regionen. Dies ist zwar niedriger als bei der Birke, liefert jedoch immer noch bessere Ergebnisse als die Persistenz. Die Region UMU zeigt sogar einen Korrelationskoeffizienten von  $r = 0.81$ , mit einer erklärten Varianz von  $RSQ = 64\%$ . Im Jahr 2017 kann für die Blattentfaltung beider Arten keine so hohe Korrelation zwischen den simulierten und beobachteten Eintrittstagen gebildet werden. Dies kann daran liegen, dass die zeitliche Interpolation der NDVI-Daten in beiden Jahren nicht gleich gut funktioniert, die Bodenbeobachtungen in einem Jahr mehr mit Fehlern behaftet sind als im anderen und/oder sich die Landnutzung innerhalb eines Jahres geändert hat. Doch auch im Jahr 2017 sticht die Region UMU wieder mit einer höheren Korrelation als die Gesamtheit heraus. Ebenso kann es hier mehrere Gründe geben, warum gerade diese Region eine bessere Performanz zeigt. Die bereits genannten Gründe könnten in der Region weniger Auswirkungen haben, vor allem scheinen sich die erreichten kumulativen NDVI-Summen in beiden Jahren sehr ähnlich zu sein. Damit würde die dieser Methode zugrunde liegende Annahme, dass nämlich eine bestimmte NDVI-Summe mit einem bestimmten phänologischen Ereignis verbunden ist, bestätigt werden. Der Mischpixel-Effekt scheint bei der zeitlichen Validierung keine allzu große Rolle zu spielen. Dies lässt sich daran erkenne, dass die Methode in den Klassen verschiedenen Laubbaumanteils ähnliche Korrelationen zeigt. Dennoch können in beiden Jahren Mischpixeleffekte zu einer allgemeinen Verringerung der Korrelationen beitragen, unabhängig vom Jahr.

Wird die räumliche Validierung der kumulativen NDVI-Methode betrachtet, zeigen sich keine derart hohen Korrelationskoeffizienten. Am stärksten schneidet dabei noch ein multiples lineares Regressionsmodell, das sowohl geographische Standortparameter als auch Maße zur Beschreibung des Mischpixeleffekts als Prädiktoren enthält, bei den Eintrittstagen der Laubentfaltung der Birke im Jahr 2016 mit  $r = 0.41$  ab. Dabei zeigt sich im Gegensatz zu einem zeitlichen Modell die Abhängigkeit der NDVI-Summen von der Höhe, da, wie oben bereits erwähnt, auch der NDVI eine Höhenabhängigkeit aufweist, als auch vom Mischpixeleffekt, besonders vom Anteil an enthaltenen Nadelbäumen im untersuchten MODIS-Pixel. Hier könnten auch Fehler in den GP-Daten einen Effekt haben. Besonders die Blattentfaltung der Buche 2017 zeigt eine deutlich höhere räumliche Variabilität der Eintrittstage im Gegensatz zu einem multiplen linearen Regressionsmodell mit Höhe, Länge und Breite als Prädiktoren. Dies könnten Ausreißer sein, die durch Fehler in der Beobachtung oder Eingabe entstanden sind und ebenfalls einen negativen

---

Einfluss auf die Korrelationen haben, auch bei der zeitlichen Validierung. Dennoch zeigt dieses MLRM höhere signifikante Korrelationen.

Zum derzeitigen Stand bietet die Verwendung an MODIS-Daten kaum zusätzlichen Nutzen in einer räumlichen Interpolation von phänologischen Bodenbeobachtungen. Allerdings zeigt die Region UMU bei der Blattentfaltung der Birke 2016 und der Buche 2016/17 wieder eine bessere Performanz mit signifikanten Korrelationen von  $r = 0.53$ ,  $r = 0.66$  und  $r = 0.55$ , was immerhin noch einer erklärten Varianz zwischen 28 % und 44 % entspricht. Die Region UVQ-UWP zeigt für die Buche 2017 sogar einen signifikanten Korrelationskoeffizienten von  $r = 0.86$ , was  $RSQ = 74\%$  erklärter Varianz entspricht, allerdings befinden sich in dieser Region nur wenige Beobachtungspunkte. Die Region UMU dürfte eine ausreichend große Stationsanzahl beinhalten, um signifikante Korrelationen zu liefern, zudem dürfte, wie bereits erwähnt, die zeitliche Interpolation der NDVI-Daten in beiden Jahren gut funktionieren, sowie weniger Fehler in den GP- und Satellitendaten enthalten sein. So lassen sich die Eintrittstage mit einem multiplen linearen Regressionsmodell mit Höhe, Länge und Breite als Prädiktoren gut simulieren und es sind weniger Ausreißer als in den anderen Gebieten zu erkennen.

Für die etablierten Methoden zur Bestimmung des SOS gelten die bereits genannten Gründe, warum kaum bis niedrige Korrelationen zu den Bodenbeobachtungen erreicht werden. So spielen verschiedene Probleme eine Rolle (Hamunyela et al., 2013; Maignan et al., 2008; Studer et al., 2007; White et al., 2009): (i) der Mischpixeleffekt, (ii) das Point vs. Pixel Problem, (iii) unterschiedliche zeitliche Auflösung von GP und LSP (day vs. composite periode), (iv) Messung verschiedener phänologischer Phänomene, (v) Fehler in den GP- und Satellitendaten sowie in den Verarbeitungsverfahren und (vi) nicht lineare Zusammenhänge zwischen GP und LSP. Diese genannten Problematiken, bis auf (iv), können ebenso Auswirkungen auf die kumulative NDVI-Methode haben.

Der große Einfluss des Mischpixeleffekts, repräsentiert durch Laubbaum-, Nadelbaumanteil und Baumkronendichte, zeigt die Notwendigkeit für Satellitensysteme mit deutlich höherer räumlicher Auflösung als 250 Meter. Darum ist die Durchführung mit Sentinel-2-Daten mit der Erwartung verbunden, dass durch die hohe räumliche Auflösung von 10 m der Mischpixeleffekt zur Bildung einer Korrelation eine deutlich kleinere Rolle spielt, im besten Falle sogar keinen Einfluss auf die Ergebnisse hat.

Mit Sentinel-2-Daten wurde diese Erwartung leider nicht erfüllt, da aufgrund der Verfügbarkeit von Daten nur eines Satelliten, der dadurch geringen zeitlichen Auflösung und noch zusätzlichen Lücken durch Wolken- und Schneefilterung bzw. vollständiger Bewölkung oftmals im Frühling nur sporadisch NDVI-Daten zur Verfügung standen. Dadurch konnten die Laubaustriebsphasen von Birke und Buche mit Sentinel-2 nicht untersucht werden. Allerdings zeigt sich ab der 2. Jahreshälfte 2017 durch das Hinzukommen von Sentinel-2B Daten, dass die zeitliche Auflösung deutlich steigt und weniger Lücken vorhanden sind. Betrachtet man die zur Verfügung stehenden Satellitendaten, erkennt man zwei negative Effekte. Die deutliche Streuung der Pixelwerte innerhalb eines MODIS-Pixel dürften einerseits auf eine noch unzureichende Wolken- bzw. Wolkenschattenfilterung, andererseits auf die Verwendung eines Landnutzungskatasters mit geringerer räumlicher Auflösung (20 statt 10 m) zurückzuführen sein. Betrachtet man allerdings den Verlauf des Mittelwertes und Medians der Pixelwerte an einzelnen Stationen mit hohem Mischpixeleffekt der MODIS-Pixel und vergleicht diese mit dem MODIS-NDVI, so lässt sich doch durch die Mittelwert- und Medianbildung eine Verringerung dieses Effektes erkennen.

Da Sentinel-2-Daten der Jahre 2016 und 2017 leider nicht für die Methodik verwendet werden konnten, kann diese Arbeit großteils nur bestehendes Wissen bestätigen. Allerdings zeigt die kumulative NDVI-Methode bei der zeitlichen Validierung (wo der Mischpixel-Effekt nicht so

dominant auftritt) durchaus brauchbare Ergebnisse. Besonders sticht die Region UMU heraus, bei der sogar hohe Korrelationen zwischen GP und LSP gefunden werden konnten. Dies dürfte ein interessanter Ansatz für spätere Untersuchungen sein, wenn von Sentinel-2-NDVI-Daten mit höherer zeitlicher Auflösung zur Verfügung stehen und Verarbeitungsprozesse und Filterungen perfektioniert werden konnten.

Für mich als Meteorologen war dieses Thema im Gebiet der Fernerkundung nicht leicht durchzuführen, da für viele technische und spezifische Themen und Probleme (beispielsweise die Wahl der optimalen Methode zur Reprojektion der verschiedenen Daten, um sie vergleichbar zu machen) Hilfe und Expertise von außen notwendig waren. Besonders im Fall der Sentinel-2-Daten, die zum Zeitpunkt der Datensuche noch neu und Expertise und Knowhow dazu erst im Entstehen waren, sind die Kontakte zu den und die Zusammenarbeit mit den verschiedenen Institutionen und Experten, die im Abschnitt 2 und 7 erwähnt werden, extrem wichtig und wertvoll. Für die Zukunft lässt sich sagen, dass neue Satellitensysteme noch ein paar Jahre benötigen, bis Werkzeuge und Tools vorhanden sind, die das Arbeiten mit deren Daten effizient, aber auch einfacher für Quereinsteiger machen. Dennoch war die Zeit, während der Durchführung dieser Arbeit, äußerst wertvoll und lehrreich für mich. Einerseits die Kontakte mit verschiedenen Experten und Institutionen, andererseits das Volontariat an der ZAMG und die Möglichkeit, an anderen Projekten mitarbeiten zu dürfen, welche im Appendix aufgelistet sind.

