Hildesheimer Geographische Studien Bd. 9	2019	S. 91 – 123

Möglichkeiten und Grenzen offener Fernerkundungsdaten und Open-Source-Software zur Landbedeckungsklassifikation des Nationalparks Cinque Terre (Italien)

Moritz Sandner, Robin Stadtmann & Martin Sauerwein

Zusammenfassung

Das Angebot frei zugänglicher Fernerkundungsdaten wurde in jüngster Vergangenheit beträchtlich erweitert. Zudem bietet offene oder freie Software eine vielfältige Palette an Verarbeitungs- und Analysemöglichkeiten solcher Daten. Die hier präsentierte Untersuchung nutzt multispektrale Bilddaten der Sentinel-2 Satelliten aus dem Copernicus-Programm der europäischen Weltraumorganisation (ESA) zur Durchführung einer pixelbasierten Landbedeckungsklassifikation für das Gebiet der historischen Terrassenlandschaft des Nationalparks Cinque Terre (Italien). Die ausschließlich auf Grundlage von Open-Source-Anwendungen beruhende Bildklassifikation mittels Random Forest-Algorithmus ist Teil einer auf Übertragbarkeit und Kostenersparnis abzielenden Methodik und wird im Rahmen der Studie auf ihre Wirksamkeit sowie ihre Vor- und Nachteile überprüft. Die Datenverarbeitung umfasst, neben der eigentlichen Klassifikation, auch die Ableitung, Auswahl und Evaluierung zusätzlicher Eingabevariablen zur Verbesserung der Klassifikationsgenauigkeit. Die Möglichkeiten und Grenzen von Datengrundlage und Methodik werden auch vor dem Hintergrund der gebietsspezifischen Anforderungen, d.h. ihrer Verwendbarkeit zur Charakterisierung von Landschaft und Nutzungswandel, diskutiert.

Schlüsselwörter: Open Data, Open Source, Sentinel-2, Landbedeckung, Random Forest, Terrassenlandschaft, Nationalpark Cinque Terre

Summary

The range of freely accessible remote sensing data has recently been considerably expanded. In addition, open or free software offers a wide range of processing and analysis options for such data. The study presented here uses multispectral image data from the Sentinel-2 satellites of the Copernicus program of the European Space Agency (ESA) to perform a pixel-based land cover classification for the area of the historic terraced landscape of the Cinque Terre National Park (Italy). The image classification by means of a random forest algorithm, which is based exclusively on open source applications, is part of a methodology aiming at transferability and cost savings and will is tested for its effectiveness as well as its advantages and disadvantages in the course of the study. The data processing includes, in addition to the actual classification, the derivation, selection and evaluation of additional input variables to improve the classification accuracy. The possibilities and limitations of the data basis and methodology are also discussed against the background of area-specific requirements, i.e. their usability for the characterisation of landscape and land use change.

Keywords: Open data, Open source, Sentinel-2, Land cover, Random forest, Terraced landscape, Cinque Terre National Park

1 Einführung und Zielsetzungen

Die modernen Instrumente und Methoden der Geoinformatik und der Fernerkundung ermöglichen die kontinuierliche Beobachtung der Erdoberfläche auf unterschiedlichen Maßstabsebenen. Insbesondere die Kartierung und Beobachtung von Vegetation und ihrer Veränderung ist ein klassisches Anwendungsgebiet für Erdbeobachtungsdaten. In vielerlei Hinsicht wirkt die derzeitige Entwicklung von Open-Source-Softwareangeboten und frei verfügbaren Datensätzen besonders attraktiv. Dank der Open Source-Philosophie vieler Anbieter und nicht zuletzt durch Beschlüsse zur internationalen Datenpolitik, wie der INSPIRE-Richtlinie der Europäischen Kommission (vgl. BARTHA & KOCSIS 2011), hat sich die Zugänglichkeit von Geo- und Fernerkundungsdaten für die behördliche, zivile und private Nutzung enorm verbessert. Frei zugängliche Daten und Instrumente können die Bearbeitung von unterschiedlichsten Fragestellungen, im Hinblick auf entfallende Lizenzkosten für kommerzielle Software und Datenprodukte, für den Endnutzer zu einem erschwinglichen Prozess und wissenschaftliche Ergebnisse uneingeschränkt reproduzierbar machen (SINGLETON et al. 2016:1508). Vor allem in gering finanzierten Projekten und Institutionen des Gebietsschutzes sowie in der universitären Forschung kann dies von Bedeutung sein (HAO et al. 2014:25). Die vorliegende Studie soll einen Beitrag dazu leisten, Möglichkeiten und Grenzen von Open Source-Anwendungen und aktuellen, frei verfügbaren Datensätzen aufzuzeigen und zugleich die Effektivität von Daten und Methodik für die Analyse eines speziellen Landschaftstyps beurteilen.

Als exemplarischer Raumausschnitt dient der besondere Kulturraum einer mediterranen Terrassenlandschaft. Die Entwicklung der italienischen „Cinque Terre“ innerhalb der vergangenen Jahrzehnte kann als symptomatisch für einen Problemkomplex aus Landnutzungswandel, Georisiken und Schutzgebietsmanagement betrachtet werden. Komplexe Beziehungen und untereinander verstärkende Trends bilden dabei ein Geflecht aus Wechselwirkungen, das im Wesentlichen durch die Aufgabe landwirtschaftlicher Flächen, deren Verfall und dadurch entstehende Geogefahren charakterisiert ist. Besonders die widersprüchliche Rolle der Sukzession, die als stabilisierender Prozess das Risiko von Rutschungen auf aufgegebenen Flächen mittelfristig verringert, jedoch langfristigen Verlust von Landschaftscharakter und Biodiversität bedeutet, macht das Gebietsmanagement zu einer Herausforderung.

Die Studie soll zur Evaluierung der genutzten Daten, Anwendungen und Methoden dienen und diese in einem anwendungsbezogenen Kontext bewerten. Im Fokus stehen dabei insbesondere das Potenzial und die Limitierungen der bewusst kostensparend ausgewählten Daten und Methoden. Dazu werden die folgenden Aspekte bearbeitet:

(1) Die Bewertung der Klassifikationsgenauigkeit durch einen Ansatz zur pixelbasierten Landbedeckungsklassifikation auf Grundlage von multispektralen Sentinel-2 Daten und Open-Source-Softwareanwendungen,

(2) die Möglichkeiten zur Steigerung der Genauigkeit des Klassifikationsergebnisses im Rahmen eines praxisnahen und deshalb zugleich einfach als auch übertragbar gehaltenen Anwendungsbeispiels,

(3) die Bewertung des Informationsgehaltes der Ergebnisse im Hinblick auf den Nutzungswandel im Untersuchungsgebiet und

(4) das Identifizieren von Limitationen und Problemen der gewählten Methodik und der Verweis auf potentielle weitere Lösungsansätze.

2 Theoretischer Hintergrund

2.1 Landbedeckungsklassifikation mediterraner Gebiete – eine Herausforderung

Kartierung und Monitoring von Landbedeckung und Landnutzung (*land cover / land use*) ist eines der Hauptanwendungsgebiete für Daten erdbeobachtender Satelliten (JENSEN 2016:361). Herausforderungen für Verfahren der überwachten Bildklassifikation zur Landbedeckungsklassifikation sind dabei generell jene Bedeckungsklassen, die sich hinsichtlich ihrer spektralen Eigenschaften sehr ähnlich sind und so eine geringe interkategorielle Trennbarkeit (*Seperability*) besitzen. Gleichzeitig weisen viele Landbedeckungsklassen eine hohe intrakategorielle Varianz auf und besitzen keinen einheitlichen Charakter, was ihre Repräsentativität einschränkt (RODRIGUEZ-GALIANO et al. 2012b:93). Beide Eigenschaften treffen verstärkt auf viele mediterrane Untersuchungsgebiete zu, da diese aufgrund ihrer Nutzungsgeschichte häufig durch ein heterogenes Mosaik unterschiedlicher Vegetationstypen geprägt sind. Macchien unterschiedlicher Wuchsformen und -höhen wechseln sich nicht selten kleinräumig mit landwirtschaftlichen Flächen ab, oder gehen, wie es mittlerweile an vielen eher marginalen Standorten der Fall ist, in Wald über (FALCUCCI et al. 2007). Insbesondere in ländlichen Gebieten mit höherer Reliefenergie fehlen des Weiteren größere und regelhaft geformte landwirtschaftliche Flächen, auf denen eindeutig zu bestimmende Feldfrüchte gedeihen. An ihre Stelle treten stattdessen kleinräumig wechselnde Landnutzungsmuster und ungenutzte Bereiche.

2.2 Sentinel-2

Das Sentinel-2-Satellitenpaar ist Teil des Erdbeobachtungsprogramms Copernicus der Europäischen Union und der Europäischen Weltraumorganisation (ESA) (ASCHBACHER & MILAGRO-PÉREZ 2012). Die baugleichen Satelliten Sentinel-2A und Sentinel-2B befinden sich seit 2015 bzw. 2017 auf sonnensynchronem Umlauf und bilden das optische Segment von Copernicus. Die Sensoren der Satelliten erfassen Strahlung in 13 spektralen Bildkanälen (Bänder) unterschiedlicher geometrischer Auflösung (Abb.1).

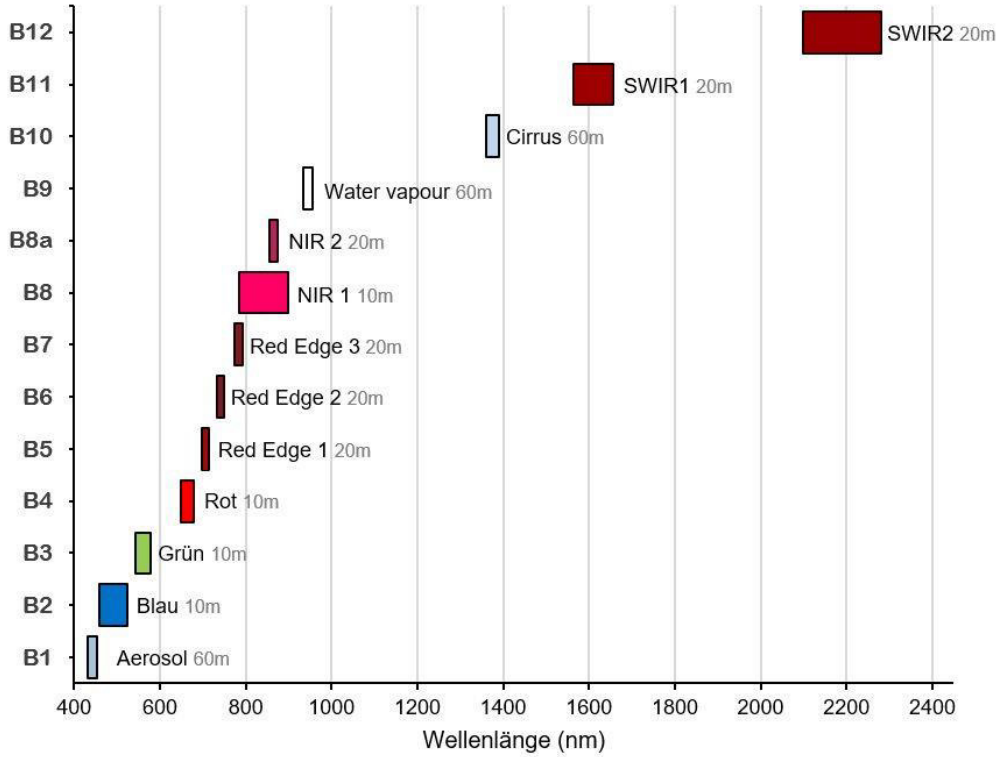

Abb. 1: Bänder des Sentinel-2-MultiSprectral Instruments nach Wellenlänge, mit geometrischer Auflösung und jeweiligem Verwendungszweck (in Anlehnung an IMMITZER et al. 2016:4).

Dabei werden die Bereiche des sichtbaren Lichts (VIS) (B2, B3, B4), des *Red Edge* (B5, B6, B7), des nahen Infrarots (NIR) (B8, B8a), sowie der Bereich des kurzwelligen Infrarots (SWIR) (B11, B12) abgedeckt. Weitere Bänder dienen dem Detektieren von Atmosphäreneigenschaften (B1, B9, B10). Zusammen mit ihrer dreistufigen geometrischen Auflösung sowie einer kurzen Wiederholungsrate, stellen sie eine bisher nicht dagewesene Grundlage für ein flächendeckendes globales Monitoring der terrestrischen Erdoberfläche und der Küstengebiete dar (DRUSCH et al. 2012:26f.).

