

# Methodische Untersuchungen zum Einsatz von Copernicus-Daten für das Monitoring im Rahmen der EU-Agrarförderung

**JULIAN HELGE BRAATZ-NEBEL<sup>1</sup>, HEIKE GERIGHAUSEN<sup>1</sup> & HOLGER LILIENTHAL<sup>1</sup>**

*Zusammenfassung: Die Europäische Kommission hat 2018 den Einsatz von Daten der Copernicus-Sentinel-Satelliten im integrierten Verwaltungs- und Kontrollsystem der Gemeinsamen Agrarpolitik beschlossen. Vor diesem Hintergrund wurde in der vorliegenden Arbeit exemplarisch für drei Untersuchungsgebiete in Niedersachsen das Potenzial von Sentinel-1 und Sentinel-2 Daten zur satellitengestützten Kontrolle der gemeldeten Kulturarten untersucht. Im Vergleich zwei verschiedener Ansätze zeigte sich das Random Forest Verfahren der Maximum-Likelihood-Methode leicht überlegen. Dabei erzielte die kombinierte Nutzung von Sentinel-1 und -2 Daten die besten Ergebnisse. Die Kombination beider Daten wirkte sich deutlich positiv auf die Klassifikationsgüte sehr kleiner Flächen (<8 ha) aus.*

## 1 Einleitung

Die Gemeinsame Agrarpolitik (GAP) ist eine der ältesten und finanziell bedeutendsten Aufgabengebiete europäischer Politik, die seit ihrer Verankerung in den Römischen Verträgen von 1957 vielfach reformiert wurde. Ein wichtiger Baustein zu Verwaltung und Kontrolle der gezahlten EU-Beihilfen ist das integrierte Verwaltungs- und Kontrollsystem (InVeKoS) (VO (EU) 1306/2013). Neue bildgebende Technologien sollen nun zur Verringerung der zeit- und kostenintensiven Vor-Ort-Kontrollen (VOK) beitragen und ein flächendeckendes Monitoring aller landwirtschaftlichen Flächen in den Mitgliedstaaten ermöglichen (DVO (EU) 809/2014). Mit den Sentinel-1 (S-1) und Sentinel-2 (S-2) Satelliten des europäischen Erdbeobachtungsprogramms Copernicus stehen für Deutschland alle 1-2 (S-1) bzw. 2-5 (S-2) Tage räumlich hochaufgelöste Bilddaten zweier unterschiedlicher Satellitensysteme frei zur Verfügung (VO (EU) 1159/2013). Sie sollen beispielsweise der Überprüfung der gemeldeten Kulturarten, der Kontrolle der landwirtschaftlichen Tätigkeit oder der Prüfung gezahlter Greeningprämien dienen.

Zahlreiche Autoren haben sich mit der Erkennung von Fruchtarten aus Satellitendaten unter Nutzung verschiedener methodischer Ansätze beschäftigt. Hierzu zählen herkömmliche statistische Schätzverfahren wie die Maximum-Likelihood-Methode (z.B. CHUST et al. 2004; OK et al. 2012), Verfahren des maschinellen Lernens, wie Support Vector Machine, Random Forest, (z.B. DURO et al. 2012; OK et al. 2012; FORKUOR et al. 2014), Entscheidungsbäume (z.B. LÖW et al. 2015) oder künstliche neuronale Netze (z.B. MCNAIRN et al. 2009; KENDUIYWO et al. 2018). Einige Autoren nutzen hierarchische Klassifikationsansätze (z.B. VILLA et al. 2015) oder integrieren zusätzliches Expertenwissen (z.B. WALDHOFF et al. 2017).

Ziel der vorliegenden Studie war es, Aufschluss über den Einfluss der Datenzusammenstellung, der Schlaggröße und –form sowie der Anwendung eines räumlichen Puffers auf die Genauigkeit

---

<sup>1</sup> Julius Kühn-Institut, Institut für Pflanzenbau und Bodenkunde, Bundesallee 69, 38116 Braunschweig, E-Mail: [Heike.Gerighausen, Holger.Lilienthal]@julius-kuehn.de

einer Fruchtartenerkennung zu erhalten. Zu diesem Zweck wurden zwei unterschiedliche methodische Ansätze, die klassische Maximum-Likelihood-Methode und das Random Forest Verfahren, gegenübergestellt.