## 6 Aussichten

Da für die betrachteten Frühlingsphasen in den Jahren 2016 und 2017 lediglich Sentinel-2A zur Verfügung steht, ist interessant zu sehen, wie sich in Zukunft die räumliche Korrelation zwischen LSP und GP verändert, wenn die Daten beider Sentinel-2 Satelliten genutzt werden können. Dadurch erhöht sich nicht nur die zeitliche Auflösung von 10 auf 5 Tage bzw. auf 2-3 Tage in den mittleren Breiten, auch können bestehende Algorithmen und Filter zur Prozessierung, etwa für Wolken und Wolkenschatten, sowie das Schließen von Lücken in den Datensätzen, verbessert werden. Ab dem Jahr 2021 sollen noch zwei weitere Sentinel-2 Satelliten (C & D) gestartet werden (Wikipedia, 2017c).

Die erfolgreiche Anwendung der beschriebenen Methode auf Basis von Sentinel-2-Daten und die Detektierung möglicher Verbesserungen, setzt die Verfügbarkeit verarbeiteter NDVI-Daten von Sentinel-2A und B voraus. Um die Auswirkungen von Wolken und Schnee zu kompensieren, wäre die Erstellung von gefilterten 7-Tage-NDVI-Composite-Daten, die mit den MODIS-NDVI-Daten (siehe Abschnitt 2.1.3) vergleichbar sind, wünschenswert.

So arbeiten beispielsweise das EODC (Earth Observation Data Centre) an einem „Data Cube“, welcher verschiedene Satellitenprodukte vereinen soll, die BOKU an einem landwirtschaftlichen Monitoring und das BFW an einem S2-Daten Archiv, das neben dem NDVI noch andere Vegetationsindizes enthalten soll (Bundesministerium für Nachhaltigkeit und Tourismus, 2018).

Betreffend der derzeit noch fehlerbehafteten Bodenbeobachtungen von Citizens Scientists, wäre es wünschenswert, neue Techniken zu entwickeln, die dazu beitragen sollen, dass eine falsche Zuordnung zwischen Beobachtungen und Standorten vermieden wird. Einen ersten Schritt setzt die ZAMG mit der Smartphone-App „Naturkalender ZAMG“. Über diese App werden die Beobachtungen verschiedenster Pflanzen und Phasen direkt mit dem Beobachtungsort, also dem GPS-Signal des Smartphones verknüpft. Neben dem Effekt der deutlich besseren Lokalisation der Daten soll natürlich auch die Anzahl an phänologischen Beobachtungen wieder steigen, da jedermann sein Smartphone immer dabei hat und die Beobachtung über die App mit nur minimalem Aufwand verbunden ist. Für weiter Details siehe Zentralanstalt für Meteorologie und Geodynamik (ZAMG), 2018b.

Darüber hinaus wird die Bereitstellung eines neuen Landnutzungskatasters auf der Grundlage von Sentinel-2-Informationen eine realistischere Bestimmung des Anteils der Laubbäume in dem untersuchten Gebiet ermöglichen. Für Österreich wurde bereits ein Projekt mit dem Namen LISA (Land Information System Austria) fertiggestellt, welches für Untersuchungsgebiete in Österreich noch genauere Informationen liefern kann. Allerdings gibt es in diesem Produkt noch keine Unterscheidung in Laub- und Nadelbäume. Für weitere Informationen siehe GeoVille GmbH, 2018.

In Zukunft könnte des Weiteren eine Unterscheidung in verschiedene Baumarten möglich sein. Erste Tests dazu gibt es bereits vom BFW im Rahmen des Copernicus-Programms (Bundesministerium für Nachhaltigkeit und Tourismus, 2018).

## 7 Danksagung

Mein Dank gilt besonders meinem Betreuer Dr. Christoph Matulla dessen ansteckende Begeisterung mir das Feld der Klimamodellierung, in dem meine Masterarbeit angesiedelt ist, erschloss. Sein unermüdliches Engagement bei der Betreuung ermöglichte mir abseits der Masterarbeit, die ich Großteils an einem eigens eingerichteten Arbeitsplatz an der ZAMG durchführte, an mittlerweile peer-reviewt publizierten Studien als Leit- bzw. Ko-Autor mitzuwirken. Davon, sowie von Konferenzen, bei denen ich meine Arbeit präsentieren konnte, habe ich persönlich in meiner wissenschaftlichen Entwicklung sehr profitiert.

Ferner möchte ich mich bei meinem Zweitbetreuer Dr. Helfried Scheifinger ausdrücklich bedanken, der mir die gesamte Zeit während dieser Arbeit mit Rat und Tat zur Seite stand, die Idee für diese Arbeit lieferte und unermüdlich bei der Beschaffung der Daten, der Planung und Durchführung, als auch bei Problemen seine Hilfe und Expertise zur Verfügung stellte. Zudem möchte ich mich ganz besonders für die Möglichkeit eines Volontariats an der ZAMG während der Verfassung meiner Masterarbeit bedanken.

Für die Bereitstellung der Satellitendaten, die Unterstützung und Kompetenz im Bereich der satellitengestützten Fernerkundung möchte ich mich bei folgenden Personen bedanken: .

- DI Heinz Gallaun und Dr. Mathias Schardt vom Joanneum Research Graz, Institut für Informations- und Kommunikationstechnologien,
- Dr. Klemens Schadauer, DI Christoph Bauerhansl und Markus Löw, MSc. vom Institut für Waldinventur des Bundesamts für Wald
- sowie Dr. Clement Atzberger und Dr. Anja Klisch vom Institut für Vermessung, Fernerkundung und Landinformation der Universität für Bodenkultur Wien

Des Weiteren danke ich Michael Avian, Chris Schubert und Matthias Schlögel von der ZAMG für Ihre Zeit, Expertise und Hilfe bei der Durchführung dieser Arbeit und den Lösungsvorschlägen bei aufgetretenen Problemen.

Zuletzt gilt mein herzlicher Dank noch meiner Familie, meinen Freunden und meiner Freundin Andrea, die über die gesamte Zeit dieser Arbeit und meines Studiums immer für mich da waren. Besonders meinen Eltern danke ich, die durch ihre Unterstützung mein Studium erst ermöglicht haben.

# Literatur

- Ahas, R., A. Aasa, A. Menzel, V. Fedotova und H. Scheifinger (2002). „Changes in European spring phenology“. In: *International journal of climatology* 22.14, S. 1727–1738.
- Atzberger, C., A. Klisch, M. Mattiuzzi und F. Vuolo (2014). „Phenological metrics derived over the European continent from NDVI3g data and MODIS time series“. In: *Remote Sensing* 6.1, S. 257–284.
- Badeck, F.-W., A. Bondeau, K. Böttcher, D. Doktor, W. Lucht, J. Schaber und S. Sitch (2004). „Responses of spring phenology to climate change“. In: *New Phytologist* 162.2, S. 295–309.
- Bammel, K. und U. Kilian (2009). *Der Brockhaus Wetter und Klima: Phänomene, Vorhersage, Klimawandel*. Brockhaus, S. 254–256. ISBN: 9783765333811.
- Beggs, P. J. (2015). „Environmental allergens: from asthma to hay fever and beyond“. In: *Current Climate Change Reports* 1.3, S. 176–184.
- Bousquet, J., N. Khaltaev, A. A. Cruz, J. Denburg, W. Fokkens, A. Togias, T. Zuberbier, C. Baena-Cagnani, G. Canonica, C. Van Weel et al. (2008). „Allergic rhinitis and its impact on asthma (ARIA) 2008“. In: *Allergy* 63, S. 8–160.
- Bundesforschungs- und Ausbildungszentrum für Wald, Naturgefahren und Landschaft (BFW) (2017a). *Bundesforschungszentrum für Wald*. URL: <http://bfw.ac.at/> (aufgerufen am 21. 12. 2017).
- (2017b). *Österreichische Waldinventur (ÖWI)*. URL: <http://bfw.ac.at/rz/wi.home> (aufgerufen am 21. 12. 2017).
- (2017c). *waldwissen.net*. URL: <https://www.waldwissen.net/> (aufgerufen am 21. 12. 2017).
- Bundesministerium für Ernährung und Landwirtschaft (2017). *Bundeswaldinventur*. URL: <https://www.bundeswaldinventur.de/> (aufgerufen am 21. 12. 2017).
- Bundesministerium für Nachhaltigkeit und Tourismus (2018). *Leben mit Naturgefahren*. URL: [http://www.naturgefahren.at/projekte/COPERNICUS/Copernicus\\_Nutzbar\\_Machen\\_II.html](http://www.naturgefahren.at/projekte/COPERNICUS/Copernicus_Nutzbar_Machen_II.html) (aufgerufen am 03. 05. 2018).
- Cleland, E. E., I. Chuine, A. Menzel, H. A. Mooney und M. D. Schwartz (2007). „Shifting plant phenology in response to global change“. In: *Trends in ecology & evolution* 22.7, S. 357–365.
- Cong, N., S. Piao, A. Chen, X. Wang, X. Lin, S. Chen, S. Han, G. Zhou und X. Zhang (2012). „Spring vegetation green-up date in China inferred from SPOT NDVI data: A multiple model analysis“. In: *Agricultural and Forest Meteorology* 165, S. 104–113.
- Cook, B. I., E. M. Wolkovich, T. J. Davies, T. R. Ault, J. L. Betancourt, J. M. Allen, K. Bolmgren, E. E. Cleland, T. M. Crimmins, N. J. Kraft et al. (2012). „Sensitivity of spring phenology to warming across temporal and spatial climate gradients in two independent databases“. In: *Ecosystems* 15.8, S. 1283–1294.
- Copernicus (2018). *DIABOLO - Distributed, Integrated and harmonised forest information for Bioeconomy Outlooks*. URL: <http://diabolo-project.eu/> (aufgerufen am 28. 03. 2018).