2.3 Hilfsdaten für die Bildklassifikation

Aufgrund des Einflusses von Höhe, Hangneigung oder Exposition auf die räumliche Verbreitung von Vegetation und somit der Landnutzung können auch digitale Informationen über das Relief eines Untersuchungsgebietes, vor allem in Form digitaler Geländemodelle (engl. *Digital Elevation Model*, kurz DEM) wichtige Informationen für semi-automatisierte Bildanalysen darstellen. In vielen Studien wurden Höhendaten erfolgreich zur Verbesserung von Landbedeckungs- und Landnutzungsklassifikationen herangezogen (z.B. RICCHETTI 2000, KEUCHEL et al. 2003, GISLASON et al. 2006). Andere Möglichkeiten, um zusätzliche Informationen zur Landbedeckung aus Fernerkundungsdaten herauszuarbeiten oder bestehende Informationen zu schärfen, sind etwa die Nutzung von Vegetationsindizes (HANSEN et al. 2000) oder Texturinformationen (RODRIGUEZ-GALIANO & CHICA-OLMO 2012). Auch die Verwendung anderer nicht-multispektraler Sensordaten wie hyperspektrale Bilddaten (XU & GONG 2007) oder Radardaten (CRAIG DOBSON et al. 1995) kann Vorteile bieten.

2.4 Maschinelles Lernen und Random Forest

Innerhalb der vergangenen zehn Jahre haben Fortschritte auf dem Gebiet des maschinellen Lernens zu einer bemerkenswerten Verbesserung von Klassifikationsergebnissen geführt (HUANG et al. 2002, ROGAN et al. 2008). Algorithmen-Kategorien dieser Sparte der Informatik sind etwa auf Entscheidungsbäumen (*decision trees*) basierende Klassifikatoren, neuronale Netze oder *Support Vector Machines*. Insbesondere bei der Verarbeitung von komplexen und multidimensionalen Datensätzen übertreffen die Ergebnisse dieser Algorithmen jene der klassischen, häufig parametrischen, d.h. von der Verteilungsfunktion der Daten abhängigen Klassifikatoren, wie etwa *Maximum Likelihood*. Auch für jüngere Studien in mediterranen Gebieten sind *Maschine Learning*-Klassifikatoren erfolgreich eingesetzt worden (z.B. RODRIGUEZ-GALIANO et al. 2012a, GOUNARIDIS et al. 2015).

Random Forests (RF) (BREIMAN 2001) sind Algorithmen zur Klassifikation und Regression aus dem Bereich des maschinellen Lernens. Sie gehören zur Kategorie der sogenannten Ensemble-Methoden (auch *ensemble learning* oder *group learning*), deren zugehörige Algorithmen die Zusammenführung von vielen einzelnen, individuellen Modellen zu einem genaueren Modell gemeinsam haben (GISLASON et al. 2006:294).

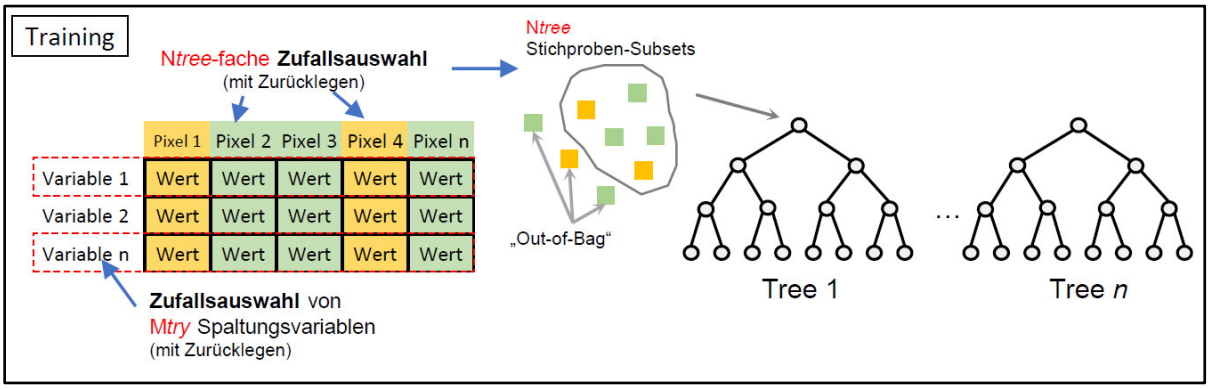

Abb. 2: Vereinfachtes Schema der Trainingsphase eines RF-Modells durch Bootstrap-Sampling und Zufallsauswahl von Spaltungsvariablen zur Definition der Knotenpunkte (nach: BELGIU & DRĂGUŢ 2016).

Random Forest-Modelle entstehen, indem *n* Entscheidungsbäume (*decision trees*) generiert werden (Abb. 2). Die Anzahl der Bäume (N*tree*) wird dabei vom Anwender vorgegeben. Für jeden Baum wird nun, zufällig und mit Zurücklegen, eine Stichprobe von derselben Größe wie die des Trainingsdatensatzes aus den Trainingsdaten gezogen. In diesem sogenannten Bootstrap-Sampling (EFRON 1979) liegt der nichtparametrische Charakter des Algorithmus begründet. Durch dieses Prinzip können Schätzungen allein auf Grundlage der Stichprobe, d.h. den Trainingsdaten, angestellt werden, ohne eine theoretische Verteilungsfunktion vorauszusetzen, wie es etwa bei der Maximum Likelihood-Methode der Fall ist. Für die Definition der jeweiligen Knotenpunkte (*split points* oder *nodes*) innerhalb jedes einzelnen Entscheidungsbaumes wird, ebenfalls zufällig, eine zuvor festgelegte Anzahl (M*try*) an Variablen, d.h. Datenkanäle innerhalb des Klassifikations-Datensets, genutzt. Für M*try* wird häufig die Quadratwurzel aus der Anzahl der Eingabevariablen oder ein geringerer Wert gewählt (BELGIU & DRĂGUŢ 2016:25).

Bei der nach dem Training des Algorithmus durchgeführten Klassifikation (Abb. 3) schließt ein ML-Algorithmus aus dem Gelernten auf die verbleibenden Daten und ordnet diese in das bestehende Kategoriensystem ein (induktives Lernen) (JENSEN 2016:439f.). Bei Random Forests geschieht dies, indem jedes zu klassifizierende Element (hier: Pixel) die Gesamtheit der Entscheidungsbäume durchläuft und von jedem der *n* Bäume der nach seinem Konstruktionsprinzip am besten passenden Klasse eingeordnet wird. Schließlich entscheidet die Mehrheit der Zuordnungen im Sinne einer „Abstimmung“ (*voting*) über die abschließende Klassifizierung des Elements. Die parallele Klassifikation durch eine Vielzahl eigenständiger Entscheidungsbäume gleicht dabei die Varianz der Entscheidung eines einzelnen Klassifikators aus und soll so zu guten Ergebnissen führen (BREIMAN 2001:29).

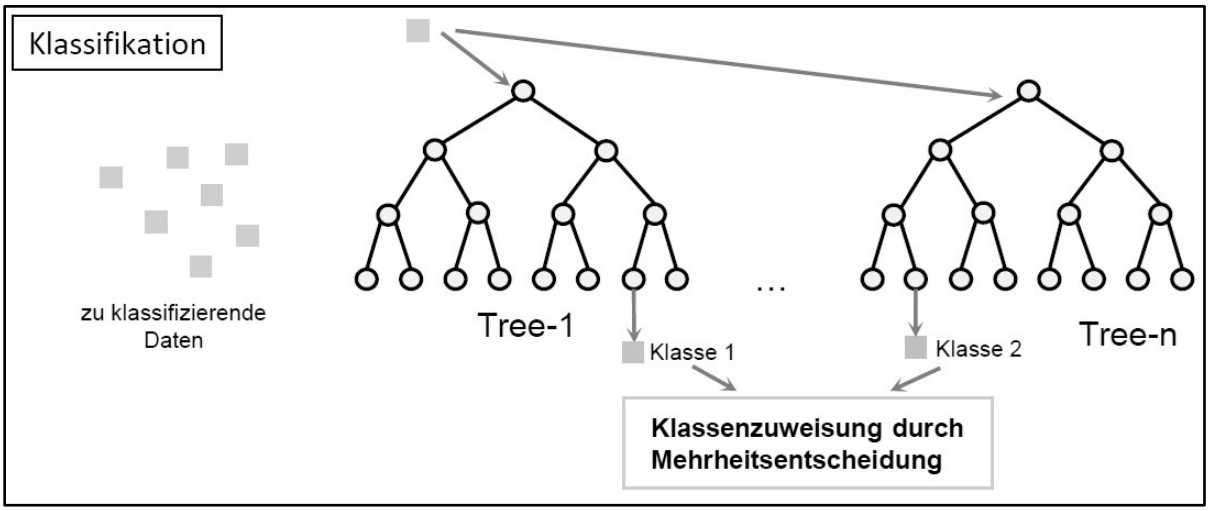

Abb. 3: Vereinfachtes Schema der Klassifikation mit trainiertem RF-Modell (nach: BELGIU & DRAGUT 2016).

Eine Besonderheit von Random Forests ist weiterhin die eingebettete Funktion zur Berechnung eines speziellen Fehlermaßes, des Out-Of-Bag-Errors (*OOB-Error*). Dies ist möglich, da von jeder Unterstichprobe (*subset*), die für einen jeweiligen Baum vorgesehen ist, nur zwei Drittel zu seiner Konstruktion verwendet werden (vgl. Abb. 3). Der Rest der Samples verbleibt „out-of-bag“ und wird, nach abgeschlossener Konstruktion des Baumes, durch diesen testweise klassifiziert. Die Anzahl an falsch klassifizierten Elementen ergibt für die Gesamtheit der Bäume schließlich eine globale und eine klassenspezifische OOB-Fehlerrate (BREIMAN 2001:11). Diese Funktion kann als modellinterne Kreuzvalidierung angesehen werden.

Durch die Möglichkeit zur Berechnung des OOB-Fehlers ergeben sich weitere nützliche Ausgabestatistiken des Algorithmus. Die Maße zur sogenannten Variablenwichtigkeit (*feature importance*) sind geeignet, um den Einfluss eines jeden Informationskanals, als Eingabevariable oder *Feature* bezeichnet,

auf die Genauigkeit des Modells im Sinne der OOB-Fehlerrate zu beurteilen. Sie werden in Form der Maße *Mean Decrease in Accuracy* (MDA) und *Mean Decrase in Gini* (MDG) durch den Algorithmus berechnet. Zur näheren Bedeutung dieser Maße siehe BREIMANN (2001). Beide Werte können in einer Strategie zur Auswahl von Variablen (*feature selection*) dazu dienen, diese in einer Wichtigkeits-Rangordnung zu betrachten, um die einflussreichsten Variablen zu identifizieren und unwichtige auszusortieren (BREIMAN 2001:23, BOULESTEIX et al. 2012:494f.). Für die Anwendung im Bereich der Fernerkundung hat sich vor allem die Nutzung der MDA durchgesetzt (BELGIU & DRĂGUŢ 2016:26).

Neben den Vorteilen durch die beschriebenen Ausgabestatistiken, gelten Random Forests als robuste Klassifikatoren, die in der Lage sind hochdimensionale Datensets zu verarbeiten und weniger zum *Overfitting* neigen als andere ML-Klassifikatoren. Außerdem sind sie relativ anwenderfreundlich, da nur wenige Parameter definiert werden müssen und der Entscheidungsprozess, trotz Black-Box-Charakter, eine gewisse Interpretierbarkeit ermöglicht (GISLASON et al. 2006:295).

Innerhalb der letzten 15 Jahre wurden Random Forests in der Geoinformatik erfolgreich zu Kartierungsaufgaben innerhalb unterschiedlicher Themengebiete, unter Verwendung von Fernerkundungsdaten, etabliert (GISLASON et al. 2006; GHIMIRE et al. 2012; GOUNARIDIS et al. 2015; BELGIU & CSILLIK 2018).

3 Untersuchungsgebiet

Die historische Terrassenlandschaft Cinque Terre liegt im Nordwesten Italiens an der Riviera di Levante in der östlichsten Provinz der Region Liguriens La Spezia. Die alte Kulturlandschaft umfasst fünf historische Ortschaften und geht mit der von VERBAS (1978) beschriebenen Ausdehnung heute in der Fläche des 1999 ausgewiesenen Nationalparks auf (3.800 ha) (Abb. 4).

