# H 85700 Institut für Vermessung, Fernerkundung und Landinformation (IVFL)

Betreuer:	Univ. Prof. Dr. rer. nat. Clement ATZBERGER
Mitbetreuerinnen:	Dr. <sup>in</sup> Anja KLISCH
	Dipl. Geographin Kathrin EINZMANN

# WINDWURFDETEKTION ANHAND VON LANDSATDATEN FÜR FORSTANWENDUNGEN – EINE ZEITREIHENANALYSE MITTELS BFAST IN EINEM WALDGEBIET IN BAYERN

Masterarbeit zur Erlangung des Titels Diplomingenieurin an der Universität für Bodenkultur Wien

> Eingereicht von Susanne Karel BSc.

Wien, Oktober 2017

# ABSTRACT

Forests are one of the most important natural resources in the world. They provide  $CO_2$  fixation which is important for air quality and steady  $O_2$  levels. But they are also used as an energy source, as construction material and many other usages and applications. It is therefore important to generate reliable information about any changes concerning this resource. This is where change detection begins. There are many different types of change and therefore different types of change detection, like different algorithms and procedures.

This work focuses particularly on the algorithm BFAST (Breaks for Additive Season and Trend), which is an iterative decomposition into the components trend, seasonality and remainder. A Landsat time series reaching from 2006-2016 was analysed in this study. The aim was to test whether the windthrows caused by storm Niklas in 2015 can be detected with this approach. Therefore, two test areas in the study area south from Munich were examined.

After some test evaluations, it was decided to shorten the time series to avoid differences of Landsat sensors and to minimize noise. The time series from 2013-2016 contains only observations from Landsat 8 and the results are visibly improved.

No more than 35% correctly detected windthrows could be reached. The results suggest that a reliable detection is only possible with the proper data and method. However, it can be assumed that better results can be achieved by reprocessing the data with a method that is suitable for the detection of abrupt changes. The combination with other sensors, respectively with a higher temporal resolution, could also improve the results, if the data can be adapted sufficiently to each other.

In summary, it can be said that change detection is a very complex issue in which one must consider diverse factors. On the one hand the data availability as well as the data quality needs to be guaranteed by the processing. If, however, not enough consecutive observations are available, the possibilities of change detection are limited.

Keywords: change detection, forest, BFAST, windthrow, abrupt changes, trend analysis

# Inhaltsverzeichnis

Abkürzungen	5
1 Einleitung	6
2 Grundlagen der Fernerkundung	8
2.2 Elektromagnetische Strahlung und Reflexionsgrad	9
2.2.1 Strahlung	9
2.2.2 Reflexionsgrad und Vegetation	10
2.2.3 Normalized Difference Vegetation Index (NDVI)	11
2.2.4 Fraction of Absorbed Photosynthetically Active Radiation (fAPAR)	12
2.2.5 Tasseled Cap Brightness (TCB)	13
2.3 Eigenschaften von Satellitendaten	14
2.3.1 Erkennbarkeit von Objekten, räumliche Auflösung	14
2.3.2 Geometrische Eigenschaften	14
2.3.3 Radiometrische und spektrale Eigenschaften	15
2.3.4 Temporale Auflösung	15
2.4 Zeitreihenanalyse und Veränderungsdetektion	16
2.5 Verschiedene Arten der Veränderungsdetektion	17
2.5.1 Überblick verschiedener Veränderungsdetektionsmethoden	18
2.5.2 Breaks for additive Season and Trend (BFAST)	19
3 Material und Methode	26
3.1 Untersuchungsgebiet	26
3.2 Datengrundlage	30
3.3 Referenzdaten	38
3.4 Methode	40
4 Ergebnisse	44
4.1 Erste Auswertung anhand von Differenzbildern	44
4.2 Auswertung mittels BFAST	47
4.2.1 Flächenhafte Auswertung der Testkachel 2013-2016	47
4.2.2 Ergebnisse Mean Shift	58
4.4 Validierung der fAPAR Ergebnisse	59
4.4.1 fAPAR 2013-2016	60
4.4.2 RMSE für fAPAR 2013-2016	64

4.4.3 Mean Shift fAPAR 2013-2016	65	
5 Diskussion6		
6 Zusammenfassung	72	
7 Bibliographie		
7.1 Abbildungsverzeichnis	80	
7.2 Tabellenverzeichnis	83	
Anhang	84	
Punktdatensatz für erste Testauswertung 2006-2016	84	
Flächenhafte Auswertung der Testkachel 2006-2016	88	
Validierung NDVI	90	
Ergebnisse der doppelten Zeitreihe	94	
Abbildungsverzeichnis für den Anhang	98	
Tabellenverzeichnis für den Anhang	99	
1. BFAST R-Script	99	
2. Rasterize R-Script	101	
3. Extract zones R-Script	102	
4. PCA R-Script	103	
5. Validierung R-Script	104	
6. RMSE R-Script	105	

# Abkürzungen

BFAST	Breaks for Additive Season and Trend
BIC	Bayesian Information Chriterion
BOA	bottom of atmosphere
CCDC	Continous Change Detection Classification
CDR	Climate Data Record
CO <sub>2</sub>	Kohlendioxid
CRM	Canopy Reflectance Models
DI	Disturbance Index
ECV	Essential Climate Variables
ETM+	Enhanced Thematic Mapper Plus
fAPAR	Fraction of Absorbed Photosynthetically Active Radiation
fMask	function to mask
GPSMAP 64	Navigationsgerät von Garmin
h	minimale Segmentgröße der gesamten Zeitreihe, innerhalt derer eine Veränderung erfasst wird
IFOV	Instantaneous Field of View
IFZ	Integrated Forest z-score
IPCC	International Panel on Climate Change
kWW	kein Windwurf
LOESS	Locally wEighted regreSsion Smoother
NaN	Not a Number
NDVI	Normalized Difference Vegetation Index
NIR	nahes Infrarot
nMAE	normalized Mean Absolute Error
NOBS	Number of OBServations
OLI	Operational Land Imager
OLS-MOSUM	Ordinary Least Square - Moving SUM
PCA	Principal Component Analysis (Hauptkomponententransformation
RED	rot
RMSE	Root Mean Square Error
STL	Seasonal Trend decomposition procedure based on LOESS
ТСВ	Tasseled Cap Brightness
TCG	Tasseled Cap Greenness
ТСТ	Tasseled Cap Transformation
TCW	Tasseled Cap Wetness
ТМ	Thematic Mapper
UAV	Unmanned Aerial Vehicle
UTM	Universal Transverse Mercator
VCT	Vegetation Change Tracker
WGS84	World Geodetic System 1984

# 1 Einleitung

"Natural resource managers, policy makers and researchers demand knowledge of land cover changes over increasingly large spatial and temporal extents for addressing many pressing issues such as global climate change, carbon budgets, and biodiversity." (Verbesselt et al., 2010a, 106; nach DeFries et al., 1999; Dixon et al., 1994).

Global gesehen, stellen Wälder eine der wertvollsten Ressourcen für das menschliche Wohlbefinden, Schutz von Wassereinzugsgebieten, Lebensraum, Biodiversität und Erholungsgebieten dar (vgl. GLP, 2005 und Millenium Ecosystem Assessment, M. A., 2005; nach Griffiths et al., 2014, 72). Außerdem spielen Wälder bei der Klimaregulierung, der Kohlenstoffbindung und dem Rückstrahlverhalten der Oberfläche eine wichtige Rolle auf globaler Ebene (vgl. IPCC, 2000; nach Griffiths et al., 2014, 2). "Wir müssen mehr über die Welt und ihre Veränderungen wissen, wenn wir die Herausforderungen unserer Zeit bestehen und zu einem weiseren Umgang mit den uns anvertrauten Ressourcen finden wollen." (Albertz, 2007, X)

Obwohl in einigen Industrieländern die Waldfläche wieder zunimmt, fehlt es häufig an Informationen über die räumlich-zeitlichen Veränderungen von Waldflächen. Denn nicht alle Aufforstungsmaßnahmen bieten dieselben ökologischen Auswirkungen von natürlich gewachsenen Waldflächen, wie zum Beispiel Lawinenschutz, Hangsicherung usw. Vor allem Monokulturen sind instabil, schädlingsanfällig und gelten damit als äußerst problematisch (vgl. Griffiths et al., 2014, 72f).

Stürme sind die häufigste natürliche Störeinwirkung für großflächigen Ausfall in mitteleuropäischen Ländern (vgl. Wohlgemut 2002; nach Kirchstetter, 2013, 17). Die Schäden betreffen jedoch nicht nur die verlorenen Festmeter Holz durch den Sturm, sondern ebenfalls im Anschluss an Sturmschäden durch Borkenkäfer befallene Bäume. Hinzukommen die Kosten für den Holztransport und andere forstliche Maßnahmen, wie zum Beispiel Wiederaufforstung (vgl. Kirchstetter, 2013, 17).

Eine Veränderung oder Störung kann definiert werden als relativ diskretes Ereignis, das innerhalb kurzer Zeit auftritt und die Struktur eines Ökosystems, einer Gesellschaft oder einer Population verändert bzw. stört. (vgl. Pickett und White, 1986; nach Verbesselt et al., 2012). Diese Veränderungen sind die zentralen Triebkräfte von räumlichen und zeitlichen Heterogenitäten (vgl. Turner, 2010; nach Verbesselt et al., 2012, 98).

6

Da viele der aktuellen Veränderungen weltweit an unbekannten, oder unzugänglichen Orten auftreten, können fernerkundliche Methoden als Frühwarnsystem fungieren, bzw. wichtige Informationen über Veränderungen bereitstellen. Satellitendaten sind gut dafür geeignet, da diese in regelmäßigen Abständen aufgenommen werden und große Flächen abdecken (vgl. Verbesselt et al., 2012, 98). Die Kartierung von Entwaldung entsteht mittlerweile in immer kürzeren Zeitabständen, was an der höheren Datenverfügbarkeit und kürzeren Intervallen zwischen zwei Bildern liegt (vgl. Asner, 2001; nach Hamunyela et.al., 2016, 126).

Dies bedeutet, dass Veränderungsdetektion unter diesen Umständen immer genauer durchführbar ist, wodurch besser und schneller auf Gefahren und Störungen reagiert werden kann. Probleme ergeben sich beim Thema Veränderungsdetektion daher, dass es zwar immer regelmäßigere Bilddaten mit unterschiedlichen Auflösungen gibt, jedoch ist der Einfluss von Störfaktoren wie z.B. Wolkenbedeckung oder Wolkenschatten nicht zu vernachlässigen. Dadurch verlängern sich die jeweiligen Aufnahmeintervalle teilweise massiv und limitieren somit die erfolgreiche Erfassung wichtiger Veränderungen. Weiters ist die Datenqualität und die Signal-to-noise-ratio potentiell ein limitierender Faktor (vgl. Hamunyela, 2016, 129). Im Bezug dazu soll diese Arbeit die folgende Forschungsfrage beantworten:

Können jene Schäden, verursacht durch Sturm Niklas im Jahr 2015, anhand von Landsatdaten mittels BFAST erfasst werden?

Der Wald besteht aus Laub-, Nadel- und Mischwaldbeständen und es soll getestet werden, inwiefern der Algorithmus BFAST die unterschiedlichen Waldarten zu verarbeiten und Veränderungen zu detektieren im Stande ist, ab wann diese Veränderungen von dem Algorithmus erfasst werden und in welchem Ausmaß.

Zur Beantwortung der Frage werden in Kapitel 2 zunächst die Grundlagen der Fernerkundung, elektromagnetischer Strahlung, Eigenschaften von Satellitendaten, sowie Zeitreihenanalyse und Veränderungsdetektion besprochen. Danach werden vier Möglichkeiten wie Veränderungsdetektion umgesetzt werden kann, beschrieben. Damit soll auf die breite Palette an verfügbaren Methoden aufmerksam gemacht werden. Der Hauptfokus liegt auf dem Algorithmus Breaks For Additive Season and Trend (BFAST), der hier im Detail erklärt wird. Anschließend werden im Kapitel 3 das Untersuchungsgebiet, sowie die Datengrundlage und die zur Verfügung stehenden Referenzdaten beschrieben. Darauf aufbauend wird schließlich die Vorgehensweise der Auswertung erläutert. Ziel ist es, die vorliegenden Normalized Difference Vegetation Index (NDVI), Fraction of Absorbed Photosynthetically Active Radiation (fAPAR) und teilweise auch Reflectance (Reflexionsvermögen) Daten mit BFAST auszuwerten und vor allem einen Windwurf im Jahr 2015 zu verifizieren und anhand dessen eine Aussage über die Funktionsfähigkeit von BFAST treffen zu können. Darauf folgen die Ergebnisse, sowie die Validierung der ausgewerteten Daten, welche im Diskussionskapitel genauer betrachtet und hinterfragt werden. Den Abschluss bildet die Zusammenfassung.

# 2 Grundlagen der Fernerkundung

Hier werden kurz die Grundlagen der Fernerkundung umrissen, um eine fundierte Ausgangsbasis für die weitere Vorgangsweise und die später folgenden Resultate zu bieten.

Es gibt zahlreiche Methoden, um Informationen über die Erdoberfläche zu erlangen. In der Fernerkundung handelt es sich um indirekte Beobachtungsverfahren, das heißt die Informationserfassung der Erdoberfläche erfolgt berührungsfrei aus der Ferne. Es geht dabei um die Generierung von räumlichen (Bild-) Informationen, die mittels Sensoren auf Flugzeugen, UAVs (Unmanned Aerial Vehicle) und Satelliten erhoben werden. Im Fokus steht die Beobachtung der Erdoberfläche, der Meeresoberfläche und der Atmosphäre mit allen darauf befindlichen Objekten und deren Eigenschaften. Die Grundlage dazu bildet die elektromagnetische Strahlung in diversen Wellenlängenbereichen, die von den zu beobachtenden Objekten reflektiert oder emittiert wird (siehe Kapitel 2.2.2) (vgl. Albertz, 2007, 1).

Fernerkundung beinhaltet jedoch nicht nur die Datenaufnahme, sondern auch die Datenspeicherung, sowie die Datenauswertung. Durch einen Sensor wird die von Objekten auf der Erdoberfläche ausgehende elektromagnetische Strahlung aufgenommen und in Bilddaten umgesetzt und gespeichert. "Dies alles setzt voraus, dass die elektromagnetische Strahlung von den Objekten an der Erdoberfläche in charakteristischer Weise beeinflusst wird, da sonst keine Objektinformation daraus abgeleitet werden könnte" (vgl. Albertz, 2007, 2).

Fernerkundlich erfasstes Bilddatenmaterial stellt eine große Menge an Informationen über das abgebildete Gelände dar. Um dieses Informationspotential ausnutzen zu können, bedarf es unterschiedlicher Auswertungsmethoden.

"Jedes Bild ist das Ergebnis eines Abbildungsprozesses, dem sowohl geometrische, als auch radiometrische (physikalische) Aspekte zugrunde liegen." (Albertz, 2007, 9)

Der geometrische Aspekt bestimmt die räumliche Lage der Bildinformation und der radiometrische gibt die Intensität und die spektrale Zusammensetzung der erfassten elektromagnetischen Strahlung an. Beide Aspekte sind für Messungen und Interpretationen der Bilddaten wichtig (vgl. Albertz, 2007, 9).

# 2.2 Elektromagnetische Strahlung und Reflexionsgrad

Zunächst wird das elektromagnetische Strahlungsspektrum grob umrissen, um darauffolgend die Erläuterung des Reflexionsgrades anhand des Beispiels Vegetation zu veranschaulichen. Desweiteren werden zwei Vegetationsindizes (Normalized Difference Vegetation Index: NDVI und Fraction of Absorbed Phototsynthetically Active Radiation: fAPAR), welche die Ausgangsbasis für die späterfolgende Auswertung der Daten darstellen, erklärt. Ein Vegetationsindex dient zur Quantifizierung der grünen Blattvegetation und soll darstellen ob die Vegetation gesund ist oder unter Stress steht (vgl. Weier und Herring, 2000, s.p.).

## 2.2.1 Strahlung

"Die elektromagnetische Strahlung ist eine Form der Energieausbreitung (Albertz, 2007, 10)" und bildet die Grundlage für die fernerkundliche Datenbeschaffung.



Abbildung 1: Elektromagnetisches Strahlungsspektrum (lt. Albertz, 2007, 11)

Wie in Abbildung 1 ersichtlich ist, teilt sich das elektromagnetische Strahlungsspektrum in nicht klar abgrenzbare Teilbereiche. Am besten bekannt ist der Bereich des sichtbaren Lichtes, der grob zwischen 400-700 nm liegt. In der Fernerkundung werden hauptsächlich der blaue, grüne, rote, sowie der nahe Infrarotbereich ausgenützt. Der kürzere Wellenlängenbereich davor besteht aus ultravioletter Strahlung und Röntgenstrahlung, welche jedoch aufgrund eines niedrigen Transmissionsgrades der Atmosphäre (Undurchlässigkeit) weniger Bedeutung für die Fernerkundung haben, da es hier keine bzw. nur sehr begrenzte Aufnahmemöglichkeiten gibt. Der längere Wellenlängenbereich im Anschluss an das sichtbare Licht bildet die Infrarotstrahlung. Diese wird grob unterteilt in nahes, mittleres und fernes/thermischen Infrarot bis 1 mm. Danach folgt der Bereich der Mikrowellen und abschließend die Radiowellen (vgl. Albertz, 2007, 11). Fernerkundlich nutzbar sind demnach die Bereiche des sichtbaren Lichts, die Infrarotstrahlung und Mikrowellenstrahlung.

"Die elektromagnetische Strahlung, die auf einen Körper trifft, wird zu einem Teil an seiner Oberfläche reflektiert, ein weiterer Teil wird von ihm absorbiert und der Rest durchdringt den Körper." (Albertz, 2007, 12)

#### 2.2.2 Reflexionsgrad und Vegetation

Jeder Körper befindet sich durch die elektromagnetische Strahlung in kontinuierlicher Wechselwirkung mit der Umgebung. "Auf den objekt- bzw. materialspezifischen Eigenschaften dieser Wechselwirkung beruht die ganze Fernerkundung." (Albertz, 2007, 12) Denn durch die unterschiedliche Beschaffenheit der Objekte ergeben sich die zu unterscheidenden spektralen Signaturen (Pixelwerte) der betreffenden Objekte, anhand derer die Unterscheidung der Objekte erst möglich wird.

Das bedeutet, dass diese spektralen Signaturen und charakteristischen Grauwerte und Farben in den Spektralbereichen des sichtbaren Lichtes und des nahen und kurzwelligen Infrarotes (die vorwiegend für Vegetationserhebungen herangezogen werden) durch den unterschiedlichen Reflexionsgrad, abhängig vom Wellenlängenbereich, unterschieden werden können (vgl. Albertz, 2007, 12).

Blätter erscheinen für das menschliche Auge grün, weil hauptsächlich grünes Licht von den chlorophyllhaltigen Blattpigmenten reflektiert wird. Rotes und blaues Licht wird jedoch vorwiegend absorbiert. Die Infrarot-Strahlung hingegen wird weitgehend an den Zellwänden und luftgefüllten Hohlräumen mehrfach gespiegelt und daher großteils reflektiert

(Vielfachreflexion bedingt hohen Reflexionsgrad). Dies erklärt warum der Reflexionsgrad im nahen Infrarotbereich für den Grad der Vitalität von Vegetation sehr aussagekräftig ist (vgl. Albertz, 2007, 19).



Abbildung 2: spektrale Signaturen (lt. Albertz, 2007, 19)

Wie in Abbildung 2 erkennbar ist, steigt der Reflexionsgrad von Vegetation beim Übergang vom sichtbaren Licht zum nahen Infrarot steil an. Durch Veränderung der Blattpigmentierung und aufgrund von Wachstumsprozessen oder unterschiedlicher anderer Störfaktoren, ändert sich das Reflexionsverhalten im Lauf der Vegetationsperiode. Vor allem mit zunehmender Schädigung der Vegetation geht eine Änderung des Reflexionsgrades einher. Im Bereich des nahen Infrarot nimmt der Reflexionsgrad mit zunehmender Schädigung ab und steigt im roten Bereich an (vgl. Albertz, 2007, 20). Deswegen bietet sich für die Auswertung von Vegetationsdaten die Verwendung des nahen Infrarotbereiches (NIR) und der Bereich des sichtbaren Lichts an.

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

Der Normalized Difference Vegetation Index (NDVI) ist ein Maß für die Vitalität der Vegetation bzw. ein Maß für die Dichte an grüner Biomasse. Er ist der am häufigsten verwendete Vegetationsindex (vgl. Huete et al., 1999, 20) und wird wie folgt berechnet:

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

Dieser Index ist somit das Ergebnis einer multispektralen Transformation, quasi einer Berechnung eines neuen Bildkanals, der die Vitalität der Vegetation in Grauwertstufen codiert.

Es handelt sich um eine topografisch-radiometrische Normalisierung, also eine radiometrische Entzerrung, mit der der Einfluss der Geländeform auf die Intensität der reflektierten Strahlung ausgeglichen wird. "Damit können die Auswirkungen von Anomalien im Witterungsverlauf analysiert und langfristige großräumige Veränderungen der Vegetationsbedeckung erfasst werden." (Albertz, 2007, 221) Er ist eine relative und indirekte Bewertung des Anteils an photosynthetischer Biomasse und korreliert mit biophysikalischen Parametern wie zum Beispiel dem grünen Biomasseanteil, der ebenfalls dem jährlichen Zyklus des Vegetationswachstums folgt (vgl. Verbesselt et al., 2010a, 108).

#### 2.2.4 Fraction of Absorbed Photosynthetically Active Radiation (fAPAR)

Fraction of Absorbed Photosynthetically Active Radiation (fAPAR), beschreibt die Effizienz der pflanzlichen Lichtabsorption und ist ein kritischer biophysikalischer Parameter in ökologischen Umweltstudien (vgl. Sellers et al., 1992 und Majasami et al., 2014; nach Wang et al., 2016, 1). Es handelt sich um den Anteil der photosynthetisch aktiven Strahlung, der von Vegetation absorbiert wird. Hierbei bezieht sich PAR auf die eintreffende solare Strahlung im sichtbaren Bereich zwischen 400-700 nm (vgl. Weiss et al., 2007; nach Wang et al., 2016, 1).

Die Berechnung aus den vorliegenden Satellitendaten lautet wie folgt:

$$\frac{0,27505 * NIR - 0,35511 * RED - (-0,004)}{(-0,322 * RED)^2 + (0,299 - NIR)^2 - (-0,0131)^2}$$

$$pro Pixel = fAPAR * \frac{0,97}{0,914} * 1000$$

Es wird darauf hingewiesen, dass die vorliegende Formel nur eine von vielen Möglichkeiten der fAPAR-Berechnung darstellt. fAPAR quantifiziert die photosynthetische Kapazität von Vegetation (vgl. GCOS, 2011) und zählt zu den Essential Climate Variables (ECV). ECVs sind technisch und ökonomisch plausible Maße der systematischen Beobachtung von Atmosphäre, Ozeanen und Land. Diese haben großen Einfluss auf die Anforderungen der United Nations Framework Convention on Climate Change (UNFCCC) und des Intergovernmental Panel on Climate Change (IPCC) (vgl. Claverie et al., 2013, 216). Zusätzlich lässt dieser Index die Schätzung der Netto-Primär-Produktivität von Vegetation zu (vgl. Yuan et al., 2015, 7426).

Empirische Modelle nutzen jedoch nicht die komplexe Übertragung von Sonnenstrahlung auf den Wald und können nur auf bestimmte Bedingungen angewendet werden. Ein potenziell

robusterer Ansatz besteht darin, Strahlungstransfermodelle zu verwenden. Physikalisch basierte Modelle können viele verschiedene Arten von Bedingungen behandeln und den Einfluss von biochemischen, strukturellen oder Beobachtungsvariablen auf die canopy reflectance (Baumkronenreflexion) nachweisen (vgl. laquinta et al., 1997; nach Yuan et al., 2016, 7426).

## 2.2.5 Tasseled Cap Brightness (TCB)

Die Tasseled Cap Transformation (TCT) ist eine orthogonale Transformation, die Landsat Bänder in drei Komponenten der jeweiligen beobachteten Oberfläche konvertiert: Brightness (TCB), Greenness (TCG) und Wetness (TCW) (vgl. Banskota et al., 2014, 11). Die Komponenten korrespondieren mit den physikalischen Eigenschaften von Vegetation und wurden bereits ausgiebig zur Veränderungsdetektion in Waldgebieten herangezogen (vgl. Cohen et al., 2002; Wulder et al., 2004; Healey et al., 2005; Jin & Sader, 2005; Kayastha et al., 2012, nach Banskota et al., 2014, 11).

Die dahinterliegende Theorie ist, dass veränderte Waldflächen höhere Helligkeitswerte (Brightness), aber niedrigere Greenness- und Wetness-Werte, als unveränderte Waldflächen haben (vgl. Thayn, 2013, 210).

TCB errechnet sich wie folgt:

$$(0,356 * (Band1) + 0,397 * (Band2) + 0,390 * (Band3) + 0,697 * (Band4) + 0,229 * (Band5) + 0,160 * (Band7))$$

Da für die folgenden Ergebnisse nur TCB berechnet wurde, werden TCG (Tasseled Cap Greenness) und TCW (Tasseled Cap Wetness) hier nicht näher behandelt. Es gäbe die Möglichkeit durch die Kombination der drei Tasseled Cap Indizes, den sogenannten Disturbance Index DI (DI=TCB-(TCG+TCW)) abzuleiten. Der Vorteil für diesen Index bezieht sich darauf, dass er nur einem vom Untersuchungsgebiet abhängigen Schwellenwert benötigt und abgesehen davon automatisiert funktioniert (vgl. Baumann et al., 2014, 174).

Landsat ist eines der besten Mittel, um langfristige Landbedeckungsveränderungen und deren Einfluss auf regionale Vegetationsproduktivität zu verstehen. Viele anthropogen Landbedeckungsveränderungen treten in Flächen unter 250 m auf, wobei die räumliche Auflösung von Landsatdaten mit 30 m ein gutes Instrument für die Erfassung solcher Veränderungen dient (vgl. Townsend, 1987; nach Neigh et al., 2014, 2783).

# 2.3 Eigenschaften von Satellitendaten

In der Folge werden die wichtigsten Eigenschaften von Satellitendaten, in diesem Fall Landsatdaten, näher beschrieben.