## 2 Material und Methoden

### 2.1 Untersuchungsgebiet

Zur Durchführung der Vor-Ort-Kontrollen werden derzeit in jedem Bundesland mehrere sogenannte *Fernerkundungszonen* festgelegt. Drei dieser Zonen befanden sich 2018 im westlichen Niedersachsen nahe der Gemeinde Kluse (KLUS), im Zentrum Niedersachsens nahe Bad Fallingb. (BAFA) und im südlichen Niedersachsen nahe Adenbüttel (ADBU) mit einer räumlichen Ausdehnung von ca. 30 km × 40 km. Sie dienen als Untersuchungsgebiet in der vorliegenden Studie (Abb. 1).




Abb. 1: Sentinel-1 Monatskomposit in RGB-Farbdarstellung und Untersuchungsgebiete in Niedersachsen. Die RGB-Farbkanäle entsprechen den Monaten Juli, Mai, März des Jahres 2018.

Die Nutzung der Landwirtschaftsfläche in diesen Zonen variiert boden- und witterungsbedingt teilweise stark. Während in der Zone ADBU Winterweizen (34 %) gefolgt von Zuckerrüben (20 %) und Mais (12 %) dominieren, bedecken Mais (41 %), Kartoffeln (23 %) und Triticale (9 %) in der Zone KLUS den größten Teil der Flächen. In der Zone BAFA werden vorwiegend Mais (34 %), Winterroggen (13 %) und Sommergerste (9 %) kultiviert. Die mittlere Schlaggröße beträgt in allen drei Zonen weniger als 3 ha (Median), das 0,75-Quantil beträgt 5 ha. Das entspricht ca. 41

% der Ackerfläche in den Zonen ADBU und BAFA sowie 53 % in der Zone KLUS. Alle Angaben beziehen sich auf das Erntejahr 2018.

## 2.2 Satellitendaten

Die Sentinel-1 Daten wurden als Level-1 Ground Range Detected (GRD) Daten vom *Copernicus Open Access Hub* der Europäischen Weltraumorganisation (ESA) heruntergeladen und mit der Software SNAP (Version 6.0) hinsichtlich der Radiometrie und Geometrie und der Topographie korrigiert. Im Ergebnis standen Gamma0 Backscatterdaten für die Polarisationen VH und VV für die Ascending (ASC) und Descending (DSC) Orbits und einer Pixelgröße von 10m x 10m zur Verfügung. Alle Einzeltracks eines Kalendermonats wurden durch Mittelwertbildung zu Monatskompositen zusammengefasst und anschließend zu deutschlandweiten Mosaiken zusammengesetzt. Für die Analysen standen somit jeweils 12 Monatskomposite für das Jahr 2018 als 1) ASC-Daten in VV-Polarisation, 2) ASC-Daten in VH-Polarisation, 3) DSC-Daten in VV-Polarisation und 4) DSC-Daten mit VH-Polarisation zur Verfügung, d.h. insgesamt 48 Datenlayer.

Die Sentinel-2 Daten wurden ebenso vom *Copernicus Open Access Hub* als L1C-Daten bezogen und mit ATCOR-3 (GEOSYSTEMS, 2014) unter Verwendung des DGM10 (BKG, 2015) atmosphären- und terrainkorrigiert. Alle Bänder wurden auf eine Pixelgröße von 10m x 10m skaliert und die Hauptkomponenten sowie der Normalized Difference Vegetation Index (NDVI) berechnet. Es wurden ausschließlich wolkenfreie Aufnahmen aus den Monaten April bis August 2018 verwendet (Tab. 1). Alle Datensätze wurden auf die räumliche Ausdehnung der Untersuchungsgebiete zugeschnitten. Sofern erforderlich erfolgte zuvor eine Mosaikierung einzelner Sentinel-2 Kacheln.

Tab. 1: Übersicht der verwendeten Sentinel-2 Daten aus dem Jahr 2018

Fernerkundungszone	Kachel	Aufnahmetermine
ADBU	UNC/ UND	10.4., 20.4., 20.5., 29.6., 19.7., 24.7., 3.8.2018
BAFA	UND	10.4., 20.4., 20.5., 29.6., 19.7., 24.7., 3.8.2018
KLUS	ULD	18.4., 8.5., 7.6., 2.7., 27.7., 6.8.2018

## 2.3 Klassifikation

Die Kulturartenklassifikation erfolgte mit der Maximum-Likelihood-Methode (ML) (LILLESAND & KIEFER 1994) und dem Random Forest-Verfahren (RF) (BREIMANN 2001). Während der ML-Methode ein parametrisches Schätzverfahren zugrunde liegt, zählt das RF-Verfahren zu den Methoden des maschinellen Lernens und basiert auf zahlreichen unkorrelierten Entscheidungsbäumen, die nach einer bestimmter Art der Randomisierung während des Lernprozesses generiert werden. Für die ML-Klassifikation wurde das semi-automatic classification Plugin (SCP) (CONGEDO 2018), für das RF-Verfahren das dzetsaka Plugin (KARASIAK 2018) in QGIS 3.4 genutzt.