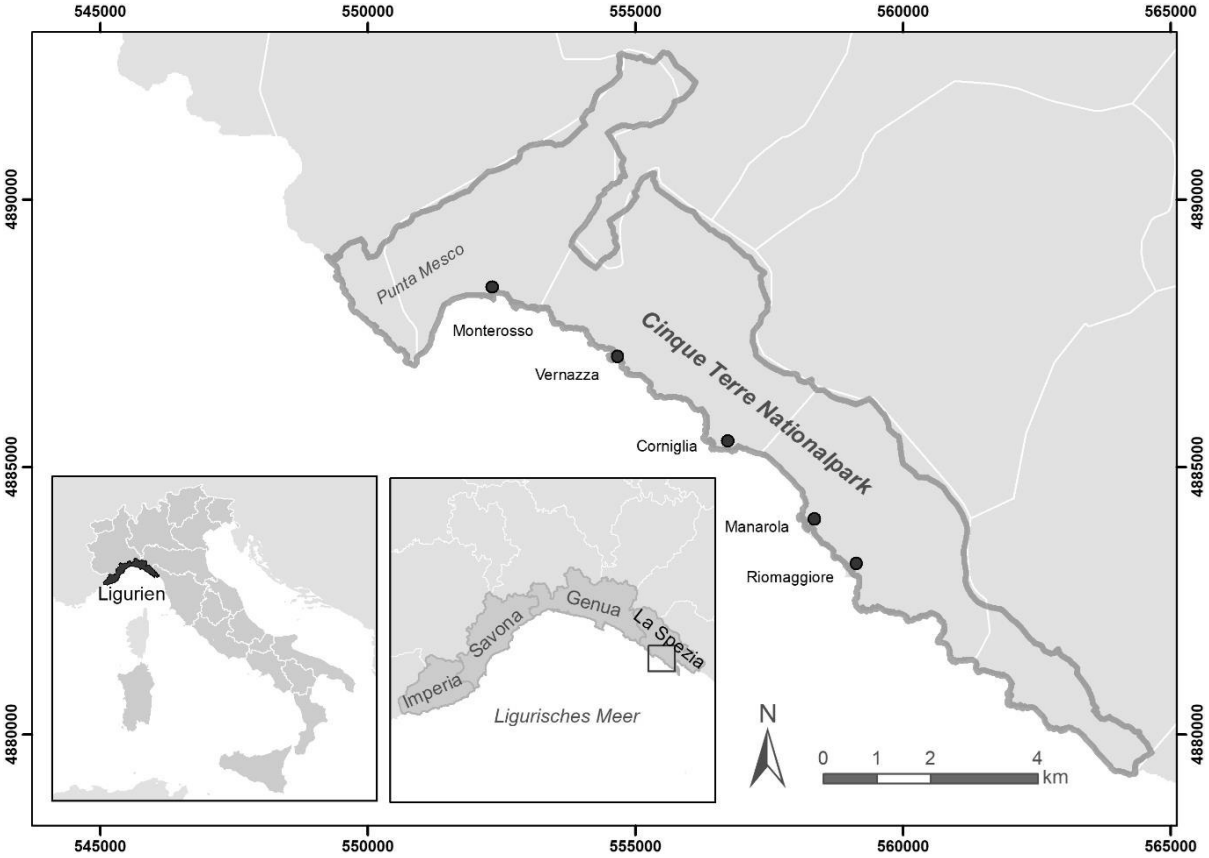

Abb. 4: Lage des Nationalparks Cinque Terre innerhalb der Region Ligurien (Italien).

Die besondere Landschaft der Cinque Terre ist ein eindrucksvolles Beispiel für die Gestaltungswirkung traditioneller menschlicher Wirtschaftsweise. Ein Grund für die Unterschutzstellung der Cinque Terre

als italienischer Nationalpark war ein notwendiger Schutzstatus für die bereits 1997 als UNESCO-Weltkulturerbe ausgezeichnete Landschaft (FOWLER 2002), in der die lange Tradition der Errichtung und Pflege von landwirtschaftlichen Terrassen zur Urbarmachung steiler Hänge bis heute praktiziert wird. Diese haben in den vergangenen Jahrhunderten den Charakter der Landschaft entscheidend geprägt. Die Effekte von landwirtschaftlichen Terrassen und ihre Bedeutung für den Landschaftshaushalt sind in der Literatur ausführlich beschrieben (z.B. TAROLLI et al. 2014, 2015; ARNÁEZ et al. 2015).

3.1 Geologie, Böden, Geomorphologie

Im größten Teil des Untersuchungsgebietes bilden oligozäne Grauwacken (Macigno-Sandstein) der toskanischen Fazies innerhalb der Flyschserie den geologischen Untergrund. Weitere Teile der Landschaft sind ferner durch die Vorkommen von oligozänen Kalkmergeln, Kalksandsteinen oder auch Kalkschiefern der anstehenden Gesteine der Liguriden-Fazies geprägt (TERRANOVA et al. 2006). Im Bereich der Punta Meso-Halbinsel im Nordwesten des Nationalparks findet sich außerdem eines der südlichsten Vorkommen von vulkanisch-metamorphen Ophiolithen Liguriens (LINGENHÖHL 2005:26f., BRANDOLINI 2017:238f.).

Die natürliche Bodenlandschaft der Cinque Terre weist in Abhängigkeit zur Geologie nur geringe Differenzierungen auf und besteht vor allem aus Braunerden über oligozänen Grauwacken (Macigno-Sandstein) und Terra fusca-Böden über oligozänem Kalkmergel, Kalksandstein oder auch Kalkschiefer. Im Zuge der menschlichen Aktivität, insbesondere des Wein- und Olivenbaus auf Terrassenflächen, wurden die Böden der Cinque Terre nahezu flächendeckend gravierend verändert (LINGENHÖHL 2005:32f.).

Über 50% des schroffen und tiefeingeschnittenen Geländes der Cinque Terre weisen Hangneigungen von über 30° auf. Flache Gebiete fehlen praktisch vollständig. Diese natürliche Morphologie ist der Grund für die, an diese Bedingungen angepasste und zugleich die Landschaft prägende, Wirtschaftsweise der vergangenen Jahrhunderte durch den Terrassenbau. Die hohen Hangneigungen führen in Kombination mit Landnutzung und dem Niederschlagsregime der Region zu einer erhöhten Bedeutung von gravitativen und fluvialen Prozessen. Dies zeigt sich insbesondere in der Häufigkeit, mit der im Untersuchungsgebiet Erdrutsche, Geländeabbrüche oder Schuttströme auftreten (BRANDOLINI 2017:238f.).

3.2 Landnutzung, Landnutzungswandel und Vegetation

Die Entwicklung des besonderen Kulturraumes Cinque Terre war in der Vergangenheit eng mit der Geschichte des Weinbaus verbunden und ist es noch heute. Aus diesem Umstand resultierte auch die Notwendigkeit zur Umwandlung der natürlichen Hänge und ihre Urbarmachung durch eine heute über tausendjährige Tradition des Terrassenbaus in den heutigen Cinque Terre (AGNOLETTI et al. 2012:41).

Eine Blütezeit des Weinbaus bedingte im Verlauf der zweiten Hälfte des 19 Jh. die Ausweitung des Terrassenbaus bis in höhere Hanglagen. Zugleich führten Bevölkerungswachstum, Beschäftigungsknappheit und Missernten wiederholt zu Aus- und Abwanderungswellen. Den mit Abstand größten und bis in jüngste Zeit andauernden Bevölkerungsrückgang verzeichnet das Gebiet jedoch seit den 1950er Jahren. Intensivierung der Landwirtschaft, Sogwirkung der wirtschaftlichen Zentren, Marktentwicklung und die ungünstigen Wirtschaftsbedingungen für Mensch und Maschine in den bergigen Regionen erzeugten so seit den 1970er Jahren einen Verlust von 70% der land- und fischereiwirtschaftlichen Produktion. Dieser nun mehr als 40 Jahre andauernde Trend der Entvölkerung des ländlichen Raumes und der fehlenden Instandhaltung der Terrassenstrukturen reduzierte die bewirtschafteten Rebhänge auf etwa 100 ha von ursprünglich 1400 ha Ende des 19. Jahrhunderts (AGNOLETTI et al. 2012:42f.). Wie nahezu im gesamten Mittelmeerraum, ist damit auch die Vegetation der Cinque Terre durch eine jahrhundertelange Nutzung der Landschaft durch den Menschen geprägt. Die landbedeckende Vegetation ist während der besonderen Historie der Landschaft verändert worden und unterliegt seit dem Rückgang der traditionellen Wirtschaftsformen einer erneuten Transformation.

Die Vegetation der Region Ligurien wurde von NOWAK (1987) in großem Maßstab untersucht. RICHTER (1989) untersuchte in seiner vergleichenden Abhandlung die Vegetationsentwicklung auf Rebbrachen innerhalb eines begrenzten Raumausschnitts der Cinque Terre, während sich LINGENHÖHL (2005) ausführlich mit der Vegetation und Phytodiversität innerhalb des Nationalparks beschäftigte. Auf letztere Untersuchung gehen viele in dieser Studie getätigte Annahmen zur Vegetation des Untersuchungsgebietes zurück.

Die Vegetation der Cinque Terre lässt sich abhängig von ihrer mesoklimatischen Differenzierung in drei thermische Höhenstufen einteilen (CARL & RICHTER 1989). Die marin beeinflusste thermomediterrane Stufe der küstennahen Gebiete reicht bis in eine durchschnittliche Höhe von 100 m ü.d.M. und ist charakterisiert durch spärliche Vegetation und niedrige Macchien mit Baum-Wolfsmilch (*Euphorbia dendroides*) und neophytische Opuntien (*Opuntia ficus-indica*). Oberhalb der Küstenvegetation schließen sich die bis in Höhen von etwa 400 bis 500 m reichenden mesomediterranen Mittellagen an. Aufgrund ihrer günstigen Klimabedingungen sind diese Bereiche seit Jahrhunderten Ort des Weinbaus und der Olivenkulturen. Im Zuge des bis heute stattfindenden Nutzungswandels wurden diese landwirtschaftlichen Nutzflächen vielerorts durch Macchien oder Wald ersetzt. Das Nebeneinander von Bewirtschaftung und Folgevegetation unterschiedlichen Alters macht die mesomediterrane Zone heute zum diversesten Bereich der Cinque Terre. Die durch unterschiedliches Alter, Randeffekte oder andere Einflüsse wie Feuer differenzierte Pflanzenformation weist unterschiedliche Artzusammensetzungen auf. Diese reichen von Leguminosen im *Calicotomo-Myrtetum*, über Brombeergestrüpp bis zu den von Baumheide (*Erica arborea*) beherrschten Aspekten des *Erico-Arbutetum*. Ohne Störungseinfluss entwickeln sich diese Flächen durch Aufwuchs von *Pinus pinaster* schließlich zu Kiefern- und Kiefernmischwälder oder bringen als Klimaxstadium schließlich Bestände von Steineichen (*Quercus ilex*) hervor (LINGENHÖHL 2005). Auf Höhen ab 500 m folgen schließlich die supramediterranen Kammlagen. Dominiert werden sie von Kastanien-Laubwäldern mit der als „Brotfrucht“ in Italien eingeführten Esskastanie (*Castanea sativa*) und Laubmischwäldern mit Kastanie und Flaumeiche (*Quercus pubescens*) (LINGENHÖHL 2005:46).

Durch ihre Bedeutung als Indikator für den fortschreitenden Nutzungswandel, als auch für den Zustand von Terrassenstrukturen, erfuhr die Sukzessionsdynamik der Rebbrachen schon vor einigen Jahren eine eingehende Betrachtung. Beschreibungen der Sukzession auf aufgegebenen Rebflächen und Ölbaumhaine in den Cinque Terre finden sich etwa bei RICHTER (1989), RICHTER & BLOCK (2001) und LINGENHÖHL (2005). Nach dem anfänglichen Stadium der Brachsukzession, den die bereits im bewirtschafteten Zustand vorhandenen Krautgesellschaften dominieren (*Stellarietae mediae*), über *Stipo-Brachypodietea dystachyae* kommt es auf Weinflächen nach etwa 10 - 15 Jahren (RICHTER & BLOCK 2001), unter begünstigten Umständen bereits nach fünf bis sieben Jahren (LINGENHÖHL 2005:126), zu einer vollständigen Besiedlung durch Brombeere (*Rubus ulmifolius*). Bleibt diese aus, können die Flächen in wenigen Fällen durch Kiefernaufwuchs direkt in die Vegetationsgesellschaft des *Quercetum ilicis pinetosum* übergehen. In vielen Fällen werden die Brombeergebüsche, etwa 15 Jahre nach der Nutzungsaufgabe, von den ausgedehnten Baumheide-Vorkommen des *Erico-Arbutetum* abgelöst. Diese auffälligen Flächen sind demnach ein Indikator von Brachestadien zwischen 15 und 30 Jahren, bis auch sie zunehmend durch Kiefernaufwuchs ihren Charakter ändern. Die Nutzungsaufgabe der heute mit Kiefern und Steineichen bewachsenen Terrassenflächen liegt zum Teil 50 - 60 Jahre zurück. Die Wiederbewaldung der aufgegebenen Standorte geht insgesamt jedoch eindrucksvoll schnell vonstatten, sodass das Ende der Sukzession nach 40 – 60 Jahren erreicht ist (RICHTER & BLOCK 2001:40).

4 Daten und Methodik

4.1 Übersicht

Abb. 5 stellt in verkürzter Form die bedeutendsten Stationen im methodischen Ablauf der Studie dar. Die gewählte Vorgehensweise kann als *Multi-Source*-Ansatz (vgl. GISLASON et al. 2006:294) einer überwachten und pixelbasierten Random Forest-Klassifikation beschrieben werden. Neben den multispektralen Sentinel-2-Daten wurden auch abgeleitete Texturmaße und DEM-Produkte verwendet. Die Klassifikation erfolgte zu Analysezwecken in einer Vielzahl an Konstellationen und Wiederholungen mit dem Ziel, das im Rahmen des Ansatzes bestmögliche Variablenset zu ermitteln.