# 2.3.1 Erkennbarkeit von Objekten, räumliche Auflösung

Ob ein Objekt erkennbar ist oder nicht, hängt von mehreren Faktoren ab. Die Erkennbarkeit ist abhängig vom Auflösungsvermögen des Aufnahmesystems, den Eigenschaften des Objekts und der Umgebung (Kontrast, Helligkeit) und dem Maßstab der Aufnahme (vgl. Albertz, 2007, 82). Die Pixelgröße, im Fall von Landsatdaten 30 m, definiert die Auflösung von Rasterbildern, und gibt an wie groß ein Pixel in der Natur ist. Dieser Wert ist aber auch abhängig von der Entfernung des Projektionszentrums zur Oberfläche und ändert sich bei unterschiedlichen Geländehöhen. Dieses Maß beschreibt also in der Regel einen idealisierten Zustand, und ist nicht als strikte Vorgabe zu sehen. Das bedeutet, dass diese die minimale Auflösung beschreibt, bei höheren Geländehöhen und damit reduziertem Abstand zwischen Gelände und Sensor wird die Auflösung dementsprechend besser (vgl. Albertz, 2007, 84).

# 2.3.2 Geometrische Eigenschaften

Geometrische Genauigkeit ist eine der wichtigsten Grundlagen in der Fernerkundung. Diese Voraussetzung muss erfüllt sein, um genaue Messungen durchführen, sowie um Objekte geometrisch richtig darstellen zu können. Vor allem wenn Bilddaten mit unterschiedlichen Aufnahmezeitpunkten kombiniert werden sollen, bedarf es einer sehr genauen geometrischen Transformation um die Lagerichtigkeit sicherzustellen (vgl. Albertz, 2007, 69). Denn es ist wichtig, die einzelnen Pixel lagemäßig exakt zuordnen zu können und damit für die Veränderungsdetektion nutzbar zu machen. Dies wird in Kapitel 2.4 näher behandelt.

## 2.3.3 Radiometrische und spektrale Eigenschaften

"Jeder Spektralbereich vermittelt andere Informationen." (Albertz, 2007, 8)

Die radiometrischen Eigenschaften ergeben sich, da Intensität und spektrale Zusammensetzung der elektromagnetischen Strahlung die Bildentstehung beeinflussen (beziehungsweise diese von der Zusammensetzung abhängt). Aus physikalischen Gründen tritt bei jeder Messung ein Rauschen auf, also eine Schwankung in den Messdaten. Nur wenn das Messsignal deutlich über dem Rauschen liegt, kann es erfasst und davon abgegrenzt werden. Das Signal-Rausch-Verhältnis (also das Verhältnis von objektspezifischen Signalen und sensorspezifischen Rauschen) bestimmt die Leistungsfähigkeit eines Sensors. Rauschen entsteht durch Wolkenbedeckung, Wolkenschatten, atmosphärische Streuung und den Sensor selbst.

Eine Verbesserung des Signal-Rausch-Verhältnisses geht immer mit einer Verschlechterung eines Parameters einher, zum Beispiel bedeutet bei digitalen Aufnahmesystemen eine höhere radiometrische Auflösung (Anzahl der möglichen Grauwertstufen) immer eine geringere geometrische Auflösung (großes IFOV – Instantaneous Field of View, also ungenauerer Bodenauflösung oder höhere Pixelgröße). Bei der Auswertung ist es vor allem wichtig, Rauschen in den Daten zu erkennen und durch Filterungsmethoden zu minimieren, ohne dabei den Informationsgehalt durch Glättung zu sehr zu verzerren (vgl. Albertz, 2007, 80).

Die spektrale Auflösung gibt an, wie viele Spektralkanäle und in welche Bandbreite des Wellenlängenspektrums diese vorliegen. Dies ist wichtig für die Erfassung unterschiedlicher spektraler Signaturen von Oberflächen, da sich hier Unterschiede in der Reflexionscharakteristik (siehe auch Kapitel 2.2.2) erheben lassen (vgl. Albertz, 2007, 81).

#### 2.3.4 Temporale Auflösung

Die temporale Auflösung gibt an, in welchem zeitlichen Abstand die Zeitreihe aufgenommen wurde. Die Landsat Satelliten benötigen 16 Tage um eine weitere Beobachtung desselben Gebiets zu liefern. Abhängig von der Wolkenbedeckung kann sich dieser Zeitraum aber auch verlängern. Mit Methoden des Gapfillings, also einer rechnerischen Interpolation vorangegangener und nachfolgender Aufnahmen, kann Abhilfe geschaffen werden (vgl. Vuolo et al., 2016, 7). Es gibt unterschiedliche Möglichkeiten ein Gapfilling durchzuführen. Diese sind davon abhängig, für welche Anwendung die Daten benötigt werden und wieviele Beobachtungen durch Wolkenbedeckung bzw. Wolkenschatten fehlen.

Es besteht auch die Möglichkeit mehrere Sensoren mit unterschiedlichen Aufnahmeintervallen zu kombinieren um somit die temporale Auflösung zu erhöhen und damit mehr Informationen über Veränderungen zu generieren (vgl. Pohl und Van Genderen, 1998, 828).

# 2.4 Zeitreihenanalyse und Veränderungsdetektion

Der erste Schritt einer Analyse ist die genaue Definition, welche Frage diese beantworten soll (vgl. Lunetta, 1999, 4). Die erste Veränderungsdetektionsanalyse anhand von Satellitendaten verwendete das "blink" Prinzip, welches ursprünglich dafür benutzt wurde Veränderungen in der Position und in der Leuchtkraft von Sternen zu erfassen (vgl. Lunetta, 1999, 10). Seither wurde in diesem Bereich viel geforscht und eine Vielzahl unterschiedlicher Methoden und Vorgehensweisen entwickelt (vgl. Menzel, 1970; Masry et al., 1975; nach Lunetta, 1999, 10). Zu diesen unterschiedlichen Zugängen und Methoden gehören zum Beispiel Post-Classification Approaches, Pre-Classification Approaches, Composite Analysis, Image Differencing, Principal Component Analysis, Change Vector Analysis und viele mehr (vgl. Lunetta, 1999, 11ff). Die angewendeten Methoden werden später beschrieben.

"Eine Zeitreihe ist eine zeitlich geordnete Folge von Merkmalswerten." (Bourier, 2011, 155) Das bedeutet am Beispiel dieser Arbeit, dass das Untersuchungsgebiet über den Zeitraum mehrerer Jahre in regelmäßigen Zeitabständen untersucht wurde. Für die Auswertung der Daten ist es von grundlegender Bedeutung die Struktur und die Gesetzmäßigkeiten (wie zum Beispiel die Zeitpunkte der Aufnahmen, Prozessierung der Daten, etc.) der Zeitreihe zu erkennen, um die Entwicklung richtig einschätzen und beurteilen zu können (vgl. Bourier, 2011, 155).

Bei einer Zeitreihenanalyse handelt es sich demnach um multitemporale Datenverarbeitung. Demnach werden mehrere Bilder desselben Geländes mit unterschiedlichem Aufnahmezeitpunkt analysiert (vgl. Albertz, 2007, 119). Daraus lassen sich Veränderungen ableiten, woraufhin sich im Laufe der Zeit der Begriff ,change detection', also Veränderungsdetektion eingebürgert hat. Dabei ist die geometrische Genauigkeit von großer Bedeutung, da die jeweiligen Pixel in der Zeitreihe unbedingt klar zuordenbar sein müssen (vgl. Albertz, 2007, 120).

Differenzbilder entstehen aus einfacher Bildsubtraktion (vgl. Vogelmann, 1988; Price et al., 1992; nach Cohen & Fiorella, 1999, 89). Dazu werden zwei Bilder zu unterschiedlichen

Zeitpunkten, welche sich lagemäßig genau decken, benötigt (vgl. Cohen & Fiorella, 1999, 89). Übrig bleiben die abweichenden Restwerte. Diese werden in einer Grauwertmatrix gespeichert und je nachdem ob die Abweichung positiv oder negativ ausschlägt, werden die veränderten Bereiche heller oder dunkler dargestellt. Dies ist eine der einfachsten Methoden der Veränderungsdetektion (vgl. Albertz, 2007, 120).

Eine Veränderung, stellt eine Abweichung des Normalzustands dar. Demnach zeigt eine Veränderung in Waldgebieten entweder eine Zu- bzw. Abnahme des erwarteten Zustands (abgeleitet aus Vorjahren). Zur genauen Zuordnung um welche Art der Veränderung es sich handelt, sind weitere zusätzliche Daten notwendig (vgl. DeVries et al., 2015; nach Hamunyela et al., 2016, 130).

Fernerkundlich überwachte Veränderungen können in die drei folgenden Kategorien unterteilt werden:

- 1. Saisonale und zyklische Veränderungen (zum Beispiel jährliche Temperaturschwankungen und variierende jährliche Niederschlagsmenge aufgrund der Jahreszeiten und damit ein unterschiedlicher Anteil an Biomasse),
- 2. Graduelle Trendveränderungen (zum Beispiel der mittlere jährliche Niederschlag und graduelle Veränderungen im Landmanagement)
- Abrupte Trendveränderungen durch anthropogene Einflüsse (zum Beispiel Abholzung) oder Naturereignisse (zum Beispiel Überschwemmungen, Dürren, Brände und Windwürfe) (vgl. Vogelmann et al., 2012; nach Verbesselt et al., 2012, 98).

Die vorliegende Arbeit untersucht Windwürfe und demnach abrupte Veränderungen.

# 2.5 Verschiedene Arten der Veränderungsdetektion

Hier werden der Vollständigkeit halber unterschiedliche Möglichkeiten der Veränderungsdetektion beschrieben, auch wenn vorliegende Arbeit sich ausschließlich auf BFAST konzentriert. Dies soll zeigen, dass es eine Vielzahl an Methoden und Vorgehensweisen gibt, Veränderungen in Satellitendaten zu detektieren.

## 2.5.1 Überblick verschiedener Veränderungsdetektionsmethoden

Der Vegetation Change Tracker (VCT) ist ein höchst automatisierter Algorithmus für die Veränderungsdetektion von Vegetation (vgl. Huang et al., 2010, 183). Um Waldveränderungen zu erfassen ist es hier wichtig, die spektralen und zeitlichen Eigenschaften zu untersuchen. Aufgrund der Absorption von grüner Vegetation und Blätterdachschatten ist Wald sehr dunkel dargestellt. Während der belaubten Vegetationsphase und in der Mitte der Wachstumsphase sind die spektralen Signaturen (im sichtbaren Bereich des Lichtes und im NIR) relativ stabil. Im Vergleich dazu besitzen Nicht-Waldflächen oft höhere Variabilität. Darauf aufbauend wird das zu bearbeitende Ursprungsbild zunächst maskiert (Wasser, Wolken, Wolkenschatten) und Beispielflächen für Wald definiert. Diese Beispielflächen werden dann dafür herangezogen um die Wahrscheinlichkeit für jedes Pixel zu berechnen ob es sich dabei um Wald handelt, oder nicht. Jene als Wald ausgewiesene Pixel werden anschließend in Vegetationsindizes umgerechnet. Der zweite Schritt ist die Zeitreihenanalyse, um Trajektorien zu berechnen und Waldveränderungen zu erfassen. Hier kann es sein, dass sich die erfassten Veränderungen nicht nur auf Waldflächen beziehen, da diese Flächen nicht direkt abgegrenzt wurden, sondern per Probabilität definiert werden (vgl. Huang et al., 2010, 185).

Weiters 2014 wurde ein neuer Algorithmus, Continous Change Detection Classification CCDC von Landbedeckung, der die gesamten verfügbaren Landsatdaten verwendet, entwickelt (vgl. Zhu & Woodcock, 2014, 152). Denn auch in Bildern mit hoher Wolkenbedeckung finden sich **Bereiche** mit Informationsgehalt, die sich dementsprechend für eine Veränderungsdetektionsanalyse eignen. Um die bestehende Wolkenbedeckung zu schätzen wird FMask (siehe Zhu & Woodcock, 2012) angewendet (vgl. Zhu & Woodcock, 2014, 153). Dadurch wird es möglich, Veränderungsdetektion mit hoher räumlicher und temporaler Auflösung durchzuführen. Sobald ein neues Landsat Bild verfügbar wird, kann es anhand dieses Algorithmus klassifiziert und auf Veränderungen untersucht werden (vgl. Zhu & Woodcock, 2014, 154).

Der Algorithmus wendet noch einen zweiten Schritt an um Ausreißer, die durch FMask nicht erfasst wurden, herauszurechnen. Er vergleicht Modellberechnungen mit Beobachtungen und erreicht damit eine Glättung der Daten (vgl. Zhu & Woodcock,2014, 155).

Auch hier werden, wie bei BFAST (siehe Kapitel 2.5.2) drei Typen der Veränderungen unterschieden. Darüber hinaus wird ein Zeitreihenmodell angewandt, das die Saisonalität, einen Trend und Unterbrechungspunkte voneinander trennt. Die Modellkoeffizienten werden mittels OLS (Ordinary Least Squares) geschätzt. Die Basis dieser Methode bildet ein Vergleich

18

von Modellvorhersagen mit den Landsat Beobachtungen, um Veränderungen herauszufiltern. Je öfter ein Pixel als verändert klassifiziert wird, umso höher ist die Wahrscheinlichkeit, dass es sich um eine Veränderung der Landbedeckung handelt, als um Rauschen in den Daten. Zeigt ein Pixel an ein oder zwei konsekutiven Zeitpunkten Veränderung, wird es als "mögliche Veränderung" klassifiziert. Tritt auch beim dritten Mal eine Änderung auf, wird dieses Pixel als verändert aufgenommen (vgl. Zhu & Woodcock, 2014, 157). Sobald eine neue Beobachtung vorhanden ist wird das bestehende Zeitreihenmodell aktualisiert und das neue Bild ebenfalls klassifiziert (vgl. Zhu & Woodcock, 2014, 158).

#### 2.5.2 Breaks for additive Season and Trend (BFAST)

Breaks For Additive Season and Trend (BFAST) ist ein im Programm R implementierter Algorithmus, der als Veränderungsdetektionsmethode eingesetzt wird. Dieser ermöglicht es, Veränderungen in Waldgebieten zu erfassen. Erstmals publiziert wurde diese Methode 2010 von Verbesselt et al., im Jahr 2012 wurde der Algorithmus angepasst (um auch nahezu Echtzeitauswertung neu verfügbarer Daten zu ermöglichen) (vgl. Hamunyela et.al., 2016, 127).

Die Erfassung und Charakterisierung von Veränderungen über längere Zeiträume ist der logische erste Schritt in Richtung Identifikation der Auslöser von Veränderungen und dem Verstehen eines Veränderungsmechanismus. Satellitendaten ermöglichen konsistente und wiederholbare Messungen im räumlichen Rahmen und sind daher gut zur Veränderungsdetektion geeignet. Die Erfassung von Veränderungen erfolgt innerhalb eines vollständigen Langzeitdatensatzes, bei gleichzeitiger Berechnung saisonalen der Schwankungen (vgl. Roy et al., 2002; nach Verbesselt et al., 2010a, 106).

Der Algorithmus ermöglicht die Erfassung verschiedener Veränderungstypen (siehe nachfolgende Seite), die in derartigen Zeitreihen auftreten können und verknüpft die Zerlegung der Zeitreihe in eine Saisonalitäts-, eine Trend- und eine Rauschkomponente für die Erfassung von multiplen Veränderungen. BFAST schätzt das Datum und die Anzahl der Veränderungen iterativ innerhalb der Saisonalitäts- bzw. der Trendkomponente in der vorliegenden Zeitreihe. Die Charakterisierung der Veränderungen entsteht durch die Erfassung des Ausmaßes/der Stärke und der Tendenz der Veränderung. Veränderungen in der Trendkomponente indizieren graduelle und abrupte Veränderungen, wobei phänologische und zyklische Abweichungen der Saisonalitätskomponente zugeschrieben werden. Es müssen keine bestimmten Landbedeckungsklassen, Referenzperioden, Schwellenwerte oder Veränderungstrajektorien festgelegt werden. Außerdem ist BFAST relativ robust gegen Rauschen und wird nicht durch die Amplitude der Veränderung der Saisonalität beeinflusst (vgl. Verbesselt et al., 2010a, 114). Diese Methode lässt sich außerdem auf unterschiedlichste Arten von Zeitreihen anwenden und nicht nur auf fernerkundliche Vegetationsindizes (vgl. Verbesselt, 2010a, 108).

"Der Trend beschreibt die langfristige Grundrichtung einer Zeitreihe. Um ihn streuen die Zeitreihenwerte im Zeitablauf. Für den Trend sind dauerhaft wirksame Einflüsse verantwortlich, die sich i.d.R. nur sehr langsam verändern. Der Trend ist daher ein glatter Kurvenverlauf." (Bourier, 2011, 156) BFAST zeigt zusätzlich auch abrupte Veränderungen in der Trendkomponente an.

Abweichungen von durchschnittlichen Saisonalitätstrends in der Vegetation über mehrere Jahre können Indikatoren für die Auslöser der Veränderungen sein. Zum Beispiel:

- physikalische (Brände, Überschwemmungen, Dürren, Windwürfe),
- biogene (pflanzenfressende Insekten, Pathogene, ...) und
- anthropogene Faktoren (Abholzung, Urbanisierung, ...) (vgl. Vogelmann et al., 2012; nach Verbesselt et al., 2012, 98).



Abbildung 3: Simulierte 16-Tage-MODIS-NDVI-Zeitreihe. Die simulierte Datenreihe (erste Grafik) ist die Summe der simulierten Saisonalitäts-, Trend- und Rauschkomponeten (- - -) und wird als Input in BFAST verwendet. Die geschätzten Saisonalitäts- (zweite Grafik), Trend- und Restkomponenten (vierte Grafik) sind rot dargestellt. Es werden drei Breakpoints innerhalb der geschätzten Trendkomponente (dritte Grafik) erkannt. (Verbesselt et al., 2010a)

In Abbildung 3 ist das Ergebnis einer BFAST-Ausgabe-Grafik dargestellt. In der obersten Grafik wird die verwendete Zeitreihe dargestellt, welche in die vorher bereits angesprochenen Komponenten zerlegt wird. In der zweiten Grafik darunter ist das angepasste Saisonalitätsmodell ersichtlich. Abweichungen der Saisonalitätskomponente werden als phänologische Veränderungen erfasst. In der dritten Grafik wird die Trendkomponente abgebildet, welche graduelle bzw. abrupte Veränderungen anzeigt. Hier sind alle zwei Jahre Knicke zu sehen, was darauf hindeutet, dass hier eine abrupte Abnahme der Biomasse durch z.B. Ernte stattgefunden hat. Die vierte und letzte Grafik stellt die Rest- bzw. Remainderkomponente dar, die Rauschen und alle Werte die nicht den anderen Komponenten zugerechnet werden konnten, beinhaltet.

BFAST ist eine generische Veränderungsdetektionsmethode, die nicht kalibriert ist um zum Beispiel Abholzung von anderen Störungen zu unterscheiden. Das bedeutet, dass die Erfassung eines negativen Unterbrechungspunktes (auch als Breakpoint bezeichnet, zeigt die Detektion einer Veränderung an, also eine Abweichung vom Normalzustand) nicht unbedingt Abholzung impliziert. Das Ausmaß der Veränderung ist wichtig für die bessere Unterscheidung zwischen Abholzung und anderen Formen von Störungen, wie Insektenbefall, Windwürfen, oder Ähnliches. Für die genaue Zuordnung der Art der Veränderung, werden zusätzliche Daten benötigt (vgl. DeVries et al., 2015; nach Hamunyela et al., 2016, 130).

Wie zu Beginn bereits erwähnt, vereint BFAST die iterative Zerlegung von Zeitreihen in Trend-, Saisonalitäts- und Rauschkomponenten mit Methoden der Veränderungsdetektion, ohne eine Referenzperiode auswählen zu müssen, ohne dem Setzen eines Schwellenwertes oder der Definition einer Veränderungstrajektorie (vgl. Verbesselt et al., 2010a, 107).

Standardzeitreihenzerlegungsmethoden nehmen an, dass Trend und Saisonalität glatt, also für alle Jahre konstant, sind und sich nur langsam verändern. Daher sind jene für diese Art der Veränderungsdetektion nicht direkt anwendbar. Diese Methode identifiziert automatisch eine stabile Referenzperiode ohne Störungen oder Veränderungen und ermöalicht Veränderungsdetektion neuer Beobachtungen nahezu in Echtzeit. Der Rauschpegel bleibt nach dem Anpassen des Saisonalitäts- und Trendmodells der Hauptfaktor der Fähigkeit zur Detektion von Veränderungen und Störungen und stellt eine Einschränkung dieser Methode dar. Da diese Methode datengetrieben, also abhängig von den zugrundeliegenden Daten ist, begrenzt das Signal-Rausch-Verhältnis die Möglichkeit zwischen Veränderung und keiner Veränderung zu unterscheiden. Denn eine Veränderung soll klar ersichtlich und klar abgrenzbar sein. Das Ausmaß bzw. die Stärke der Veränderung im Vergleich zum Rauschen ist wichtig und es müssen mehrere Beobachtungen mit der beinhalteten Veränderung vorhanden sein, um ein aussagekräftiges Ergebnis liefern zu können (vgl. Verbesselt et al., 2012, 105).

Das bedeutet, dass das Signal-Rausch-Verhältnis die Fähigkeit der Veränderungsdetektion beeinflusst und dass eine konsequente Vorprozessierung, die die Qualität und Zuverlässigkeit der Zeitreihe gewährleisten soll, vonnöten ist um die Veränderungsdetektion zu verbessern bzw. zu ermöglichen. Es ist wichtig Jahreszeitenwechsel zu berücksichtigen, weil diese den Rauschpegel erhöhen und damit die Wahrscheinlichkeit der Veränderungsdetektion minimieren.

Satellitenbasierte Daten beinhalten immer ein Rauschen. Das bedeutet, dass es negative Ausreißer in der Zeitreihe gibt, welche aufgrund von Wolkenbedeckung, atmosphärischer Streuung, etc., hohe Kommissionsfehler erzeugen und soweit wie möglich herausgerechnet werden sollen (vgl. Hamunyela et al., 2016, 129).

Für die Zerlegung der Zeitreihe durch BFAST in ihre einzelnen Komponenten, wird die STL-Methode (Seasonal Trend decomposition procedure based on Loess) angewandt, welche es ermöglicht eine Zeitreihe mittels LOcally wEighted regreSsion Smoother (LOESS) (vgl. Cleveland et al, 1990; nach Verbesselt et al., 2010a, 107) flexibel in eine Trend-, eine Saisonalitäts- und eine Rauschkomponente zu zerlegen. Diese Methode ermöglicht es, die meisten benötigten Parameter automatisch festzulegen (vgl. Cleveland et al., 1990, 28).

Der Ablauf der Zerlegung gliedert sich wie folgt:

- 1. Schätzung der Saisonalitätskomponente (Berechnung des Mittelwerts der saisonalen Anteile der Zeitreihe)
- OLS-MOSUM (Ordinary Least Square Moving Sum) Test f
  ür Anzahl und Position der Breakpoints der Trendkomponente
- 3. Berechnung der Trendkoeffizienten mittels robuster Regression
- 4. OLS-MOSUM Test für Anzahl und Position der Breakpoints der Saisonalitätskomponente, geschätzt von den trendbereinigten Daten
- 5. Berechnung der Saisonalität mittels robuster Regression
- 6. Iterativer Vorgang bis Anzahl und Position der erfassten Breakpoints unverändert bleibt

Abbildung 4 zeigt ausschließlich die Zerlegung einer CO2 Zeitreihe, in die Komponenten Saisonalität, Trend und Remainder bzw. Rest. Da die Entwicklung der CO2 Werte graduell erfolgt und auch keine saisonalen Abweichungen auftreten, werden hier keine Breakpoints angezeigt. Die Abbildung dient maßgeblich zur Veranschaulichung des Zerlegungsprozesses, erfasste Breakpoints werden in einem späteren Beispiel dargestellt.



Abbildung 4: Zerlegungsplot von täglichen CO<sub>2</sub> Daten, vertikale Einheiten in ppm (Cleveland et al., 1990, 28).

Der iterative Prozess der Breakpointbestimmung beginnt mit einer Schätzung der Saisonalitätskomponente mittels STL Methode (Abbildung 4). Zunächst wird der Mittelwert aller saisonalen Anteile der Zeitreihe erfasst. Werden dann im nächsten Schritt mittels OLS-

MOSUM (Ordinary Least Squares-Moving Sum) Test Breakpoints in der Trendkomponente gezeigt, können Anzahl und Position von den saisonal angepassten Daten geschätzt werden. Die Trendkoeffizienten werden anschließend mittels robuster Regression (angelehnt an M-Schätzungen von Venables und Ripley, 2002) berechnet.

Erkennt der OLS-MOSUM Test Breakpoints in der Saisonalitätskomponente, werden die Anzahl und Position der saisonalen Breakpoints von den trendbereinigten Daten geschätzt. Anschließend werden auch die Saisonalitätskomponenten mittels robuster Regression, basierend auf der vorhergenannten M-Schätzung, berechnet. Diese iterative Vorgehensweise wird solange fortgesetzt, bis sich die Anzahl und die Positionen der Breakpoints nicht mehr verändern (vgl. Verbesselt et al., 2010a, 108). Die optimale Position der Breakpoints kann durch die Minimierung der Summe der quadrierten Residuen gefunden werden. Das Datum, die Magnitude und das Konfidenzintervall werden für jeden einzelnen Breakpoint geschätzt (vgl. Verbesselt et al., 2010a, 108).

Ziel des Saisonalitätsmodells und der Trendbestimmung ist es, deren Muster in den resultierenden Resten der Zeitreihe zu entfernen (siehe Potter et al., 2003), während hier die Anpassung in einem einzigen Schritt durch OLS-Anpassung des Saison-Trend-Modells erfolgt. Wenn in den untersuchten Daten kein Trend und / oder keine Saisonalität vorliegen, können auch die entsprechenden Elemente des Regressors weggelassen werden (vgl. Verbesselt et al., 2012, 100)."

Die Saisonalitätskomponente ist zwischen Breakpoints fixiert, sie kann jedoch darüber hinaus variieren (also über mehrere Breakpoints nicht fixiert, sondern variabel). Außerdem müssen sich die Breakpoints der Saisonalität und denen des Trends nicht decken um eine Veränderung zu erfassen (vgl. Verbesselt et al., 2010a, 107), da die Ursache der Veränderung entweder durch phänologische Veränderungen (Saisonalitätskomponente), oder durch abrupte bzw. graduelle Veränderungen (Trendkomponente) bedingt ist (siehe Kapitel 2.4).