- Copernicus (2017). *Land Monitoring Service*. URL: <http://land.copernicus.eu/> (aufgerufen am 25.07.2017).
- Darbyshire, R., L. Webb, I. Goodwin und S. Barlow (2011). „Winter chilling trends for deciduous fruit trees in Australia“. In: *Agricultural and forest meteorology* 151.8, S. 1074–1085.
- Defila, C. (2007). „Alpine Pflanzenphänologie in der Schweiz“. In: *promet* 33.1/2, S. 36–39.
- Defila, C. und B. Clot (2001). „Phytophenological trends in Switzerland“. In: *International Journal of Biometeorology* 45.4, S. 203–207.
- Delbart, N., L. Kergoat, T. Le Toan, J. Lhermitte und G. Picard (2005). „Determination of phenological dates in boreal regions using normalized difference water index“. In: *Remote Sensing of Environment* 97.1, S. 26–38.
- Department of Geodesy and Geoinformation, TU Wien (2018). *Ermittlung von Schäden durch Borkenkäfer - Beitrag der Fernerkundung Phase I*. URL: <https://rs.geo.tuwien.ac.at/projects/current-projects/1472364/> (aufgerufen am 04.01.2018).
- Deutsches Zentrum für Luft- und Raumfahrt e.V. (DLR) (2017). *ECoLaSS - Evolution of Copernicus Land Services based on Sentinel data*. URL: <https://www.ecolass.eu/> (aufgerufen am 21.12.2017).
- European Forest Genetic Resources Programme (EUFORGEN) (2017). *EUFORGEN*. URL: <http://www.euforgen.org/> (aufgerufen am 21.12.2017).
- European Space Agency (ESA) (2017a). *Sentinel Online*. URL: <https://sentinels.copernicus.eu/web/sentinel/technical-guides/sentinel-2-msi/level-2a/algorithm> (aufgerufen am 25.07.2017).
- (2017b). *Sentinel Online*. URL: <https://sentinel.esa.int/web/sentinel/home> (aufgerufen am 25.07.2017).
- (2017c). *Sentinel-2 Products Specification Document*. URL: [https://sentinel.esa.int/documents/247904/349490/S2\\_MSI\\_Product\\_Specification.pdf](https://sentinel.esa.int/documents/247904/349490/S2_MSI_Product_Specification.pdf) (aufgerufen am 25.07.2017).
- Fu, Y. H., S. Piao, M. Op de Beeck, N. Cong, H. Zhao, Y. Zhang, A. Menzel und I. A. Janssens (2014). „Recent spring phenology shifts in western Central Europe based on multiscale observations“. In: *Global ecology and biogeography* 23.11, S. 1255–1263.
- Garonna, I., R. De Jong, A. J. De Wit, C. A. Mücher, B. Schmid und M. E. Schaepman (2014). „Strong contribution of autumn phenology to changes in satellite-derived growing season length estimates across Europe (1982–2011)“. In: *Global Change Biology* 20.11, S. 3457–3470.
- Gassner, G. (1918). *Beiträge zur physiologischen Charakteristik sommer- und winterannueller Gewächse, insbesondere der Getreidepflanzen*.
- GeoVille GmbH (2018). *LISA (Land Information System Austria)*. URL: <https://www.landinformationssystem.at> (aufgerufen am 03.05.2018).
- Gong, Z., K. Kawamura, N. Ishikawa, M. Goto, T. Wulan, D. Alateng, T. Yin und Y. Ito (2015). „MODIS normalized difference vegetation index (NDVI) and vegetation phenology dynamics in the Inner Mongolia grassland“. In: *Solid Earth* 6.4, S. 1185–1194.

- Gorlier, A., M. Lonati, M. Renna, C. Lussiana, G. Lombardi und L. Battaglini (2012). „Changes in pasture and cow milk compositions during a summer transhumance in the western Italian Alps“. In: *Journal of Applied Botany and Food Quality* 85, S. 216–223.
- Gosling, W. D., C. S. Miller und D. A. Livingstone (2013). „Atlas of the tropical West African pollen flora“. In: *Review of Palaeobotany and Palynology* 199, S. 1–135.
- Gounari, S. (2006). „Studies on the phenology of Marchalina hellenica (gen.) (Hemiptera: Coccoidea, Margarodidae) in relation to honeydew flow“. In: *Journal of apicultural research* 45.1, S. 8–12.
- Grímsson, F., R. Zetter, H. Halbritter und G. W. Grimm (2014). „Aponogeton pollen from the Cretaceous and Paleogene of North America and West Greenland: Implications for the origin and palaeobiogeography of the genus“. In: *Review of Palaeobotany and Palynology* 200, S. 161–187.
- Hamunyela, E., J. Verbesselt, G. Roerink und M. Herold (2013). „Trends in spring phenology of western European deciduous forests“. In: *Remote Sensing* 5.12, S. 6159–6179.
- Hargrove, W. W., J. P. Spruce, G. E. Gasser und F. M. Hoffman (2010). „High-Resolution National Phenological Ecoregions, and Their Utility for Forest Monitoring“. In: 25th Annual Symposium of the International Association for Landscape Ecology (US-IALE) (Athens, Georgia, USA, Apr. 2010). URL: <https://www.geobabble.org/~hnw/first/iale10/slideshow.html> (aufgerufen am 25.07.2017).
- Helbig, N., B. Vogel, H. Vogel und F. Fiedler (2004). „Numerical modelling of pollen dispersion on the regional scale“. In: *Aerobiologia* 20.1, S. 3–19.
- Humboldt-Universität zu Berlin (2017). *Die Internationalen Phänologischen Gärten Europas (IPG)*. URL: <http://ipg.hu-berlin.de/> (aufgerufen am 30.11.2017).
- Janssen, W., C. Frühauf und T. Junghänel (2017). „Limitierende Wettersituationen für die Landwirtschaft im Jahr 2017“. In: *DWD Klimastatusbericht* 2017, S. 55–66.
- Jin, H. und L. Eklundh (2014). „A physically based vegetation index for improved monitoring of plant phenology“. In: *Remote Sensing of Environment* 152, S. 512–525.
- Jolly, W. M. und S. W. Running (2004). „Effects of precipitation and soil water potential on drought deciduous phenology in the Kalahari“. In: *Global Change Biology* 10.3, S. 303–308.
- Kapp, C. J. (2008). „Manipulation of the chilling requirement of sweet cherry trees“. Dissertation. Stellenbosch: University of Stellenbosch.
- Klisch, A. und C. Atzberger (2016). „Operational drought monitoring in Kenya using MODIS NDVI time series“. In: *Remote Sensing* 8.4, S. 267.
- Klosterman, S., K. Hufkens, J. Gray, E. Melaas, O. Sonnentag, I. Lavine, L. Mitchell, R. Norman, M. Friedl und A. Richardson (2014). „Evaluating remote sensing of deciduous forest phenology at multiple spatial scales using PhenoCam imagery“. In: *Biogeosciences*, S. 4305.
- Lang, A. und W. G. Kerckhoff (1951). „Untersuchungen über das Kältebedürfnis von zweijährigem *Hyoscyamus niger*“. In: *TAG Theoretical and Applied Genetics* 21.7, S. 241–243.

- Lange, M., B. Dechant, C. Rebmann, M. Vohland, M. Cuntz und D. Doktor (2017). „Validating MODIS and sentinel-2 NDVI products at a temperate deciduous forest site using two independent ground-based sensors“. In: *Sensors* 17.8, S. 1855.
- Lapen, A., H. Henry, M. Vuille und J. Mower (2014). „Climatic factors controlling plant sensitivity to warming“. In: *Climatic change* 122.4, S. 723–734.
- Le Roux, X., T. Bariac und A. Mariotti (1995). „Spatial partitioning of the soil water resource between grass and shrub components in a West African humid savanna“. In: *Oecologia* 104.2, S. 147–155.
- Luedeling, E. (2012). „Climate change impacts on winter chill for temperate fruit and nut production: a review“. In: *Scientia Horticulturae* 144, S. 218–229.
- Luedeling, E., A. Kunz und M. M. Blanke (2013). „Identification of chilling and heat requirements of cherry trees—a statistical approach“. In: *International Journal of Biometeorology* 57.5, S. 679–689.
- Luterbacher, J., M. A. Liniger, A. Menzel, N. Estrella, P. M. Della-Marta, C. Pfister und E. Xoplaki (2007). „Exceptional European warmth of autumn 2006 and winter 2007: Historical context, the underlying dynamics, and its phenological impacts“. In: *Geophysical Research Letters* 34.12.
- Maignan, F., F.-M. Bréon, C. Bacour, J. Demarty und A. Poirson (2008). „Interannual vegetation phenology estimates from global AVHRR measurements: Comparison with in situ data and applications“. In: *Remote Sensing of Environment* 112.2, S. 496–505.
- Matsushita, B., W. Yang, J. Chen, Y. Onda und G. Qiu (2007). „Sensitivity of the enhanced vegetation index (EVI) and normalized difference vegetation index (NDVI) to topographic effects: a case study in high-density cypress forest“. In: *Sensors* 7.11, S. 2636–2651.
- Measham, P. F., A. G. Quentin und N. MacNair (2014). „Climate, winter chill, and decision-making in sweet cherry production“. In: *Hortscience* 49.3, S. 254–259.
- Menzel, A. (2002). „Phenology: its importance to the global change community“. In: *Climatic change* 54.4, S. 379–385.
- (2007). „Phänologische Modelle“. In: *Promet* 33.1/2, S. 20–27.
- Menzel, A., T. H. Sparks, N. Estrella, E. Koch, A. Aasa, R. Ahas, K. Alm-Kübler, P. Bissolli, O. Braslavská, A. Briede et al. (2006). „European phenological response to climate change matches the warming pattern“. In: *Global change biology* 12.10, S. 1969–1976.
- Mokarram, M. und D. Sathyamoorthy (2015). „Modeling the relationship between elevation, aspect and spatial distribution of vegetation in the Darab Mountain, Iran using remote sensing data“. In: *Modeling Earth Systems and Environment* 1.4, S. 30.
- National Aeronautics and Space Administration (NASA) (2018). *Earth Observatory*. URL: <https://earthobservatory.nasa.gov/features/MeasuringVegetation> (aufgerufen am 04.01.2018).
- (2017). *MODIS - Moderate Resolution Imaging Spectroradiometer*. URL: <https://modis.gsfc.nasa.gov/> (aufgerufen am 09.12.2017).