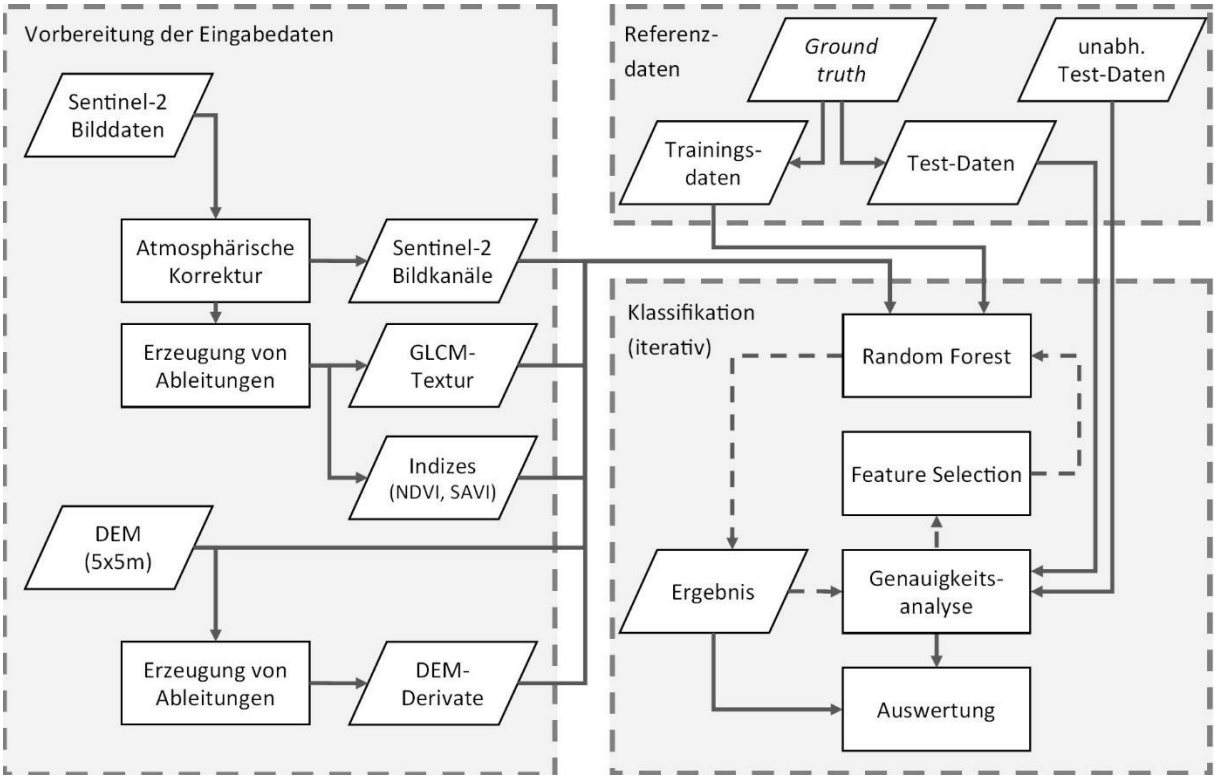

Abb. 5: Übersicht zu den wichtigsten Arbeitsaufläufen der Datenverarbeitung.

4.2 Daten und Preprocessing

4.2.1 Sentinel-2-Satellitenbilddaten

Zentraler Datensatz für die Bildklassifikation sind die multispektralen Bilddaten der Sentinel-2-Satelliten. Von den insgesamt dreizehn verfügbaren Spektralkanälen (Bänder) wurden alle Kanäle mit der geometrischen Auflösung von 10m und 20m verwendet. Der Datensatz umfasst damit die Kanäle des sichtbaren Lichts (B2, B3, B4), des nahen Infrarots (B8 und B8a) des *Red edge* (B5, B6, B7) und jene des kurwelligen Infrarots (B11 und B12).

Nach eingehender Überprüfung der Sentinel-2-Bildszenen für den Zeitraum von November 2016 bis Oktober 2017 hinsichtlich ihrer Verwendbarkeit fiel die Wahl auf die Bilddaten des 03. Juli 2017. Diese Aufnahme weist weder Wolkenbedeckung, noch ausgeprägte Reliefschatten auf und unterscheidet sich zeitlich nur um wenige Tage von den sehr hochauflösenden Luftbildern aus Google Earth (für die Cinque Terre zumeist 07.07.2017), die für die Erfassung von Referenzdaten herangezogen werden (s. 4.4.2). Unterstützend wurde zusätzlich eine Bildszene mit dem Aufnahmedatum des 08. März 2017, stellvertretend für die Zeit vor dem Blattaustrieb von *Castanea sativa* herangezogen (s. 4.3.2).

Die Bilddaten wurden unter Verwendung des Sen2Cor-Prozessors (v.2.4.0 für Windows, eigenständige Installation) (LOUIS et al. 2016) einer atmosphärischen Korrektur unterzogen und so von *Top-Of-Atmosphere* (TOA) zu *Bottom-Of-Atmosphere* (BOA) (Level 2A) vorverarbeitet (vgl. LOUIS et al. 2016:1). Neben der standardmäßigen atmosphärischen Korrektur wurde weiterhin die Korrektur unter Verwendung eines digitalen Geländemodells (*terrain correction*) durchgeführt. Zu diesem Zweck bietet Sen2Cor die Option zur Verwendung von SRTM-Daten mit einer räumlichen Auflösung von 90x90 m. Von einer Nutzung höher aufgelöster Geländemodelle wurde abgesehen, da das Korrektur-Verfahren zum Zeitpunkt der Studie bisher nur unter den zuvor genannten Einstellungen evaluiert wurde (MÜLLER-WILM et al. 2017:20).

4.2.2 Digitales Geländemodell

Digitale Höhendaten, frei verfügbar im Geoportal der Region Ligurien (REGIONE LIGURIA 2017a), liegen als digitales Geländemodell (DEM) mit einer räumlichen Auflösung von 5 m vor. Die mehrere Rasterdatensets umfassenden DEM-Daten wurden in SAGA (*System for Automated Geoscientific Analysis*) (CONRAD et al. 2015) zusammengefügt, auf die Ausdehnung der Satellitenbilddaten (*Subset*) zugeschnitten und auf deren geometrische Auflösung von 10 m angepasst (*Resampling*). Datenfehler im Geländemodell, sogen. Senken, wurden automatisch detektiert und gefüllt.

4.3 Abgeleitete Variablen (Derivate)

4.3.1 Textur-Variablen (GLCM)

Textur-Maße sind der Versuch, Eigenschaften jenseits der spektralen Charakteristika von Einzelpixeln aus Bilddaten herauszuarbeiten. Ziel ist es, weitere Aspekte des menschlichen Sehens, wie etwa das Erkennen von Kanten, Kontext oder Varianz von Grauwerten abzudecken und für die automatisierte Bildanalyse nutzbar zu machen (RODRIGUEZ-GALIANO et al. 2012a:93). Eine der bekanntesten Varianten der Textur-Variablen ist die sogenannte *Gray-Level Co-occurence Matrix* (GLCM) (HARALICK et al. 1973). Diese Variablen basieren auf dem raumabhängigen Vorkommen von Grauwerten eines Bildausschnittes und werden als unterschiedliche Statistiken zweiter Ordnung innerhalb eines quadratischen Kernel-Fensters mit festgelegter Größe für den jeweils zentralen Pixel berechnet (JENSEN 2016:345). In verschiedenen Studien zur Landbedeckungsklassifikation konnten GLCM-Features erfolgreich zur Steigerung der Klassifikationsgenauigkeit eingebunden werden (z.B. JOHANSEN et al. 2007, RODRIGUEZ-GALIANO et al. 2012a, KABIR et al. 2013; TASSETTI et al. 2010).

Für diese Studie wurden zehn der von HARALICK et al. (1973) postulierten Textur-Maße verwendet: verwendet: *Contrast, Homogeneity, Dissimilarity, Angular Second Moment (ASM), Energy, Entropy, MAX, GLCM Mean, GLCM Variance, GLCM Correlation*. Sie sind in der Open Source-Software SNAP (*Sentinel Application Plattform*) der ESA (SNAP 2017) implementiert. Dadurch, dass die Maße jeweils für jeden Sentinel-2-Bänder B2, B3, B4 und B8 in den Fenstergrößen 5x5, 7x7, 9x9 und 11x11 berechnet wurden ergibt sich eine Anzahl von insgesamt 160 Rasterdatensets. Die mehr oder weniger starken Korrelationen zwischen den GLCM-Statistiken machen eine spezifische Auswahl der für die Analyse wichtigsten Datensätze notwendig (CLAUSI 2002:58, BEEKHUIZEN & CLARKE 2010:128) (s. 4.6). Weiterführende Informationen zum Umgang mit GLCM-Features finden sich etwa bei HALL-BEYER (2017a, b).

4.3.2 Vegetationsindices

Vegetationsindices werden klassischerweise zu unterschiedlichen Analysen, darunter auch die Bildklassifikation, herangezogen (JENSEN 2016:325). Als Ableitungen aus den Sentinel-2-Daten wurden in dieser Studie der *Normalized Difference Vegetation Index* (NDVI) (vgl. ROUSE et al. 1974) sowie der *Soil-Adjusted Vegetation Index* (SAVI) (HUETE 1988), als Alternative zum NDVI, berechnet.

$$NDVI = \frac{NIR-RED}{NIR+RED} \qquad (1)$$

$$SAVI = \frac{NIR-RED}{(NIR+RED+L)}(1+L) \quad (2)$$

Beide Indices berechnen sich aus den Verhältnissen der zur Vegetationserfassung wichtigen Wellenlangebereiche des roten Lichts (RED) und des Nahen Infrarots (NIR). Zur Berechnung des SAVI wird weiterhin ein Faktor (L) zur Reduzierung des Bodeneinflusses einbezogen. Für L wurde bei der Berechnung des SAVI die Standardeinstellung von 0,5 beibehalten. Als bitemporales Derivat zweier Aufnahmezeitpunkte wurde außerdem die Differenz der SAVI-Indices für die S2-Aufnahmen vom 03.07.2017 und dem 08.03.2017 berechnet. Das generierte Feature enthält somit Informationen über die Veränderung grüner Biomasse zwischen Frühjahr und Sommer. Dies stellt den Versuch dar, eine bessere Trennung der winterkahlen Kastanienbestände von den immergrünen Laubwäldern während der Klassifikation zu ermöglichen.

$$SAVI_{Change} = \frac{NIR_{Sommer}-RED_{Sommer}}{(NIR_{Sommer}+RED_{Sommer}+L)}(1+L) - \frac{NIR_{Frühjahr}-RED_{Frühjahr}}{(NIR_{Frühjahr}+RED_{Frühjahr}+L)}(1+L) \quad (3)$$

4.3.3 Ableitungen des digitalen Geländemodells

Neben Datenderivaten, die aus den Satellitenbilddaten mehr oder weniger direkt abgeleitet werden, zählen vom Sentinel-2-Sensor unabhängige Hilfsdaten zu den unterstützenden Variablen von Landbedeckungsklassifikationen. Vor allem Höhendaten und ihre Ableitungen stellen häufig wertvolle Hilfsvariablen dar, da sie Informationen über höhen- und positionsabhängige Eigenschaften von Bedeckungsklassen bereitstellen können. Auf Grundlage des vorliegenden Geländemodells wurden die in Tab. 1 aufgestellten Variablen in SAGA erzeugt.

Tab. 1: Übersicht zu den berechneten DEM-basierten Variablen.

DEM-Feature	Beschreibung
DEM	Kontinuierliche Höhendaten (Digitales Geländemodell 5x5 m)
Slope	Neigungswinkel der benachbarten DEM-Rasterzellen (TRAVIS et al. 1975)
Aspect	Exposition der DEM-Rasterzellen in 0-360° (TRAVIS et al. 1975)
Topographic Wettness Index (TWI)	Index für den topographischen Kontrolleinfluss auf hydrologische Prozesse (BOEHNER et al. 2002)
Topographic Ruggedness Index (TRI)	Maß der topographischen Heterogenität zwischen benachbarten Rasterzellen (RILEY et al. 1999)
LSfactor	Faktor der Hanglänge, *slope length* (LS); Teil der *Universal Soil Loss Equation* (USLE) (MOORE et al. 1991)
Valley Depth	Vertikale Distanz zur Tiefenlinie
Vertical Distance to Channel Network	Invertierte vertikale Distanz zur Tiefenlinie

4.4 Trainings- und Testdaten

4.4.1 Referenzdaten

Für den Prozess der Trainings- und Testdatensammlung, wurden unterschiedliche Datensätze herangezogen. Darunter Bodennutzungsdaten (*Uso del Suolo*) von 2015 (REGIONE LIGURIA 2017b), Infrarotluftbilder aus dem Jahr 2016 (WMS-Dienst) (REGIONE LIGURIA 2017c), sehr hochauflösende Luftbilddaten und 3D-Geländedarstellung aus den Digital-Globe-Bilddatensätzen von Google Earth (GOOGLE EARTH 2017). Weiterhin wurde zur Gewinnung von Referenzinformationen auf bestehende Beschreibungen und Kartierungen innerhalb des Untersuchungsgebietes zurückgegriffen. Zu diesen Literaturreferenzen und zugehörigen Kartendarstellungen gehören die Vegetationsaufnahmen von NOWAK (1987) und

LINGENHÖHL (2005), Untersuchungen an Brachflächen von CARL & RICHTER (1989), sowie die Landnutzungskartierung von CEVASCO et al. (2013) für das Vernazza-Einzugsgebiet.