Die hier beschriebene Vorgehensweise bezieht sich auf das harmonische Saisonalitätsmodell, welches eines von drei im Algorithmus implementierten Modellen ist. Dieses eignet sich am besten um phänologische Veränderungen abzubilden. Weiters gibt es noch ein "dummy"-Modell, welches sich vor allem auf Veränderungen in der Trendkomponente bezieht und für Daten ohne bzw. geringe saisonale Zyklen besteht zudem die Möglichkeit, kein Saisonalitätsmodell anzupassen. Wenn kein Modell angepasst wird, muss jedoch bedacht werden, dass sich die auftretenden Veränderungen dieser Komponente dann zumindest teilweise auf die Trendkomponente auswirkt (vgl. Verbesselt et al., 2015, 4). Nach Bestimmung der Breakpoints wird die Stärke bzw. das Ausmaß (Magnitude), sowie die Tendenz der Veränderung aus der Differenz unterschiedlicher Zeitpunkte und deren Werten abgeleitet. Dies stellt eine einfache und robuste Methode der Veränderungsdetektion in Zeitreihen dar (vgl. Verbesselt et al., 2010a, 107). Neben der Magnitude, aus der sich die Tendenz bzw. die Richtung der Veränderung ableiten lässt, kann für jeden Breakpoint auch das Konfidenzintervall ausgegeben werden.

Die Erfassung kurzfristiger, abrupter Störungen hängt vom Ausmaß der Störung im Vergleich zu dem Signal-Rausch-Verhältnis ab, die durch spektrale, räumliche und temporale Beschaffenheit der Daten beeinflusst wird. Das Erfassen solcher Veränderungen ist ein Schritt in Richtung besseren Verständnisses der Prozesse und Auslöser, die zu derartigen Veränderungen führen. Die Fähigkeit eines Systems, Ökosystemveränderungen abzubilden hängt von der Kapazität zur Unterscheidung zwischen normalen phänologischen Zyklen und abnormen Veränderungen ab (vgl. Verbesselt et al., 2012, 99). Eine große negative Abweichung der Werte in der Zeitreihe, die nicht von der Saisonalität abhängig ist, stellt eine Waldveränderung dar (vgl. Hamunyela et.al., 2016, 128).

Wenn Lücken in der Zeitreihe enthalten sind (zum Beispiel durch Wolkenbedeckung oder atmosphärische Streueffekte) werden diese Bereiche in der Berechnung ausgelassen, da der Regressionsparameter trotzdem geschätzt werden kann, solange nicht alle Beobachtungen mit bestimmten Frequenzen fehlen (vgl. Jönsson & Eklundh, 2002; nach Verbesselt et al., 2012, 99).

Die Bearbeitung der gesamten Zeitreihe ermöglicht die Beschreibung eines kontinuierlichen Prozesses, da nicht nur bestimmte Zeitpunkte, sondern kontinuierliche Daten herangezogen werden (vgl. Bradley & Mustard, 2008; nach Verbesselt et al., 2010b, 2977).

Zusammenfassend lässt sich folgendes über den Algorithmus sagen:

- 1. er arbeitet schnell und benötigt wenig Zeit zur Prozessierung
- 2. es sind keine Schwellenwerte erforderlich
- 3. es können auch lückenhafte Zeitreihen analysiert werden und
- 4. es ist die gesamte zeitliche Information der Zeitreihe nutzbar (vgl. Verbesselt et al., 2012, 106).

Ad. 1: Der Algorithmus benötigt ca. 0,02 Sekunden um ein Pixel einer zehnjährigen Zeitreihe mit 16-tägigen Aufnahmeintervallen auf einem durchschnittlichen Standcomputer zu berechnen (vgl. Verbesselt et al., 2012, 106).

Ad. 2: Um unzureichende Dateninformation einzelner Pixel zu umgehen, entschieden Hamunyela et al. (2016, 127) all jene Pixel, welche aufgrund von Wolken etc. weniger als 15 Beobachtungen in der gesamten Zeitreihe (über 200 Beobachtungen) haben, zu maskieren, um aufgrund fehlender Information keine falschen Auswertungsdaten zu generieren. Dies bezieht sich vor allem auf aufeinanderfolgende fehlende Beobachtungen.

# **3 Material und Methode**

In diesem Kapitel wird zunächst das Untersuchungsgebiet genau beschrieben und erläutert. Danach wird die vorliegende Datengrundlage dargestellt und anschließend die Methode und die weitere Vorgehensweise der Analyse erklärt.

# 3.1 Untersuchungsgebiet

Das Untersuchungsgebiet befindet sich in einem Waldgebiet in Bayern südlich von München. In der nachfolgenden Abbildung 5 ist die Ausdehnung und Positionierung mittels einer Open Street Map und fAPAR-Daten abgebildet. Zusätzlich sind die beiden Testgebiete abgebildet.

Die Fläche beträgt insgesamt 4.924 km<sup>2</sup> und besteht aus unterschiedlichen Landbedeckungsarten, wie urbanem Raum, Wasserflächen, landwirtschaftlich genutzten Flächen und Wald, welcher auf Veränderungen analysiert wird.

Das Gelände liegt im Bereich der Münchner Schotterebene und zeichnet sich durch geringe Höhenvariationen aus (vgl. Einzmann et al., 2017, 3).



Abbildung 5: Untersuchungsgebiet (Open Street Map), sowie den fAPAR-Daten und den Umgrenzungen der Testgebiete München und Landsberg (Zeitpunkt Anfang April 2015)

Wie man an der Corine Landbedeckungskarte von 2016 in der nur Waldklassen dargestellt werden (Abbildung 6) sehen kann, überwiegt in dem Gebiet der Nadelwald. Die am häufigsten vorkommende Baumart ist die gemeine Fichte (*picea abies*). In Europa gab es bereits 1990 aufgrund der Stürme Vivian und Wiebke große Schäden. Gefolgt von Lothar im Jahr 1999, Kyrill im Jahr 2007 und schließlich Niklas im Jahr 2015 entstanden weitreichende Waldschäden. Oft waren die beschädigten Waldgebiete bereits durch Insektenbefall (Borkenkäfer) im Vorhinein geschwächt, was als Auslöser für das große Ausmaß der Sturmschäden gesehen wird. Aufgrund dessen wurde seither zusätzlich mit hartem Laubholz aufgeforstet, um derartige Ausfälle in Zukunft zu minimieren (vgl. Einzmann et al., 2017, 1ff).



Am 31. März 2015 griff das Sturmtief "Niklas" mit einem sehr heterogenen Schadensbild um sich. Mit bis zu 192 km/h in den bayerischen Alpen und bis zu 120 km/h im Tiefland, zerstörte er weite Waldbestände und war damit der stärkste Frühjahrssturm während der letzten 30 Jahre. Neben großflächigen Verlusten wurden auch kleine Gruppen, bzw. einzelne windgeworfene Bäume erfasst (vgl. Einzmann et al., 2017, 3). In Abbildung 7 werden die Orthofotos, anhand derer die Windwürfe abgeleitet wurden, und die erfassten Windwurfpolygone aus dem Testgebiet München veranschaulicht.



Abbildung 7: Ausschnitt der Windwurfflächen 2015 mit hinterlegtem Orthofoto (von der Bayerischen Vermessungsverwaltung aus 2015)

Ein Windwurf stellt eine abrupte Veränderung infolge eines Sturmereignisses dar. Manchmal sind einzelne Bäume oder Baumgruppen (auch als Nestwurf bekannt) betroffen, bis hin zu großflächigen Waldverlusten.

Nach einem Windwurfereignis werden die betroffenen Flächen meist geräumt, also das beschädigte Holz entfernt. Zurück bleibt dabei offener Boden, der ein ganz anderes Reflexionsvermögen besitzt als Waldbestand, wodurch die Detektion der abrupten Veränderung auch in Satellitendaten erkennbar sein sollte, sofern die Auflösung hoch bzw. die Fläche groß genug ist.

Der offene Boden wird dann bald von sogenannten Schlagflurklassen besiedelt. Dazu zählen zuerst Gräser und eventuell kleine Sträucher, welche sich teilweise bis zu 10 Jahren halten können. Nach und nach nimmt dann auch der Baumbestand auf entweder natürliche Weise oder durch Wiederaufforstung wieder zu. Nach 20 Jahren sind die meisten Windwurfereignisse nicht mehr feststellbar (vgl. Kirchstetter, 2013, 46).

# 3.2 Datengrundlage

Landsatsensoren sind gut geeignet um Waldflächen in angemessenem Maßstab und ausreichender räumlicher (30 m) und spektraler Auflösung abzubilden. Zudem sind Landsatdaten ab 1970 verfügbar, was auch längere Zeitreihenanalysen ermöglicht. Auch das 16-Tagesaufnahmeintervall ist gut geeignet. Es muss jedoch mit Wolkenbedeckung gerechnet werden, was spezifische Methoden für eine adäquate Kartierung und Monitoring erfordert (vgl. Griffiths et al., 2014, 73).

Die hier vorliegenden Daten, welche von Vuolo et al. (2016) zur Verfügung gestellt werden, sind eine Kombination mehrerer bereits atmosphärisch korrigierter Daten der folgenden Landsatsensoren: Landsat 4-5 Thematic Mapper (TM), Landsat-7 enhanced Thematic Mapper Plus (ETM+), Landsat-8 Operational Land Imager (OLI) und Landsat Surface Reflectance Climate Data Record (Landsat CDR). Landsat CDR ist ein Level-2A Produkt, um zu große Sensorunterschiede zu vermeiden und die Genauigkeit, trotz der Sensorunterschiede, der atmosphärischen Korrektur einzuhalten, wurde das blaue Band exkludiert (vgl. Vuolo et al., 2016, 7).

Die vorliegenden Daten wurden geglättet und ein Gapfilling vorgenommen. Es handelt sich um eine Zeitreihe von Anfang 2005 bis Ende August 2016, mit einem 15-Tagesintervall, also 24 Aufnahmen pro Jahr und im Jahr 2016 mit 16 Aufnahmen. Das gesamte Untersuchungsgebiet ist in 6 aneinandergrenzende Kacheln aufgeteilt, woraus sich eine Bildanzahl von 280 Aufnahmen pro Kachel ergibt.

Wie in Abbildung 8 dargestellt, werden die Daten anhand dieser Vorgehensweise prozessiert:



Abbildung 8: Vorgehensweise der Datenprozessierung (Voulo et al., 2016, 3)

Um die ursprüngliche Pixelgröße, die geografische Projektion (UTM WGS84) und den Tag der Aufnahme unverändert beizubehalten, wurden die Daten zu Bildkacheln mit 1000x1000 Pixeln geclippt. Um Wolkenpixel zu maskieren und fehlende Informationen zu identifizieren wurde in einem folgenden Schritt "Function to mask" – kurz "fmask" angewendet. Diese Funktion lokalisiert und maskiert Wolken, Wolkenschatten und Schneepixel. In einem dritten Schritt werden die Beobachtungen insoweit transformiert, dass eine temporale Auflösung von 15 Tagen in regelmäßigen Abständen entsteht (1. und 16. Tag jedes Monats). Werden zwei oder mehr gültige Pixel in einem 15-Tagesintervall gefunden, so wird der Mittelwert für das Gapfilling ermittelt. An diesem Punkt bestehen die Lücken in den Daten noch (vgl. Vuolo et al., 2016, 2).

Anschließend werden Templates gebildet, also eine Zeitreihe von Pixeln, die eine hohe Anzahl an gültigen Beobachtungen haben. Für Lücken in den Templates wurde der Whittaker smoother von Eilers (2003) verwendet, der die Genauigkeit der Daten in den Vordergrund stellt und nicht die Datenglättung. Als fünfter Schritt wurde ein sogenanntes "Template matching" vorgenommen. Hier wird die euklidische Distanz zwischen den Templates und jedem Pixel berechnet. Danach wird jede ungültige Beobachtung mit dem Wert aus dem bestangepassten Template ersetzt. Abschließend wird der Whittaker smoother unabhängig für jedes Band und jedes Pixel angewandt, um als Ergebnis eine geglättete und Gapfilled Zeitreihe zu erhalten (vgl. Vuolo et al., 2016, 2ff). In Abbildung 11 wird der Ablauf der Prozessierung bildhaft dargestellt.

Abschließend wurden aus den fertig prozessierten Reflectance-Daten verschiedenste Vegetationsindizes berechnet. Für die folgende Auswertung wurde hauptsächlich mit fAPAR-Daten gearbeitet und um Vergleiche anstellen zu können, werden zudem NDVI-Daten ausgewertet.

In den folgenden Abbildungen 9 und 10 sind die Windwurf-Datensätze, die in Kapitel 3.3 näher besprochen werden, veranschaulicht. In Abbildung 9 sind diese anhand der fAPAR-Daten der ersten Aprilaufnahme von 2015 abgebildet. Gezeigt wurde ein kleiner Ausschnitt aus dem Testgebiet München, welches im Anschluss näher erläutert ist. Die Referenzdaten beinhalten Windwurfpolygone, welche die Windwürfe, die der Sturm Niklas verursacht hat erfassen. Ziel ist es, diese Flächen ebenfalls mit dem Algorithmus BFAST zu detektieren. Die Referenzdaten dienen daher ebenfalls zur Validierung der Ergebnisse.



Abbildung 9: Lage der Windwurfflächen südlich von München anhand des verwendeten Testausschnitts der fAPAR-Daten von Mai 2015

In Abbildung 10 ist derselbe Ausschnitt desselben Zeitpunktes mit NDVI-Daten visualisiert.



676500 677000 677500 678000 678500 679000 679500

Abbildung 10: Lage der Windwurfflächen südlich von München anhand des verwendeten Testausschnitts der NDVI-Daten von Mai 2015

Zusätzlich zu den bereits besprochenen Daten, wurde auch eine Waldmaske verwendet. Da in diesem Fall nur die Waldfläche von Interesse ist, wurde der Algorithmus ausschließlich auf den Wald angewendet um die Berechnungszeit zu verkürzen.

An dieser Stelle muss jedoch auf die Datenqualität aufmerksam gemacht werden. Wie man in der Abbildung 11 unten sehen kann, zeigen die Reflectance-Daten einige Flecken mit untypisch kontraststarken Konturen, die wiederholt im ganzen Gebiet auftreten.



NDVI

Abbildung 11: Beispiele für Abweichungen und Flecken in den Daten, oben links: Reflectance-Daten Mai 2015 CIR, oben rechts: fAPAR-Daten Mai 2015, unten links: NDVI-Daten Mai 2015

Doch die Datenfehler betreffen nicht nur die Reflectance-Daten. Auch bei fAPAR treten diese Unregelmäßigkeiten auf, wenn auch nur vereinzelt. In Abbildung 12 kann man im Vergleich zur Abbildung 11 bei fAPAR keine Fehler entdecken. Beim NDVI hingegen, treten die Unregelmäßigkeiten verstärkt auf.



Abbildung 12: Beispiele für Abweichungen und Flecken in den Daten, oben links: Reflectance-Daten Mai 2015 CIR, oben rechts: fAPAR-Daten Mai 2015, unten links: NDVI-Daten Mai 2015

Der Zeitpunkt mit Mai 2015 wurde deswegen ausgewählt, da hier die Abweichungen am stärksten ausgeprägt sind. Auffällig werden sie schon ab April und nehmen gegen Ende Mai wieder ab. Dies lässt darauf schließen, dass die verwendete Wolkenmaske (Abbildung 13), bzw. NOBS (Abbildung 14) nicht gut geeignet sind. NOBS steht für Number Of Observations und stellt Informationen über die Anzahl der Beobachtungen bezogen auf das Gapfilling bzw. die Ausmaße des Gapfillings. Das bedeutet es wird angezeigt, in welchen Bereichen wie oft richtige Beobachtungen vorliegen. Außerdem lässt die Methode der Prozessierung, wie im
Paper von Vuolo et al. (2016) bereits erwähnt, darauf schließen, dass abrupte Veränderungen wohl weniger gut erfasst werden können. Diese Methode der Datenprozessierung glättet die zeitlichen Trajektorien der Spektralwerte und es wird nicht empfohlen, diese für die Detektion abrupter Veränderungen einzusetzen. Es wird davon ausgegangen, dass eine Methode, wie zum Beispiel von Verbesselt et al. (2010a) besser für diese Art der Veränderung geeignet sein könnte. Desweiteren gibt es bei der vorliegenden Methode Limitierungen durch nicht erfasste Wolkenbedeckung durch die Wolkenmaske "fmask". Darüber hinaus gibt es meist nicht ausreichend viele aufeinanderfolgende, wolkenlose Beobachtungen, was wiederum die Detektion der Veränderungen erschwert bzw. teilweise unmöglich macht (vgl. Vuolo et al., 2016, 9).



Abbildung 13: Wolkenmaske, Kachel 104\_19

Abbildung 14: NOBS, Kachel 104\_19

Wie aus den obigen Abbildungen 13 und 14 ersichtlich wird, ist die Aufnahme der NOBS nicht wirklich typisch (zahlreiche dunkle Flecken, die auch in den Daten wieder auftauchen). Dies legt die Vermutung nahe, dass Wolken und Wolkenschatten nicht einwandfrei erfasst werden konnten und bzw. oder auch das Template Matching nicht erfolgreich war.

Die Vermutung liegt nahe, dass jene Unregelmäßigkeiten, aufgrund der unterschiedlichen Gewichtung und des größeren Einflusses des NIR-Bandes in der Berechnung von fAPAR (siehe Kapitel 2.2.4) zustande kommt, denn das NIR Band wurde bei der Prozessierung besser bereinigt als das rote Band. Es konnte bei den NIR Daten ein nMAE (Normalized Mean Absolute Error) von 10% erreicht werden, wobei im Vergleich die Daten des roten Spektralbandes nur 15 % erzielen konnten. Vor allem in Kontext zu den gesamten Bändern, die 12 % erreichen konnten, ist das rote Band eindeutig weniger gut bereinigt (vgl. Vuolo et

al., 2016, 8). Dafür spricht auch die geringe Korrelation, die in einigen Pixeln zwischen den fAPAR und NDVI-Daten vorherrscht (Abbildung 15 und 16), obwohl hier die Korrelation fast 1, also nahezu gleich, sein sollte.



Abbildung 15: Korrelation fAPAR und NDVI für ein Pixel in einer Windwurffläche; Y-Achse: fAPAR skaliert 1:10000, NDVI skaliert 1:1000, X-Achse: Bildanzahl der Zeitreihe als Zeitangabe (88 Aufnahmen, 24 pro Jahr)

In Abbildung 15 und 16 wird ersichtlich, dass die beiden Kurven immer wieder voneinander abweichen, bzw. die fAPAR-Werte um einiges stärker ausschlagen.



Abbildung 16: Korrelation fAPAR und NDVI für ein Pixel in unveränderter Waldfläche; Y-Achse: fAPAR skaliert 1:10000, NDVI skaliert 1:1000, X-Achse: Bildanzahl der Zeitreihe als Zeitangabe (88 Aufnahmen, 24 pro Jahr)

### 3.3 Referenzdaten

Die Abbildung 17 zeigt die Kachelung des Untersuchungsgebiets, sowie die Lage der beiden Testgebiete München und Landsberg.



Abbildung 17: Testgebiete Landsberg und München im Untersuchungsgebiet Südbayern, Kachelung der Landsatdaten, hinterlegt mit einer Open Street Map

Die Testgebiete teilen sich wie folgt auf die Kacheln im Untersuchungsgebiet auf: Testgebiet "München" beinhaltet die Kachel 104\_19 und 104\_20 und Testgebiet "Landsberg" erstreckt sich über 104\_18 und 105\_18. Diese Angabe bezieht sich auf die UTM Projektion in Zone 32, basierend auf dem WGS84. Dabei bezieht sich die erste Zahl (z.B. 104) auf die obere Zeile im Untersuchungsgebiet und die zweite (z.B. 19) bezieht sich auf die Spalte. Die Kachel 104\_19, welche im Testgebiet München liegt, wurde für Testzwecke als Testkachel genutzt und wird weiters auch als solche bezeichnet.

Das gesamte Untersuchungsgebiet umfasst folgende Kacheln:

Tabelle 1: Auflistung der Kacheln im Untersuchungsgebiet, blau: Testgebiet München, grün: Testgebiet Landsberg

Untersuchungsgebiet:			
104_18 104_19 104_20			
105_18	105_19	105_20	

Die Referenzdaten sind in zwei Testgebiete unterteilt, wie man in Abbildung 17 erkennen kann. Das Testgebiet München liegt südwestlich von München und beinhaltet Windwürfe mit einer Größe zwischen 0,1 bis 6 ha, wobei es hier eine höhere Anzahl an kleineren Flächen gibt. Das zweite Testgebiet befindet sich in der Umgebung Landsberg und erstreckt sich zwischen Landsberg am Lech, dem Ammersee und dem Staffelsee. Die Vorgehensweise für die Generierung des Windwurfdatensatzes ist kohärent mit jener des Testgebiets München. Die Größe der Windwurfflächen ist mit 0,1 – 2 ha im Vergleich kleiner als im Testgebiet München. Außerdem sind in diesem Gebiet mehr Laubbäume zu finden und auch hier überwiegen die kleinen Windwurfflächen bzw. sind die Windwürfe im Testgebiet Landsberg kleinräumiger.

Diese Datensätze wurden nach und nach anhand von Radarbildern, die direkt nach dem Sturm aufgenommen wurden, digitalisiert. Einige der beschädigten Flächen wurden außerdem mit Garmin GPSMAP 64 Geräten aufgenommen. Zusätzlich wurden Informationen über das Ausmaß und den Typ des Sturmholzes (z.B. einzelne windgeworfene Bäume, Nestwürfe und großflächige Windwürfe), Baumschäden (z.B. gebrochene Äste, gespaltene Bäume, entwurzelte Bäume) und die hauptsächlich betroffene Baumart erhoben (vgl. Einzmann et al., 2017, 5). Die erfassten Windwurfflächen wurden großteils aufgearbeitet und geräumt. Der Referenzdatensatz München wurde anhand hochauflösender Orthofotos erstellt. Die verwendeten Orthofotos wurden im Juni und Juli 2015 akquiriert und liegen als Falschfarbeninfrarotbilder mit einer räumlichen Auflösung von 20 cm vor. Die Orthofotos wurden visuell interpretiert und Windwürfe über 0,5 ha manuell digitalisiert. Die betreffenden Flächen wurden mit älteren Orthofotos, welche vor dem Sturm aufgenommen wurden, sowie mit RapidEye Daten abgeglichen (vgl. Einzmann et al., 2017, 5).

Dazu sei angemerkt, dass die Orthofotos erst einige Monate nach dem Sturmereignis aufgenommen wurden. Während dieser Zeit wurden bereits mehrere Windwurfflächen geräumt. Zusätzlich dazu wurden teilweise (zu Waldschutzzwecken) auch unbeschädigte Bäume entnommen. Daher sind diese Flächen in den aus den Orthofotos abgeleiteten Shapefiles größer als der ursprüngliche Windwurf. Die Information über die betroffenen

39

Flächen wurde in den Daten mit ausgewiesen und bei der Validierung berücksichtigt (vgl. Einzmann et al., 2017, 5f).

### 3.4 Methode

Abbildung 18 zeigt die Vorgehensweise für die Generierung von Ergebnissen mit BFAST.



Abbildung 18: Flowchart der Vorgehensweise für die Ergebnisgenerierung mit BFAST aus den fAPAR Daten

Die Datengrundlage bilden zuvor prozessierte Landsatdaten im bereits beschriebenen Untersuchungsgebiet in Südbayern. Die vorliegenden und im vorangegangenen Kapitel bereits erklärten fAPAR- und NDVI-Daten sollen mittels des BFAST Algorithmus auf Veränderungen in der Waldfläche analysiert werden. Da in vorliegenden Referenzdaten (Shapefiles von Sturm Niklas 2015, Gebiete München und Landsberg) schon erfasste Windwürfe vorhanden sind, werden diese als Validierungsdaten herangezogen. In diesen Bereichen kann also davon ausgegangen werden, dass es sich definitiv um Windwurfflächen handelt und es wird angenommen, dass diese im April 2015, zumindest in den größeren Flächen, zeitgerecht detektiert werden wird.

Es wird kontrolliert, zu welchem Zeitpunkt die Veränderung in den Daten detektierbar ist, und ob auch in anderen Bereichen Veränderung auftreten. Weiters wird untersucht, ob und inwiefern sich die Ergebnisse der beiden Indizes unterscheiden.

Der Zeitpunkt der Veränderung ist insofern wichtig, als untersucht werden soll, ob eine derartige Veränderung wie ein Windwurf bereits erfassbar ist, wenn sie auftritt, oder erst mit Entnahme der beschädigten Bäume. (Wobei bei der Entnahme zu Schutzzwecken meist auch noch gesunde Baumbestände entnommen werden, um weitere Schäden zu verhindern) (vgl. Einzmann et al., 2017, 6).

Aufgrund der Größe der Windwurfgebiete und der räumlichen Auflösung von 30 m wird davon ausgegangen, dass der Windwurf zumindest teilweise und vor allem im Testgebiet München (aufgrund der größeren Windwurfflächen) erfasst werden wird. Die Vermutung liegt ebenfalls nahe, dass sich Laub- und Nadelwald in der Erfassung aufgrund unterschiedlicher Variabilität der Saisonalität differenziert. Desweiteren hat das Signal-Rausch-Verhältnis einen großen Einfluss auf die Fähigkeit des Algorithmus, Veränderungen zu erfassen. Je höher also der Anteil des Rauschens in den Daten, desto weniger werden Veränderungen richtig erfasst. Ebenfalls beeinflusst die vorher besprochene Datenqualität und damit die Prozessierung die Funktionsfähigkeit von BFAST, was in dem Fall darauf schließen lässt, dass kein eindeutig positives Ergebnis zu erzielen ist (vgl. Verbesselt et al., 2010a, 110).