Vor der Klassifikation wurden alle Satellitendaten mit den Schlagvektoren der Antragsdaten aus der Agrarförderung Niedersachsen des Servicezentrum Landentwicklung und Agrarförderung maskiert. Für die verbleibenden Ackerflächen wurden für jeden Sentinel-1 und Sentinel-2 Datensatz (vgl. Kap. 2.2) der Mittelwert pro Schlag bestimmt. Jede Rasterzelle innerhalb eines Schlages wurde anschließend mit dem entsprechenden Mittelwert belegt. Um den Einfluss von Randeffekten und Mischpixeln zu prüfen, wurde dieser Vorgang unter Verwendung eines Puffers von 10m

für alle Datensätze wiederholt. Abschließend wurden unterschiedliche Datenzusammenstellungen generiert (vgl. Tab. 2). Informationen zur zeitlichen Abfolge der Satellitenaufnahmen wurden nicht explizit integriert.

Auf Basis der Antragsdaten wurden die Kulturartenklassen definiert. Kulturarten, die weniger als < 2 % der Fläche bedecken, wurden in einer Klasse „Sonstiges“ zusammengefasst. In QGIS wurde aus diesem Datensatz über eine randomisierte Auswahl ein Trainings- und ein Validationsdatensatz im Verhältnis 30/70 erstellt. Die Klassifikationsgenauigkeiten wurden mithilfe einer Konfusionsmatrix ermittelt.

Um den Einfluss der Schlaggröße auf die Gesamtgüte der Klassifikation zu analysieren, wurden 10.000 Schläge (ca. 69 % aller Validationsflächen) zufällig ausgewählt. Diese wurden aufsteigend nach der Größe sortiert und in 10 Klassen zu je 1.000 Schlägen gruppiert. Für jede dieser Klassen wurden Konfusionsmatrizen zur Ermittlung der größenabhängigen Klassifikationsgüte erstellt. Zusätzlich wurde für jede Klasse die mittlere Schlaggröße und die Standardabweichung ermittelt. Als Maß für die Flächenform wurde für alle Flächen zusätzlich die Kompaktheit nach POLSBY & POPPER (1991) berechnet.

### 3 Ergebnisse und Diskussion

Für die Fernerkundungszone ADBU wurde mehrere Klassifikationen mit unterschiedlichen Datenzusammenstellungen (vgl. Tab. 2) mit bis zu 69 Bändern durchgeführt (Tab. 3). Unabhängig vom Eingangsdatensatz und der Vorverarbeitung erzielte die RF-Methode in allen Fällen eine etwas höhere Gesamtgüte als das ML-Verfahren. Das RF-Verfahren zeigte sich aber vor allem in Bezug auf die Prozessierungsdauer deutlich überlegen. Eine Klassifikation mit 69 Bändern war mit der ML-Methode nicht möglich, da der Prozess nach 38 Minuten durch das Programm abgebrochen wurde. Alle Zeitangaben in Tab. 3 beziehen sich dabei auf einen Arbeitsplatzrechner mit einem Intel Core TM i3-6100CPU, 3.7GHz mit 16Gb RAM und einen Windows 10/ 64bit Betriebssystem.

Einen wesentlichen Einfluss auf die Höhe der Klassifikationsgüte (Gesamtgüte) hatte die Art und die Anzahl der Eingangsdaten. Die besten Ergebnisse wurden bei Verwendung von Sentinel-1 und -2 Daten erzielt. Die separate Verwendung von Sentinel-1 oder Sentinel-2 resultierte in etwas besseren Ergebnissen bei Nutzung der Sentinel-1 Daten. Dabei erwies sich insbesondere eine Kombination von ASC-VH und DSC-VV als zielführend. Die Verwendung eines räumlichen Puffers führte nur zu einer geringfügigen Verbesserung der Gesamtgüte. Sie verbesserte vor allem die Trefferquote der Klasse *Sonstiges*. Flächen dieser Klasse wiesen eine mittlere Flächengröße von weniger als 0,7 ha auf.

Die Nutzer- und Herstellergenauigkeiten (nicht dargestellt) variierten je nach Fruchtart. Für die Klassifikation mit der höchsten Gesamtgüte (RF-69p) wurden sehr gute Ergebnisse bei der Erkennung von Winterweizen, Winterraps und Hackfrüchten einschließlich Mais erzielt. Schwierigkeiten traten bei der Identifikation von Sommerweizen auf, der in vielen Fällen der Klasse Winterweizen zugeordnet wurde. Außerdem kam es zu Fehlzuweisungen zwischen Winterroggen, Wintergerste und Winterweizen.