4.4.2 Klassifikationssystem

Das für die Bildklassifikation verwendete Kategoriensystem (Klassifikationssystem) mit insgesamt 13 Bedeckungsklassen (Tab. 2) ist das Ergebnis eines Abwägungsprozesses zwischen Informationsgehalt der Referenzdaten, ihrer Adaption auf die Bilddaten und den Eigenschaften der digitalen Kategorien im Sinne von Repräsentativität und Klassentrennbarkeit. Vegetationskundlich betrachtet stützt sich das erstellte Klassifikationssystem vor allem auf die Untersuchungen von LINGENHÖHL (2005) und versucht wesentliche Aspekte der Einordnungen auf spektral abgrenzbare Bedeckungskategorien zu übertragen. Hierzu wurden Klassen zusammengeführt, erweitert oder auch gänzlich ignoriert. Nur durch diese Generalisierung ist es möglich, ein in der angestrebten Bildklassifikation verwendbares Kategoriensystem zu erhalten. Limitiert wurde die Vorgehensweise vor allem durch nicht eindeutig zu bestimmende Bedeckungssituationen oder Widersprüche innerhalb der Referenzdaten.

Tab. 2: Klassifikationssystem mit den verwendeten Bedeckungskategorien.

Klassenname	Code	Beschreibung
Kiefernbestände	PIN	Durch *Pinus pinaster* und/oder deren Aufwuchs dominierte Flächen.
Winterkahle Baumbestände	CAS	Vorwiegend durch *Castanea sativa* gebildeter Bestand. Vor allem in den Kammlagen verbreitet.
Immergrüne Laubbaumbestände	GRE	Umfasst sowohl reine Bestände von *Quercus ilex,* sowie gemischte Laubwaldareale u.a. mit *Quercus pubescens*. *Castanea sativa* kann enthalten sein, dominiert jedoch nicht die Reflexionswerte.
Baumheide	ERI	Durch flächenhafte Vorkommen von *Erica arborea* charakterisierte Macchie. Vorkommen insbes. auf Brachflächen. Häufig mit Aufwuchs von *Pinus pinaster*.
Andere Macchie	MAC	Macchien und Strauchvegetation unterschiedlicher Ausprägung und Wuchshöhe. Stärker von Myrthen, Pistazien, Euphorbien, *Rhamnus alaternus* und anderen Arten dominiert als ERI. Sowohl auf Brachflächen als auch natürliche Vorkommen.
Küstenmacchie	KUE	Macchie der thermomediterranen Zone im Einfluss der Küste. Botanisch von MAC durch Vorkommen von *Euphorbia dendroides* und *Pistazia lentiscus* zu trennen. Zum Teil mit Beständen von *Quercus ilex*, die bis in Küstennähe. Klasse letztendlich nur durch Nähe zur Küste in Bilddaten abgrenzbar.
Gebüsch	GEB	Zumeist dichte Vegetationsdecke aus Polykormonen wie Brombeere (*Rubus ulmifolius*) und anderen Arten. Begleitvegetation entlang von Wegen oder Straßen. Auf Rebflächen meist frühes Brachestadium mit *Rubus ulmifolius.*
Tiefenlinie	TFL	Vegetation der Tiefenlinien und feuchteren Talbereiche, sonst oft wie GEB. Einzelstandorte mit *Alnus glutinosa* möglich.
Spärliche Vegetation	SPR	Bereiche mit lückenhaftem Bewuchs und höherem Einfluss von offenem Boden und Gestein. Auch Garrigueformation auf Serpentinit im Norden des USG (Punta Mesco-Halbinsel).
Wein	WEI	Flächen mit Wein im Spalier- oder Pergolaanbau. Insbesondere auf terrassierten Hangbereichen. Zum Teil jedoch nicht von Gemüseanbau zu unterscheiden.
Oliven	OLI	Von Ölbäumen bestandene Flächen, darunter sowohl bewirtschaftete Olivenhaine, als auch Brachflächen unterschiedlichen Alters mit *Olea europaea*. Je nach Art und Deckung der Begleitvegetation sehr divers.
Ohne Vegetation	NOV	Vegetationsfreie Bereiche mit massivem Gestein, lockerem Schutt oder offenem Boden. Umfasst auch Strandbereiche oder vegetationsfreie Schuttflächen im Bereich von Rutschungen.
Infrastruktur	INF	Wohnbebauung, Straßen und Parkplätze.

4.4.3 Stichprobendesign

4.4.3.1 Trainings- und Testdaten

Da die Konzipierung der vorliegenden Studie keine Sammlung von Felddaten im Sinne einer *Ground Truth*-Datenerhebung vorsah, musste das Stichprobendesign an den Informationsgehalt der zur Verfügung stehenden Referenzdaten angepasst werden. Aus diesem Grund wurde das klassische Sammeln von Trainingspixeln in Form von Polygonen mit als repräsentativ erachteten Pixelclustern angewendet. Vor der Konvertierung in zentroide Punktdaten der einzelnen Referenz-Pixel wurden die Trainingsdaten auf der Ebene der Polygone durch Zufallsauswahl in ein Trainings-Set (~70%) und ein Validierungs-Set (~30%) für die spätere Kreuzvalidierung, im Folgenden als *abhängige Validierung* bezeichnet, aufgetrennt (siehe 4.7). Auf diese Weise soll eine zusätzliche Autokorrelation der ohnehin geclusterten Daten vermieden werden (vgl. BELGIU & CSILLIK 2018:512). Eine Übersicht über Trainings- und abhängige Testdaten gibt Tab. 3.

Tab. 3: Umfang von Trainings- und Referenzdaten zur Kreuzvalidierung auf Polygon- und Pixelebene.

Klasse		Training		Validierung	
		Polygone	Pixel	Polygone	Pixel
Kiefern	PIN	29	2581	12	788
Winterkahle Laubbäume	CAS	13	3237	6	1144
Immergrüne Laubbäume	GRE	21	1689	9	823
Baumheide	ERI	15	910	6	256
Andere Macchie	MAC	17	1533	7	688
Küstenmacchie	KUE	14	739	6	235
Gebüsch	GEB	12	412	6	150
Vegetation der Tiefenlinien	TFL	11	250	4	107
Spärliche Vegetation	SPR	8	434	2	186
Wein	WEI	22	931	9	359
Oliven	OLI	14	766	6	297
Ohne Vegetation	NOV	14	617	4	292
Infrastruktur	INF	18	840	8	272
Gesamt		209	14939	85	5597

Um eine Abweichung der Proportionalität der Trainingsklassen von den realen Flächenanteilen des Untersuchungsgebiets begrenzt zu halten, wurden die Anteile mit korrespondierenden Klassen aus der für Ligurien vorliegenden Landnutzungskartierung von 2015 (REGIONE LIGURIA 2017b) verglichen. Ein annähernd direkter Vergleich konnte jedoch nur in wenigen Fällen, etwa bei Nadelwald, angestellt werden.

4.4.3.2 Unabhängige Validierung mit geschichteter Zufallsstichprobe

Im Gegensatz zur Kreuzvalidierung durch ungenutzte aber statistisch abhängige Trainingsdaten stellt die Überprüfung mit Hilfe von unabhängigen Zufallsstichproben ein objektiveres Genauigkeitsmaß für thematische Klassifikationsergebnisse dar (CONGALTON 1991:36). Zur Überprüfung der Genauigkeit des Klassifikationsergebnisses wurden dazu insgesamt 975 geschichtete Zufallsstichproben erzeugt.

Die Schichtung der Stichprobe soll die Stichprobenanzahl von 30 Pixeln pro Klasse garantieren und so die Einbeziehung der geringvertretenden Klassen gewährleisten. Stichproben, die entweder keiner Bedeckungsklasse zugeordnet werden konnten oder deren Einordnung durch fehlende Referenzdaten

äußerst spekulativ ausgefallen wäre, wurden aus dem Set entfernt. Das verbleibende unabhängige Validierungsset umfasst abschließend insgesamt 944 Stichproben zu mindestens 34 Samples pro Klasse (Tab. 4).

Tab. 4: Anzahl und Verteilung der geschichteten Zufallsstichprobe nach Klassen.

Klasse	Code	Anzahl (Pixel)	Klasse	Code	Anzahl (Pixel)
Kiefern	PIN	97	Vegetation der Tiefenlinien	TFL	34
Winterkahle Laubbäume	CAS	53	Spärliche Vegetation	SPR	65
Immergrüne Laubbäume	GRE	129	Wein	WIE	44
Baumheide	ERI	87	Oliven	OLI	45
Andere Macchie	MAC	111	Ohne Vegetation	NOV	78
Küstenmacchie	KUE	48	Infrastruktur	INF	73
Gebüsch	GEB	80	**Gesamt**		**944**

4.5 Random Forest-Klassifikation

Die praktische Durchführung von Modellbildung und Klassifikation mittels Random Forest wurde für diese Studie zum Zweck der Analyse und Evaluation von Daten und Methode in der Open-Source-Statistiksoftware R (R CORE TEAM 2017) umgesetzt. Durch die Nutzung der R-Packages „randomForest" (LIAW & WIENER 2002), „raster" (HIJMANS 2017), „sp" (PEBESMA & BIVAND 2005) sowie "rgdal" (BIVAND et al. 2017) konnte die Einbindung von Raster- und Geodaten sowie die Durchführung der Random Forest-Klassifikationen in R durchgeführt werden.

Da jede RF-Klassifikation, aufgrund ihres Zufallseinflusses (s. 2.4) trotz gleicher Trainings- und Eingabedaten, leicht unterschiedliche Ergebnisse liefert, empfiehlt es sich zu diagnostischen Zwecken, die Klassifikationsergebnisse mehrerer Durchläufe zu mitteln. Zur Automatisierung dieses Vorgangs wurde auf die Schleifen-Funktion des von MILLARD & RICHARDSON (2015) veröffentlichten R-Skriptes zurückgegriffen. Alle Klassifikationen, die zu Vergleichszwecken durchgeführt wurden, waren mit einer Anzahl von tausend Entscheidungsbäumen (N*tree* = 1000) und einer einzigen zufälligen Spaltungsvariable (M*try* = 1) für die Generierung der *Split-Points* der Bäume justiert. Die relativ hohe Anzahl an Bäumen soll eine robuste Schätzung garantieren, gleichzeitig kann ein höherer Wert für N*tree* keinen Negativeinfluss auf die Modellgenauigkeit haben (BELGIU & DRĂGUŢ 2016:25). Die Wahl von M*try* geschieht zugunsten von vergleichbaren Ergebnissen und zur Vermeidung einer gesteigerten Gefahr für eine Überanpassung des Modells. Erst zum Ende der Analysephase wurde der Wert für M*try* angepasst, um ein bestmögliches Endergebnis zu erhalten.

4.6 *Feature Selection*

Ziel der Variablenauswahl, bzw. der sogenannten *Feature Selection*, ist die Ermittlung einer möglichst geringen Anzahl an effektiven Eingabevariablen, d.h. die Reduzierung ohne Verlust an wichtigen Informationen. Durch den Prozess soll der Rechenaufwand des Modells verringert und gleichzeitig die Genauigkeit der Klassifikation verbessert werden. Zu diesem Zweck wurde die Variablenwichtigkeit, in Form der Maße *Mean Decrease in Accuracy* (MDA) sowie *Mean Decrease in GINI* (MDG), für jede der insgesamt 181 initial verwendeten Variablen herangezogen. Weiterhin wurde für jede Landbedeckungskategorie die klassenspezifische Variablenwichtigkeit in Form der MDA abgeleitet. Zur Übersichtlichkeit und um Veränderungen innerhalb des Modells mit zunehmender Entfernung von Redundanz und Rauschen im Auswahlprozess zu berücksichtigen, wurde mit jeder erfolgten Reduzierung der Variablen auf die Wichtigkeitsmaße des jeweils verkleinerten Datensets zurückgegriffen.

Zur Reduzierung der Dimensionalität des Datensatzes wurden die Eingabevariablen sukzessiv um zunächst jeweils 10% ihrer unwichtigsten Features, d.h. jene mit der niedrigsten MDA-Wertung, reduziert und jeweils die gemittelten Fehlerraten aus fünf Klassifikationsdurchläufen (N*tree*=1000, M*try*=1) des jeweils verkleinerten Datensatzes ermittelt.

Um die unterschiedliche Bedeutung der ausgewählten Landbedeckungsklassen für die Fragestellung dieser Studie zu berücksichtigen, wurde die Entscheidung über die zu löschenden Variablen nicht allein durch das Maß der MDA für das gesamte Modell bestimmt, sondern die Variablenwichtigkeiten für jede einzelne Bedeckungsklasse herangezogen. Variablen, die sich unter den wichtigsten Variablen für eine Klasse befinden, wurden vorwiegend vor einer Löschung bewahrt. Auf diese Weise soll das Aussortieren von Variablen verhindert werden, die für die Gesamtgenauigkeit von eher geringer Bedeutung sind und dennoch Abgrenzungsmerkmale für bestimmte Bedeckungsklassen liefern. Zur detaillierteren Betrachtung der ermittelten Wichtigkeitsmaße siehe SANDNER (2018).