Die Auswertung der Daten erfolgt in aufbauenden Schritten. Zunächst wird anhand von Differenzbildern eruiert ob bzw. wann der Windwurf 2015 in den Daten erkennbar ist. Danach wird mit mehreren Punktdatensätzen getestet, welche Ergebnisse BFAST mit den verschiedenen Saisonalitätsmodellen liefert und welchen Einfluss die Einstellung des h-Wertes (wird im folgenden Kapitel erläutert) darauf hat. Einen weiteren Parameter stellt die Anzahl der durchgeführten Iterationen dar, welche ebenfalls getestet werden. Anschließend wird nach den ersten Erkenntnissen eine flächige Auswertung vorgenommen. Dazu werden kleinere Testgebiete ausgewählt und die Parameter entsprechend eingestellt. An dieser Stelle werden die einzustellenden Parameter des Algorithmus BFAST angeführt und erklärt. Zu diesen zählt der h-Wert, das anzuwendende Saisonalitätsmodell und die Anzahl an Iterationen. Der h-Wert definiert die minimale Segmentgröße der Zeitreihe, innerhalb derer eine bzw. die größte Veränderung als Breakpoint erfasst wird. Gibt es also in diesem Abschnitt der Zeitreihe mehrere Abweichungen, wird jeweils die größte als Breakpoint ausgegeben. Der Wert errechnet sich aus der Anzahl der Beobachtungen, welche die Segmentgröße definieren, durch die Gesamtanzahl an vorhandenen Beobachtungen der gesamten Zeitreihe. Liegt also eine Zeitreihe von ca. 3,5 Jahren vor, welche 88 Beobachtungen beinhaltet, und eine Zeitspanne von ca. 1,5 Jahren als minimale Segmentgröße für die Detektion von Windwürfen definiert wird, ergibt dies bei einem Aufnahmeintervall von 15 Tagen 36/88=0,41 als h-Wert. Die minimale Segmentgröße ergibt sich also aus dem Aufnahmeintervall der vorhandenen Beobachtungen innerhalb derer man eine Veränderung erfassen möchte, im Bezug zur Gesamtlänge der Zeitreihe. Dazu soll noch angeführt werden, dass ein absoluter h-Wert von 0,5 nicht überschritten werden kann, da ansonsten die Bestimmung der Werte nicht durchgeführt werden kann. Das bedeutet, dass die Segmentgröße nur so groß werden kann, wie die Hälfte der zu untersuchenden Zeitreihe. Im Bezug zur Windwurfdetektion, kann dies als limitierender Faktor angesehen werden, da ein Windwurfereignis nicht derart regelmäßig auftreten kann. Wie später in Kapitel 4 genauer erläutert wird, kann es je nach Ausmaß bis zu 20 Jahre dauern, bis ein Windwurf im Waldgebiet nicht mehr erkennbar ist (vgl. Kirchstetter, 2013, 46).

Ein weiterer Parameter ist das anzuwendende Saisonalitätsmodell, welches in Kapitel 2.5.2 schon kurz angesprochen wurde. Es gibt hier drei Möglichkeiten dieses anzupassen. Die erste Möglichkeit heißt "harmonic" und stellt ein harmonisches Modell dar, welches vor allem für die Detektion phänologischer, also Veränderungen in der Saisonalitätskomponente, dient. In diesem Fall werden Breakpoints der Trendkomponente genauso bestimmt wie mit dem Modell "dummy", welches abrupte und graduelle Veränderungen erfasst. Die dritte Möglichkeit besteht darin kein Saisonalitätsmodell anzupassen.

Als letzter einzustellender Parameter sind die Anzahl der Iterationen anzuführen, also wie oft die Bestimmung der Breakpoints wiederholt wird.

Als klar wird, dass diese Vorgehensweise nicht zielführend ist, wird die Zeitreihe entsprechend angepasst und die Berechnungen wurden erneut durchgeführt. Für Testzwecke wurden ebenfalls der Index TCB (Tasseled Cap Brightness Kapitel 2.2.4) sowie die Reflectance RED und die Reflectance NIR getestet. Die gesamte Auswertung bezieht sich jedoch vor allem auf

42

die fAPAR-Daten. Der NDVI wird ebenfalls ausschließlich in den Bereichen mit den Referenzdaten ausgewertet (siehe Anhang).

Eine weitere Auswertungsmethode war es, die Testkachel zu segmentieren und für die jeweiligen Segmente den Mittelwert, Median und Quantile zwischen 5 und 90 zu berechnen, wie die Abbildung 19 verdeutlichen soll.



Abbildung 19:Flowchart der Vorgehensweise für die Ergebnisgenerierung mit BFAST und der Anwendung von Mean Shift

Dazu wurde zuerst eine Hauptkomponententransformation (principal components analysis – PCA) mithilfe eines R-Scriptes (siehe Anhang 4. PCA R-Script) auf die gesamte Zeitreihe (2013-2016) vorgenommen. Eine PCA ist eine statistische Methode, die auf die Reduzierung von Daten (bzw. Rauschen) abzielt und Komponenten identifiziert, welche die Gesamtvariabilität innerhalb der berücksichtigten Variablen einbeziehen. Die Hauptkomponenten sind lineare Kombinationen dieser Variablen, welche die von ihnen erklärte gemeinsame und einzigartige Variabilität berücksichtigten (vgl. Petrisor et al., 2012, 249).

Im nächsten Schritt wurden die ersten sechs Bänder der PCA ausgewählt. Dies soll, wie bereits erwähnt, dazu dienen, bei maximalem Informationsgehalt die Datenmenge zu

reduzieren. Anschließend auf die Bänder wurde ersten sechs der Hauptkomponententransformation der in QGIS implementierte Algorithmus Mean Shift angewendet, was zur Segmentierung des Gebiets diente. Dieser Algorithmus (Mean Shift) ist eine Clustering-Technik, um sinnvolle Zentren von beliebig verteilten Punkten in einem Vektorraum zu finden. Mean Shift macht keine Annahmen über die Art der Verteilung, welche die Punkte erzeugt hat. Er gehört zur Klasse der nichtparametrischen Clustering-Methoden (vgl. Subbaro & Meer, 2009, 1). Die Mindestanzahl an Pixel wurde auf 10 gesetzt um einerseits die Berechnung des Median, etc. durchführen zu können, andererseits wurde versucht die Segmente klein genug zu halten, damit die Windwurfflächen detektierbar bleiben.

Die Validierung der Ergebnisse wird so vorgenommen, dass die bereits erfassten Windwurfflächen mit den Ergebnissen von BFAST (berechnete Breakpoints, die eine Veränderung anzeigen und der positiven Magnitude, welche auf Windwürfe schließen lässt) abgeglichen werden. Dies soll Aufschluss darüber geben ob ein Windwurf richtig oder falsch erfasst wurde, bzw. ob unveränderte Waldflächen als solche richtig bzw. falsch erkannt wurden.

# 4 Ergebnisse

In diesem Kapitel werden die Ergebnisse der Auswertung mittels BFAST abgehandelt und visualisiert. Zunächst wird der Windwurf aus 2015 anhand von Differenzbildern verifiziert, bevor dann der Algorithmus angewandt wird.

### 4.1 Erste Auswertung anhand von Differenzbildern

Wie in Abbildung 18 erkennbar, werden hier ein verändertes und ein unverändertes Pixel der fAPAR-Daten dargestellt



Abbildung 20: Veranschaulichung des Windwurfs Ende März 2015, anhand von fAPAR-Daten mittels Differenzenbild 1. Juni 2015 – Ende März 2015 und Diagrammen jeweils eines Pixels für 2015, WW=Windwurf, kWW=unveränderter Wald; Diagramme: Y-Achse: fAPAR skaliert 1:10000, X-Achse: Bildanzahl der Zeitreihe als Zeitangabe für ein Jahr (24 Beobachtungen)

Bei dem veränderten Pixel handelt es sich um einen Windwurf (fAPAR WW), der am 31. März 2015 durch den Sturm Niklas, welcher den südbayerischen Wald verwüstete, entstanden ist (vgl. Bauer et al., 2016, 28).

Wie an den Diagrammen der Abbildungen 20 und 21 links und rechts erkennbar, ist bei dem unveränderten Pixel (Diagramm rechts) in der ersten Jahreshälfte ein Wachstum ersichtlich, bei dem veränderten (Diagramm links), ist der Knick nach unten, der den Windwurf symbolisiert, erkennbar. Die Zeitpunkte (Mitte März und Anfang Juni) der beiden für das Differenzbild verwendeten Bilder wurden so gewählt, da sich durch die potentielle Wolkenbedeckung nach dem Sturm der Windwurf in den Daten nicht sofort nach Auftreten visualisieren lässt. Hier hat auch die Vorprozessierung der Daten aufgrund des durchgeführten

Gapfillings, sowie die verwendete Wolkenmaske Einfluss. Inwieweit dies die Ergebnisse mit BFAST beeinflusst wird im folgenden Kapitel erläutert.



Abbildung 21: Veranschaulichung des Windwurfs Ende März 2015, anhand von NDVI-Daten mittels Differenzenbild 1. Juni 2015 – Ende März 2015 und Diagrammen jeweils eines Pixels für 2015, WW=Windwurf, kWW=unveränderter Wald; Diagramme: Y-Achse: WW=Windwurf, NDVI skaliert 1:1000, X-Achse: kWW=unveränderter Wald, Bildanzahl der Zeitreihe als Zeitangabe für ein Jahr (24 Beobachtungen)

Wenn man Abbildungen 20 und 21 nebeneinander betrachtet, fallen schon hier bei den einfachen Differenzbildern die Unterschiede zwischen den beiden Indizes auf. In beiden Bildern ist nicht eindeutig, wo genau die Windwurfbereiche liegen, da auch hier sehr viele Flächen mit negativer Differenz auftreten. Der Zeitraum über den sich die Differenz erstreckt ist Juni abzüglich März, was darauf hindeutet, dass auch andere Veränderungen miterfasst wurden, potentiell sind auch jene Windwurfflächen enthalten, die durch die Aufarbeitung vergrößert wurden.

### 4.2 Auswertung mittels BFAST

In diesem Kapitel werden die Ergebnisse der Datenauswertung mit dem Algorithmus BFAST veranschaulicht und erklärt.

#### 4.2.1 Flächenhafte Auswertung der Testkachel 2013-2016

Aufgrund der sehr wenig aussagekräftigen Ergebnisse mit der Zeitreihe von 2006-2016 (siehe Anhang) und der Kombination aus den Daten von Landsat 4-8 wurde entschieden, die Zeitreihe auf 2013-2016 zu verkürzen. In dem Zeitraum beinhaltet die Zeitreihe nur noch Daten von Landsat 8, was die Fehlereinflüsse durch unterschiedliche Sensoren minimiert (die Vorprozessierung hätte dies ausreichend korrigieren sollen). Wie Abbildung 22 zeigt, ist der Datenverlauf (oberste Grafik) um einiges näher an dem, wie der zeitliche Verlauf eines Waldpixels erwartet werden würde.



Abbildung 22: BFAST-Grafik fAPAR 2013-2016, h=0,38, harmonisches Saisonalitätsmodell, Erfassung des Breakpoints im Jahr 2015

In der zweiten Grafik ist das angepasste Saisonalitätsmodell dargestellt, dabei bildet die vertikale strichlierte Linie einen Breakpoint der Saisonalitätskomponente ab, was auf eine phänologische Veränderung im Jahr 2014 schließen lässt. In der dritten Grafik ist die Trendkomponente dargestellt. Hier wird im Jahr 2015 ein Breakpoint erfasst, welcher die Detektion eines Windwurfes abbildet. In der Restkomponente (letzte Grafik) werden die Restwerte, die nicht für die Bestimmung des Saisonalitätsmodells bzw. für die Trendkomponente genutzt wurden, gezeigt.

Um die Parameter bestmöglich einzustellen, werden verschiedene Varianten getestet. Aufgrund der ersten Ergebnisse wird entschieden, die Anzahl der Iterationen auf 1 zu stellen, da sich bei 5 oder 10 die Erfassung der Breakpoints nicht verändert, aber die Dauer der Berechnung maßgeblich ansteigt. Für die Bestimmung des Saisonalitätsmodells wird das harmonische verwendet. Hier werden zusätzlich zur Breakpointberechnung der Trendkomponente auch phänologische Veränderungen aus der Saisonalität bestimmt, welche für Testzwecke ebenfalls untersucht werden. Für die Ergebnisgenerierung, die hier dargestellt wird, werden jedoch nur die Veränderungen aus der Trendkomponente herangezogen, welche mit dem "dummy"-Modell in gleicher Form bestimmt werden. Auch das wurde getestet.

Für die Bestimmung des h-Wertes wird ein Testausschnitt aus der Kachel 104\_19 ausgewählt, der für die koordinative Verortung in folgender Abbildung 23 dargestellt wird. In weiterer Folge wird für die bessere Ansicht der Ergebnisdarstellung auf das Koordinatengitternetz verzichtet.



Abbildung 23: Koordinative Verortung des Testausschnittes, anhand der Umrandung des Untersuchungsgebiets sowie der Kachel 104\_19, dargestellt mit der Waldmaske und den Windwurfgebieten

Da es nicht zielführend ist, jeden einzelnen getesteten h-Wert zu visualisieren, wird hier eine Auswahl über die gesamte Bandbreite der Testwerte getroffen, um einen Überblick zu schaffen.

Der default-Wert für h beträgt 0,15, was bei der vorliegenden Zeitreihe die minimale Segmentgröße für eine Detektion auf ca. 13 Beobachtungen, also ca. ein halbes Jahr, begrenzt.



Abbildung 24: Breakpoints mit positiver Magnitude im Testausschnitt der fAPAR-Daten für 2015, harmonisches Saisonalitätsmodell, h=0,15, Berechnungszeitraum 2013-2016 mit Windwurfflächen, Waldmaske und rechts Grafik aus BFAST zur Darstellung des gekennzeichneten Pixels

Die Abbildung 24 zeigt die erfassten Breakpoints der Trendkomponente mit positiver Magnitude, welche mit dem h-Wert 0,15 berechnet werden. Die Grafik rechts stellt ein Windwurfpixel dar, welches mit dem roten Kreuz verortet wird. Dieses Pixel liegt eindeutig in einer der größeren Windwurfflächen. Wie man jedoch in der Grafik erkennen kann, kann hier im Jahr 2015 aber kein Windwurf erfasst werden. Betrachtet man den gesamten Testausschnitt, wird schnell ersichtlich, dass wenige Windwürfe richtig erfasst werden und in den unveränderten Waldflächen zu viel detektiert wird. Auch die Zeitpunkte der Breakpoints varieren über das ganze Jahr. In hellgrau werden alle Bereiche abgebildet, welche nicht als Wald klassifiziert werden können (zB. Siedlungsfläche oder landwirtschaftliche Flächen). Alle

weißen Pixel fallen in die Kategorie Wald, entweder kann hier kein Breakpoint gefunden werden, oder die Magnitude ist negativ.



Abbildung 25: Breakpoints mit positiver Magnitude im Testausschnitt der fAPAR-Daten für 2015, harmonisches Saisonalitätsmodell, h=0,3, Berechnungszeitraum 2013-2016 mit Windwurfflächen, Waldmaske und rechts Grafik aus BFAST zur Darstellung des gekennzeichneten Pixels

Als nächstes wird ein h-Wert von 0,3 getestet, wie in Abbildung 25 zu sehen ist. Hier beträgt die minimale Segmentgröße ca. 26 Beobachtungen, also etwas über ein Jahr. Wie man hier erkennen kann, werden insgesamt mehr Veränderungen nebeneinander angezeigt und nicht einzeln verteilt, wie in Abbildung 24. Die Windwürfe werden zusehends besser abgebildet, dennoch treten auch in den unveränderten Waldflächen viele Veränderungen auf, woraufhin weitere Tests notwendig sind. Außerdem werden diese Veränderungen hauptsächlich im Juli angezeigt, obwohl der Sturm Niklas, welcher für die Windwürfe verantwortlich ist, 3 Monate davor stattgefunden hat. In der Grafik rechts ist die Veränderung im Juli ebenfalls abgebildet, außerdem geht daraus hervor, dass es in diesem Pixel auch im Jahr 2014 eine Veränderung gegeben hat.



Abbildung 26: Breakpoints mit positiver Magnitude im Testausschnitt der fAPAR-Daten für 2015, harmonisches Saisonalitätsmodell, h=0,38, Berechnungszeitraum 2013-2016 mit Windwurfflächen, Waldmaske und rechts Grafik aus BFAST zur Darstellung des gekennzeichneten Pixels

Ein h-Wert von 0,38 wird in Abbildung 26 dargestellt. Wie zu sehen ist, werden nach wie vor auch einige Veränderungen in der unveränderten Waldfläche angezeigt. Die richtig erfassten Windwürfe werden im April detektiert, was gut mit dem Zeitpunkt des Sturms zusammenpasst. Auch in der Grafik rechts, welche das Beispielpixel abbildet, wird die Veränderung richtig im April 2015 erfasst wird. Wie man sieht werden keine weiteren Breakpoints erfasst, auch das Saisonalitätsmodell weist keine phänologischen Veränderungen auf. Da diese Parametereinstellung für die Berechnung des gesamten Untersuchungsgebiets herangezogen wird, werden die Ergebnisse im Anschluss genauer besprochen.



Abbildung 27: Breakpoints mit positiver Magnitude im Testausschnitt der fAPAR-Daten für 2015, harmonisches Saisonalitätsmodell, h=0,45, Berechnungszeitraum 2013-2016 mit Windwurfflächen, Waldmaske und rechts Grafik aus BFAST zur Darstellung des gekennzeichneten Pixels

Es wurde vermutet, dass ein höherer h-Wert die Erfassung von Windwürfen besser abbildet. Betrachtet man Abbildung 27, in der die Ergebnisse des h-Wertes von 0,45, also eine minimale Segmentgröße von ca. 40 Beobachtungen, was eine Zeitspanne von 1 ¾ Jahren begrenzt, abgebildet sind. Hier wird jedoch klar, dass die Vermutung in diesem Fall nicht bestätigt werden kann. Die Veränderungen werden im Jänner relativ großflächig erfasst und ist dementsprechend keine zielführende Parametereinstellung. Da mit dem Wert h=0,5 keine Breakpoints detektiert werden, wurde auf eine Visualisierung verzichtet.

Angesichts dieser Ergebnisse wird der h-Wert von 0,38 als bestes Ergebnis ausgewählt und für die Berechnung des gesamten Gebieets angewendet. Dies entspricht einer Segmentgröße von ca. 1,5 Jahren mit 34/88 Beobachtungen. Wie in Kapitel 3.4 schon besprochen, beschreibt der Wert 34 die Anzahl der Landsatbeobachtungen welche die Segmentgröße definieren, 88 steht für die Anzahl an Beobachtungen der gesamten Zeitreihe. Es liegt dabei nahe, dass ein Windwurf an derselben Stelle nicht im nächsten Jahr gleich wieder passieren kann, da sich die Vegetation erst erholen muss und so ein längerer Zeitraum legitimiert wird, da es folglich keinen Windwurf geben kann, wenn kein Wald vorhanden ist. Bei der Einstellung des h-Wertes

wurde vor allem Wert daraufgelegt, dass die Windwurfflächen gut herausgearbeitet werden und der Zeitpunkt so nah wie möglich an dem Sturmereignis im März angezeigt wird. Bei dieser Vorgehensweise werden auch in unveränderten Flächen viele Veränderungen angezeigt, doch auch mit anderen Testparametern (wie aus den vorangegangenen Abbildungen hervorgeht) kann kein besseres Ergebnis erzielt werden. Es war von Beginn an unwahrscheinlich, dass mit dieser Art der Prozessierung eine eindeutige Auswertung möglich ist (vgl. Vuolo et al., 2016, 9).

Die Windwürfe werden, sofern sie erkannt werden, hauptsächlich zum richtigen Zeitpunkt (Anfang April 2015) erfasst. Der großteil der Bereiche in denen keine bekannte Veränderung stattgefunden hat, wird zwar in weiten Teilen als solche detektiert, dennoch ist die Zahl von hier falsch erfassten Pixeln zu hoch, um ein aussagekräftiges Ergebnis zu erhalten.

Es ist nicht möglich, nur aufgrund der Breakpoints zu sagen, dass es sich wirklich um einen Windwurf handelt. Ein Breakpoint zeigt lediglich die Veränderung an und sagt noch nichts über die Art der Veränderung aus, es könnte also auch ein Anstieg an Biomasse vorliegen. Hier kommt die Magnitude zu tragen (wurde in den Ergebnisdarstellungen immer berücksichtigt), welche das Ausmaß der Veränderung, sowie deren Richtung angibt, also ob die Veränderung positiv oder negativ ist. Aufgrund der Berechnung werden hier positive Magnituden mit einem Windwurf assoziiert, diese geben eine negative Veränderung, also eine Abnahme der Biomasse (Wald) zwischen zwei aufeinanderfolgenden Zeitpunkten an.

Eine weitere Differenzierung nach dem Zeitpunkt der Erfassung ist nicht möglich, da im Jahr 2015 ab April keine Veränderungen mehr erfasst wurden. Es wird vermutet, dass hier die Datenqualität und die Wolkenbedeckung, neben dem h-Wert den größten Einfluss auf das Ergebnis haben. Wie in Abbildung 27 ersichtlich ist, tauchen in den Reflectance-Daten, aus denen der Index fAPAR berechnet wurde, genau Anfang April die bereits besprochenen Flecken und Unregelmäßigkeiten in den Daten auf.

Die Vermutung liegt nahe, dass diese Unregelmäßigkeiten auf das durchgeführte Gapfilling und die verwendete Wolkenmaske zurückzuführen sind und deshalb als Veränderung, vor allem in den unveränderten Waldgebieten, erfasst werden. Außerdem passt der Zeitpunkt in die Mitte des zweiten Segments, wenn man nach dem h-Wert geht (2015: Bild 49-68 der Zeitreihe, Bild 55 ist die erste Aprilaufnahme). Laut visueller Überprüfung spricht allerdings nichts dafür, dass die Flecken einen Unterschied bei der Detektion machen. Dennoch verändert sich das Reflexionsvermögen flächendeckend, was der Grund dafür sein könnte, dass die Veränderungen in der Art erfasst werden. Zur besseren Veranschaulichung der Unregelmäßigkeiten wurde in Abbildung 28 die erste Aufnahme im Mai 2015 der Reflectance-Daten ausgewählt, da hier die Fehler am eindeutigsten ersichtlich sind.



0 250 500

Abbildung 28: Unregelmäßigkeiten der Reflectance-Daten, abgebildet mit Breakpoints aus fAPAR-Daten für das Jahr 2015, h=0.38, harmonisches Saisonalitätsmodell und Windwürfe München (Berechnungszeitraum 2013-2016)

Eine Möglichkeit der Verwendung dieser Auswertungsergebnisse wäre die Eingrenzung der Gebiete in denen nach Windwürfen gesucht wird. Anhand dieser Daten würde die Waldfläche von potentiell veränderten Flächen auf ca. 20 % der gesamten Waldfläche reduziert werden, was den Aufwand, die Windwürfe zu lokalisieren, reduzieren würde.

Wie in Abbildung 29 erkennbar wird, erstreckt sich das Testgebiet Landsberg über die Kacheln 104\_18 und 105\_18, wobei der Großteil der Windwürfe in Kachel 105\_18 zu finden ist. Hier tritt auch vermehrt Laubwald auf, im Vergleich zum Testgebiet München, in dem hauptsächlich Nadelwald zu finden ist. Das Testgebiet München erstreckt sich über die Kacheln 104\_19 und 104\_20, wobei hier die Windwürfe hauptsächlich in Kachel 104\_19 zu finden sind, welche auch zuvor als Testkachel für die Festlegung des h-Wertes verwendet wurde.



Abbildung 29: Testgebiete und Kacheln im Untersuchungsgebiet, fAPAR-Daten 2013-2016, Breakpoints mit positiver Magnitude für das Jahr 2015, h=0,38 und harmonisches Saisonalitätsmodell

Abbildung 30 zeigt links oben das Ergebnis des NDVI. Wie man auf den ersten Blick erkennen kann, wird sehr wenig detektiert, egal ob in unveränderte Waldflächen oder in den bekannten Windwurfgebieten. Die wenigen Windwurfpixel, die erfasst werden, stimmen bezüglich des Zeitpunktes, jedoch treten jene auch in den unveränderten Gebieten auf und lassen daher keine Aussage zu.



Abbildung 30: Breakpoints mit positiver Magnitude für das Jahr 2015, Berechnungszeitraum 2013-2016, h= 0,38, harmonisches Saisonalitätsmodell; oben links: NDVI, oben rechts: TCB, unten links: Refelctance NIR, unten rechts: Reflectance Red

Das Problem tritt auch bei TCB (Abbildung 30, oben rechts) und bei den beiden Reflectance Ergebnissen auf. Bei der Reflectance Red fällt auf, dass in Windwurfflächen keine Veränderung auftritt, dafür aber in den unveränderten Bereichen. Im Vergleich zu den Ergebnissen mit fAPAR in Abbildung 26, wird die Aussage der besseren Detektionsfähigkeit mit den fAPAR-Daten unterstrichen. BFAST ist zwar nicht an bestimmte Vegetationsindizes gebunden, doch wurde schon anhand der umfangreichen Literaturrecherche (z.B. Verbesselt, 2010a, 2010b; Hamunyela, 2016) klar, dass Reflectance-Daten nicht für eine derartige Auswertung verwendet werden, sondern diverse Vegetationsindizes zur Anwendung kommen (siehe auch Kapitel 2.5).

Wie Abbildung 26 zeigt, liefert fAPAR die besten Ergebnisse. Dies bestätigt die Aussage von Baković (2017), der Daten derselben Prozessierungsvorgehensweise bearbeitet hat und ebenfalls zu dem Schluss kam, dass fAPAR die größte Aussagekraft besitzt und der NDVI weniger gut funktioniert als erwartet.

Deswegen werden auch nur fAPAR und NDVI für beide Testgebiete ausgewertet und validiert. Bei TCB, Reflectance Red und Reflectance NIR wurde anhand der visuellen Interpretation entschieden, diese nicht weiterzuverfolgen und auch keine Validierung vorzunehmen. Die Ergebnisse des NDVI sind zwar ebenfalls fraglich, aber Ziel ist es, einen Vergleichswert für fAPAR zu generieren.



Abbildung 31: Vergleich der fAPAR Ergebnisse der Breakpoints mit harmonischem Saisaonalitätsmodell (links: 2006-2016, h=0,09; rechts: 2013-2016, h=0,38)

Abbildung 31 zeigt für Vergleichszwecke links einmal die Ergebnisse der langen Zeitreihe (2006-2016) (siehe Anhang) und rechts jene der verkürzten (2013-2016) der fAPAR-Daten. Hier wird eindeutig klar, dass die Verbesserung zwar groß ist, aber dennoch für kein aussagekräftiges Ergebnis reicht.