- Oliver, S., H. Oliver, J. Wallace und A. Roberts (1987). „Soil heat flux and temperature variation with vegetation, soil type and climate“. In: *Agricultural and Forest Meteorology* 39.2-3, S. 257–269.
- Parry, M., M. L. Parry, O. Canziani, J. Palutikof, P. Van der Linden und C. Hanson (2007). *Climate change 2007-impacts, adaptation and vulnerability: Working group II contribution to the fourth assessment report of the IPCC*. Bd. 4. Cambridge University Press.
- Pasken, R. und J. A. Pietrowicz (2005). „Using dispersion and mesoscale meteorological models to forecast pollen concentrations“. In: *Atmospheric Environment* 39.40, S. 7689–7701.
- Piao, S., J. Fang, L. Zhou, P. Ciais und B. Zhu (2006). „Variations in satellite-derived phenology in China’s temperate vegetation“. In: *Global change biology* 12.4, S. 672–685.
- Pietzsch, S., M. Wegener und J. Fildebrandt (2016). „Die agrarmeteorologische Situation im Jahr 2016“. In: *DWD Klimastatusbericht 2016*, S. 32–47.
- (2017). „Die agrarmeteorologische Situation im Jahr 2017“. In: *DWD Klimastatusbericht 2017*, S. 33–43.
- Rechid, D., S. Hagemann und D. Jacob (2009a). „Sensitivity of climate models to seasonal variability of snow-free land surface albedo“. In: *Theoretical and Applied Climatology* 95.1, S. 197–221.
- Rechid, D., T. J. Raddatz und D. Jacob (2009b). „Parameterization of snow-free land surface albedo as a function of vegetation phenology based on MODIS data and applied in climate modelling“. In: *Theoretical and applied Climatology* 95.3-4, S. 245–255.
- Reed, B. C., J. F. Brown, D. VanderZee, T. R. Loveland, J. W. Merchant und D. O. Ohlen (1994). „Measuring phenological variability from satellite imagery“. In: *Journal of vegetation science* 5.5, S. 703–714.
- Reflund, J., E. Dellwik, A. N. Hahmann, M. J. Barlage und E. Boegh (2014). „Development of satellite green vegetation fraction time series for use in mesoscale modeling: application to the European heat wave 2006“. In: *Theoretical and applied climatology* 117.3-4, S. 377–392.
- Richardson, A. D., R. S. Anderson, M. A. Arain, A. G. Barr, G. Bohrer, G. Chen, J. M. Chen, P. Ciais, K. J. Davis, A. R. Desai et al. (2012). „Terrestrial biosphere models need better representation of vegetation phenology: results from the North American Carbon Program Site Synthesis“. In: *Global Change Biology* 18.2, S. 566–584.
- Rodriguez-Galiano, V., J. Dash und P. M. Atkinson (2015). „Intercomparison of satellite sensor land surface phenology and ground phenology in Europe“. In: *Geophysical Research Letters* 42.7, S. 2253–2260.
- Roetzer, T., M. Wittenzeller, H. Haeckel und J. Nekovar (2000). „Phenology in central Europe—differences and trends of spring phenophases in urban and rural areas“. In: *International Journal of Biometeorology* 44.2, S. 60–66.
- Rojas, O. (2007). „Operational maize yield model development and validation based on remote sensing and agro-meteorological data in Kenya“. In: *International Journal of Remote Sensing* 28.17, S. 3775–3793.

- Rosenzweig, C., G. Casassa, D. J. Karoly, A. Imeson, C. Liu, A. Menzel, S. Rawlins, T. L. Root, B. Seguin, P. Tryjanowski et al. (2007). „Assessment of observed changes and responses in natural and managed systems“. In: *Climate change 2007*, S. 79.
- Rötzer, T. und F.-M. Chmielewski (2001). „Phenological maps of Europe“. In: *Climate research* 18.3, S. 249–257.
- Rutishauser, T., J. Luterbacher, C. Defila, D. Frank und H. Wanner (2008). „Swiss spring plant phenology 2007: Extremes, a multi-century perspective, and changes in temperature sensitivity“. In: *Geophysical Research Letters* 35.5.
- Sassen, T. C. F. (2018). „Comparing WWII aerial photographs to Sentinel-2 data“. Masterarbeit. Niederlande: Delft University of Technology. URL: <https://repository.tudelft.nl/islandora/object/uuid:57192922-7ec7-4592-88d6-fd7506fb327a/dastream/0BJ/download>.
- Scheifinger, H., J. Belmonte, J. Buters, S. Celenk, A. Damialis, C. Dechamp, H. García-Mozo, R. Gehrig, L. Grewling, J. M. Halley et al. (2013). „Monitoring, modelling and forecasting of the pollen season“. In: *Allergenic pollen*, S. 71–126.
- Scheifinger, H., T. Hübner, E. Koch und M. Ungersböck (2017). „Rückblick auf das phänologische Jahr 2017“. In: *ZAMG Newsletter* 2017.2, S. 16.
- Scheifinger, H., C. Matulla, P. Cate, A. Kahrer und E. Koch (2007). „Climate impact on plant and insect phenology in Austria I“. In:
- Scheifinger, H., A. Menzel, E. Koch, C. Peter und R. Ahas (2002). „Atmospheric mechanisms governing the spatial and temporal variability of phenological phases in central Europe“. In: *International Journal of Climatology* 22.14, S. 1739–1755.
- Schwartz, M. D., B. C. Reed und M. A. White (2002). „Assessing satellite-derived start-of-season measures in the conterminous USA“. In: *International Journal of Climatology* 22.14, S. 1793–1805.
- Sinergise (2018). *Sentinel Hub*. URL: <https://www.sentinel-hub.com/eoproducts/ndvi-normalized-difference-vegetation-index> (aufgerufen am 25.12.2018).
- Sofiev, M., P. Siljamo, H. Ranta und A. Rantio-Lehtimäki (2006a). „Towards numerical forecasting of long-range air transport of birch pollen: theoretical considerations and a feasibility study“. In: *International Journal of Biometeorology* 50.6, S. 392.
- Sofiev, M., P. Siljamo, I. Valkama, M. Ilvonen und J. Kukkonen (2006b). „A dispersion modelling system SILAM and its evaluation against ETEX data“. In: *Atmospheric Environment* 40.4, S. 674–685.
- Sofiev, M. und K.-C. Bergmann (2013). *Allergenic pollen*. Springer.
- Song, J. (1999). „Phenological influences on the albedo of prairie grassland and crop fields“. In: *International Journal of Biometeorology* 42.3, S. 153–157.
- Studer, S., R. Stöckli, C. Appenzeller und P. L. Vidale (2007). „A comparative study of satellite and ground-based phenology“. In: *International Journal of Biometeorology* 51.5, S. 405–414.
- Templ, B., E. Koch, K. Bolmgren, M. Ungersböck, A. Paul, H. Scheifinger, M. Busto, F.-M. Chmielewski, L. Hájková, S. Hodžić et al. (2018). „Pan European Phenological database