Neben der Ermittlung von Wichtigkeitsmaßen wurde außerdem ein Rangkorrelationstest nach Spearman für jede paarweise Variablenkombination durchgeführt. Die Ergebnisse wurden genutzt, um stark miteinander korrelierte und daher redundante Variablen zu identifizieren und im Entscheidungsprozess zumeist jene mit der niedrigeren Feature-Wichtigkeit zu entfernen. Es wurden vor allem besonders starke Korrelationen von mindestens r_s= > 0,9 bzw. r_s= < -0,9 als Entscheidungskriterium verwendet, um jene Variablen zu konservieren, die zumindest einen Teil an potenziell zusätzlichen Informationen enthalten. Zur Bestätigung der Korrelation wurden außerdem die zugehörigen p-Wert überprüft. Nur Korrelationen mit einem p-Wert von < 0,05 (5%-Signifikanzniveau) führen zur Ablehnung der Nullhypothese (es besteht kein Zusammenhang der Variablen untereinander). Die Ergebnisse des Korrelationstests sind in der Anlage der dieser Veröffentlichung zugrundeliegenden Arbeit in digitaler Form enthalten (siehe SANDNER 2018).

Ausnahmen im Prozess der Variablenauswahl stellen jedoch Fälle von offensichtlich fehlerbeeinflussten Wichtigkeits-Einschätzungen des Modells dar. Diese wurden im Einzelfall durch die Hinzunahme von Zusatzinformationen aus der Literatur (vgl. CLAUSI 2002, HALL-BEYER 2017b) beurteilt. Indem die Klassifikationsgenauigkeit vor und nach dem Aussortieren einer bestimmten Variablen verglichen wurde, konnten zudem im Einzelfall Kosten-Nutzen-Entscheidungen getroffen werden. Diese Lösung wurde aufgrund ihres vergleichsweise hohen Zeit- und Arbeitsaufwands jedoch nur eingesetzt, wenn erhebliche Zweifel an den restlichen Auswahlkriterien bestanden.

Es soll an dieser Stelle darauf hingewiesen werden, dass die angewendete Methodik zur Variablenreduzierung keiner strengen und standardisierten Reglementierung unterworfen wurde. Einzelfallentscheidungen, bei denen eine Variable im Widerspruch zu einem der genutzten Auswahlkriterien aus dem Datensatz entfernt wurde, sind in dieser Vorgehensweise ausdrücklich nicht ausgeschlossen. Den Autoren ist bewusst, dass dadurch die Subjektivität der Analyse gesteigert und die Reproduzierbarkeit dieses Arbeitsschrittes verringert wird. Da jedoch nicht die systematische Evaluierung dieses Auswahlprozesses im Vordergrund dieser Studie steht, soll der Erfolg dieser Vorgehensweise lediglich anhand der entstandenen Genauigkeitsveränderungen bemessen werden (siehe 5.2).

4.7 Genauigkeitsanalyse

In dieser Studie wurde zur Evaluierung und Interpretation des Modells auf eine Kreuzvalidierung unter Verwendung der zuvor von den Trainingsdaten getrennten Testdaten zurückgegriffen (s. 4.4.3.1). Diese Art der Validierung wurde für den Vergleich des Klassifikationserfolges unterschiedlicher Datensets genutzt. Zusätzlich wurde das unabhängige Sampling mit insgesamt 944 zufällig über das Untersuchungsgebiet verteilten Validierungspunkten verwendet (s. 4.4.3.2). Diese objektivste der hier verwendeten Validierungsmethoden dient der Relativierung von Aussagen zur Modellgenauigkeit und um Rückschlüsse auf die Qualität der Trainingsdaten und das Kategoriensystem anzustellen.

Da Random Forest-Modelle, bedingt durch ihre Funktionsweise, stets eine Zufallskomponente enthalten, wurden die Genauigkeiten der geprüften Modelle bzw. Datenkombinationen stets auf Grundlage mehrerer Klassifikationsdurchläufe berechnet.

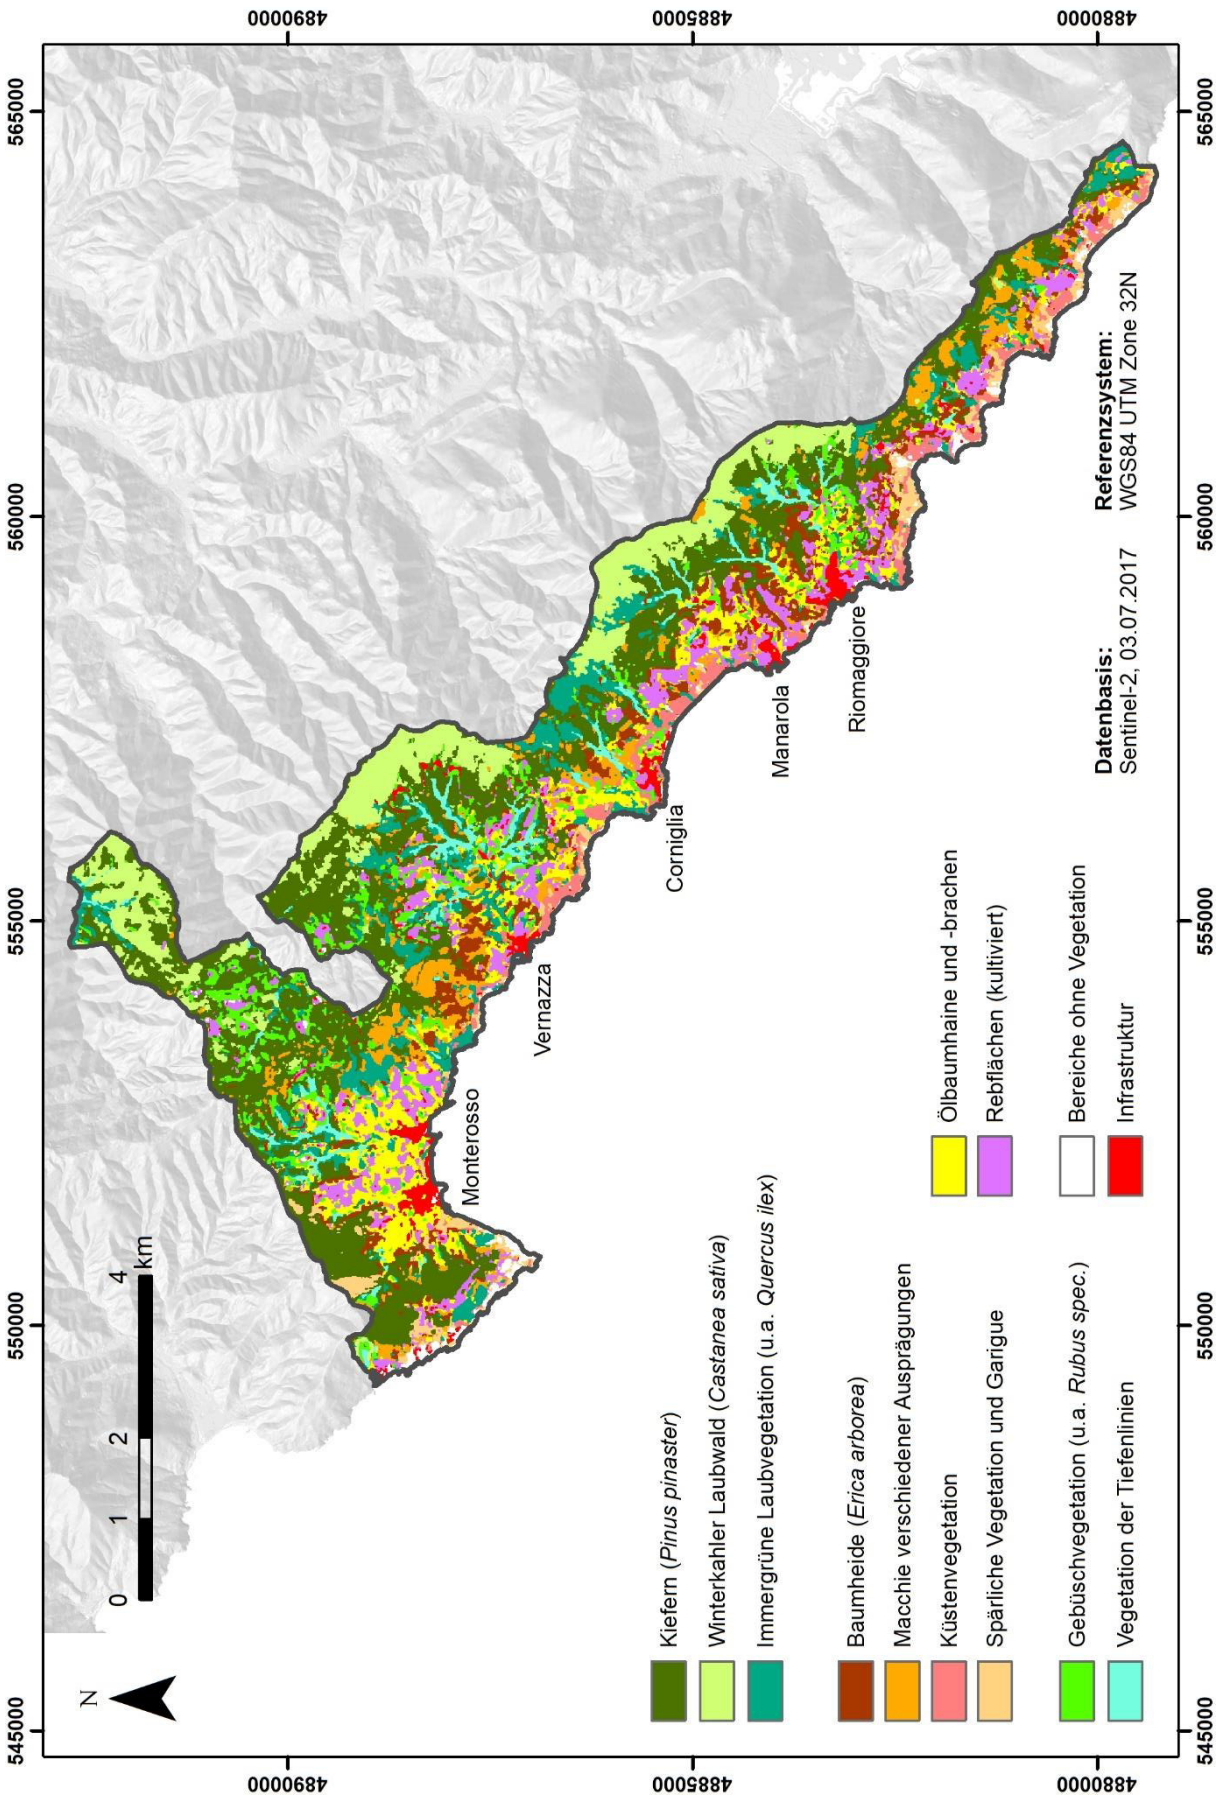

Abb. 6: Landbedeckung des Nationalparks Cinque Terre basierend auf Sentinel-2 Bilddaten und digitalen Höhendaten (REGIONE LIGURIA 2017a).

5 Ergebnisse

Die Landbedeckungsklassifikation für den Nationalpark Cinque Terre ist in Abb. 6 als thematische Karte dargestellt. Die Ergebnisse der Feature Selection und der iterativen Analyse der Klassifikationsgenauigkeiten werden im Folgenden beschrieben. Für eine ungekürzte Ergebnisdarstellung sei an dieser Stelle auf SANDNER (2018) verwiesen.

5.1 Variablenwichtigkeit

Als wichtige Größen bei der Auswahl bedeutungsschwerer Variablen fanden die Wichtigkeitsmaße OOB-*Mean Decrease in Accuracy* (*MDA*) und *Mean Decrease in Gini* (*MDG*) Verwendung. Zur Begrenzung des Arbeitsaufwandes wurden die Werte stets als "Momentaufnahme" aus einem Klassifikationsdurchlauf pro Reduzierungsstufe entnommen. Die sich aus den Maßen ergebende Rangfolge unter den Variablen wurde genutzt, um schrittweise die vermeintlich unwichtigsten Variablen aus den Eingabedaten zu entfernen.

Eine detaillierte Beschreibung und Diagramme zu den Wichtigkeitsmaßen der 30 höchstbewerteten Variablen für eine Klassifikation mit allen 181 Variablen sowie die Darstellung spezifischer MDA-Wichtigkeiten für die einzelnen Bedeckungsklassen finden sich in bei SANDNER (2018). Hervorzuheben sei an dieser Stelle die nahezu durchweg hoch eingestufte Wichtigkeit der Variable "Elevation" (unveränderte Höhendaten des digitalen Geländemodells).

Ebenfalls offensichtlich wurde eine gewisse Redundanz bei der Bewertung vieler Textur-Variablen. Die starke Korrelation innerhalb dieser Variablengruppe führte zu einem Verdrängen der Sentinel-Bänder und der DEM-Derivate auf die mittleren Rangplätze der Wichtigkeitsskala und muss bei der Variablenreduzierung berücksichtigt werden.