#### 4.2.2 Ergebnisse Mean Shift

In Abbildung 32 wird das Ergebnis der Mittelwertberechnung der Segmente dargestellt, welches ebenfalls mithilfe eines R-Scriptes durchgeführt wurde (siehe Anhang 2 Rasterize und 3 Extract Zones). Wie auf den ersten Blick deutlich wird, verbessert sich das Ergebnis im Vergleich zu fAPAR nicht, sondert zeichnet ein sehr ähnliches Bild. Die Segmente passen teilweise in die Windwurfbereiche, aber es fällt auf, dass mehr Segmente als Veränderung in der unveränderten Waldfläche auftreten. Die Zeitpunkte der Erfassung decken sich weitestgehend mit denen Ergebnissen von fAPAR. Die erhoffte Reduktion des Rauschens hat dementsprechend nicht zielführend funktioniert. Auf die endgültigen Ergebnisse wird in Kapitel 4.4 näher eingegangen.



Abbildung 32: Breakpoints mit positiver Magnitude aus der Berechnung des 40 % Quantils für das Jahr 2015, fAPAR 2013-2016, h=0,38, harmonisches Saisonalitätsmodell

Hier wird darauf verzichtet alle Ergebnisse der Segmentierung abzubilden, da sie hauptsächlich sehr ähnlich sind und keine neuen Erkenntnisse bringen. Im folgenden Kapitel Validierung wird dennoch genauer darauf eingegangen.

### 4.4 Validierung der fAPAR Ergebnisse

In diesem Kapitel erfolgt die Validierung der vorher besprochenen Ergebnisse für den Index fAPAR. Dies dient dazu, ein Genauigkeitsmaß für die vorgenommene Auswertung zu generieren und um eine Aussage über die Funktionalität des Algorithmus bzw. der Daten treffen zu können. Zunächst wird eine TRUE-positive/FALSE-positive/TRUE-negative/FALSE-negative-Matrix pro Testgebiet und Index, berechnet. Tabelle 2 soll dies für leichteres Verständis veranschaulichen.

Validierung München	
104_19	Anzahl Pixel
WW richtig erfasst	
WW falsch erfasst	
kWW richtig erfasst	
kWW falsch erfasst	

Tabelle 2: Validierungstabelle zur besseren Verdeutlichung der Ergebnisdarstellung

Als "Windwurf richtig" wurden alle Pixel ausgewiesen, die innerhalb der Windwurfflächen liegen und im April mit einer positiven Magnitude erfasst wurden. Als "Windwurf falsch" wurden alle Pixel erfasst, die zwar innerhalb der Windwurfgebiete liegen, aber entweder nicht im April erfasst wurden oder deren Magnitude negativ bzw. null war. Außerdem kommen hier auch alle Pixel hinzu, die in Windwurfgebieten liegen, jedoch ohne Veränderung erfasst wurden.

"WW" steht für "Windwurf" und bildet all jene Flächen ab, die in den Referenzdaten innerhalb der Windwurfpolygone liegen. Demnach werden hier Veränderungen richtig erfasst, wenn es sich um einen detektierten Windwurf handelt. Wird kein Breakpoint innerhalb dieser Polygone erfasst, bezieht sich das Ergebnis auf einen falsch erfassten Windwurf. "kWW" steht für "kein Windwurf" und bildet die unveränderte Waldfläche ab. "kWW richtig" beinhaltet demnach alle Pixel, die außerhalb der Windwurfgebiete, aber im Wald und ohne Veränderung erfasst wurden. Alle falsch erfassten unveränderten Bereiche zeigen jene Pixel der Waldfläche, in denen Veränderungen erfasst wurden, jedoch in unverändertem Waldgebiet liegen. Das Testgebiet Landsberg beinhaltet zwar mehr Laubwald, doch die Windwürfe sind im Hinblick auf die Größe viel kleinräumiger und werden dadurch schlechter erkannt als im Testgebiet München.

### 4.4.1 fAPAR 2013-2016

In den folgenden Tabellen und Abbildungen werden die Ergebnisse der Validierung der fAPAR-Daten dargestellt. In Tabelle 3 ist die jeweilige Pixelanzahl der vier oben erklärten Validierungsfälle für das Testgebiet München angeführt. Als erstes fällt auf, dass die meisten Windwurf-Pixel in Kachel 104\_19 auftreten. Dabei werden in Kachel 104\_20 verhältnismäßig um einiges mehr Windwürfe richtig detektiert als in der Kachel 104\_19. In den unveränderten Bereichen fällt diesbezüglich kein größerer Unterschied auf:

Validierung München	
104_19	
WW richtig erfasst	986
WW falsch erfasst	2 450
kWW richtig erfasst	150 494
kWW falsch erfasst	35 003
104_20	
WW richtig erfasst	615
WW falsch erfasst	535
kWW richtig erfasst	62 330
kWW falsch erfasst	16 351

Tabelle 3: Validierungsergebnisse pro Kachel im Testgebiet München, fAPAR für das Jahr 2015, h=0.38, harmonisches Saisonalitätsmodell, Berechnungszeitraum 2013-2016, Breakpoints mit positiver Magnitude

In der folgenden Tabelle 4 sind die Ergebnisse für fAPAR mit einem h-Wert von 0,38 und mit dem harmonischen Saisonalitätsmodell dargestellt. Als richtig erfasst dienen nur Breakpoints im April mit einer positiven Magnitude. Die Höhe der Magnitude bewegt sich zwischen 0 und 50. Es liegt nahe, dass die niedrige Magnitude durch das angepasste Saisonalitätsmodell beeinflusst wird. Geht man davon aus, dass dieses überbestimmt wurde und die Veränderungen somit größer sein müssen um detektiert zu werden, liegt es nahe, dass jene Werte niedriger als erwartet ausfallen.

MÜNCHEN	fAPAR Pixel	%		fAPAR Pixel
WW richtig erfasst	1 601	0,60	WW gesamt	4 586
WW falsch erfasst	2 985	1,11	kWW gesamt	264 178
kWW richtig erfasst	212 824	79,19	richtig erfasste Pixel	214 425
kWW falsch erfasst	51 354	19,11	falsch erfasste Pixel	54 339,00

Tabelle 4: Validierung fAPAR für das Jahr 2015 im Testgebiet München, h=0.38, harmonisches Saisonalitätsmodell, Berechnungszeitraum 2013-2016, Breakpoints mit positiver Magnitude

Wie in obiger Tabelle 4 ersichtlich wird, überwiegt eindeutig die unveränderte Waldfläche, was die Gesamtgenauigkeit in % nicht wirklich repräsentativ macht. Im Vergleich zu den unveränderten Flächen mit 264 178 Pixel fällt auf, dass die Windwurfbereiche um einiges kleiner sind, da diese nur 4 586 Pixel enthalten.

Das Gesamtergebnis für fAPAR im Testgebiet München lautet wie folgt: die unveränderten Waldflächen wurden zu 79% (212.824 Pixel) richtig erfasst und zu 19% (51.354 Pixel) falsch. Das bedeutet, die Windwürfe wurden nur weniger als 1% (1.601 Pixel) richtig erfasst und zu knapp über 1% (2.985 Pixel) falsch. Dabei muss jedoch, wie bereits erwähnt bedacht werden, dass die Gesamtfläche der unveränderten Fläche um einiges größer ist als jene der Windwurfgebiete.

Betrachtet man allein die Ergebnisse für die Windwurfflächen (Abbildung 33, links), so werden diese mit 35% bezogen auf die Gesamtfläche der Windwurfflächen, richtig erfasst. Das bedeutet, dass jedes dritte Windwurfpixel richtig berechnet wurde.



Abbildung 33: Validierungsergebnisse im Testgebiet München 2015, fAPAR, h=0,38, harmonisches Saisonalitätsmodell, Berechnungszeitraum 2013-2016; links: erfasste Windwürfe, Mitte: erfasste unveränderte Waldflächen, rechts: Anzahl der Pixel richtig/falsch Im Vergleich dazu (siehe Abbildung 33, Mitte), steigt die Genauigkeit für richtig erfasste Pixel der unveränderten Waldfläche auf 81%. In dem Fall wird nur jedes fünfte Pixel nicht als unveränderter Wald erfasst, bzw. werden vier von fünf unveränderten Waldpixeln richtig erfasst.

Wird, wie hier in Abbildung 33 rechts, nur danach gegangen wie viele Pixel richtig erfasst wurden und welche nicht, pendelt sich die Genauigkeit auf 80% richtiger Berechnungen ein.

Die Tabelle 5 stellt die Daten aus dem Testgebiet Landsberg nach den jeweiligen Kacheln dar. Hier fällt auf, dass es nicht möglich war, in Kachel 104\_18 einen Windwurf richtig zu detektieren. Da jedoch in Kachel 105\_18 Ergebnisse vorliegen, wird mit dem Gesamtwert weitergearbeitet. Die Kachel 104\_18 enthält insgesamt 85.819 Pixel, wovon 221 auf Windwürfe entfallen. Die zweite Kachel im Testgebiet, 105\_18, enthält insgesamt 247.806 Pixel, hier entfallen 2.865 Pixel auf Windwürfe. Schon allein aufgrund der Anzahl der Pixel pro Kachel liegt es nahe, dass in Kachel 104\_18 kein Windwurf detektiert wurde.

Validierung Landsberg	
104_18	
WW richtig erfasst	0
WW falsch erfasst	221
kWW richtig erfasst	73 667
kWW falsch erfasst	11 931
105_18	
WW richtig erfasst	38
WW falsch erfasst	2 727
kWW richtig erfasst	199 022
kWW falsch erfasst	46 019

Tabelle 5: Validierungsergebnisse pro Kachel im Testgebiet Landsberg für das Jahr 2015, fAPAR, h= 0.38, harmonisches Saisonalitätsmodell, Berechnungszeitraum 2013-2016, Breakpoints mit positiver Magnitude

Das Testgebiet Landsberg enthält insgesamt weniger und viel kleinflächigere Windwürfe als das Testgebiet München. Hier treten zwar Windwürfe auch im Laubwald auf, jedoch scheinen diese zu klein um dementsprechend erfasst zu werden. Daher ist es nicht möglich einen Unterschied in der Erfassung bei Laub- und Nadelwald festzustellen. Auch im Testgebiet München war es nicht möglich die kleinen Flächen zu erfassen. Deshalb ist es wenig überraschend, dass dies in Landsberg ebenfalls nicht möglich war.

Tabelle 6: Validierung im Testgebiet Landsberg für das Jahr 2015, fAPAR, h= 0.38, harmonisches
Saisonalitätsmodell, Berechnungszeitraum 2013-2016, Breakpoints mit positiver Magnitude

LANDSBERG	fAPAR Pixel	%		fAPAR Pixel
WW richtig erfasst	38	0,01	WW gesamt	2 986
WW falsch erfasst	2948	0,89	kWW gesamt	330 639
kWW richtig erfasst	272689	81,73	richtig erfasste Pixel	272 727
kWW falsch erfasst	57950	17,37	falsch erfasste Pixel	60 898

Insgesamt werden hier, wie in Tabelle 6 ersichtlich ist, von 333.625 Pixel vergleichsweise sehr wenige Windwürfe erfasst (0,01 %). Das kann mitunter daran liegen, dass die Windwurfflächen im Testgebiet Landsberg hauptsächlich kleiner sind und noch weniger vorkommen als im Testgebiet München, denn auch hier konnten die kleineren Windwürfe nicht bzw. nur vereinzelt erfasst werden. Wie man sehen kann, liegt die Genauigkeit für alle Pixel, bezogen auf die richtig erfassten Windwurfpixel bei 0,01% (38 Pixel). Die falsch erfassten Windwurfpixel liegen bei knapp unter 1% (2.948 Pixel). Die unveränderten Waldflächen werden zu fast 82% (272.689 Pixel) richtig detektiert und nur zu 17,4% (57.950 Pixel) falsch. Natürlich ist die prozentuale Aufschlüsselung durch die höhere Anzahl der unveränderten Waldpixel beeinflusst.



Abbildung 34: Validierungsergebnisse im Testgebiet Landsberg für das Jahr 2015, fAPAR, h=0,38, harmonsiches Saisonalitätsmodell, Berechnungszeitraum 2013-2016; links: erfasste Windwürfe, Mitte: erfasste unveränderte Waldflächen, rechts: Anzahl der Pixel richtig/falsch

Betrachtet man hier lediglich die Windwurfpixel (Abbildung 34, links), verbessert sich das Ergebnis kaum. Nur 1% wird richtig erfasst, der Rest der Windwurfflächen wird entweder zu früh oder gar nicht als Veränderung detektiert und damit als falsch erfasst.

Wie in der Mitte der Abbildung 34 ersichtlich ist, werden die unveränderten Waldpixel um einiges besser erfasst. Hier stimmt die Berechnung zu 82% mit den Referenzdaten überein. Das bedeutet, es werden 4 von 5 Pixeln richtig berechnet.

Abbildung 34, rechts zeigt die Aufteilung aller Pixel in richtig bzw. falsch erfasste Pixel. Auch hier stimmt die Berechnung zu 82%, was maßgeblich daran liegt, dass die unveränderten Waldpixel ein Vielfaches der Windwurfpixel darstellen.

### 4.4.2 RMSE für fAPAR 2013-2016

Abschließend wurde für die Validierung auch der Root Mean Square Error (RMSE) der Restkomponente berechnet (R-Script 6. RMSE im Anhang). Dies sollte dazu dienen eine Aussage darüber tätigen zu können, wie gut die Berechnung der Saisonalitäts- bzw. der Trendkomponente funktioniert hat.

Die Berechnung basiert ebenfalls auf jenen vier Fällen, die auch für die Validierung herangezogen wurden (siehe R-Script 5. Validierung im Anhang) und bezieht sich auf die gesamte Waldfläche in der jeweiligen Kachel. Ein kleiner RMSE-Wert steht für ein gut angepasstes Modell, je größer er wird, desto schlechter funktioniert das Modell.

Aufgrund dessen wurde angenommen, dass der RMSE für die richtig detektierten Pixel klein sein sollte und demnach bei den falsch erfassten Pixel einen höheren Wert liefern würde. Dieser vermutete Zusammenhang lässt sich nicht bestätigen (siehe Tabelle 7).

Tabelle	7: berechneter	RMSE der	<sup>.</sup> Restkomponente	pro Kachel	und Index,	basierend	auf den	Ergebnissen	mit
h=0,38,	harmonischem	Saisonalitä	tsmodell und dem	Berechnung	szeitraum 2	013-2016			

IAFAR				
	München		Landsberg	
	104_19	104_20	104_18	105_18
WW richtig erfasst	340,21	298,51	NaN	205,43
WW falsch erfasst	221,97	197,35	418,11	197,35
kWW richtig erfasst	370,70	321,18	419,81	324,74
kWW falsch erfasst	288,47	248,97	387,96	308,62

N	n١	

FADAD

	München		Landsberg	
	104_19	104_20	104_18	105_18
WW richtig erfasst	280,18	288,18	NaN	273,92
WW falsch erfasst	225,63	230,99	197,35	207,51
kWW richtig erfasst	316,19	346,99	318,03	302,54
kWW falsch erfasst	307,43	311,16	321,54	302,98

Das NaN der richtig erfassten Windwürfe in Kachel 104\_18 ergibt sich daher, dass hier kein Pixel richtig als Windwurf detektiert wurde. NaN wird immer dann ausgegeben, wenn kein Zahlenwert vorliegt und steht für Not a Number.

### 4.4.3 Mean Shift fAPAR 2013-2016

Die folgende Tabelle 8 zeigt alle Validierungsergebnisse der vier Fälle der Validierung – Windwurf richtig, Windwurf falsch, unveränderter Wald richtig und unveränderter Wald falsch erfasst. Zuerst wird der Mittelwert (Mean), dann der Median und danach diverse Quantile dargestellt.

Tabelle 8: Validierung der Mean Shift-Ergebnisse für das Jahr 2015, Kachel 104\_19 fAPAR, h=0,38, harmonisches Saisonalitätsmodell, Berechnungszeitraum 2013-2016

Validierung	MEAN
104_19	
WW richtig erfasst	698
WW falsch erfasst	2 738
kWW richtig erfasst	156 395
kWW falsch erfasst	29 102

Validierung	MEDIAN		١
104_19			
WW richtig erfasst	767		١
WW falsch erfasst	2 669		١
kWW richtig erfasst	153 115		ł
kWW falsch erfasst	32 382		ł
	Validierung 104_19 WW richtig erfasst WW falsch erfasst kWW richtig erfasst kWW falsch erfasst	ValidierungMEDIAN104_19WW richtig erfasst767WW falsch erfasst2 669kWW richtig erfasst153 115kWW falsch erfasst32 382	ValidierungMEDIAN104_19WW richtig erfasst767WW falsch erfasst2 669kWW richtig erfasst153 115kWW falsch erfasst32 382

	Validierung	Q05
	104_19	
	WW richtig erfasst	787
)	WW falsch erfasst	2 649
	kWW richtig erfasst	157 116
	kWW falsch erfasst	28 381

Validierung	Q10
104_19	
WW richtig erfasst	727
WW falsch erfasst	2 709
kWW richtig erfasst	156 552
kWW falsch erfasst	28 945

Validierung	Q20
104_19	
WW richtig erfasst	761
WW falsch erfasst	2 675
kWW richtig erfasst	156 338
kWW falsch erfasst	29 159

Validierung	Q30
104_19	
WW richtig erfasst	813
WW falsch erfasst	2 623
kWW richtig erfasst	154 939
kWW falsch erfasst	30 558

Validierung	Q40
104_19	
WW richtig erfasst	884
WW falsch erfasst	2 552
kWW richtig erfasst	153 418
kWW falsch erfasst	32 079
itter falcon on acot	

Validierung	Q60
104_19	
WW richtig erfasst	705
WW falsch erfasst	2 731
kWW richtig erfasst	152 994
kWW falsch erfasst	32 503

Validierung	Q70
104_19	
WW richtig erfasst	705
WW falsch erfasst	2 731
kWW richtig erfasst	152 817
kWW falsch erfasst	32 680

Validierung	Q80	Validierung	Q90
104_19		104_19	
WW richtig erfasst	644	WW richtig erfasst	488
WW falsch erfasst	2 892	WW falsch erfasst	2 948
kWW richtig erfasst	154 585	kWW richtig erfasst	154 996
kWW falsch erfasst	30 912	kWW falsch erfasst	30 501

Diese Vorgehensweise wurde zu Testzwecken durchgeführt und deshalb nur auf die Testkachel 104\_19 angewendet. Wie in Tabelle 8 ersichtlich wird, liefert das 40 % Quantil das beste Ergebnis mit 884 Pixeln, die richtig als Windwurf erfasst wurden. An die zweite Stelle tritt das 30% Quantil mit 813 Pixeln.

Weiters erzielt das 5% Quantil 787 richtige Pixel, wobei der Median mit 767 knapp dahinterliegt. Die restlichen Ergebnisse variieren zwischen 760-488 richtig erfassten Pixeln. Wobei das 90% Quantil den schlechtesten Wert der richtig erfassten Windwurfpixel liefert. Insgesamt beziehen sich jene Werte auf die Windwurfflächen, die gesamt 3 436 Pixel ausmachen. Zudem fällt auf, dass ein Zusammenhang zwischen der Erfassung der Windwürfe und der unveränderten Flächen besteht. Es zeigt sich in allen Berechnungen der Mean Shift Segmentierung, dass entweder die unveränderten Flächen besser detektiert wurden und dafür die Windwürfe besser, oder die unveränderten Flächen besser detektiert wurden und dafür die Windwürfe weniger erfolgreich.

Tabelle 9: Validierung Mean Shift 40 % Quantil-Berechnung für das Jahr 2015, basierend auf fAPAR der Testkachel 104\_19, h=0.38, harmonisches Saisonalitätsmodell, Berechnungszeitraum 2013-2016, Breakpoints mit positiver Magnitude

MÜNCHEN	fAPAR Pixel	%		fAPAR Pixel
WW richtig erfasst	884	0,47	Windwurf gesamt	3 436
WW falsch erfasst	2 552	1,35	kWW gesamt	185 497
kWW richtig erfasst	153 418	81,20	richtig erfasste Pixel	154 302
kWW falsch erfasst	32 079	16,98	falsch erfasste Pixel	34 631

Um hier den Rahmen nicht zu sprengen, werden nur die Ergebnisse der Berechnung des 40 % Quantils (Tabelle 9) genau betrachtet. Diese Auswertung bezieht sich ausschließlich auf die Kachel 104\_19 aus dem Testgebiet München. Insgesamt umfasst das Gebiet 188.933 Pixel. Davon beziehen sich wie bereits erwähnt 3.436 auf Windwürfe und der Rest auf den unveränderten Wald.



Abbildung 35: Validierungsergebnisse im Testgebiet München für das Jahr 2015, 40% Quantil der Segmentierung, h=0,38, harmonisches Saisonalitätsmodell, Berechnungszeitraum 2013-2016; links: erfasste Windwürfe, Mitte: erfasste unveränderte Waldflächen, rechts: Anzahl der Pixel richtig/falsch

Es sind im Gesamtergebnis 0,47% (884 Pixel) Windwürfe richtig erfasst, 1,35% (2.552 Pixel) falsch und die unveränderten Waldgebiete zu fast 81% (153.418 Pixel) richtig erfasst und nur 16,98% (32.079 Pixel) falsch.

Werden lediglich die Windwurfpixel betrachtet, wie in Abbildung 35 (links), steigt die Genauigkeit erneut auf 26% richtig erfasster Windwürfe, was sehr nahe an die fAPAR Ergebnisse des gesamten Testgebiets München herankommt.

In Abbildung 35 (Mitte) wird der unveränderte Wald zu 83% richtig erfasst und 17% bleiben als falsch erfasst übrig. Die Aufteilung der richtig bzw. falsch erfassten Pixel gliedert sich auf 82% richtig und 18% falsch erfasste Pixel, wie man in Abbildung 35 (rechts) sehen kann. Dieses Ergebnis ähnelt dem vorangegangenen fAPAR Ergebnis sehr, die gehoffte Verbesserung konnte jedoch nicht erzielt werden. Eventuell wäre es zielführender gewesen die Segmentierung auf die erste Aprilaufnahme der fAPAR-Daten im Jahr 2015 anzuwenden.

## **5** Diskussion

Satellitendaten besitzen signifikantes Potential für Vegetationsmonitoring auf regionaler und globaler Ebene (vgl. Anaymaba & Eastman, 1996 und Azzali und Menenti, 2000; nach Verbesselt et al., 2010b, 2970). Dennoch birgt die Auswertung von diesen Daten auch diverse Probleme, die im Folgenden näher erläutert werden.

Wie in Kapitel 2.5.2 eingehend erläutert wurde, handelt es sich bei der Veränderungsdetektion mit BFAST um die iterative Zerlegung einer fernerkundlichen Zeitreihe in ihre Komponenten Trend, Saisonalität und Remainder (Verbesselt et al., 2010a, 107). Da der Trend und die Saisonalität der gesamten Zeitreihe berechnet werden, wird die gesamte Information nutzbar, da kein Datenverlust durch Aufsummierung oder Ähnliches entsteht. Weitere Vorteile ergeben sich daraus, dass keine Festlegung von Landbedeckungsklassen, Referenzperioden, Veränderungstrajektorien oder Schwellenwerten notwendig ist. Nur der sogenannte h-Wert, also die minimale Segmentgröße der Zeitreihe in der eine Veränderung erfasst werden kann, muss definiert werden (Verbesselt et al., 2010a, 112).

Weitere Vorteile sind z.B. die schnelle Verarbeitung und damit wenig Zeitaufwand bei der Auswertung. Laut Verbesselt (2012, 106) braucht der Algorithmus 0,02 Sekunden um ein Pixel einer zehnjährigen Zeitreihe auf einem durchschnittlichen Standcomputer zu verarbeiten. Dies kann anhand des vorliegenden Beispiels durchaus bestätigt werden. Desweiteren benötigt BFAST kein Gapfilling, sondern kann auch mit lückenhaften Datensätzen arbeiten, sofern nicht zu viele aufeinanderfolgende Beobachtungen fehlen (Hamunyela et al., 2016, 127).

Es wurde ein Unterschied bei der Erfassung von Laub- bzw. Nadelwald erwartet. Da jedoch die Windwurfbereiche im Gebiet Landsberg, in welchem mehr Laubwald vorkommt, im Vergleich klein sind, konnte hier kein Vergleich gezogen werden, denn auch im Testgebiet München konnten Windwürfe mit dieser Größe nicht bzw. nur vereinzelt erfasst werden.

Es besteht jedoch die Möglichkeit die Saisonalität von anderen Daten abzuleiten und beide zu kombinieren. Dies umgeht auch das Problem eines Sensorausfalles. (vgl. DeVries et al., 2015; Zhu & Woodcock, 2014; nach Hamunyela et.al., 2016, 127).

Der Rauschpegel bleibt nach dem Anpassen des Saison-Trend-Modells der Hauptfaktor der Fähigkeit zur Detektion von Veränderungen und Störungen und stellt eine Einschränkung dieser Methode dar. Weil diese Methode datengetrieben, also abhängig von den zugrundeliegenden Daten ist, begrenzt das Signal-Rausch-Verhältnis die Möglichkeit, zwischen Veränderung und keiner Veränderung zu unterscheiden. Denn eine Veränderung soll klar ersichtlich und klar abgrenzbar sein. Das Ausmaß bzw. die Stärke der Veränderung im Vergleich zum Rauschen ist wichtig und es müssen mehrere Beobachtungen mit der beinhalteten Störung vorhanden sein um erfolgreich detektieren zu können (vgl. Verbesselt et al., 2012, 105).

Dies bedeutet, dass das Signal-Rausch-Verhältnis die Fähigkeit der Veränderungsdetektion beeinflusst und eine konsequente Vorprozessierung, welche die Qualität und Zuverlässigkeit der Zeitreihe gewährleisten soll, notwendig ist um die Veränderungsdetektion zu verbessern bzw. zu ermöglichen. Außerdem ist es wichtig die Jahreszeitenwechsel zu berücksichtigen, weil diese den Rauschpegel erhöhen und damit die Wahrscheinlichkeit der Veränderungsdetektion minimieren. BFAST liefert keine direkt verwertbaren Informationen über die Quelle oder den Auslöser der Veränderung, aber Auswertungsergebnisse lassen darauf schließen. Vor allem in Kombination mit anderen Daten lassen sich jene Faktoren, welche die jeweilige Veränderung auslösen, ableiten. Ein solcher Faktor kann zum Beispiel ausbleibender Niederschlag sein. Der Auslöser dafür kann etwa ein Jahreszeitenwechsel oder eine Dürre sein. In beiden Fällen gibt es weniger Niederschlag, was sich im Reflexionsvermögen wiederspiegelt und dadurch erfassbar wird (vgl. Funk & Budde, 2009; Vrieling et al., 2011; nach Verbesselt et al., 2012, 106).