In den Fernerkundungszonen KLUS und BAFA konnten mit dem RF-Verfahren und kombinierten Sentinel-1 und -2 Daten Gesamtgenauigkeiten von 94,8% und 89,5% erreicht werden, wobei die

niedrigere Klassifikationsgüte für die Zone BAFA durch einen hohen Anteil der Klasse Sonstiges (12%) zur erklären ist.

Tab. 2: Übersicht über die Datenzusammenstellungen (DZ) für die Fernerkundungszone ADBU

DZ	Anzahl der Bänder	Eingangsdaten
I	69	S-1 (48 Bänder): ASC-VV, ASC-VH, DSC-VV, DSC-VH S-2 (14 Bänder): 1. + 2. Hauptkomponente, NDVI
II	24	S-1 (24 Bänder): ASC-VH, DSC-VV
II	14	S-2 (14 Bänder): 1.+2. Hauptkomponente

Tab. 3: Ergebnisse verschiedener Klassifikationsvarianten für die Fernerkundungszone ADBU; RF ... Random Forest, ML... Maximum-Likelihood, S1 ... Sentinel-1, S2... Sentinel-2.

Name	DZ	Methode	Anzahl der Bänder	Daten	Puffer (10m)	Gesamtgüte [%]	Dauer [min] †)
RF-69p	I	RF	69	S1+S2	ja	95,7	8
ML-69p	I	ML	69	S1+S2	ja	- <sup>†)</sup>	- <sup>†)</sup>
RF-69	I	RF	69	S1+S2	nein	95,4	8
RF-24p	II	RF	24	S1	ja	92,8	6
ML-24p	II	ML	24	S1	ja	92,1	31
RF-14p	III	RF	14	S2	ja	91,1	2
ML-14p	III	ML	14	S2	ja	89,6	16

†) Abbruch durch das Programm nach 38 min; ‡) Die Zeiten beziehen sich auf einen Arbeitsplatzrechner mit einem Intel Core TM i3-6100CPU, 3.7GHz mit 16Gb RAM, Windows 10 64bit

Abb. 2 zeigt die Klassifikationsgüte (nur RF) in Abhängigkeit von der Schlaggröße und der Datenzusammenstellung. In allen Fällen steigt die Klassifikationsgüte mit Zunahme der Schlaggröße logarithmisch an. Flächen kleiner 8 ha werden deutlich besser bei Verwendung von Sentinel-1 und Sentinel-2 Daten erfasst. Die Klassifikationsgüte für die kleinste Größenklasse (<0,4 ha) beträgt mit Sentinel-1 und -2 Daten 87 %, bei Nutzung von Sentinel-2 nur noch 83 % und auf Basis der Sentinel-1 Daten 79 %. Für Flächen >8 ha wurden indes bessere Ergebnisse mit Sentinel-1 als mit Sentinel-2 erreicht. Bei Flächen größer 10 ha spielt die Art der Datenzusammenstellung eine zunehmend geringere Rolle. Bislang liegen keine Erkenntnisse vor, ob und inwiefern sich die Heterogenität landwirtschaftlicher Bestände in ausgeräumten Agrarlandschaften wie beispielsweise in Mecklenburg-Vorpommern mit sehr großen Nutzungseinheiten auf den verwendeten Klassifikationsansatz auswirkt. Die ist in weiterführenden Studien zu prüfen. Bei kleinen Flächen lassen erste Analysen einen signifikanten Zusammenhang zwischen Klassifikationsgüte und Kompaktheit der Schläge erkennen.




Abb. 2: Klassifikationsgenauigkeit in Abhängigkeit von der Schlaggröße und verwendeten Eingangsdaten: blau: Sentinel-1 (24 Bänder, RF-24p), orange: Sentinel-2 (14 Bänder, RF-14p), grau: Sentinel-1 und Sentinel-2 (69 Bänder, RF-69p).

## 4 Fazit & Ausblick

Die Ergebnisse dieser Studie zeigen, dass für ein flächendeckendes Monitoring der Kulturarten im Rahmen des integrierten Verwaltungs- und Kontrollsystem der EU die kombinierte Verwendung von Sentinel-1 und Sentinel-2 Daten anzustreben ist. Dies gilt nicht nur im Hinblick auf Einschränkungen in der Datenverfügbarkeit durch Wolken (S-1) und Starkniederschläge (S-2), sondern vor allem in Bezug auf die Überprüfung gezahlter Beihilfen in stark kleinstrukturierten Agrarräumen wie beispielsweise in Hessen, Baden-Württemberg oder Bayern. In diesem Zusammenhang sind weitere Untersuchungen zum Einfluss der Schlagform erforderlich.