5.2 Variablenreduzierung

Unter Berücksichtigung der Variablenwichtigkeit und der Spearman-Rangkorrelation konnte das Variablenset kontinuierlich unter zugleich sinkender Fehlerrate der auf 23 Variablen reduziert werden (Abb. 7). Dies entspricht einer Reduktion um 87%. Erst bei weiterer Verkleinerung des Datensatzes wird ein Wiederanstieg der Fehlerrate festgestellt. Dieser Trend zeigt sich sowohl bei der Genauigkeitsermittlung durch abhängige Kreuzvalidierung, als auch durch die Überprüfung mit unabhängiger Zufallsstichprobe. In Tab. 5 sind die verbleibenden Variablen aufgelistet, die nach der durchgeführten Analyse als verbessertes „reduziertes“ Eingabedatenset angenommen werden.

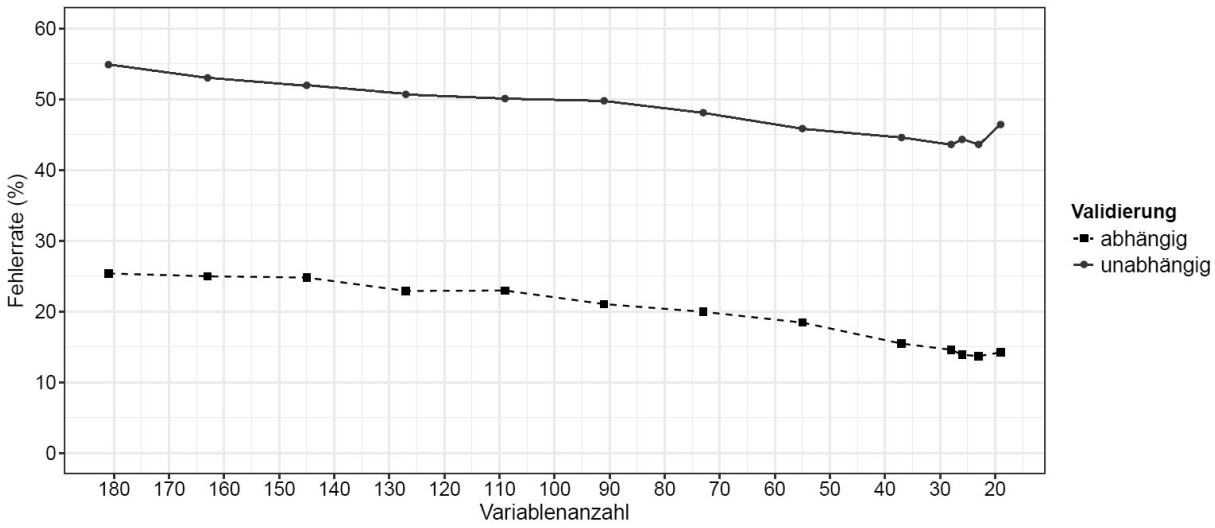

Abb. 7: Entwicklung der Fehlerrate aus abhängiger und unabhängiger Validierung mit zunehmender Reduzierung der Variablenanzahl (mittlere Fehlerraten von jeweils fünf RF-Iterationen).

Abweichungen innerhalb der gelisteten Variablen im Vergleich zur Rangordnung der Wichtigkeitsvariablen begründen sich auf den unter 4.6 beschriebenen zusätzlichen Auswahlkriterien der Korrelation oder Überprüfung der Genauigkeitsänderung, sowie der Veränderung der Wichtigkeitsmaße im Zuge der Variablenreduzierung.

Tab. 5: Nach Abschluss der Variablenauswahl verbleibende Features (V=23) im reduzierten Variablenset.

S2-Bänder	Indices	DEM-Features	GLCM-Features	S2-Bänder	Indices	DEM-Features	GLCM-Features
B2	SAVI	Elevation	B4_Contr_11x11	B6		LSfactor	B8_Var_9x9
B3	SAVI. change	Slope	B4_Corr_11x11	B8			B8_Contr_11x11
B4		Valley Depth	B4_Mean_11x11	B11			B8_Entr_11x11
B5		VertDistCN	B4_Var_x11	B12			B8_Corr_11x11

5.3 Klassifikationsgenauigkeiten

Mit der Durchführung von iterativen Random Forest-Klassifikationen mit unterschiedlichen Eingabedatensets können Klassifikationsgenauigkeiten, bzw. Fehlerraten, unterschiedlicher Eingabedatensets miteinander verglichen werden. Herausgearbeitet werden können so unterschiedliche Aspekte: (1) Der Genauigkeitsgewinn durch die Hinzunahme von Hilfsvariablen im Allgemeinen, sowie der Einfluss der Variablenreduzierung. (2) Der Anteil des Genauigkeitsgewinns von höhenbasierten Variablen, Textur-Variablen und der multitemporalen SAVI-Variable. (3) Der Einfluss der Verwendung der Terrainkorrektur während der atmosphärischen Korrektur der Sentinel-2-Bildkanäle.

5.3.1 Einfluss der Hilfsvariablen und der Variablenreduzierung

Unabhängig von der Art der Validierungsmethode zeigt sich, dass die Fehlerrate mit dem reduzierten Variablenset deutlich stärker gesenkt werden konnte, als durch eine unbegrenzte Verwendung der erzeugten Hilfsvariablen (Abb.8).

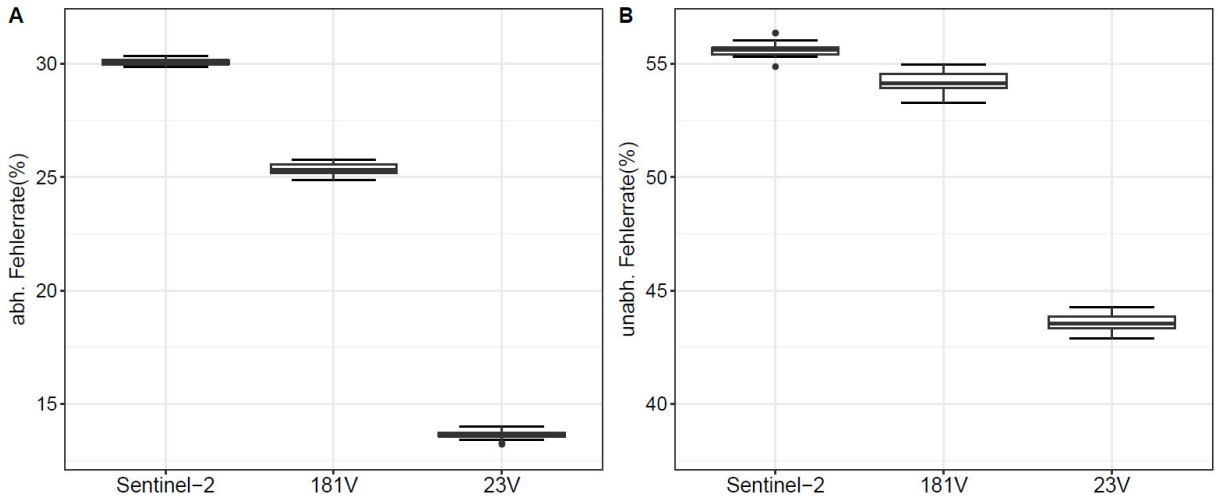

Abb. 8: Vergleich der Fehlerraten unterschiedlicher Eingabedaten in abhängiger Validierung (A) und unabhängiger Validierung (B) in Abhängigkeit vom Eingabedatenset: Sentinel-2 = alle Sentinel-2-Bänder, 181V = erweitertes Variablenset vor Reduzierung, 23V = erweitertes Variablenset nach Reduzierung (n=25).

Die Fehlerrate konnte so, im Vergleich zur Klassifikationsgenauigkeit, die allein durch Verwendung der Sentinel-Bänder erreicht wurde, um etwa 12 % (unabhängige Validierung) bzw. 16,4 % (abhängige Validierung) verringert werden. Der Genauigkeitsgewinn durch die Reduzierung der Variablen beträgt in beiden Betrachtungsweisen knapp mehr als 10%.

5.3.2 Einfluss der Variablengruppen und Vorverarbeitung

Der Vergleich des Einflusses bestimmter Variablengruppen auf die Klassifikationsgenauigkeiten zeigt, dass die Fehlerrate am deutlichsten durch die Verwendung der DEM-Variablen reduziert werden konnte (ca. 8%), während die Bitemporale SAVI-Variable zumindest in der unabhängigen Validierung eine geringe Verbesserung der Genauigkeit erzeugt. Auch ein positiver Einfluss der Terrain-Korrektur im Zuge der Vorverarbeitung der Satellitenbildszene mit Sen2Cor bildet sich in den Fehlerraten der betrachteten Klassifikationsiterationen ab. Für eine detailliertere Beschreibung weiterer Ergebnisse und deren graphische Darstellung siehe SANDNER (2018).

Die aus den bisher beschriebenen Ergebnissen hervorgegangenen Klassifikationsgenauigkeiten liegen in der bestmöglichen ermittelten Klassifikation bei einer globalen, d.h. für die gesamte Klassifikation durchschnittliche Gesamtgenauigkeit von > 85% in der abhängigen Validierung. Eine objektivere Einschätzung der Gesamtgenauigkeit stellt die Genauigkeitsanalyse mittels unabhängiger Stichprobe dar. Die Fehlerrate, ermittelt durch unabhängige Validierung, ist mit 43,5% im Median um knapp 30% höher als die durch abhängige Validierung erhaltene.

5.4 Klassenspezifische Genauigkeiten und Fehlermatrix

Die bisher dargestellten Gesamtgenauigkeiten lassen nur sehr begrenzt Rückschlüsse auf die Genauigkeiten einzelner Bedeckungsklassen zu. Um die Ursachen der Klassifikationsfehler zu ergründen empfiehlt es sich, die Betrachtung der Klassifikationsgenauigkeiten für jede im Klassifikationssystem enthaltene Klasse einzubeziehen. Abb. 9 zeigt die Verteilung der klassenspezifischen Genauigkeiten in der unabhängigen Validierung.

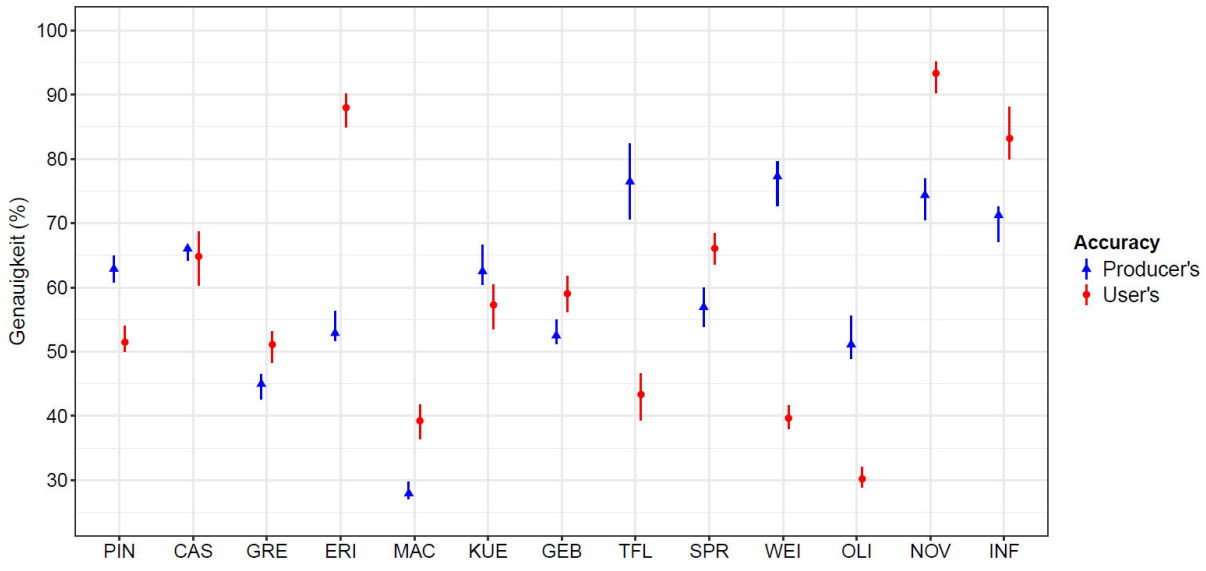

Abb. 9: Median und Spannweite der klassenspezifischen Producer's Accuracy (PA) und User's Accuracy (UA) aus unabhängiger Validierung mit 25 Klassifikations-Wiederholungen.

Dargestellt sind die Maße *Producer's Accuracy* (PA) und *User's Accuracy* (UA). Die Producer's Accuracy, ist ein Maß dafür, wie häufig in den Referenzdaten mit einer bestimmten Klasse bezeichneten Elemente auch wirklich als diese klassifiziert werden. Die PA macht somit Aussage über das Ausmaß an Auslassungsfehlern (*Errors of Omission*). Im Gegensatz dazu erfasst die User's Accuracy die Fehler der

fälschlichen Hinzunahme (*Errors of Commission*) und zeigt bei einer geringen Ausprägung an, dass viele Bildelemente, die einer bestimmten Kategorie zugeschlagen werden, in den Referenzdaten jedoch anderen Klassen zugeordnet sind. Unter Hinzunahme einer kompletten Fehlermatrix (*confusion matrix*) für eine einzelne RF-Klassifikation können zudem Aussagen über die Richtungen der Fehlklassifizierungen angestellt werden. Tab. 6 zeigt die Fehlermatrix einer Klassifikation des optimalen Variablensets (ntree = 1000, mtry = 1) erhalten durch unabhängige Validierung.