- (PEP725): a single point of access for European data“. In: *International journal of biometeorology*, S. 1–5.
- Visser, M. E. (2008). „Keeping up with a warming world; assessing the rate of adaptation to climate change“. In: *Proceedings of the Royal Society B: Biological Sciences* 275.1635, S. 649–659.
- Visser, M. E., L. te Marvelde und M. E. Lof (2012). „Adaptive phenological mismatches of birds and their food in a warming world“. In: *Journal of Ornithology* 153.1, S. 75–84.
- Vitasse, Y., S. Delzon, E. Dufrêne, J.-Y. Pontailler, J.-M. Louvet, A. Kremer und R. Michalet (2009). „Leaf phenology sensitivity to temperature in European trees: Do within-species populations exhibit similar responses?“ In: *Agricultural and forest meteorology* 149.5, S. 735–744.
- Vogel, H., A. Pauling und B. Vogel (2008). „Numerical simulation of birch pollen dispersion with an operational weather forecast system“. In: *International journal of biometeorology* 52.8, S. 805–814.
- White, M. A., D. Beurs, M. Kirsten, K. Didan, D. W. Inouye, A. D. Richardson, O. P. Jensen, J. O’Keefe, G. Zhang, R. R. Nemani et al. (2009). „Intercomparison, interpretation, and assessment of spring phenology in North America estimated from remote sensing for 1982–2006“. In: *Global Change Biology* 15.10, S. 2335–2359.
- White, M. A., F. Hoffman, W. W. Hargrove und R. R. Nemani (2005). „A global framework for monitoring phenological responses to climate change“. In: *Geophysical Research Letters* 32.4.
- White, M. A., P. E. Thornton und S. W. Running (1997). „A continental phenology model for monitoring vegetation responses to interannual climatic variability“. In: *Global biogeochemical cycles* 11.2, S. 217–234.
- Wikipedia (2018). *Latitudinaler Biodiversitätsgradient*. URL: [https://de.wikipedia.org/wiki/Latitudinaler\\_Biodiversit%C3%A4tsgradient](https://de.wikipedia.org/wiki/Latitudinaler_Biodiversit%C3%A4tsgradient) (aufgerufen am 25.12.2018).
- (2017a). *Moderate-resolution Imaging Spectroradiometer*. URL: [https://de.wikipedia.org/wiki/Moderate-resolution\\_Imaging\\_Spectroradiometer](https://de.wikipedia.org/wiki/Moderate-resolution_Imaging_Spectroradiometer) (aufgerufen am 09.12.2017).
- (2017b). *Normalized Difference Vegetation Index*. URL: [https://de.wikipedia.org/wiki/Normalized\\_Difference\\_Vegetation\\_Index](https://de.wikipedia.org/wiki/Normalized_Difference_Vegetation_Index) (aufgerufen am 25.07.2017).
- (2017c). *Sentinel-2*. URL: <https://en.wikipedia.org/wiki/Sentinel-2> (aufgerufen am 25.07.2017).
- Wolkovich, E. M., B. I. Cook, J. M. Allen, T. M. Crimmins, J. L. Betancourt, S. E. Travers, S. Pau, J. Regetz, T. J. Davies, N. J. Kraft et al. (2012). „Warming experiments underpredict plant phenological responses to climate change“. In: *Nature* 485.7399, S. 494–497.
- World Health Organization (WHO) (2018). *Fact sheet Asthma*. URL: <https://www.who.int/en/news-room/fact-sheets/detail/asthma> (aufgerufen am 25.12.2018).
- Zentralanstalt für Meteorologie und Geodynamik (ZAMG) (2018a). *KLIMAMONITORING der ZAMG*. URL: <https://www.zamg.ac.at/cms/de/klima/klima-aktuell/klimamonitoring/> (aufgerufen am 09.01.2018).

- Zentralanstalt für Meteorologie und Geodynamik (ZAMG) (2018b). *Naturkalender*. URL: <https://www.naturkalender.at> (aufgerufen am 03.05.2018).
- (2018c). *Phänologie-Spiegel*. URL: <https://www.zamg.ac.at/cms/de/klima/klima-aktuell/phaenospiegel> (aufgerufen am 09.01.2018).
- (2018d). *PhenoWatch - ZAMG Phänologie*. URL: <http://www.phenowatch.at/beobachtung/phaenologischer-kalender.html> (aufgerufen am 09.01.2018).
- (2018e). *PhenoWatch - ZAMG Phänologie*. URL: <http://www.phenowatch.at/ueber-die-phaenologie/phaenologie-an-der-zamg.html> (aufgerufen am 09.01.2018).
- (2018f). *Webseite der ZAMG*. URL: <http://www.zamg.ac.at/> (aufgerufen am 09.01.2018).
- Zhan, Z.-Z., H.-B. Liu, H.-M. Li, W. Wu und B. Zhong (2012). „The Relationship between NDVI and Terrain Factors—A Case Study of Chongqing“. In: *Procedia Environmental Sciences* 12, S. 765–771.
- Zhang, Y., L. Bielory, Z. Mi, T. Cai, A. Robock und P. Georgopoulos (2015). „Allergenic pollen season variations in the past two decades under changing climate in the United States“. In: *Global change biology* 21.4, S. 1581–1589.
- Zimmermann, K. und C. Polte-Rudolf (2016). „Das phänologische Jahr in Deutschland betrachtet von 1997 bis 2016“. In: *DWD Klimastatusbericht* 2016, S. 89–90.
- Zink, K., H. Vogel, B. Vogel, D. Magyar und C. Kottmeier (2012). „Modeling the dispersion of Ambrosia artemisiifolia L. pollen with the model system COSMO-ART“. In: *International journal of biometeorology* 56.4, S. 669–680.

# Appendix

## Meetings

- **12.09.2017** mit Christoph Matulla, Barbara Widhalm, Angelika Höfler:  
Meeting an der ZAMG über die Verfügbarkeit von Sentinel-2-NDVI-Daten an der ZAMG
- **09.10.2017** mit Helfried Scheifinger, Heinz Gallaun, Mathias Schardt:  
Meeting am Joanneum Research Graz, Institut für Informations- und Kommunikationstechnologien, bezüglich der Verfügbarkeit von Sentinel-2-NDVI-Daten, Unterstützung und Kompetenzen
- **02.11.2017** mit Helfried Scheifinger, Matthias Langer, Andreas Krimbacher:  
Meeting an der ZAMG über den Sentinel National Mirror Austria an der ZAMG und der EODC (Earth Observation Data Centre for Water Resources Monitoring)
- **07.11.2017** mit Helfried Scheifinger, Chris Schubert, Michael Avian:  
Meeting an der ZAMG zwecks Kompetenzen im Fernerkundungsbereich an der ZAMG
- **08.11.2017** mit Helfried Scheifinger, Clement Atzberger, Anja Klisch:  
Meeting an der Universität für Bodenkultur Wien über die Verfügbarkeit von MODIS- und Sentinel-2-NDVI-Daten
- **14.11.2017** Sentinel-Koordinationstreffen mit Helfried Scheifinger, Annett Bartsch, Barbara Widhalm, Kurt Maringer (EKT), Marcus Hirtl (CWET/UMWE), Stefan Schneider (REMSE), Alexander Jann (REMSE), Chris Schubert (CCCA), Anton Neureiter an der ZAMG
- **04.12.2017** mit Helfried Scheifinger, Klemens Schadauer, Christoph Bauerhansl und Markus Löw:  
Meeting am Institut für Waldinventur des Bundesamts für Wald (BFW) über die Verfügbarkeit von Sentinel-2-NDVI-Daten aus der Kooperation mit der TU im Rahmen einer Untersuchung von Borkenkäferbefall
- **16.01.2018** Sentinel-Koordinationstreffen mit Helfried Scheifinger, Michael Avian, Barbara Widhalm (beide Stabsstelle EO), Höfler Angelika (KLFOL), Marcus Hirtl (CWET/UMWE), Stefan Schneider (REMSE), Alexander Jann (REMSE), Chris Schubert (CCCA), Kurt Mahringer, Andreas Krimbacher (ZAMG IT) an der ZAMG
- **29.05.2018** mit Helfried Scheifinger, Christoph Matulla, Michael Avian, Matthias Schlögel:  
Meeting an der ZAMG wegen Reprojektion und Resampling der verschiedenen Satelliten- und Landnutzungsdaten, um diese miteinander vergleichbar zu machen

## Abstracts und Einreichungen

- **18. Dezember 2017:** Einreichung des Abstracts für den Klimatag 2018 in Salzburg
- **10. Januar 2018:** Einreichung des Abstracts für die EGU 2018 in Wien
- **30. März 2018:** Einreichung des Papers „Establishment of a long-term lake-surface temperature dataset within the European Alps extending back to 1880“ für das internationale Journal *Climate Dynamics*
- **18. Juni 2018:** Einreichung des Abstracts für die EMS 2018 in Budapest
- **18. Juni 2018:** Einreichung des Abstracts für die Phenology 2018 Conference in Melbourne
- **03. Dezember 2018:** Einreichung des Abstracts für die DACH 2019 in Garmisch-Partenkirchen
- **01.10.2017 - 31.06.2018** Mitarbeit und Einreichung des 2. Kapitels im APCC Special Report 2018: „Gesundheit, Demographie und Klimawandel“

## Poster, Präsentationen und Veröffentlichungen

- **24. Januar 2018:** 1. Präsentation der Masterarbeit im Rahmen des Masterseminars an der Universität Wien
- **23. - 25. April 2018:** Posterpräsentation Klimatag 2018 in Salzburg
- **3. - 7. September 2018:** Posterpräsentation EMS 2018 in Budapest
- **13. September 2018:** Präsentation des APCC Special Report 2018 von Willi Haas gemeinsam mit Nachhaltigkeitsministerin Elisabeth Köstinger (Bundesministerium für Nachhaltigkeit und Tourismus (BMNT)) in Wien
- **23. - 27. September 2018:** Posterpräsentation Phenology 2018 Conference in Melbourne
- **24. September 2018:** Veröffentlichung des Papers „Establishment of a long-term lake-surface temperature dataset within the European Alps extending back to 1880“ im internationale Journal *Climate Dynamics*
- **14. November 2018:** 2. Präsentation der Masterarbeit im Rahmen des Masterseminars an der Universität Wien

Eine Auswahl an Abstracts, Postern und Veröffentlichungen folgen auf den nächsten Seiten.