Darüber hinaus ist die Monitoringfähigkeit einer Vielzahl anderer Prüfkriterien wie die Mindesttätigkeit auf Brachen oder die landwirtschaftliche Tätigkeit auf Grünland zu testen, um das Potenzial der Sentinel-Satelliten voll auszuschöpfen.

## 5 Literaturverzeichnis

BKG, 2015: Digitales Geländemodell Gitterweite 10m, DGM10. Bundesamt für Kartographie und Geodäsie, URL: [https://sg.geodatenzentrum.de/web\\_public/gdz/dokumentation/deu/dgm10.pdf](https://sg.geodatenzentrum.de/web_public/gdz/dokumentation/deu/dgm10.pdf)

BREIMANN, L., 2001: Random Forests, Machine Learning **45**, 5-32.

CHUST, G., DUCROT, D. & PRETUS, J.L.L., 2004: Land cover discrimination potential of radar multitemporal series and optical multispectral images in a Mediterranean cultural landscape. International Journal of Remote Sensing **25**, 3513-3528.

CONGEDO, L., 2018: Semi-Automatic Classification Plugin Documentation - Release 5.3.6.1.

- DURO, D.C., FRANKLIN, S.E. & DUBÉ, M.G., 2012: A comparison of pixel-based and object-based image analysis with selected machine learning algorithms for the classification of agricultural landscapes using SPOT-5 HRG imagery. *Remote Sensing of Environment*, 118, 259-272.
- DVO (EU) 809/2014: Durchführungsverordnung (EU) 2018/746 der Kommission vom 18. Mai 2018, Amtsblatt der Europäischen Union, 22.5.2018.
- FORKUOR, G., CONRAD, C., THIEL, M., ULLMANN, T. & ZOUNGRANA, E., 2014: Integration of optical and synthetic aperture radar imagery for improving crop mapping in northwestern Benin, West Africa. *Remote Sensing* 6, 6472-6499.
- GEOSYSTEMS, 2014: ATCOR for IMAGINE 2016. User manual ATCOR 2 und ATCOR 3. Manual Version 29/07/2016, Geosystems GmbH.
- KARASIAK, N. & PERBET, P., 2018: Remote Sensing of Distinctive Vegetation in Guiana Amazonian Park. In: *QGIS and Applications in Agriculture and Forest*, 215-245.
- KENDUIYWO, B., K., BARGIEL, D. & SOERGEL, U. 2018: Crop-type mapping from a sequence of Sentinel 1 images. *International Journal of Remote Sensing* 39(19), 6383-6404.
- LILLESAND, T.M. & KIEFER, R.W., 1994: *Remote Sensing and Image Interpretation*. 3rd. Edition, John Wiley & Sons, Inc.
- LÖW, F., CONRAD, C. & MICHEL, U., 2015: Decision fusion and non-parametric classifiers for land use mapping using multi-temporal RapidEye data. *ISPRS J. Photogramm. Remote Sensing* 108, 191-204.
- McNAIRN, H., CHAMPAGNE, C., SHANG, J., HOLMSTROM, D. & REICHERT, G., 2009: Integration of optical and Synthetic Aperture Radar (SAR) imagery for delivering operational annual crop inventories. *Journal of Photogrammetry and Remote Sensing* 64, 434-449.
- OK, A.O., AKAR, O. & GUNGOR, O., 2012: Evaluation of random forest method for agricultural crop classification. *European Journal of Remote Sensing* 45, 421-432.
- VILLA, P., STROPIANA, D., FONTANELLI, G., AZAR, R. & BRIVIO, P.A., 2015: In-season mapping of crop type with optical and X-band SAR data: a classification tree approach using synoptic seasonal features. *Remote Sensing* 7, 12859-12886.
- VO (EU) 1306/2013: Verordnung (EU) Nr. 1306/2013 des Europäischen Parlaments und des Rates vom 17. Dezember 2013, Amtsblatt der Europäischen Union, 20.12.2013.
- VO (EU) 1159/2013: Delegierte Verordnung (EU) Nr. 1159/2013 der Kommission, Amtsblatt der Europäischen Union, 19.11.2013.
- WALDHOFF, G., LUSSEM, U. & BARETH, G., 2017: Multi-Data Approach for remote sensing-based regional crop rotation mapping: A case study for the Rur catchment, Germany. *International Journal of Applied Earth Observation and Geoinformation* 61, 55-69.