Um eindeutig zu definieren was eine signifikante Veränderung ist, muss die Landoberflächenphänologie und Hintergrundvariation bekannt sein. Dies ist eine der kritischsten Komponenten in der globalen Veränderungsforschung (vgl. deBeurs & Henebry, 2005; nach Verbesselt et at., 2010b, 2976).

Die Erfassung kurzfristiger, abrupter Störungen hängt vom Ausmaß der Störung im Vergleich zum Signal-Rausch-Verhältnis ab, welches durch spektrale, räumliche und temporale Beschaffenheit der Daten beeinflusst wird. Das Erfassen solcher Veränderungen oder Störungen ist ein Schritt in Richtung besseren Verständnisses der Prozesse und Auslöser, die zu derartigen Veränderungen führen. Die Fähigkeit eines Systems Ökosystemveränderungen abzubilden, hängt von der Kapazität zur Unterscheidung zwischen normalen phänologischen Zyklen und abnormen Veränderungen ab (vgl. Verbesselt et al., 2012, 99).

Außerdem muss beachtet werden, dass der Rauschpegel auch nach Anpassung des Trendbzw. Saisonalitätsmodells den größten Einfluss auf die Detektionsfähigkeit und -qualität hat (Hamunyela et al., 2016, 105). Alles deutet darauf hin, dass die erzielten Ergebnisse aufgrund der Datenqualität und verfügbarkeit nicht zufriedenstellend ausfallen. Wie bereits angesprochen, ist die Methode der Prozessierung der Daten nicht für die Detektion abrupter Veränderungen geeignet und die Bereinigung der Bänder fiel unterschiedlich aus. Zusätzlich dazu liegt die Vermutung nahe, dass die verwendete Wolkenmaske die Wolkenbedeckung und den Wolkenschatten nur unzureichend gefiltert hat. Dies führt zu den in Kapitel 3.2, angesprochenen Flecken und Fehlern in den Daten. Die Flecken treten im Jahr 2015 maßgeblich Anfang April auf, zu diesem Zeitpunkt tritt auch der Großteil der erfassten Veränderungen auf.

Zudem spielt auch die Wolkenbedeckung für den Algorithmus eine große Rolle. Ist die Wolkenbedeckung großflächig und langanhaltend, kommt es ebenfalls zu einer verspäteten Detektion, da nicht genug aufeinanderfolgende Beobachtungen vorhanden sind (Hamunyela et al., 2016, 137). In diesem Fall ist auch das durchgeführte Gapfilling nicht zielführend, da durch die Interpolation der Grauwerte eine Abweichung zu den realen Gegebenheiten auftritt. Hinzu kommt die Wolkenbedeckung, die vor allem nach Sturmereignissen auftritt und wodurch viel Information verloren geht, wobei auch kein Gapfilling erfolgreich ist.

Es ist wichtig zu verstehen, wie unterschiedliche Veränderungen erfasst werden, vor allem in Ökosystemen mit starken saisonalen Veränderungen und hohem Rauschanteil im spektralen Signal. Auch hier stellt die Wolkenbedeckung ein großes Problem dar, da sie die 16-Tage Aufnahmeintervalle von Landsat stark verlängern kann. Hier bietet sich die Verknüpfung mit zusätzlichen Daten an (vgl. Hilker et al., 2009; nach Verbesselt et al., 2010a, 114).

Zusätzlich dazu haben auch Ungenauigkeiten in der Waldmaske, sowie die räumliche Auflösung von 30 m Einfluss auf die Detektierbarkeit. Bei der Waldmaske kann es sein, dass in Randbereichen zum Teil auch andere Landbedeckungsarten miteinbezogen werden. Vor allem bei kleinräumigen Veränderungen kann die Auflösung mit 30 Metern zu grob sein um besonders kleinere Abweichungen zu erkennen.

Betrachtet man die Ergebnisse von fAPAR (2013-2016 mit h=0,38; 35% richtig erfasste Windwürfe mit positiver Magnitude, siehe Kapitel 4.4.1) anhand dieser Gesichtspunkte, wird schon bald klar, dass die Datenqualität bei dieser Art der Auswertung, neben der Wolkenbedeckung, der größte limitierende Faktor ist.

Desweiteren kann nicht ausgeschlossen werden, dass in dem großen Untersuchungsgebiet keine anderen, zusätzlichen Veränderungen aufgetreten sind. Hier ist es wieder wichtig, ausreichend zusätzliche Daten, auch als Validierungsdaten, verfügbar zu haben. Hinzu kommt die Größe der Flächen, in denen Veränderungen auftreten. Denn umso kleiner ein z.B. Windwurf ist, desto schlechter detektierbar ist er. Vor allem bezogen auf Landsatdaten mit 30 m Auflösung können durch die Mischpixelproblematik kleinräumige Veränderungen in den Daten untergehen.

Um eine aussagekräftige Validierung und eine eindeutige Zuordnung, ob es sich bei der Veränderung um einen Windwurf handelt, vornehmen zu können, müssen die Daten zusätzlich mit in-situ Daten abgeglichen werden, welche jedoch oft schwer zu bekommen sind (vgl. Verbesselt et al., 2010a, 108).

Angesichts der Tatsache, dass weniger als die Hälfte der Windwürfe richtig erfasst wurde, muss die Forschungsfrage "Können die Schäden, verursacht durch Sturm Niklas im Jahr 2015, anhand von Landsatdaten mittels BFAST erfasst werden?" anhand der gegebenen Daten mit Nein beantwortet werden. In diesem Beispiel ist es nicht möglich, die Windwürfe brauchbar zu detektieren. Es liegt nahe, die Vorgehensweise mit neu prozessierten Daten ohne Gapfilling zu wiederholen. Die Wahrscheinlichkeit, somit bessere Ergebnisse zu erzielen ist sehr hoch. Abschließend kann man sagen, dass der Algorithmus in der Anwendung einfach und leicht verständlich ist und damit weitere Forschungszwecke sicherlich legitimiert.
# 6 Zusammenfassung

Wald ist eine der wichtigsten Ressourcen weltweit, sei es die Holznutzung, die CO<sub>2</sub> Bindung oder die vielfachen weiteren Verwendungsmöglichkeiten. In Anbetracht dessen liegt es nahe, über jegliche Veränderungen dieser Ressource so viele Informationen zu generieren wie möglich. Genau hier setzt die Veränderungsdetektion an. Es eine Vielzahl an Algorithmen und Vorgehensweisen um eine solche Detektion durchzuführen.

Vorliegende Arbeit konzentrierte sich im Speziellen auf den Algorithmus BFAST (Breaks for Additive Season and Trend), bei dem es sich um eine iterative Zerlegung in die Komponenten Trend, Saisonalität und Remainder handelt. Es wurde eine Landsat Zeitreihe von 2006-2016 für die der Index fAPAR berechnet wurde, bearbeitet. Im Untersuchungsgebiet südlich von München sollte damit innerhalb von 2 Testgebieten getestet werden, ob die 2015 durch Sturm Niklas entstandenen Windwürfe mit dieser Vorgehensweise detektierbar sind.

Nach einigen wenig erfolgreichen Testauswertungen wurde entschieden, die Zeitreihe zu verkürzen, um die Sensorunterschiede zwischen den verschiedenen Landsataufnahmen zu umgehen und Rauschen zu minimieren. 2013-2016 enthält nur noch Beobachtungen von Landsat 8 und die Ergebnisse verbessern sich dadurch sichtlich. Es konnte dennoch kein besseres Ergebnis als 35% richtig detektierter Windwürfe erfasst werden. Demnach wurde auch die Forschungsfrage mit Nein beantwortet. Es liegt jedoch die Vermutung nahe, dass mit einer erneuten Prozessierung der Daten, die auch für die Detektion abrupter Veränderungen geeignet ist, bessere Resultate erzielt werden könnten. Auch die Kombination mit anderen Sensoren, bzw. mit größerer temporaler Auflösung, könnte das Ergebnis verbessern, sofern die Daten ausreichend aneinander angepasst werden können.

Zusammenfassend lässt sich sagen, dass Veränderungsdetektion ein sehr komplexes Thema ist, bei dem unterschiedlichste Faktoren berücksichtigt werden müssen. Zum einen die Datenverfügbarkeit, sowie die Datenqualität, die durch die Prozessierung gewährleistet werden soll. Sind aber nicht genug aufeinanderfolgende Beobachtungen verfügbar, sind die Möglichkeiten der Detektion sehr begrenzt.

**Schlagwörter**: Veränderungsdetektion, Wald, BFAST, Windwurf, abrupte Veränderungen, Trend

## 7 Bibliographie

- Albertz, J., 2007. Einführung in die Fernerkundung. 3. Aktualisierte und erweiterte Auflage. Darmstadt: Wissenschaftliche Buchgesellschaft.
- Anyamba, A., Eastman, J. R., 1996. Interannual variability of NDVI oder Africa and its relation to El Nino Southern Oscillation. International Journal of Remote Sensing, 17 (13), 2533-2548.
- Asner, G. P. 2001. Cloud cover in Landsat observations of the Brasilian Amazon. International Journal of Remote Sensing, 22 (18), 3855-3862.
- Azzali, S., Menenti, M., 2000. Mapping vegetation-soil-climate complexes in southern Africa using temporal Fourier analysis of NOAA-AVHRR NDVI data. International Journal of Remote Sensing, 21 (5), 973-996.
- Bauer, O., Einzmann, K., Schmitt, A., Seitz, R., 2016. Fernerkundungsunterstützung bei der Kalamitätsbewältigung im Wald (FastResponse). Freising, Deutschland.
- Baković, D. 2017. Drought effects on vegetation activity and growing season length of deciduous forests: an analysis of the 2015 drought using Landsat time series in Austria. Institut für Vermessung, Fernerkundung und Landinformation, Universität für Bodenkultur Wien.
- Banskota, A., Kayastha, N., Falkowski, M. J., Wulder, M. A., Froese, R. E., White, J. C.,
  2014. Forest monitoring using Landsat time-series data A review. Canadian Journal of Remote Sensind, 40 (5), 362-384.
- Baumann, M., Ozdogan, M., Wolter, P. T., Krylov, A., Vladimirova, N., Radeloff, V. C., 2014.
   Landsat remote sensing of forest windfall disturbance. Remote Sensing of
   Environment, 143, 171-179.
- Bradley, B. A., Mustard, J. F., 2008. Comparison of phenology trends by land cover class: a case study in the Great Basin, USA. Global Change Biology, 14 (2), 334-346.
- Bourier, G., 2011. Beschreibende Statistik Praxisorientierte Einführung mit Aufgaben und Lösungen. 9. Auflage. Regensburg: Gabler Verlag.
- Claverie, M., Vermote, E.F., Weiss, M., Baret, F., Hagolle, O., Demarez, V., 2013. Validation of coarse spatial resolution LAI and FAPAR time series over cropoland in southwest France. Remote Sensing of Environment, 139, 216-230.
- Cleveland, R.B., Cleveland, W.S., McRae, J.E., Terpenning, I., 1990. STL: A Seasonal-Trend Decomposition Procedure Based on Loess. Journal of Official Statistics, 6 (1), 3-73.
- Cohen, W. B., Fiorella, M., 1999. Comparison of Methods for Detecting Conifer Forest Change with Thematic Mapper Imagery. In: Lunetta, R. S., Elvidge, C. D., Hrsg.

Remote Sensing Change Detection – Environmental Monitoring Methods and Applications. London: Sleeping Bear Press, Inc, 89-102.

- Cohen, W. B., Spies, T. A., Alig, R. J., Oetter, D. R., Maiersperger, T. K., Fiorella, M., 2002.
  Characterizing 23 years (1972-1995) of stand replacement disturbance in western
  Oregon forests with Landsat imagery. Ecosystems, 5 (2), 122-137.
- de Beurs, K. M. Henebry, G. M., 2005. Land surface phenology and temperature variation in the International Geosphere-Biosphere Program high-latitude transects. Global Change Biology, 11 (5), 779-790.
- DeVries, R. S., Field, C. B., Fung, I., Collatz, G. J., Bounoua, L., 1999. Combining satellite data and biochemical models to estimate global effects of human-induced land cover change on carbon emissions and primary productivity. Global biochemical Cycles, 13 (3), 803-815.
- DeVries, B., Verbesselt, J., Kooistra, L., Herold, M., 2015. Robust monitoring of small scale forest disturbances in a tropical montane forest using Landsat time series. Remote Sensing of Environment, 161, 107-121.
- Dixon, R. K., Solomon, A. M., Brown, S., Houghton, R. A., Trexier, M. C., Wisniewski, J., 1994. Carbon pools and flux of global forest ecosystems. Science, 263 (5144), 185-190.
- Eilers, P. H. C., 2003. A perfect smoother. Analytical Chemistry, 75 (14), 3631-3636.
- Einzmann, K., Immitzer, M., Böck, S., Bauer, O., Schmitt, A., Atzberger, C., 2017. Windthrow Detection in European Forests with Very High-Resolution Optical Data. Forests, 8 (21), 1-26.
- Funk, C., Budde, M. E., 2009. Phenologically-tuned MODIS NDVI-based production anomaly estimates for Zimbabwe. Remote Sensing of Environment, 113,115-125.
- GCOS, 2011. Systematic observation requirements for satellite-based products for climate. 2011 update. Supplemental details to the satellite-based component of the Implementation Plan for the Global Observing System for Climate in Support of the UNFCCC, GCOS-154.
- GLP, 2005. Science plan and implementation strategy. IGBP Report No. 55. Stockholm: IGBP Secretariat.
- Goward, S. N., Masek, J. G., Cohen, W., Moisen, G., Collatz, G. J., Healey, S., Houghton,
  R., Huang, C., Kennedy, R., Law, B., Turner, D., Powell, S. Wulder, M., 2008. Forest
  disturbance and North American carbon flux. EOS Transactions, American
  Geophysical Union, 89, 105-106.

- Griffiths, P., Kuemmerle, T., Baumann, M., Radeloff, V. C., Abrudan, I. V., Lieskovsky, J.,
  Munteanu, C., Ostapowicz, K., Hostert, P., 2014. Forest disturbances, forest
  recovery, and changes in forest types across the Carpartian ecoregion from 1985 to
  2010 based on Landsat image composites. Remote Sensing of Environment, 151, 7288.
- Hamunyela, E., Verbesselt, J., Herold, M., 2016. Using spatial context to improve early detection of deforestation from Landsat time series. Remote Sensing of Environment, 172, 126-138.
- Healey, S. P., Cohen, W. B., Zhiqiang, Y., Krankina, O. N., 2005. Comparison of Tasseled Cap-based Landsat data structures for use in firest disturbance detection. Remote Sensing of Environment, 97, 301-310.
- Hilker, T., Wulder, M. A., Coops, N. C., Linke, J., McDermid, G., Masek, J. G., Gao, F.,
  White, J. C., 2009. A new data fusion model for high spatial- and temporal resolution mapping of forest disturbance based on Landsat and MODIS. Remote Sensing Environment, 113 (8), 1613-1627.
- Huang, C., Goward, S. N., Masek, J. G., Thomas, N., Zhu, Z., Vogelmann, J. E., 2010. An automated approach for reconstructing recent forest disturbance history using dense Landsat time series stacks. Remote Sensing of Environment, 114, 183-198.
- Huete, A., Justice, C., Van Leeuwen, W., 1999. MODIS vegetation index (MOD13). Algorithm theoretical basis document, 3.
- Iaquinta, J., Pinty, B., Privette, J.L., 1997. Inversion of a physically based bidirectional reflectance model of vegetation. IEEE Transactions on Geosciences and Remote Sensing, 35, 687-698.IPCC, 2000. Land use, land-use change, and forestry. IPCC special report – Summary for policymakers. Cambridge: Cambridge University Press.
- IPCC (2000). Land use, land-use change, and forestry. IPCC special report Summary for Policymakers.
- Jin, S., Sader, S. A., 2005. Comparison of time series tasselled cap wetness and the normalized difference moisture index in detecting forest disturbances. Remote Sensing of Environment, 94 (3), 364-372.
- Jönsson, P., Eklundh, I., 2002. Seasonality extraction by function fitting to time- series of satellite sensor data. IEEE Transactions on Geoscience and Remote Sensing, 40, 1824-1832.
- Kayastha, N., Thomas, V., Galbreith, J., Banskota, A., 2012. Monitoring wetland change using inter-annual Landsat time-series data. Wetlands, 32 (6), 1149-1162.

- Kirchstetter, J., 2013. Vegetationskundliche Langzeitbeobachtungen zur natürlichen Waldentwicklung nach Windwurf. 20 Jahre Forschungsfläche Edelwies im Wildnisgebiet Dürrenstein. Diplomarbeit. Institut für Botanik und Biodiversitätsforschung, Universität Wien.
- Li, M., Huang, C., Zhu, Z., Shi, H., Lu, H., Peng, S., 2009a. Assessing rates of forest change and fragmentation in Alabama, USA, using the vegetation change tracker model. Forest Ecology & Management, 257, 1480-1488.
- Li, M., Huang, C., Zhu, Z., Shi, H., Lu, H., Peng, S., 2009b. Use of remote sensing coupled with a vegetation change tracker model to assess rates of forest change and fragmentation in Mississippi, USA. International Journal of Remote Sensing, 30 (24), 6559-6574.
- Lunetta, R. S. 1999. Applications, Project Formulation and Analytical Approach. In: Lunetta,
   R. S., Elvidge, C. D., Hrsg. Remote Sensing Change Detection Environmental
   Monitoring Methods and Applications. London: Sleeping Bear Press, Inc, 1-19.
- Masry, S. E., Crawley, B. G., Holborn, W. H., 1975. Difference detection. Photographic Enineering and Remote Sensing, 41 (9), 1145-1148.
- Majasalmi, T., Rautiainen, M., Stenberg, P., 2014. Modeled and measured FPAR in a boreal forest: Validation and application of a new model. Agricultural and Forest Meteorology, 189-190, 118–124.
- Menzel, D. H., Whipple, F. L., de Vaucourleurs, G., 1970. Survey of the Universe. New Jersey: Englewood Cliffs.
- Millenium Ecosystem Assessment, M.A., 2005. Ecosystems and human well-being: Synthesis. Washington: Island Press.
- Neigh, C. S. R., Bolton, D. K., Diabate, M., Williams, J. J., Carvalhais, N., 2014. An Automated Approach to Map the History of Forest Disturbance from Insect Mortality and Harvest with Landsat Time-Series Data. Remote Sensing, 6, 2782-2808.
- Peddle, D.R., Teillet, P.M., Wulder, M.A., 2003. Radiometric image processing. In: Wulder,
   M., Franklin, S., Hrsg. Remote Sensing of Forest Environments: Concepts and Case
   Studies. Berlin:Springer, 181–208.
- Petisor, A. I., Ianos, I., Iurea, D., Vaidianu, M. N., 2012. Applications of Principal Components Analysis integrated with GIS. Procedia Environmental Sciences, 14, 247-256.
- Pickett, S. T. A., White, P. S., 1986. An introduction. The ecology of natural disturbance and patch dynamics. New York: Academic Press.

- Pohl, C., Van Genderen, J. L., 1998. Review article multisensor image fusion in remote sensing: concepts, methods and applications. International journal of remote sensing, 19(5), 823-854.
- Potter, C., Tan, P. N., Steinbach, -m., Klooster, S., Kumar, V., Myneni, R., 2003. Major disturbance events in terrestrial ecosystems detected using global satellite data sets. Global Change Biology, 9, 1005-1021.
- Price, K. P., Pyke, D. A., Mendes, L., 1992. Shrub dieback in a semiarid ecosystem: The integration of remote sensing and geographic informationsystems for detecting vegetation change. Photogrammetric Engineering & Remote Sensing, 58, 455-463.
- Roy, D. P., Borak, J. S., Devadiga, S., Wolfe, R. E., Zheng, M., Descloitres, J., 2002. The MODIS land product quality assessment approach. Remote Sensing of Environment, 83 (1-2), 62-76.
- Sellers, P.J., Berry, J.A., Collatz, G.J., Field, C.B., Hall, F.G., 1992. Canopy reflectance, photosynthesis, and transpiration, III. A reanalysis using improved leaf models and a new canopy integration scheme. Remote Sensing of Environment, 42, 187–216.
- Shepherd, J.D., Dymond, J.R., 2003. Correcting satellite imagery for the variance of reflectance and illumination with topography. International Journal of Remote Sensing, 24, 3503–3514.
- Steinberg, D.C., Goetz, S.J., Hyer, E.J., 2006. Validation of MODIS F-PAR products in boreal forests of Alaska. IEEE Transactions on Geosciences and Remote Sensing, 44, 1818-1828.
- Subbarao, R., Meer, P., 2009. Nonlinear Mean Shift over Riemannian Manifolds. International Journal of Computer Vision, 84, 1-20.
- Thayn, J. B., 2013. Using a remotely sensed optimized Disturbance Index to detect insect defoliation in the Apostle Islands, Wisconsin, USA. Remote Sensing of Environment, 136, 210-217.
- Townsend, J. R. G., 1987. Remote Sensing-Global and Local Views. In: Clark, M. J., (Hrsg.) Horizons in Physical Geography. London: Macmillan Education UK
- Turner, M. G., 2010. Disturbance and landscape dynamics in a changing world. Ecology, 91, 2833-2849.
- Vanockelen, S., Lhermitte, S., Balthazar, V., Van Rompaey, A., 2014. Performance of atmospheric and topografic correction methods on Landsat imagery in mountain areas. International Journal of Remote Sensing, 35, 4952-4972.
- Venables, W. N., Ripley, B. D., 2002. Modern applied statistics with S. 4. Auflage. New York: Springer-Verlag.

- Verbesselt, J. Hyndman, R., Newnham, G., Culvenor, D. 2010a. Detecting trend and seasonal changes in satellite image time series. Remote Sensing of Environment, 114, 106-115.
- Verbesselt, J., Hyndman, R., Zeileis, A., Culvenor, D., 2010b. Phenological change detection while accounting for abrupt and gradual trends in satellite image time series. Remote Sensing of Environment, 114, 2970-2980.
- Verbesselt, J., Zeileis, A., Herold, M., 2012. Near real-time disturbance detection using satellite image time series. Remote Sensing of Environment, 123, 98-108.
- Verbesselt, J., Zeileis, A., Hyndman, R., 2015. Package 'bfast'. Verfügbar in: https://cran.rproject.org/web/packages/bfast/bfast.pdf [Abfrage am 18.06.2017].
- Verger, A., Baret, F., Camacho, F., 2011. Optimal modalities for radiative transfer-neural network estimation of canopy biophysical characteristics: Evaluation over an agricultural area with CHRIS/PROBA observations. Remote Sensing of Environment, 115, 415-426.
- Vogelmann, J. E., 1988. Detection of Forest change in the Green Mountains of Vermont using Multispectral Scanner data. International Journal of Remote Sensing, 9, 1187-1200.
- Vogelmann, J. E., Xian, G., Homer, C., Tolk, B., 2012. Monitoring gradual ecosystem change using Landsat time series analysis: Case studies in selected forest and rangeland ecosystems. Remote Sensing of Environment, 122, 92-105.
- Vuolo, F., Ng, W., Atzberger, C., 2016. Smoothing and gap-filling of high resolution multispectral time series: Example of Landsat data. International Journal of Applied Earth Observation and Geoinformation, 57, 1-11.
- Vrieling, A., de Beurs, K. M., Brown, M. E., 2011. Variability of African farming systems from phenological analysis of NDVI time series. Climatic Change, 109 (3), 455-477.
- Wang, Y., Xie, D., Liu, S., Hu, R., Li, Y., Yan, G., 2016. Scaling of FAPAR from the Field tot he Satellite. Remote Sensing, 8 (310), 1-23.
- Weier, J., Herring, D., 2000. Measuring Vegetation. Washington: NASA. Verfügbar in: https://earthobservatory.nasa.gov/Features/MeasuringVegetation/ [Abfrage am 14.08.2017]
- Weiss, M., Baret, F., Garrigues, S., Lacaze, R., 2007. LAI and FAPAR cyclopes global products derived from vegetation. Part 2: Validation and comparison with MODIS collection 4 products. Remote Sensing of Environment, 110, 317–331.
- Wohlgemut, T., Kull, P., Wütthrich, H. 2002. Disturbance of microsites and early tree regeneration after windthrow in Swiss mountain forests due to the winter storm Vivian

1990. Forest, Snow and Landscape Research 77, 17-47.

- Wulder, M. A., Hall, R. J., Coops, N. C., Franklin, S. E., 2004. High Spatial Resolution Remotely Sensed Data for Ecosystem Characterization. Bioscience, 54 (6), 511-521.
- Yuan, H., Ma, R., Atzberger, C., Li, F., Loiselle, S. A., Luo, J., 2015. Estimating Forest fAPAR from Multispektral Landsat-8 Data Using tje Invertible Forest Reflectance Model INFORM. Remote Sensing, 7, 7425-7446.
- Zeileis, A., Leisch, F., Hornik, K., Kleiber, C., 2002. Strucchange: An R package for testing for structural change in linear regression models. Journal of Statistical Software, 7 (2), 1-38.
- Zhu, Z., Woodcock, C. E., 2012. Object-based cloud and cloud shadow detection in Landsat imagery. Remote Sensing of Environment, 118, 83-94.
- Zhu, Z., Woodcock, C. E., 2014. Continuous change detection and classification of land cover using all available Landsat data. Remote Sensing of Environment, 144, 152-171.