## **Detection of phenological occurrence dates from space with Sentinel-2 and MODIS**

Hans Ressl (1,2), Christoph Matulla (1), Helfried Scheifinger (1), and Barbara Chimani (1)

(1) Climate Impact Team (CIT), Climate Research Branch, Zentralanstalt für Meteorologie und Geodynamik (ZAMG), Vienna, Austria, (2) Institute for Meteorology and Geophysics, University of Vienna, Vienna, Austria

This study aims at establishing a relationship between satellite-based land surface phenology (LSP) and ground phenology (GP) such that phenological occurrence dates can be determined from space. Therefore we use the Normalized Difference Vegetation Index (NDVI that describes photosynthetic activity of the Earth's vegetation) inferred from Sentinel-2 data and apply various approaches based on its development. These approaches are subsequently validated and compared amongst each other in order to identify the most suitable formulation.

Here, we focus on the leaf shoots of birch and beech since the European phenological database PEP725 contains a large number of pertaining observations. The beech is a dominant tree species in Central European deciduous forests, whereas pure birch forests are restricted to Scandinavian countries. In Austria, birches begin to sprout first leaves in about mid-March whilst in Sweden this phase occurs approximately two months later. Throughout the bygone half-century occurrence dates of beech- and birch-leaf-unfolding show shifts towards earlier Julian days of about one and a half week in Central Europe.

The analysis carried out is based (i) on the 2016, 2017 (and perhaps 2018) spring phases for Tyrol and southern Germany and (ii) on the 2017 (2018) spring phase(s) for Upper and Lower Austria. Aside from Sentinel-2 we use satellite data from MODIS too. These data have a spatial resolution of 250m and a temporal resolution of about 5 days. Results show (i) how well Sentinel-2 data, which have a spatial-temporal resolution of 10m and 10 days, determine occurrence dates of birch- and beech-leaf-unfolding as well as (ii) how much findings improve by using Sentinel-2 data instead of MODIS.

#### Introduction

The photosynthetic activity of plants can be observed from space via satellites and may be described by the Normalized Difference Vegetation Index (NDVI). Based on Sentinel-2 data this poster deals with establishing a relationship between satellite-based land surface phenology (LSP) and ground phenology (GP) allowing for the detection of phenological occurrence dates from satellite data directly. Comparisons with MODIS data, which have a significantly lower resolution, are supposed to show the improvement achieved by Sentinel. This poster presents results for beech and birch spring phases.

#### Beech and Birch

Beeches (*Fagus sylvatica* aka 'red beech') are deciduous trees, that can grow up to a height of 35 m. They are a shade, stand-forming species, preferring nutrient-rich soils. Beeches can occur up to about 1500 m above sea level. Therefore beeches are to be found mainly in plains and low mountain ranges (see Figure 1).

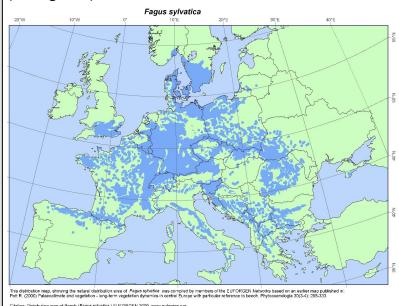


Figure 1a: Distribution of beeches in Europe.  
(Source: EUFORGEN)



Figure 1b: Distribution of birches in Europe.  
(Source: EUFORGEN)

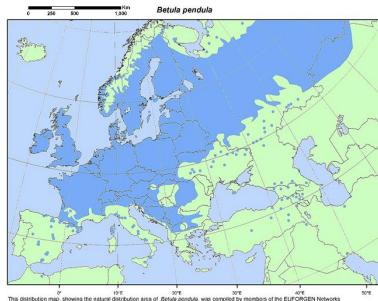


Figure 1b: Distribution of birches in Europe.  
(Source: EUFORGEN)

Birches (*Betula pendula*) are deciduous trees, growing up to 20 m high. They have pointed conical, narrow crowns, which bulge later or become irregular. Birches are a pioneer tree species developing on loose, light raw soils and are, thus, frequently used for recolonization of bare areas. As a robust pre-forest tree species, resistant to cold, birches hardly suffer from late frost events.

#### Data and NDVI

The space mission Sentinel-2 consists of Sentinel-2A, launched in June 2015 and Sentinel-2B, launched in March 2017. **Sentinel Data** used here have been provided by:

- Institute for Information and Communication Technologies, Joanneum Research Graz – Projects:** "Evolution of Copernicus Land Services based on Sentinel data" (ECOlaSS) and "Distributed, Integrated and harmonized forest information for Bioeconomy Outlooks" (Diabololo). Data cover Tyrol and southern Germany and contain NDVI information for 2016 and 2017 (10m + 10day spatio-temporal resolution). Cloud and snow filtering has been carried out. Cloud shadows, however, have not been corrected.
- Institute for Forest Inventory of the Federal Office of Forests (BFW) – Projects:** "Determination of damage caused by bark beetles - contribution of the remote sensing phase I". NDVI for 2017 is based on cloud filtered data. Cloud shadows have been identified and excluded.

#### MODIS Data (Moderate Resolution Imaging Spectroradiometer) from:

- Institute for Surveying, Remote Sensing and Land Information (BOKU)** They have NDVI information for 2016 and 2017 over Central Europe and Sweden (250m + 7 day spatio-temporal resolution).

**Phenological observations (GP)** for 2016 and 2017 are provided by the ZAMG (PEP725) and extend across the D-A-CH region and Sweden.

The linkage of Sentinel and MODIS NDVI data to phenological records, however, requires the use of a land-use inventory too. Copernicus High Resolution Layers for forests 2015 with a spatial resolution of 20m are used for this purpose, also a map of tree cover density with same resolution.

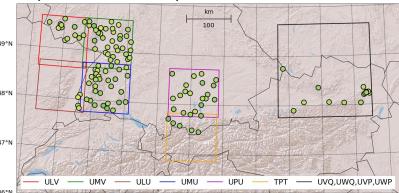


Figure 2: Target regions investigated here (data provider: Joanneum (left and middle) and (BFW) (right)). Borders of Sentinel data are shown as coloured rectangles (see legend). Dots indicate phenological observing sites, whereby colours notify 'leaf unfolding' entry dates of birches in 2017 (see colour scale).

**NDVI (Normalized Difference Vegetation Index) : Differences in reflectance between the red-visible and the NIR spectral ranges:**

$$NDVI = \frac{NIR - Red}{NIR + Red}$$

Reflectivity in the NIR range corresponds to the presence of chlorophyll.

#### References

- European Forest Genetic Resources Programme (EUFORGEN) (2017). EUFORGEN. url: <http://www.euforgen.org/> (called 21. 12. 2017).  
Bundesforschungs- und Ausbildungszentrum für Wald, Naturgefahren und Landschaft (BFW) (2017). url: <http://bfw.ac.at/> (called 21. 12. 2017).  
Cong, N., S. Piao, A. Chen, X. Wang, X. Lin, S. Chen, S. Han, G. Zhou and X. Zhang (2012). "Spring vegetation green-up date in China inferred from SPOT NDVI data: A multiple model analysis". In: Agricultural and Forest Meteorology 165, S. 104–113.  
Klisch, A., & Atzberger, C. (2016). Operational drought monitoring in Kenya using MODIS NDVI time series. *Remote Sensing*, 8(4), 267.

#### Comparison

For each of the years (2016 and 2017), a time series is calculated within a certain radius around the phenological sites from the NDVI values of a MODIS pixel and the sentinel pixels contained therein (Figures 3, 4 and 5). The pixels are selected according to the land use inventory, which provides information on the kind (coniferous or deciduous) and percentage of forest cover. Then the NDVI levels accumulated from the beginning of the season until the time of the phenological entry dates are calculated at each phenological station for each of the two seasons, 2016 and 2017. For validation purposes the accumulated NDVI levels of 2016 are applied to the NDVI curves of 2017 in order to calculate the phenological entry dates of 2017 and compare them with the observed ones. This is also done the other way round. In a spatial validation approach the entry date at one station is modeled by the NDVI – entry date relationship derived from all other stations.

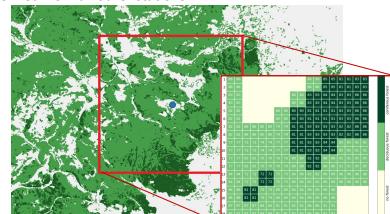


Figure 3: Copernicus High Resolution Layers for the detection of forested land within a MODIS pixel representative for a phenological observing site (blue dot) and the zoomed area with the dominant leaf type (deciduous or coniferous) and tree cover density.

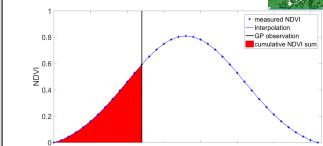


Figure 4: Schematic representation of the seasonal variation of NDVI values at one site throughout one year and the calculation of the cumulative NDVI.

Apart from this rather new approach other methods are evaluated too. Occurrence dates may be, for instance, estimated more directly from NDVI data via:  $\frac{NDVI_{max,0} - NDVI_{min,0}}{NDVI_{max,0} - NDVI_{min,1}}$  or from the date at which the NDVI's first derivative attains its maximum (for the start of season).

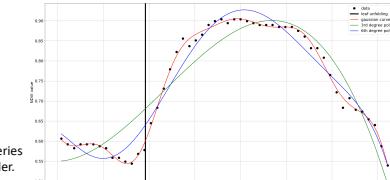


Figure 5: Interpolation of MODIS NDVI time series by gaussian curve and splines of different order.