# 7.1 Abbildungsverzeichnis

Abbildung 1: Elektromagnetisches Strahlungsspektrum (lt. Albertz, 2007, 11)
Abbildung 2: spektrale Signaturen (lt. Albertz, 2007, 19)11
Abbildung 3: Simulierte 16-Tage-MODIS-NDVI-Zeitreihe. Die simulierte Datenreihe (erste
Grafik) ist die Summe der simulierten Saisonalitäts-, Trend- und Rauschkomponeten ()
und wird als Input in BFAST verwendet. Die geschätzten Saisonalitäts- (zweite Grafik),
Trend- und Restkomponenten (vierte Grafik) sind rot dargestellt. Es werden drei Breakpoints
innerhalb der geschätzten Trendkomponente (dritte Grafik) erkannt. (Verbesselt et al.,
2010a)20
Abbildung 4: Zerlegungsplot von täglichen CO <sub>2</sub> Daten, vertikale Einheiten in ppm (Cleveland
et al., 1990, 28)23
Abbildung 5: Untersuchungsgebiet (Open Street Map), sowie den fAPAR-Daten und den
Umgrenzungen der Testgebiete München und Landsberg (Zeitpunkt Anfang April 2015)27
Abbildung 6:Corine 2016 LandCover Map, ausschließlich Waldklassen, hinterlegt mit
National Geografic World Map28
Abbildung 7: Ausschnitt der Windwurfflächen 2015 mit hinterlegtem Orthofoto (von der
Bayerischen Vermessungsverwaltung aus 2015)29
Abbildung 8: Vorgehensweise der Datenprozessierung (Voulo et al., 2016, 3)31
Abbildung 9: Lage der Windwurfflächen südlich von München anhand des verwendeten
Testausschnitts der fAPAR-Daten von Mai 2015
Abbildung 10: Lage der Windwurfflächen südlich von München anhand des verwendeten
Testausschnitts der NDVI-Daten von Mai 2015
Abbildung 11: Beispiele für Abweichungen und Flecken in den Daten, oben links:
Reflectance-Daten Mai 2015 CIR, oben rechts: fAPAR-Daten Mai 2015, unten links: NDVI-
Daten Mai 2015
Abbildung 12: Beispiele für Abweichungen und Flecken in den Daten, oben links:
Reflectance-Daten Mai 2015 CIR, oben rechts: fAPAR-Daten Mai 2015, unten links: NDVI-
Daten Mai 2015
Abbildung 13: Wolkenmaske, Kachel 104_1936
Abbildung 14: NOBS, Kachel 104_1936
Abbildung 15: Korrelation fAPAR und NDVI für ein Pixel in einer Windwurffläche; Y-Achse:
fAPAR skaliert 1:10000, NDVI skaliert 1:1000, X-Achse: Bildanzahl der Zeitreihe als
Zeitangabe (88 Aufnahmen, 24 pro Jahr)

Abbildung 16: Korrelation fAPAR und NDVI für ein Pixel in unveränderter Waldfläche; Y-Achse: fAPAR skaliert 1:10000, NDVI skaliert 1:1000, X-Achse: Bildanzahl der Zeitreihe als Abbildung 17: Testgebiete Landsberg und München im Untersuchungsgebiet Südbayern, Abbildung 18: Flowchart der Vorgehensweise für die Ergebnisgenerierung mit BFAST aus den fAPAR Daten ......40 Abbildung 19: Flowchart der Vorgehensweise für die Ergebnisgenerierung mit BFAST und der Anwendung von Mean Shift......43 Abbildung 20: Veranschaulichung des Windwurfs Ende März 2015, anhand von fAPAR-Daten mittels Differenzenbild 1. Juni 2015 – Ende März 2015 und Diagrammen jeweils eines Pixels für 2015, WW=Windwurf, kWW=unveränderter Wald; Diagramme: Y-Achse: fAPAR skaliert 1:10000, X-Achse: Bildanzahl der Zeitreihe als Zeitangabe für ein Jahr (24 Beobachtungen)......45 Abbildung 21: Veranschaulichung des Windwurfs Ende März 2015, anhand von NDVI-Daten mittels Differenzenbild 1. Juni 2015 – Ende März 2015 und Diagrammen jeweils eines Pixels für 2015, WW=Windwurf, kWW=unveränderter Wald; Diagramme: Y-Achse: WW=Windwurf, NDVI skaliert 1:1000, X-Achse: kWW=unveränderter Wald, Bildanzahl der Zeitreihe als Zeitangabe für ein Jahr (24 Beobachtungen)......46 Abbildung 22: BFAST-Grafik fAPAR 2013-2016, h=0,38, harmonisches Saisonalitätsmodell, Erfassung des Breakpoints im Jahr 2015 ......47 Abbildung 23: Koordinative Verortung des Testausschnittes, anhand der Umrandung des Untersuchungsgebiets sowie der Kachel 104\_19, dargestellt mit der Waldmaske und den Windwurfgebieten......48 Abbildung 24: Breakpoints mit positiver Magnitude im Testausschnitt der fAPAR-Daten für 2015, harmonisches Saisonalitätsmodell, h=0,15, Berechnungszeitraum 2013-2016 mit Windwurfflächen, Waldmaske und rechts Grafik aus BFAST zur Darstellung des Abbildung 25: Breakpoints mit positiver Magnitude im Testausschnitt der fAPAR-Daten für 2015, harmonisches Saisonalitätsmodell, h=0,3, Berechnungszeitraum 2013-2016 mit Windwurfflächen, Waldmaske und rechts Grafik aus BFAST zur Darstellung des Abbildung 26: Breakpoints mit positiver Magnitude im Testausschnitt der fAPAR-Daten für 2015, harmonisches Saisonalitätsmodell, h=0,38, Berechnungszeitraum 2013-2016 mit Windwurfflächen, Waldmaske und rechts Grafik aus BFAST zur Darstellung des 

Abbildung 27: Breakpoints mit positiver Magnitude im Testausschnitt der fAPAR-Daten für 2015, harmonisches Saisonalitätsmodell, h=0,45, Berechnungszeitraum 2013-2016 mit Windwurfflächen, Waldmaske und rechts Grafik aus BFAST zur Darstellung des Abbildung 28: Unregelmäßigkeiten der Reflectance-Daten, abgebildet mit Breakpoints aus fAPAR-Daten für das Jahr 2015, h=0.38, harmonisches Saisonalitätsmodell und Windwürfe München (Berechnungszeitraum 2013-2016).....54 Abbildung 29: Testgebiete und Kacheln im Untersuchungsgebiet, fAPAR-Daten 2013-2016, Breakpoints mit positiver Magnitude für das Jahr 2015, h=0,38 und harmonisches Abbildung 30: Breakpoints mit positiver Magnitude für das Jahr 2015, Berechnungszeitraum 2013-2016, h= 0,38, harmonisches Saisonalitätsmodell; oben links: NDVI, oben rechts: TCB, unten links: Refelctance NIR, unten rechts: Reflectance Red......56 Abbildung 31: Vergleich der fAPAR Ergebnisse der Breakpoints mit harmonischem Saisaonalitätsmodell (links: 2006-2016, h=0,09; rechts: 2013-2016, h=0,38) ......57 Abbildung 32: Breakpoints mit positiver Magnitude aus der Berechnung des 40 % Quantils für das Jahr 2015, fAPAR 2013-2016, h=0,38, harmonisches Saisonalitätsmodell......58 Abbildung 33: Validierungsergebnisse im Testgebiet München 2015, fAPAR, h=0,38, harmonisches Saisonalitätsmodell, Berechnungszeitraum 2013-2016; links: erfasste Windwürfe, Mitte: erfasste unveränderte Waldflächen, rechts: Anzahl der Pixel richtig/falsch ......61 Abbildung 34: Validierungsergebnisse im Testgebiet Landsberg für das Jahr 2015, fAPAR, h=0,38, harmonsiches Saisonalitätsmodell, Berechnungszeitraum 2013-2016; links: erfasste Windwürfe, Mitte: erfasste unveränderte Waldflächen, rechts: Anzahl der Pixel richtig/falsch Abbildung 35: Validierungsergebnisse im Testgebiet München für das Jahr 2015, 40% Quantil der Segmentierung, h=0,38, harmonisches Saisonalitätsmodell, Berechnungszeitraum 2013-2016; links: erfasste Windwürfe, Mitte: erfasste unveränderte 

# 7.2 Tabellenverzeichnis

Tabelle 1: Auflistung der Kacheln im Untersuchungsgebiet, blau: Testgebiet München, grün:
Testgebiet Landsberg
Tabelle 2: Validierungstabelle zur besseren Verdeutlichung der Ergebnisdarstellung59
Tabelle 3: Validierungsergebnisse pro Kachel im Testgebiet München, fAPAR für das Jahr
2015, h=0.38, harmonisches Saisonalitätsmodell, Berechnungszeitraum 2013-2016,
Breakpoints mit positiver Magnitude60
Tabelle 4: Validierung fAPAR für das Jahr 2015 im Testgebiet München, h=0.38,
harmonisches Saisonalitätsmodell, Berechnungszeitraum 2013-2016, Breakpoints mit
positiver Magnitude61
Tabelle 5: Validierungsergebnisse pro Kachel im Testgebiet Landsberg für das Jahr 2015,
fAPAR, h= 0.38, harmonisches Saisonalitätsmodell, Berechnungszeitraum 2013-2016,
Breakpoints mit positiver Magnitude
Tabelle 6: Validierung im Testgebiet Landsberg für das Jahr 2015, fAPAR, h= 0.38,
harmonisches Saisonalitätsmodell, Berechnungszeitraum 2013-2016, Breakpoints mit
positiver Magnitude63
Tabelle 7: berechneter RMSE der Restkomponente pro Kachel und Index, basierend auf den
Ergebnissen mit h=0,38, harmonischem Saisonalitätsmodell und dem Berechnungszeitraum
2013-2016
Tabelle 8: Validierung der Mean Shift-Ergebnisse für das Jahr 2015, Kachel 104_19 fAPAR,
h=0,38, harmonisches Saisonalitätsmodell, Berechnungszeitraum 2013-201665
Tabelle 9: Validierung Mean Shift 40 % Quantil-Berechnung für das Jahr 2015, basierend auf
fAPAR der Testkachel 104_19, h=0.38, harmonisches Saisonalitätsmodell,
Berechnungszeitraum 2013-2016, Breakpoints mit positiver Magnitude

# Anhang

#### Punktdatensatz für erste Testauswertung 2006-2016

Das Jahr 2005 wurde von Anfang an aufgrund der Datenqualität ausgeschlossen. Die Zeitreihe besteht nun aus Daten von Landsat 4-8 und 256 Bildern, da im Jahr 2016 zum Zeitpunkt der Prozessierung nur Beobachtungen bis Ende August 2016 (16 Aufnahmen) verfügbar waren. Ein weiterer Parameter der neben dem Saisonalitätsmodell einzustellen ist, ist der sogenannte h-Wert, der die minimale Segmentgröße, innerhalb derer eine Veränderung in der Zeitreihe als Breakpoint erfasst werden soll, definiert. Gibt es in diesem Abschnitt mehrere Veränderungen, wird die jeweils größte als Breakpoint ausgegeben.

Berechnet wird dieser h-Wert aus der Anzahl der Beobachtungen, welche die Segmentgröße definieren, durch die Gesamtanzahl der vorhandenen Beobachtungen der gesamten Zeitreihe. In diesem Fall wurde mit 24/256~0,09 gerechnet, hier wurde die Segmentgröße also auf ein Jahr der Zeitreihe 2006-2016 begrenzt (Verbesselt et al., 2015, 4). Desweiteren gilt es noch die Anzahl der Iterationen festzulegen, wie im Kapitel 3.4 Methode bereits beschrieben wurde, erzielten Iterationen mit 1,5 und 10 hauptsächlich die gleichen Ergebnisse. Daraufhin wurde entschieden den Wert 1 beizubehalten um den Berechnungszeitraum zu verkürzen.

Für die ersten Testzwecke wurde die Kachel 104\_19 (die in weiterer Folge als Testkachel bezeichnet wird) ausgewählt, da hier der größte Teil des Testgebiets München abgedeckt wird. Die Punktgruppen wurden so angelegt, dass 105 Punkte in Windwurfbereichen und 95 in unveränderten Waldflächen gegliedert sind. In Abbildung 36 sind die 200 Samplepunkte für die Auswertung mit BFAST anhand der fAPAR-Daten erfasst und visualisiert.





Abbildung 36: Veranschaulichung der 200 Samplepunkte mit fAPAR-Daten und Windwurfflächen, hinterlegt mit den flächigen Ergebnissen der Magnitude aus dem Jahr 2015, mit dem h-Wert 0,09 und dem harmonischem Saisonalitätsmodell, Berechnungszeitraum 2006-2016; Einteilung richtig (Windwurf richtig erfasst bzw. unveränderter Wald richtig erfasst) und falsch (Windwurf falsch erfasst bzw. unveränderte Fläche falsch erfasst)

Abbildung 37 zeigt die Grafik der Zerlegung in die drei Komponenten, anhand derer BFAST Veränderungen ableitet.



Abbildung 37: BFAST Grafik von zwei richtig erfassten (Windwurf/unveränderter Wald) Pixeln der fAPAR-Daten, h=0,09, harmonisches Saisonalitätsmodell, Berechnungszeitraum 2006-2016

Bei Abbildung 37 links handelt es sich um ein richtig erfasstes Windwurfpixel der fAPAR-Daten, rechts handelt es sich um ein Pixel einer unveränderten Waldfläche. Die jeweils oberste Grafik bildet die gesamte Zeitreihe für ein bestimmtes Pixel ab. Hier ist bereits erkennbar, dass dies keine typische Signatur eines Waldpixels ist, da hier eine halbwegs regelmäßige Jahreszeitenabfolge erwartet werden würde (bzw. ein Anstieg bzw. Abfall der Kurve pro Jahr, anhand der Vegetationsabfolge und jahreszeitlichem Verlauf). Die jeweils zweite Grafik stellt die Saisonalitätskomponente dar und damit das angepasste Saisonalitätsmodell. Hier können phänologische Veränderungen detektiert werden. Die jeweils dritte Grafik verkörpert die Trendkomponente, anhand derer graduelle bzw. abrupte Veränderungen erfasst werden, welche sich mit einem Knick der Linie bemerkbar machen. In diesem Abschnitt sollen auch die Windwurfflächen auftreten. Die jeweils vierte und letzte Grafik beinhaltet die sogenannte Restbzw. Rauschkomponente. Wie Abbildung 37 zeigt, wird fast in jedem Jahr eine abrupte Trendänderung erfasst. Dies entspricht nicht der Annahme, dass Wald eine eher stabile Landbedeckungsart ist. Wie schon vorher erwähnt, dauert es bis zu 20 Jahre, bis ein Windwurf wieder unerkennbar wird (vgl. Kirchstetter, 2013, 46). Es wurden umfassende Tests mit unterschiedlichen h-Werten, sowie den drei Saisonalitätsmodellen und der Anzahl an Iterationen durchgeführt. Anhand des Punktdatensatzes wurden für die Anzahl der Iterationen pro Pixel die Werte 1, 5 und 10 getestet. Da sich jedoch die angezeigten Breakpoints mit dieser Einstellung nicht unterscheiden, wurde aufgrund der Dauer der Auswertung die Einstellung mit einer Iteration pro Pixel beibehalten. Außerdem wurde bald klar, dass das harmonische Saisonalitätsmodell und ein h mit 0,09 für diese Zeitreihe die plausibelsten Ergebnisse liefert. Dabei ist festzuhalten, dass die Ergebnisse der verschiedenen Saisonalitätsmodelle (harmonisch, dummy und die Möglichkeit kein Saisonalitätsmodell zu berechnen) in dem Testgebiet keine unterschiedlichen Ergebnisse brachten. Dies führte zu der Entscheidung, das harmonische Modell und eine Iteration für die weiteren Tests zu verwenden.

Da die Ergebnisse mit 0,09 die plausibleren Ergebnisse lieferte und erst die Auswertung einer gesamten Kachel wirklich eine Aussage erlaubt und somit auch eingehender getestet wird, werden nur diese hier veranschaulicht.

fAPAR		NDVI	
WW richtig erfasst	94	WW richtig erfasst	91
WW falsch erfasst	11	WW falsch erfasst	14
kWW richtig erfasst	12	kWW richtig erfasst	2
kWW falsch erfasst	83	kWW falsch erfasst	93

Tabelle 10: Gegenüberstellung der fAPAR/NDVI Ergebnisse anhand des Punktdatensatzes, h=0,09, harmonisches Saisonalitätsmodell für das Jahr 2015, Berechnungszeitraum 2006-2016, WW=Windwurf, kWW=kein Windwurf

Die Tabelle 10 zeigt eine Gegenüberstellung der Ergebnisse des Punktdatensatzes mit dem verwendeten h-Wert von 0,09. Die Abkürzung WW steht für Windwurf, kWW steht für kein Windwurf – bezieht sich also auf das unveränderte Waldgebiet. Wie man hier erkennen kann, liefern die fAPAR-Daten die besseren Ergebnisse im Vergleich zum NDVI, da hier mehr Pixel richtig erfasst werden, obwohl diese noch keine klare Aussage darüber erlauben, ob es sich bei einer detektierten Veränderung um einen Windwurf handelt. Dazu sei gesagt, dass hier vor allem Wert darauf gelegt wurde, eine bekannte Veränderung zu erfassen. Die Magnitude wurde hier noch nicht berücksichtigt.

Es sei festgehalten, dass sehr viele Veränderungen detektiert werden. Erstens werden zu viele Pixel im unveränderten Waldgebiet als verändert berechnet, zweitens wird auch im Zeitverlauf der 11 Jahre sehr oft eine Veränderung detektiert (wie in Abbildung 21 zu sehen ist). Beides spricht nicht für die Datenqualität und Genauigkeit der Auswertung. Da aber aus dieser geringen Anzahl an Beispielpunkten noch auf keine flächige Aussage geschlossen werden kann, wird im nächsten Schritt die ganze Waldfläche der Testkachel ausgewertet.

### Flächenhafte Auswertung der Testkachel 2006-2016

In der folgenden Abbildungen 38 werden die Ergebnisse für den Zeitraum 2006-2016, einem h-Wert von 0,09 (24/256), dem harmonischen Saisonalitätsmodell und mit der Anzahl 1 an Iterationen dargestellt. Die Darstellung (Abbildung 38) der fAPAR-Daten zeigt einen Ausschnitt der Testkachel mit den erfassten Breakpoints im Jahr 2015, welche innerhalb der Zeitreihe 2006 bis 2016 berechnet wurden und somit auf Windwürfe schließen lassen sollten.



Abbildung 38: Breakpoints mit positiver Magnitude der fAPAR-Daten für das Jahr 2015, h=0,09, harmonisches Saisonalitätsmodell, Berechnungszeitraum 2006-2016

Der h-Wert wurde umfassend getestet, dabei wurde zwischen 0,04 und 0,18 in 0,1'er Schritten jeder Wert getestet (die Segmentgröße in der somit eine Veränderung erfasst wird bewegt sich hier also zwischen fünf Monaten und zwei Jahren). Auch die Verwendung verschiedener Saisonalitätsmodelle brachte keine genaueren Ergebnisse. Aufgrund der Fülle an Daten beschränkt sich die Darstellung auch hier auf die wichtigsten Ergebnisse.

Wie in Abbildung 38 erkenntlich wird, werden hier sehr viele Veränderungen erfasst, was wenig plausibel ist. Einerseits werden die Windwurfflächen gut erfasst, obwohl die Änderung mit September bereits sehr spät und eher unerwartet auftritt. Wird das h zu klein gesetzt, werden noch viel mehr Veränderungen erfasst. Auch weil es mehr und kleinere Segmente der Zeitreihe gibt, innerhalb derer versucht wird einen passenden Breakpoint zu berechnen. Wird das h zu groß gesetzt, wird viel weniger erfasst und vor allem die Windwurfbereiche werden schlecht abgebildet, wie man an den angeführten Beispielen erkennen kann.

In Abbildung 38 werden nur jene Breakpoints abgebildet, die auch eine positive Magnitude haben. Eine positive Magnitude heißt in diesem Fall also die Abnahme der Biomasse im betreffenden Pixel, was in diesem Fall auf einen Windwurf schließen lässt. Der positive Wert ergibt sich aufgrund der Berechnung (siehe R-Script 1. BFAST im Anhang).

Es lässt dennoch keine Aussage darüber zu, ob es sich bei einer detektierten Veränderung um einen Windwurf handelt, da nach wie vor fast die gesamte Waldfläche mit einer Änderung im Jahr 2015 erfasst wird. Auch durch den Zeitpunkt der Erfassung kann in diesem Beispiel keine Differenzierung gefunden werden. Da aufgrund der visuellen Interpretation das Ergebnis nicht aussagekräftig war, wird auf eine Validierung verzichtet.

Angesichts der enormen Überschätzung der unveränderten Flächen, wäre es notwendig die Parameter anhand besserer Daten weiterzutesten. Es ging bereits laut Vuolo et al. (2016) hervor, dass abrupte Veränderungen aufgrund der Vorprozessierung schwer detektierbar sein werden, wurde dennoch getestet ob dies möglich ist.

## Validierung NDVI

Die NDVI-Daten im Testgebiet München zeigen auf den ersten Blick (Tabelle 11), dass die Indizes fAPAR (Tabelle 3) und NDVI sehr unterschiedliche Ergebnisse erzielen.

Tabelle 11: Validierungsergebnisse pro Kachel im Testgebiet München für das Jahr 2015, NDVI, h=0.38, harmonisches Saisonalitätsmodell, Berechnungszeitraum 2013-2016, Breakpoints mit positiver Magnitude

Validierung München	
104_19	
WW richtig erfasst	266
WW falsch erfasst	3 170
kWW richtig erfasst	126 102
kWW falsch erfasst	59 395
104_20	
WW richtig erfasst	249
WW falsch erfasst	901
kWW richtig erfasst	65 403
kWW falsch erfasst	13 278

Die Zahl der richtig erfassten Windwürfe teilt sich zwar pro Kachel in etwa gleich auf, jedoch sind in Kachel 104\_19 ca. 3,5-mal so viele Windwurfpixel vorhanden.

Tabelle 12: Validierung im Testgebiet München für das Jahr 2015, NDVI, h=0.38, harmonisches Saisonalitätsmodell, Berechnungszeitraum 2013-2016, Breakpoints mit positiver Magnitude

MÜNCHEN	NDVI Pixel	%		NDVI Pixel
WW richtig erfasst	515	0,19	WW gesamt	4 586
WW falsch erfasst	4 071	1,51	kWW gesamt	264 178
kWW richtig erfasst	191 505	71,25	richtig erfasste Pixel	192 020
kWW falsch erfasst	72 673	27,04	falsch erfasste Pixel	76 744

Bei Betrachtung des Testgebiets München (siehe Tabelle 12), zeigt sich, das von den 268.764 Pixeln insgesamt nur 515 (von 4.589) richtig als Windwurf erkannt werden.

Die Gesamtgenauigkeit der NDVI Ergebnisse kommt nicht an die fAPAR Ergebnisse heran. Die Windwürfe werden nur zu 0,2% richtig erkannt und 1,5% falsch. Auch bei den unveränderten Waldflächen geht die Genauigkeit im Vergleich zu fAPAR (79,2% richtig) zurück, sie liegt nun bei 71,3% richtig erfasst und 27% falsch berechnet. Werden ausschließlich die Windwurfflächen betrachtet (Abbildung 39, links), werden diese mit 11% richtig (im Gegensatz zu fAPAR mit 35%) berechnet. 89% davon werden entweder zu früh oder gar nicht als Veränderung erfasst.



Abbildung 39: Validierungsergebnisse im Testgebiet München für das Jahr 2015, NDVI, h=0,38, harmonisches Saisonalitätsmodell, Berechnungszeitraum 2013-2016; links: erfasste Windwürfe, Mitte: erfasste unveränderte Waldflächen, rechts: Anzahl der Pixel richtig/falsch

Wie in Abbildung 39, Mitte, ersichtlich ist, sinkt auch bei unverändertem Wald die Genauigkeit der NDVI-Daten im Vergleich zu fAPAR auf 72% (fAPAR 80%). Dies unterstreicht die vorher getätigte Aussage, die fAPAR-Daten seien besser geeignet. Mit den folgenden Ergebnissen wird die Tatsache weiter untermauert.

Die Gegenüberstellung der richtig bzw. falsch erfassten Pixel in Abbildung 39, rechts, teilt sich logischerweise ähnlich auf wie die unveränderten Waldflächen und liegt bei 71 % richtig bzw. 29% falsch erfassten Pixeln.

Tabelle 13: Validierungsergebnisse pro Kachel im Testgebiet Landsberg für das Jahr 2015, NDVI, h=0.38, harmonisches Saisonalitätsmodell, Berechnungszeitraum 2013-2016, Breakpoints mit positiver Magnitude

Validierung Landsberg	
104_18	
WW richtig erfasst	0
WW falsch erfasst	221
kWW richtig erfasst	37 767
kWW falsch erfasst	47 831
105_18	
WW richtig erfasst	9
WW falsch erfasst	2 756
kWW richtig erfasst	136 228
kWW falsch erfasst	108 813

Da schon die fAPAR Ergebnisse im Testgebiet Landsberg schlechter waren als jene des Testgebiets München, ist es nicht überraschend, dass die NDVI Ergebnisse auch hier in Tabelle 13 schlechtere Werte ergeben. Desweiteren wurde in Kachel 104\_18 kein Windwurfpixel richtig erfasst und in Kachel 105\_18 nur 9 Pixel richtig erfasst (im Gegensatz zu fAPAR, 38 Pixel).

Tabelle 14: Validierung im Testgebiet Landsberg für das Jahr 2015, NDVI, h=0.38, harmonisches Saisonalitätsmodell, Berechnungszeitraum 2013-2016, Breakpoints mit positiver Magnitude

LANDSBERG	NDVI Pixel	%		NDVI Pixel
WW richtig erfasst	9	0,01	WW gesamt	2 986
WW falsch erfasst	2977	0,89	kWW gesamt	330 639
kWW richtig erfasst	173995	52,15	richtig erfasste Pixel	174 004
kWW falsch erfasst	156644	46,95	falsch erfasste Pixel	159 621

Da die richtig erfassten Pixel im Gegensatz zu den falsch erfassten so wenige sind, ist auch der Prozentsatz aller richtigen Windwurf Pixel mit 0,01% (Tabelle 14) nicht verwunderlich. Es fällt sofort auf, dass hier auch in den unveränderten Flächen viel weniger richtig detektiert wurde.

Auch wenn man die Windwurfpixel isoliert betrachtet, wie in Abbildung 40, links, werden somit nur zu 0,3% richtig erfasst. Dies führt dazu, dass diesem Ergebnis keinerlei Aussagekraft zukommt.



Abbildung 40: Validierungsergebnisse im Testgebiet Landsberg für das Jahr 2015, NDVI, h=0,38, harmonisches Saisonalitätsmodell, Berechnungszeitraum 2013-2016; links: erfasste Windwürfe, Mitte: erfasste unveränderte Waldflächen, rechts: Anzahl der Pixel richtig/falsch

Was in Abbildung 40, Mitte auffällt wurde auch vorher schon kurz thematisiert. Es werden auch die unveränderten Waldflächen viel ungenauer erfasst. Nur 53% (zu 82% der fAPAR-Daten) werden hier richtig detektiert, was Beträchtliche 47% falsch erfasste Waldpixel bedeutet.

Insgesamt werden, wie in Abbildung 40, rechts, dargestellt, demnach auch nur 52% aller Pixel richtig bzw. 48% falsch erfasst. Das bedeutet, dass jedes zweite Pixel falsch bzw. richtig erfasst wird um demnach kein aussagekräftiges Ergebnis vorliegt.

### Ergebnisse der doppelten Zeitreihe

Eine weitere Analyse ist die Verwendung der doppelten fAPAR Zeitreihe. Hier wird getestet ob es zu aussagekräftigeren Ergebnissen führt, wenn die Segmentgröße der Detektion (der vorher beschriebene h-Wert) vergrößert wird. Da dieser auf 0,5, also die Hälfte der jeweiligen Zeitreihe limitiert ist

Dies wird versucht, indem die Zeitreihe zweimal hintereinandergelegt wird und somit verlängert wird. Auch hier wurden unterschiedliche Werte getestet, die folgenden Abbildungen sollen einen Überblick über die Ergebnisse schaffen. Die neu entstandene Zeitreihe beinhaltet hier 160 Beobachtungen, da das Jahr 2016 nur einmal vorkommt. Diese Entscheidung wurde getroffen, da es wegen den fehlenden Beobachtungen (September bis Dezember 2016) Schwierigkeiten bei der Aufteilung in die richtigen Jahre gab.



Abbildung 41: Breakpoints mit positiver Magnitude im Testausschnitt der fAPAR-Daten für 2015, harmonisches Saisonalitätsmodell, h=0,1, Berechnungszeitraum 2013-2016 doppelt, mit Windwurfflächen, Waldmaske und rechts Grafik aus BFAST zur Darstellung des gekennzeichneten Pixels

Wie in Abbildung 41 dargestellt, erzeugt die doppelte Zeitreihe mit einem h-Wert von 0,1 (16 Beobachtungen, also knapp über einem halben Jahr) vor allem Veränderungen im August und

September, außerhalb der Windwurfbereiche. In der Grafik recht fällt auf, dass hier in jedem Jahr Veränderungen der Trendkomponenete auftreten, das Saisonalitätsmodell zeigt auch hier keine Veränderungen.



Abbildung 42: Breakpoints mit positiver Magnitude im Testausschnitt der fAPAR-Daten für 2015, harmonisches Saisonalitätsmodell, h=0,15, Berechnungszeitraum 2013-2016 doppelt, mit Windwurfflächen, Waldmaske und rechts Grafik aus BFAST zur Darstellung des gekennzeichneten Pixels

Auch hier wird der h-Wert 0,15 (entspricht 24 Beobachtungen, also genau ein Jahr) getestet. In Abbildung 37 ist zu erkennen, dass hier wieder weniger Veränderungen erfasst werden. Es treten jedoch nur sehr vereinzelt Breakpoints mit positiver Magnitude in Windwurfbereichen auf. Außerdem wird die Veränderung erst im November bzw. Dezember erfasst, was mit dem Windwurfereignis gar nicht zusammenpasst. Das Beispielpixel wird ebenfalls mit diesem Zeitpunkt erfasst. Es fällt zudem auf, dass auch hier in allen Jahren Veränderungen erfasst werden.



Abbildung 43: Breakpoints mit positiver Magnitude im Testausschnitt der fAPAR-Daten für 2015, harmonisches Saisonalitätsmodell, h=0,2, Berechnungszeitraum 2013-2016 doppelt, mit Windwurfflächen, Waldmaske und rechts Grafik aus BFAST zur Darstellung des gekennzeichneten Pixels

Im Vergleich zu Abbildung 42, treten in Abbildung 43 die Veränderungen zwar zum gleichen Zeitpunkt auf, werden aber viel großflächiger erfasst, sodass fast die gesamte unveränderte Fläche als Veränderung errechnet wird. Und gerade die Windwurfbereiche wieder nur vereinzelt richtig detektiert werden. Hier wurde der h-Wert 0,2 verwendet, was 32 Beobachtungen und damit knapp 1,5 Jahre als minimale Segmentgröße definiert.



Abbildung 44: Breakpoints mit positiver Magnitude im Testausschnitt der fAPAR-Daten für 2015, harmonisches Saisonalitätsmodell, h=0,3, Berechnungszeitraum 2013-2016 doppelt, mit Windwurfflächen, Waldmaske und rechts Grafik aus BFAST zur Darstellung des gekennzeichneten Pixels

Der h-Wert 0,3, welcher in Abbildung 44 dargestellt ist, begrenzt die minimale Segmentgröße mit 48 Beobachtungen, also genau 2 Jahre. Hier fällt auf, dass nur sehr wenige Breakpoints mit positiver Magnitude erfasst wurden und diese schon im Jänner auftreten. Außerdem treten die wenigen Veränderungen fast ausschließlich in der unveränderten Fläche auf. Dies die Annahme, dass diese wenig zufriedenstellenden Ergebnisse auf die Datenqualität und die Methode der Prozessierung zurückzuführen sind. Da es sonst möglich sein sollte, mindestens die größeren Windwürfe teilweise zu erfassen und die Anzahl der falsch detektieren Veränderungen im unveränderten Gebiet zu dezimieren.

Da mit höheren h-Werten nur noch sehr vereinzelte bzw. keine Breakpoints mit positiver mehr detektiert werden konnten, wird deshalb auf die Visualisierung verzichtet. Aufgrund dieser Ergebnisse wird außerdem auf eine Validierung dieser Vorgehensweise verzichtet, da schon bei der visuellen Prüfung klar wird, dass diese Resultate keine Aussagekraft besitzen.

### Abbildungsverzeichnis für den Anhang

Abbildung 36: Veranschaulichung der 200 Samplepunkte mit fAPAR-Daten und Windwurfflächen, hinterlegt mit den flächigen Ergebnissen der Magnitude aus dem Jahr 2015, mit dem h-Wert 0,09 und dem harmonischem Saisonalitätsmodell, Berechnungszeitraum 2006-2016; Einteilung richtig (Windwurf richtig erfasst bzw. unveränderter Wald richtig erfasst) und falsch (Windwurf falsch erfasst bzw. unveränderte Fläche falsch erfasst) ......85 Abbildung 37: BFAST Grafik von zwei richtig erfassten (Windwurf/unveränderter Wald) Pixeln der fAPAR-Daten, h=0,09, harmonisches Saisonalitätsmodell, Berechnungszeitraum Abbildung 38: Breakpoints mit positiver Magnitude der fAPAR-Daten für das Jahr 2015, h=0,09, harmonisches Saisonalitätsmodell, Berechnungszeitraum 2006-2016......88 Abbildung 39: Validierungsergebnisse im Testgebiet München für das Jahr 2015, NDVI, h=0,38, harmonisches Saisonalitätsmodell, Berechnungszeitraum 2013-2016; links: erfasste Windwürfe, Mitte: erfasste unveränderte Waldflächen, rechts: Anzahl der Pixel richtig/falsch Abbildung 40: Validierungsergebnisse im Testgebiet Landsberg für das Jahr 2015, NDVI, h=0,38, harmonisches Saisonalitätsmodell, Berechnungszeitraum 2013-2016; links: erfasste Windwürfe, Mitte: erfasste unveränderte Waldflächen, rechts: Anzahl der Pixel richtig/falsch Abbildung 41: Breakpoints mit positiver Magnitude im Testausschnitt der fAPAR-Daten für 2015, harmonisches Saisonalitätsmodell, h=0,1, Berechnungszeitraum 2013-2016 doppelt, mit Windwurfflächen, Waldmaske und rechts Grafik aus BFAST zur Darstellung des Abbildung 42: Breakpoints mit positiver Magnitude im Testausschnitt der fAPAR-Daten für 2015, harmonisches Saisonalitätsmodell, h=0,15, Berechnungszeitraum 2013-2016 doppelt, mit Windwurfflächen, Waldmaske und rechts Grafik aus BFAST zur Darstellung des Abbildung 43: Breakpoints mit positiver Magnitude im Testausschnitt der fAPAR-Daten für 2015, harmonisches Saisonalitätsmodell, h=0,2, Berechnungszeitraum 2013-2016 doppelt, mit Windwurfflächen, Waldmaske und rechts Grafik aus BFAST zur Darstellung des Abbildung 44: Breakpoints mit positiver Magnitude im Testausschnitt der fAPAR-Daten für 2015, harmonisches Saisonalitätsmodell, h=0,3, Berechnungszeitraum 2013-2016 doppelt, mit Windwurfflächen, Waldmaske und rechts Grafik aus BFAST zur Darstellung des 

### Tabellenverzeichnis für den Anhang

Tabelle 10: Gegenüberstellung der fAPAR/NDVI Ergebnisse anhand des Punktdatensatzes	,
h=0,09, harmonisches Saisonalitätsmodell für das Jahr 2015, Berechnungszeitraum 2006-	
2016, WW=Windwurf, kWW=kein Windwurf8	37
Tabelle 11: Validierungsergebnisse pro Kachel im Testgebiet München für das Jahr 2015,	
NDVI, h=0.38, harmonisches Saisonalitätsmodell, Berechnungszeitraum 2013-2016,	
Breakpoints mit positiver Magnitude	)0
Tabelle 12: Validierung im Testgebiet München für das Jahr 2015, NDVI, h=0.38,	
harmonisches Saisonalitätsmodell, Berechnungszeitraum 2013-2016, Breakpoints mit	
positiver Magnitude9	)0
Tabelle 13: Validierungsergebnisse pro Kachel im Testgebiet Landsberg für das Jahr 2015,	
NDVI, h=0.38, harmonisches Saisonalitätsmodell, Berechnungszeitraum 2013-2016,	
Breakpoints mit positiver Magnitude	)2
Tabelle 14: Validierung im Testgebiet Landsberg für das Jahr 2015, NDVI, h=0.38,	
harmonisches Saisonalitätsmodell, Berechnungszeitraum 2013-2016, Breakpoints mit	
positiver Magnitude	)2

#### 1. BFAST R-Script

library("bfast") library("forecast") library("raster") library("rgdal")

#### 

hVal <- 0.38

# Bezug zur Rasterdatei der Waldmaske maskFile <- "~/DATA/SusanneMaster/Wald\_104\_19.tif" mask <- raster(maskFile) NAvalue(mask)<-0 maskVEC<-values(mask)</pre>

# erstelle ts-Objekt setwd("~/DATA/SusanneMaster/bi-monthly-fAPAR/32\_104\_19/") files <- list.files(path="~/DATA/SusanneMaster/bi-monthly-fAPAR/32\_104\_19/", pattern="\*.tif\$", full.names=TRUE) #files <- files[grep("2013011",files):grep("2016082",files)]</pre>

#install rgdal
ras <- stack(files, quick=TRUE)
mat <- values(ras) # dauert!!</pre>

```
setwd("~/DATA/SusanneMaster/results")
```

```
nyears <- 4 #Anzahl der Jahre
peryear <- 24 # Anzahl der Bilder pro Jahr
```

```
Breakpoints<- matrix(NA,nrow=length(maskVEC),ncol=nyears)
lowerCl <- matrix(NA,nrow=length(maskVEC),ncol=nyears)
upperCl <- matrix(NA,nrow=length(maskVEC),ncol=nyears)
magnitude <- matrix(NA,nrow=length(maskVEC),ncol=nyears)
```

```
idx <- which(!is.na(maskVEC))</pre>
```

```
for(i in ( 1:length(idx))){#i<-1
cat(i,"/",length(idx),"\n")
fAPAR <- ts(mat[idx[i],],start=c(2013,1), frequency=24) #erstellt ts und extrahiert NDVI-
Werte an geforderten Positionen der Samples
```

```
if (sum(fAPAR) > 0) {
    fit2 <- bfast(fAPAR, h=hVal, season="harmonic",max.iter=1)
    if (!is.na(fit2$output[[1]]$ci.Vt)) {
        npoints <- dim(fit2$output[[1]]$ci.Vt$confint)[1] # Anzahl der Breakpoints = Anzahl der</pre>
```

rows

```
# upperCl
temp <- fit2$output[[1]]$ci.Vt$confint[,3]
yearIdx <- ceiling(temp/peryear)
yearVal <- temp-(floor(temp/peryear)*peryear)
yearVal[yearVal==0] <- peryear
upperCl[idx[i],yearIdx] <- yearVal</pre>
```

```
# Breakpoints
temp <- fit2$output[[1]]$ci.Vt$confint[,2]
yearIdx <- ceiling(temp/peryear)
yearVal <- temp-(floor(temp/peryear)*peryear)
yearVal[yearVal==0] <- peryear
Breakpoints[idx[i],yearIdx] <- yearVal
# magnitude of change in trend
magnVal <- fit2$output[[1]]$Tt[fit2$output[[1]]$ci.Vt$confint[,2]]-
fit2$output[[1]]$Tt[fit2$output[[1]]$ci.Vt$confint[,2]+1]
magnitude[idx[i],yearIdx] <- magnVal</pre>
```

```
# lowerCl
temp <- fit2$output[[1]]$ci.Vt$confint[,1]
yearIdx <- ceiling(temp/peryear)
yearVal <- temp-(floor(temp/peryear)*peryear)
yearVal[yearVal==0] <- peryear
lowerCl[idx[i],yearIdx] <- yearVal
}
</pre>
```

```
BreakpointsRAS <- stack(ras[[1:nyears]])
BreakpointsRAS <- setValues(BreakpointsRAS, Breakpoints)
```

writeRaster(BreakpointsRAS, filename=paste0("Breakpoints\_fAPAR\_32\_104\_19\_20132016\_h038.tif"), datatype='INT1U', overwrite=TRUE, format='GTiff', options="COMPRESS=LZW",NAflag=0)

upperCIRAS <- stack(ras[[1:nyears]]) upperCIRAS <- setValues(upperCIRAS, upperCI) writeRaster(upperCIRAS, filename=paste0("upperCI\_fAPAR\_32\_104\_19\_20132016\_h038.tif"), datatype='INT1U', overwrite=TRUE, format='GTiff', options="COMPRESS=LZW",NAflag=0)

```
lowerCIRAS <- stack(ras[[1:nyears]])
lowerCIRAS <- setValues(lowerCIRAS, lowerCI)
writeRaster(lowerCIRAS,
filename=paste0("lowerCI_fAPAR_32_104_19_20132016_h038.tif"),
datatype='INT1U', overwrite=TRUE,
format='GTiff', options="COMPRESS=LZW",NAflag=0)
```

### 2. Rasterize R-Script

library(raster)

```
# vorhandenes Rasterbild, das als Template verwendet wird
in_file <-
'C:/Users/Susanne/Documents/Studium/FenE/5.Semester/Masterarbeit/Datengrundlage/bi-
monthly fAPAR/32_104_19/2013011_fAPAR_tile_32_104_19.tif'
# Ausgabedatei
out_file <- 'C:/Users/Susanne/Documents/Studium/FenE/5.
Semester/Masterarbeit/Ergebnisse/ab0505/PCA_meanshift/BFAST/band1/rasterize_zonen_
ms_band1_wald2305.tif'
```

library(rgdal) # Loads SP package by default

```
#shape file mit Polygonen: Pfad und Shapefilename ohne Endung
shp <- readOGR('C:/Users/Susanne/Documents/Studium/FenE/5.
Semester/Masterarbeit/Ergebnisse/ab0505/PCA_meanshift/BFAST/band1',
'ms_band1_wald')
```

r <- raster(in\_file) # 'Zonen' ist hier Spaltenname in der Attributtabelle, deren Werte in das Raster geschrieben werden sollen rp <- rasterize(shp, r, 'Zonen') writeRaster(rp,filename=out\_file, datatype='INT2U', overwrite=TRUE, format='GTiff', options="COMPRESS=LZW")

#### 3. Extract zones R-Script

```
require(raster)
require(rgdal) # Loads SP package by default
```

inpath <paste0('C:/Users/Susanne/Documents/Studium/FenE/5.Semester/Masterarbeit/Datengrundla ge/bi-monthly fAPAR/32\_104\_19') outpath <- paste0('C:/Users/Susanne/Documents/Studium/FenE/5. Semester/Masterarbeit/Ergebnisse/ab0505/PCA\_meanshift/BFAST/band1/')

# zonen tiff vorher erzeugen mit rasterize script # 0=no zone, 1=zone1, 2=zone2, .... fzone <- paste0('C:/Users/Susanne/Documents/Studium/FenE/5. Semester/Masterarbeit/Ergebnisse/ab0505/PCA\_meanshift/BFAST/band1/rasterize\_zonen\_ meanshift\_waldmaske.tif')

```
#define scaling parameters:
val_nodata <- -3000
```

```
zone_ras <- raster(fzone)
NAvalue(zone_ras) <- 0
zone_arr <- getValues(zone_ras)
zoneID <- unique(zone_ras)
zone_ind <- list()
for (i in zoneID){
    temp <- which(zone_arr==i)
    zone_ind <- c(zone_ind,list(temp))
}
files <- list.files(inpath, pattern="*.tif$",full.names=TRUE)
    outputMean <- matrix(NA, nrow=length(files),ncol=length(zoneID))
    outputP90 <-outputP80 <- outputP70 <- outputP60 <- outputP40 <- outputP30 <- outputP20
    <- outputP10 <- outputP5 <- outputMedian <- outputMean</pre>
```

```
for(y in seq_along(files)) #
{ #y<-1
    cat("file: ",y,"/",length(y),"/n")</pre>
```

```
# read file
r <- raster(files[y])
NAvalue(r) <- val_nodata
val <- getValues(r)</pre>
```

```
for (z in seq_along(zoneID)){
zoneVal <- val[zone_ind[[z]]]
outputMean[y,z] <- mean(zoneVal,na.rm=TRUE)
outputMedian[y,z] <- median(zoneVal,na.rm=TRUE)
outputP5[y,z] <- quantile(zoneVal,na.rm=TRUE,probs=0.05)
outputP10[y,z] <- quantile(zoneVal,na.rm=TRUE,probs=0.10)
outputP20[y,z] <- quantile(zoneVal,na.rm=TRUE,probs=0.20)
outputP30[y,z] <- quantile(zoneVal,na.rm=TRUE,probs=0.30)
outputP40[y,z] <- quantile(zoneVal,na.rm=TRUE,probs=0.40)
```

```
outputP60[y,z] <- quantile(zoneVal,na.rm=TRUE,probs=0.60)
outputP70[y,z] <- quantile(zoneVal,na.rm=TRUE,probs=0.70)
outputP80[y,z] <- quantile(zoneVal,na.rm=TRUE,probs=0.80)
outputP90[y,z] <- quantile(zoneVal,na.rm=TRUE,probs=0.90)
}
```

```
}
```

write.csv2(t(outputMean), file = paste0(outpath,"meanshift wald 104 19 MEAN.csv"),row.names=FALSE,guote=FALSE) write.csv2(t(outputMedian), file = paste0(outpath,"meanshift wald 104 19 MEDIAN.csv"),row.names=FALSE,quote=FALSE) write.csv2(t(outputP5), file = paste0(outpath,"meanshift\_wald\_104\_19\_P05.csv"),row.names=FALSE,quote=FALSE) write.csv2(t(outputP10), file = paste0(outpath,"meanshift wald 104 19 P10.csv"),row.names=FALSE,guote=FALSE) write.csv2(t(outputP20), file = paste0(outpath,"meanshift wald 104 19 P20.csv"),row.names=FALSE, guote=FALSE) write.csv2(t(outputP30), file = paste0(outpath,"meanshift wald 104 19 P30.csv"),row.names=FALSE, guote=FALSE) write.csv2(t(outputP40), file = paste0(outpath,"meanshift\_wald\_104\_19\_P40.csv"),row.names=FALSE,quote=FALSE) write.csv2(t(outputP60), file = paste0(outpath,"meanshift wald 104 19 P60.csv"),row.names=FALSE,guote=FALSE) write.csv2(t(outputP70), file = paste0(outpath,"meanshift wald 104 19 P70.csv"),row.names=FALSE, guote=FALSE) write.csv2(t(outputP80), file = paste0(outpath,"meanshift wald 104 19 P80.csv"),row.names=FALSE,quote=FALSE) write.csv2(t(outputP90), file = paste0(outpath,"meanshift wald 104 19 P90.csv"),row.names=FALSE,guote=FALSE)

#### 4. PCA R-Script

setwd("C:/Users/Susanne/Documents/Studium/FenE/5.Semester/Masterarbeit/Ergebnisse/a b0505/PCA\_meanshift") files <- list.files(path="C:/Users/Susanne/Documents/Studium/FenE/5. Semester/Masterarbeit/Ergebnisse/ab0505/Daten\_fAPAR", pattern="\*.tif\$", full.names=TRUE) ras <- stack(files, quick=TRUE)

fasterPCA <- function(ras, spca = TRUE, maskCheck = TRUE){
 require(raster)
 require(matrixStats)</pre>

val <- getValues(ras)</pre>

# Now val contains a matrix of the pixel values, where each row is a pixel and # each column represents a layer.

# This part does the same as the 'maskCheck' in rasterPCA, but uses the matrix # of pixel values instead of the image:

# rowAnyMissings() checks, if a row contains a NA in any column, so the inverse

# 1.) (!rowAnyMissing()) is the 'complete observations'. # 2.) val[!validPix, ] <- NA is the same as masking the image, i.e. setting all layers of a pixel to NA, if a single layer contains an NA for that # # pixel. if (isTRUE(maskCheck)){ validPix <- !rowAnyMissings(val)</pre> if(!any(validPix)) stop("img contains either a layer with NAs only or no single pixel with valid values across all layers") val[!validPix, ] <- NA } # Instead of using (slow) layerStats() on the img, we use cov() directly on # the values: covMat <- list(covariance = cov(x = val, use="complete.obs"),mean = colMeans(val, na.rm = TRUE)) # (NOTE: layerStats returns covMat as list containing the 'covariance' matrix and the 'mean' pixel values of the layers. cov() only returns the # # covariance matrix, so the list has to be created 'by hand'.) # This part is (nearly) the same as in RStoolbox::rasterPCA() model <- princomp(covmat = covMat\$covariance, cor = spca) #model <- princomp(covmat = covMat\$covariance) model\$center <- covMat\$mean ### In rasterPCA the total number of pixel is used as n.obs. ### model\$n.obs <- ncell(img)</pre> ### but maybe it's better to use the number of 'non-NA' pixel instead: model\$n.obs <- sum(!rowAnyMissings(val))</pre> if (spca) { S <- diag(covMat\$covariance) model\$scale <- sqrt(S \* (model\$n.obs - 1)/model\$n.obs) } # The PCA model is applied to the values: pca0 <- predict(model, val)</pre> # and the result is put back in the image: ras[] <- pca0 return(ras) }

#### 5. Validierung R-Script

```
library(raster)
setwd("C:/Users/Susanne/Documents/Studium/FenE/5.Semester/Masterarbeit/Endergebniss
e/fAPAR")
```

bp<-stack("Breakpoints\_fAPAR\_32\_104\_19\_20132016\_h038.tif", bands=3) mag<-stack("magnitude\_fAPAR\_32\_104\_19\_20132016\_h038.tif", bands=3) valid<-raster("Validierung\_Muenchen\_104\_19.tif")

bpm <- crop(bp,valid) magm <- crop(mag,valid) bpVal <- values(bpm) magVal <- values(magm) validVal <- values(valid)

#alle waldpixel unverändert unv <- sum(validVal==2 & !is.na(validVal)) #alle Windwurfpixel wwf <- sum(validVal==1 &!is.na(validVal)) #alle Validierungspixel total <- sum(!is.na(validVal))</pre>

windwurf\_richtig <- sum(bpVal==7 & magVal>0 & !is.na(bpVal) & !is.na(magVal) & validVal==1 & !is.na(validVal))

windwurf\_falsch1 <- sum(is.na(bpVal) & validVal==1 & !is.na(validVal))

windwurf\_falsch2 <- sum(bpVal==7 & magVal<=0 & !is.na(bpVal) & !is.na(magVal) & validVal==1 & !is.na(validVal))

windwurf\_falsch3 <- sum(bpVal!=7 & !is.na(bpVal) & validVal==1 & !is.na(validVal))

windwurf\_falsch <- windwurf\_falsch1+windwurf\_falsch2+windwurf\_falsch3

kwindwurf\_richtig <- sum(is.na(bpVal) & validVal==2 & !is.na(validVal))

kwindwurf\_falsch <- sum(bpVal & !is.na(bpVal) & validVal==2 & !is.na(validVal))

windwurf\_richtig windwurf\_falsch kwindwurf\_richtig kwindwurf\_falsch

#### 6. RMSE R-Script

library(raster) setwd("C:/Users/Susanne/Documents/Studium/FenE/5.Semester/Masterarbeit/Endergebniss e/fAPAR") bp<-stack("Breakpoints\_fAPAR\_32\_104\_19\_20132016\_h038.tif", bands=3) mag<-stack("magnitude\_fAPAR\_32\_104\_19\_20132016\_h038.tif", bands=3) rms<-stack("rms\_fAPAR\_32\_104\_19\_20132016\_h038.tif", bands=3) valid<-raster("Validierung\_Muenchen\_104\_19.tif")

```
bpm <- crop(bp,valid)</pre>
magm <- crop(mag,valid)</pre>
bpVal <- values(bpm)
magVal <- values(magm)
validVal <- values(valid)</pre>
rmsm <- crop(rms,valid)
rmsVal <- values(rmsm)
meanrmswwfR <- mean(rmsVal[bpVal==7 & magVal>0 &
                 !is.na(bpVal) & !is.na(magVal) &
                 validVal==1 & !is.na(validVal)],na.rm=TRUE)
meanrmswwfF1 <- mean(rmsVal[is.na(bpVal) & validVal==1 & !is.na(validVal)],
na.rm=TRUE)
meanrmswwfF2 <- mean(rmsVal[bpVal!=7 & !is.na(bpVal) &
                 validVal==1 & !is.na(validVal)], na.rm=TRUE)
meanrmswwfF3 <- mean(rmsVal[bpVal==7 & !is.na(bpVal) & validVal==1 &
                 !is.na(validVal)], na.rm=TRUE) - mean(rmsVal[bpVal==7 & magVal>0
                                            & !is.na(bpVal) & !is.na(magVal) &
                                            validVal==1 & !is.na(validVal)], na.rm=TRUE)
meanrmswwfF <- (meanrmswwfF1+meanrmswwfF2+meanrmswwfF3)/3
meanrmsKwwfR <- mean(rmsVal[is.na(bpVal) & validVal==2 & !is.na(validVal)],
na.rm=TRUE)
meanrmsKwwfF <- mean(rmsVal[bpVal & !is.na(bpVal) &
                 validVal==2 & !is.na(validVal)], na.rm=TRUE)
meanrmswwfR
meanrmswwfF
meanrmsKwwfR
meanrmsKwwfF
```