#### Results

The results show for MODIS that the cumulative NDVI seems to be robust enough to simulate the entry dates for one year on basis of the other year (Figure 6). On average, the difference between observations and simulation is about 13-14 (beech) and 16-17 (birch) days. The method also shows an average difference of 12-14 days for the spatial approach in connection with a multiple regression. Some stations, especially the results for the other methods and the spatial approach with MODIS reveal a low correlation between observed and simulated entry dates (<0.5), which may result from incorrectly assigning phenological observations to sites. Frequently localities at which 'leaf unfolding' is reported are far away from forests or groups of trees. Another source of error may be the so-called 'mixed-pixel' problem, which signifies the presence of various land-cover-classes within a MODIS pixel (250 x 250 m<sup>2</sup>).

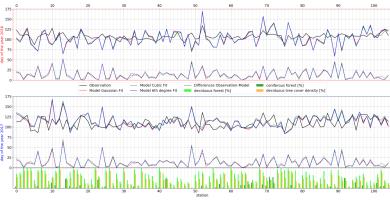


Figure 6 shows the comparison of the NDVI data of a MODIS pixel and the sentinel pixels in it, which contain deciduous forest. The sentinel pixels scatter strongly, which could be due to the fact that the resolution of the land use inventory is still insufficient or land use has changed since provided. It is also possible that cloud filtering does not yet work satisfactorily or that cloud shadows should be filtered in all data, which can be seen by values close to zero. Nevertheless, the mean values show a similar course to that of MODIS NDVI values.

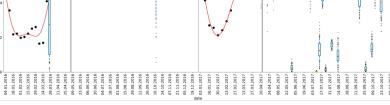


Figure 7: NDVI values for 2016 and 2017 and observed birch leaf unfolding from one MODIS pixel (black dots) and the sentinel pixels in it, which contain deciduous forest (boxplots).

#### Outlook

The successful application of the described method to Sentinel-2 data and the detection of possible improvements, processed NDVI data of Sentinel-2 A and B would have to be available. To compensate the effect of clouds and cloud shadows, the creation of filtered 7-day NDVI composite images comparable to the MODIS NDVI composite images would be desirable.

Concerning ground based observations made by citizens scientists, which are currently fraught with errors referring to the observing sites, we hope that new techniques will help avoiding incorrect allocations between observations and sites.

Apart from that, the forthcoming provision of a new land-use inventory based on SENTINEL-2 information will allow for a more realistic identification of the percentage of deciduous trees within the area under investigation.

#### Contacts:

- Hans Ressl, BSc, ressl.ha@gmail.com  
Dr. Helfried Scheifinger, helfried.scheifinger@zamg.ac.at  
P.D. Dr. Christoph Matulla, christoph.matulla@zamg.ac.at

## Lake Surface Temperatures in the European Alps from 1880 to 2100 – Reconstructions and Projections derived at twelve lakes located within the complex topography of Austria

Christoph Matulla (1), Manfred Ganekind (1), Matthias Schlögl (2), Hans Ressl (1,3), and Barbara Chimani (1)

(1) Zentralanstalt für Meteorologie und Geodynamik (ZAMG), Vienna, Austria (christoph.matulla@zamg.ac.at), (2) Institute of Applied Statistics and Computing, University of Natural Resources and Life Sciences, Vienna, Austria, (3) Institute of Meteorology and Geophysics, University of Vienna, Vienna, Austria

This study is devoted to the development of long-term time-series for Lake Surface Temperatures (LSTs) in the Central Alps. This endeavor comprises three steps: (i) the reconstruction of LSTs from 1949 back to 1880, (ii) the homogenization of records from 1950 to 2012 and (iii) the derivation of climate change projections from 2013 to 2100 driven by two different Representative Concentration Pathways (RCP8.5, indicating a ‘business as usual’ scenario, and RCP4.5, representing a more climate-friendly pathway).

The generation of LST reconstructions is obtained by digitizing monthly LSTs at twelve selected lakes from hydrographic yearbooks and by merging them with corresponding time-series covering most recent decades, which are available in already digitized form from the ministry of water resources (BMLFUW). Based on results achieved by the application of (i) a Rotated Empirical Orthogonal Functions (REOFs) Analysis and (ii) hierarchical clustering methods two groups of lakes are specified. Homogeneous LST time series from 1950 to 2012 are established through applying a homogenization procedure called HOMER (Mestre et al. 2013) to LST time-series within these two groups and additional appropriate amendments.

In order to reconstruct seasonal LST developments back to 1880, we make use of the so-called HISTALP database (Auer et al. 2007) comprising regularly updated, homogeneous, monthly time-series of various atmospheric elements at 133 stations across the European Alps back to 1762. Throughout the period shared by HISTALP and our LSTs (1950-2012), Multiple Linear Regression (MLR) Models are established for each lake and every season, using air-temperature, precipitation totals and air-pressure as covariates. Based on extensive validation experiments, the three best-performing MLR-models are applied to reconstruct LSTs back to 1880.

In order to derive ensembles of LST projections at each lake until 2100, 60 Global Climate Model (GCM) simulations driven by the above mentioned RCP-pathways are refined via empirical, statistical downscaling (ESD) techniques, which have been thoroughly evaluated in various validation experiments. In total there are 30 climate-change projections for each RCP-pathway available at every HISTALP station. These ensembles are subsequently transferred to the lakes via the aforementioned MLR-models. Hence, 30 LST projections from 2013 until 2100 are available at each lake for each RCP-pathway and each (of three) MLR-model. These extensive ensembles of LST-projections are utilized to sketch out probable future LST corridors until the end of this century.

This study attempts (i) to contribute to a better understanding of lake ecosystems by providing long-term LST time-series throughout the past - through which direct measurements and proxy-data describing biological activity and associated processes impacted by LSTs are available as well as (ii) to foster the implementation of efficient and effective protection measures according to the derived corridors within the European Alps. Findings will also support decision-makers in ecosystem protection, tourism and water resource management.

Mestre et al., 2013: HOMER: A homogenization software – methods and applications, *Időjárás*, 117, 47-67.

Auer et al., 2007: HISTALP Historical Instrumental Climatological Surface Time Series of the Greater Alpine Region, *International Journal of Climatology*, 17, 14-46.



## **Establishment of a long-term lake-surface temperature dataset within the European Alps extending back to 1880 and climate change driven scenarios until 2100 – Reconstructions and Projections derived at twelve lakes located within the complex topography of Austria**

Christoph Matulla (1), Janos Tordai (1), Matthias Schlögl (2), Manfred Ganekind (1), Herbert Matulla (3), Hans Ressl (4), and Barbara Chimani (1)

(1) Zentralanstalt für Meteorologie und Geodynamik, ZAMG, Climate Impact Team, Climate Research Branch, Vienna, Austria, (2) Institute of Applied Statistics and Computing, University of Natural Resources and Life Sciences, Vienna, Austria, (3) Technical High School for Chemistry and Chemical Industry, Vienna, Austria, (4) Institute for Meteorology and Geophysics, University of Vienna, Vienna, Austria

Lake surface temperature (LST) is a key characteristic of lakes, shaping the ecological properties of these inland water bodies and their environment. This study aims at establishing a long-term, high-quality, monthly LST dataset within the European Alps reaching back to 1880, which is provided to the scientific community for further research.

Therefore monthly temperature records from Austrian lakes covering a period of about six decades are digitized from hydrological yearbooks. Clustering techniques (REOFs, cluster analysis) are used to identify groups of lakes signified by inner similarity and outer separation. These are not only used for an overall quality assessment, but also provide optimal starting conditions for the application of a homogenization procedure, warranting homogeneous LST data from 1950 onwards.

LST reconstructions back to 1880 are derived from atmospheric covariates (provided by HISTALP) via sets of transfer-functions, which have passed a selection process ensuring mathematical, physical and quality requirements and are selected from about 160 million candidates according to their skill in validation experiments.

From 1880 to 1950 LSTs feature generally slight increases accompanied by a succession of climate states. These are in alignment with outstanding climate periods and sustained, far-reaching repercussions triggered by significant events, which are known from historical documents. LST developments throughout the second half of the 20th century up to date are characterized by a decline until the mid-1980s, indicating the impact of industrial aerosols. This behaviour is superseded by a steep increase, revealing the gradual unmasking of the anthropogenic greenhouse effect by the continuous reduction of aerosol loads in the atmosphere.

In order to derive ensembles of LST projections at each lake until 2100, 60 Global Climate Model (GCM) simulations driven by RCP-pathways are regionalized by empirical, statistical downscaling (ESD) techniques, which have been thoroughly evaluated in various validation experiments. In total there are 30 climate-change projections for each RCP-pathway available at every HISTALP station. These ensembles are subsequently transferred to the lakes via the aforementioned transfer-functions. Hence, 30 LST projections from 2013 until 2100 are available at each lake for each RCP-pathway and each (of three) transfer-functions. These extensive ensembles of LST-projections are utilized to sketch out probable future LST corridors until the end of this century.

This study attempts (i) to contribute to a better understanding of lake ecosystems by providing long-term LST time-series throughout the past - through which direct measurements and proxy-data describing biological activity and associated processes impacted by LSTs are available as well as (ii) to foster the implementation of efficient and effective protection measures according to the derived potential future LST corridors within the European Alps. Findings will also support decision-makers in ecosystem protection, tourism and water resource management.



# Establishment of a long-term lake-surface temperature dataset within the European Alps extending back to 1880

Christoph Matulla<sup>1</sup> · János Tordai<sup>1</sup> · Matthias Schlögl<sup>1,2</sup> · Manfred Ganekind<sup>3</sup> · Herbert Matulla<sup>4</sup> · Hans Ressl<sup>1,5</sup> · Barbara Chimani<sup>3</sup>

Received: 30 March 2018 / Accepted: 24 September 2018  
© The Author(s) 2018, corrected publication 2018

## Abstract

Lake surface temperature (LST) is a key characteristic of lakes, shaping the ecological properties of these inland water bodies and their environment. This study aims at establishing a long-term, high-quality, monthly LST dataset within the European Alps reaching back to 1880, which is provided to the scientific community for further research. Therefore monthly temperature records from Austrian lakes covering a period of about six decades are digitized from hydrological yearbooks. Clustering techniques (rotated empirical orthogonal functions and hierarchical cluster analysis) are used to identify groups of lakes signified by inner similarity and outer separation. These are not only used for an overall quality assessment, but also provide optimal starting conditions for the application of a homogenization procedure, warranting homogeneous LST data from 1950 onwards. LST reconstructions back to 1880 are derived from atmospheric covariates (provided by HISTALP) via sets of transfer-functions. Applied transfer-functions have passed a selection process ensuring mathematical, physical and quality requirements. They are selected from about 160 million candidates according to skill, which is determined through a comprehensive assessment based on validation experiments and several performance measures. Results show overall high skill following a seasonal cycle. From 1880 to 1950 LSTs feature generally slight increases accompanied by a succession of climate states. These are in alignment with outstanding climate periods and sustained, far-reaching repercussions triggered by significant events, which are known from historical documents. LST developments throughout the second half of the twentieth century up to date are characterized by a decline until the mid-1980s, indicating the impact of industrial aerosols. This behaviour is superseded by a steep increase, revealing the gradual unmasking of the anthropogenic greenhouse effect by the continuous reduction of aerosol loads in the atmosphere. The latter substantiates man-made climate change, whose prove is based on atmospheric variables by different data pertaining to the hydrosphere. Potential research hypotheses corresponding to various fields of science that may be investigated by using the here established LST dataset are considered. We hope that these data sets and associated findings will make a contribution to the broader research community.

**Keywords** Lake surface temperature · Homogenization · Transfer functions · Long-term dataset · Reconstruction

**Mathematics Subject Classification** 86A10 · 86A05

✉ Christoph Matulla  
christoph.matulla@zamg.ac.at

<sup>1</sup> Climate Impact Team, Climate Research Branch,  
Zentralanstalt für Meteorologie und Geodynamik, Vienna,  
Austria

<sup>2</sup> Institute of Applied Statistics and Computing, University  
of Natural Resources and Life Sciences, Vienna, Austria

<sup>3</sup> Climate Monitoring Team, Climate Research Branch,  
Zentralanstalt für Meteorologie und Geodynamik, Vienna,  
Austria

<sup>4</sup> Technical High School for Chemistry, Vienna, Austria

<sup>5</sup> Institute for Meteorology and Geophysics, University  
of Vienna, Vienna, Austria

## Beobachtung phänologischer Phasen mit MODIS und Sentinel-2

Hans Ressl (1), Christoph Matulla (2), and Helfried Scheifinger (2)

(1) Institut für Meteorologie und Geophysik, Universität Wien, Wien, Österreich, (2) Climate Impact Team (CIT), Abteilung Klimaforschung, Zentralanstalt für Meteorologie und Geodynamik (ZAMG), Wien, Österreich

Diese Studie zielt darauf ab, einen Zusammenhang zwischen der satellitengestützten Landoberflächenphänologie (LSP) und den phänologischen Bodenbeobachtungen (GP) herzustellen, die es schließlich erlauben sollte, phänologische Eintrittsdaten aus dem All zu bestimmen. Dazu betrachten wir in einem Jahr die Eintrittstermine einer (bzw. zwei) phänologischen Phase(n) an verschiedenen Orten sowie die dort bis dahin beobachteten Verläufe des aus Sentinel-2-Daten abgeleiteten Normalized Difference Vegetation Index (NDVI, der die photosynthetische Aktivität der Vegetation beschreibt) und versuchen mit verschiedenen Ansätzen charakteristische NDVI Werte abzuleiten. Die Eignung verschiedener Ansätze bzw. charakteristischer NDVI Werte wurden durch Vergleich von geschätzten mit beobachteten phänologischen Eintrittsterminen bewertet. Als diese Arbeit durchgeführt wurde, waren Sentinel-2 Daten nur für 2 Jahre verfügbar. Damit war es möglich, das jeweils andere Jahr zu Validierung heranzuziehen.

Hier betrachten wir den Laubaustrieb von Birke und Buche, da die europäische phänologische Datenbank PEP725 eine große Anzahl von Beobachtungen dieser Phase bereithält. In den mitteleuropäischen Laubwäldern ist die Buche eine dominante Baumart, während reine Birkenwälder auf skandinavische Länder konzentriert sind. In Österreich beginnen Birken etwa gegen Ende März erste Blätter sprießen zu lassen, während in Schweden diese Phase etwa zwei Monate später eintritt. Im Laufe der vergangenen fünf Dekaden zeigen die Beobachtungen dieser Blatt-Phasen über Mitteleuropa – unabhängig von der geographischen Breite – Verschiebungen zu rund 10 Tage früheren Eintrittsterminen.

Die gezeigten Resultate basieren auf den Frühjahrsphasen 2016 und 2017 für Tirol und Süddeutschland und auf den Frühjahrsphasen 2017 für Ober- und Niederösterreich. Neben Sentinel-2 verwenden wir auch Satellitendaten von MODIS, die eine räumliche Auflösung von 250m aufweisen. Die Ergebnisse zeigen, wie gut Sentinel-2-Daten, die eine räumliche Auflösung von 10 m aufweisen, die Bestimmung der Eintrittstermine der Birken- und Buchenlaub-Entfaltung ermöglichen. Darüber hinaus soll die Erhöhung der Brauchbarkeit der LSP durch die hohe Auflösung der Sentinel 2 Daten im Vergleich mit den MODIS Daten demonstriert werden.

Da sich der Start von Sentinel-2B verschoben hat, stehen für die ersten Halbjahre nur Daten von Sentinel-2A zur Verfügung, wodurch sich die zeitliche Auflösung vermindert. Die Ergebnisse zeigen, dass für die untersuchten Jahre keine Untersuchung der Korrelation zwischen Satellitendaten und phänologischen Bodenbeobachtungen möglich ist. Die geringe zeitliche Auflösung wird durch das Fehlen von Satellitenbildern an Zeitpunkten mit vollständiger Bewölkung und den Lücken, die durch Schnee- und Wolkenfilterung entstehen, verursacht. Analysen der vorhandenen Daten zeigen allerdings, dass eine Verbesserung durch die Verringerung des Mischpixeleffekts mit Sentinel-2 Daten durchaus möglich sein wird, sobald eine höher zeitliche Auflösung vorliegt und Lücken geschlossen werden können.

# Zeitplan Masterseminar

Mi 13.00-14.30, HS1

Termin	Thema	Vortragende(r)
6.12.2017	Uncertainties in the Makkonen model	Clemens Weiß
10.1.2018	Correlation between $\delta\text{O}^{18}$ amount and precipitation characteristics $\delta\text{O}^{18}$ distribution for selected precipitation events	Isabel Auer Martin Hornbogner
17.1.2018	The ENSO signal in early upper air observations and surface data only reanalyses	Benjamin Schaden
24.1.2018	Phenological phases from space	Hans Ressl
31.1.2018	Erstellung einer österreichweiten Ereignisdatenbank und Evaluierung von Zusammenhängen zwischen lokalskaliger Wetterentwicklung und Extremereignissen Kopplung großräumiger atmosphärischer Prozesse an regionalskalige Wetterentwicklungen mit Fokus auf Extremereignisse im komplexen Gelände	Katharina Enigl Andreas Mansberger



Meteorologisches Seminar WS 2017



universität  
wien

# Zeitplan Masterseminar

Mi 13.00-14.30, Hörsaal 1

Termin	Thema	Vortragende(r)
24.10.	Synoptische Einflussfaktoren für Starkniederschläge in Österreich (1.)	Sabine Hittmeir
31.10.	Ensembles regionalskaliger Klimaprojektionen zur Bewertung potentieller Veränderungen künftiger Extremereignisse (2.) Eine österreichweite Ereignisdatenbank und Zusammenhänge zwischen lokaler Wetterentwicklung und Extremereignissen (2.) Downscaling von großkaligen Wetterentwicklungen auf regionalskalige Extremereignisse (2.)	Fabian Frank Katharina Enigl Andreas Mansberger
14.11.	Beobachtung phenologischer Phasen aus dem All (2.) Comparison of statistical and machine learning methods for forecasting wind turbine icing (1.)	Hans Ressl Lukas Kugler
28.11.	Detection and attribution of anthropogenic impacts on phenological phases (2.)	Sebastian Lehner
12.12.	CAPE als Prädiktor für Starkniederschlag (1.) Rolle des österreichischen Waldes im Kohlenstoffkreislauf (1.)	Christoph Matella Anita Zolles
9.1.2019	Modellierung und Verifikation des Windfeldes im Aichfeld (1.) Räumliche Verifikation von Ensemblevorhersagen mit WRF (1.)	Kevin Hebenstreit Judith Svacina
16.1.	TBA Ausbreitungsrechnungen mit AUSTAL2000 (1.) 2. Vortrag	M. Weissinger Jessica Kult Sabine Hittmeir
23.1.	Saharastaub TBA	Katharina Perny Ulrich Voggenberger
30.1.	Verifikation von Windprognosen	Sabrina Marth



**Meteorologisches Seminar WS 2018**