Klassen, die durch die Ergebnisse der unabhängigen Validierung (Abb. 9, Tab. 6) als überschätzt angesehen werden können, sind vor allem WEI, OLI und TFL. Sie weisen eine im Vergleich zur PA mind. um 20% niedrigere UA auf. Geringere Überschätzungen finden sich auch bei PIN und KUE.

Auffällig ist weiterhin die geringe PA der Klasse ERI. Eine größere Anzahl der Validierungsstichproben dieser Klasse wurde stattdessen als PIN klassifiziert. Weitere Fehlklassifikationen führten außerdem zu falschen Zuschlägen von ERI-Referenzen bei den Klassen OLI und MAC. Umgekehrt verhält sich die Klasse WEI, die durch Überschätzung vor allem auch dort klassifiziert wurde, wo SPR oder INF, seltener auch GEB, die Referenz darstellen.

Tab. 6: Konfusionsmatrix für eine Klassifikation mit reduziertem Variablenset, unabhängige Validierung (n=944, Kappa = 0,53).

	Referenzdaten												
Klasse	PIN	CAS	GRE	ERI	MAC	KUE	GEB	TFL	SPR	WEI	OLI	NOV	INF
PIN	**59**	5	13	18	9	0	3	0	3	0	3	3	1
CAS	7	**35**	5	0	1	0	2	2	0	0	0	0	0
GRE	10	6	**58**	2	16	9	5	4	2	0	3	3	0
ERI	2	0	0	**46**	1	1	0	0	0	0	1	0	0
MAC	4	2	30	6	**32**	1	1	1	0	0	3	0	0
KUE	0	0	5	2	6	**29**	2	0	5	0	2	0	0
GEB	6	3	5	1	10	0	**43**	3	0	2	0	0	0
TFL	2	2	10	1	8	0	10	**24**	0	0	0	0	0
SPR	4	0	0	1	3	6	0	0	**37**	0	0	4	0
WEI	1	0	1	4	2	1	6	0	15	**35**	8	5	11
OLI	2	0	2	6	23	1	8	0	1	5	**25**	0	7
NOV	0	0	0	0	0	0	0	0	1	0	0	**59**	2
INF	0	0	0	0	0	0	0	0	1	2	0	4	**52**
PA [%]	60,82	66,04	44,96	52,87	28,83	60,42	53,75	70,59	56,92	79,55	55,56	75,64	71,23
UA [%]	50,43	67,31	49,15	90,20	40,00	56,86	58,90	42,11	67,27	39,33	31,25	95,16	88,14

Die Klassen mit der höchsten Fehlerquote (MAC, OLI) weisen unterschiedliche Gründe für ihr schlechtes Abschneiden auf. Während MAC mit einer geringen PA (<30%) vor allem durch Fehlklassifizierungen an nahezu alle Vegetationsklassen an Genauigkeit verliert, ist OLI eine offensichtlich überschätzte Klasse mit einer schlechten UA (<32%), die insbesondere zur falschen Klassifikation bei anderen Klassen führt.

5.5 Visuelle Beurteilung

Ergänzend zur statistischen Auswertung kann die visuelle Interpretation ausgewählter Bildbereiche zum besseren Verständnis der Klassifikationsergebnisse beitragen.

Die starke Fragmentierung der Landschaft des Untersuchungsgebiets äußert sich insbesondere in den Bildbereichen, die die mittleren Hangbereiche abbilden (Abb. 10). Dennoch führt die räumliche Auflösung der Sentinel-Bilddaten automatisch zu einer Generalisierung kleinräumiger Unterschiede. Das Nebeneinander von Weinbau und Baumheide auf den Hangbereichen kann im Rahmen dieser Einschränkung relativ gut wiedergegeben werden. Die Klassifikation von Infrastruktur zeigt vor allem bei schmalen oder in diagonaler Richtung des Bildrasters verlaufenden Straßen wenig Erfolg. Schwer zu beurteilen ist die Verbreitung der Klasse OLI, da sie sowohl bewirtschaftete, als auch brachliegende

Flächen beinhaltet und zudem nur unsicher validiert werden konnte. Bei Betrachtung eines ausgewählten Hanges, aus dessen Bildbereich keine Trainingsdaten gewonnen wurden, lassen sich exemplarisch Aussagen über die Klassifikationseigenschaften machen.

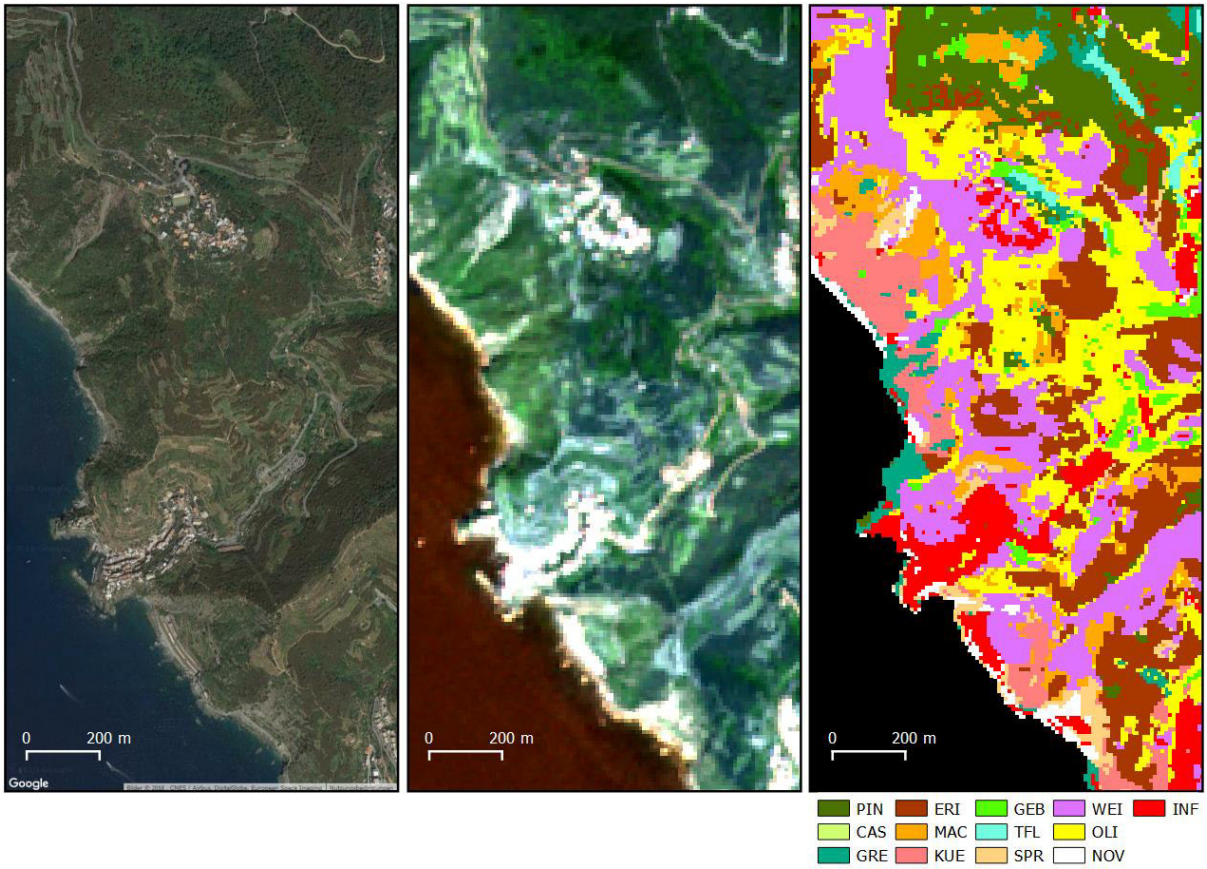

Abb. 10: Vergleich von Klassifikation und Bilddaten. Sehr hochauflösende Bilddaten (GOOGLE EARTH 2017), Sentinel-2-Bilddaten und RF-Klassifikation (v.l.n.r.).

Der in Abb. 11 dargestellte Hangbereich im Norden Manarolas weist die im Untersuchungsgebiet typische Koexistenz von bewirtschafteten Rebgärten und brachliegenden Flächen in unterschiedlichen Sukzessionsstadien auf. Größere, zusammenhängende Bereiche aus Brachen mit Baumheideanteil finden sich im Klassifikationsergebnis wider.

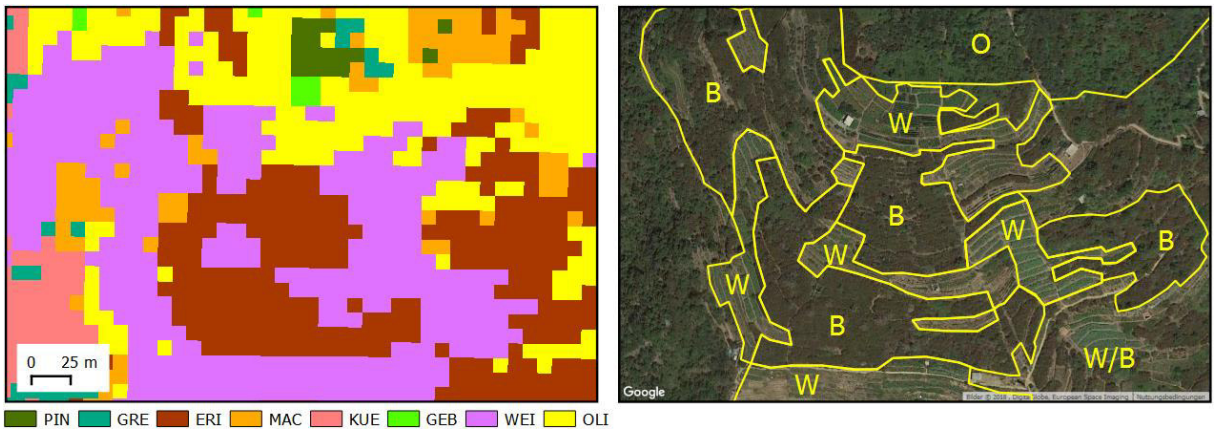

Abb. 11: Detailansicht eines Komplexes aus Reb- und Brachflächen im Norden von Manarola. Links: RF-Klassifikation. Rechts: Grobe Kartierung nach Google-Bilddaten (B = Brache, W = Wein, O = Oliven) (Datengrundlage: GOOGLE EARTH 2017).

Die Abbildung kleinräumiger Wechsel der Landbedeckung bzw. Landnutzung kann jedoch in den meisten Bildbereichen durch die begrenzte räumliche Auflösung der Sentinel-2-Bilddaten nicht erfolgen. Für Fehlklassifikationen sorgen außerdem Bereiche in denen brachliegende Flächen einen heterogenen Charakter mit kleinräumigen Unterschieden in Alter und Bedeckungsgrad der Sukzession aufweisen (Brachfläche im Nordwesten des Bildausschnittes). Im oberen Bildausschnitt wird zudem die Überschätzung der Klasse OLI zum Nachteil der Rebflächen (WEI) deutlich.

Abb. 12 zeigt vorwiegend als Weinbau klassifizierte Bereiche mit unterschiedlichen Kultur- und Anbauformen. Nutzflächen dieser Art bilden aufgrund ihres sporadischen Charakters keine eigene Kategorie im Klassifikationssystem und können nach der gewählten Klasseneinteilung nicht korrekt klassifiziert werden.

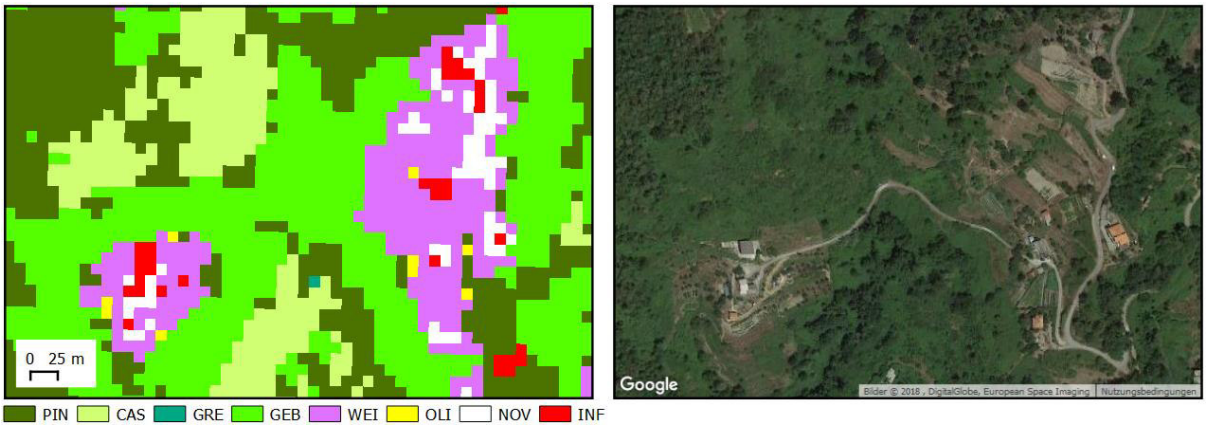

Abb. 12: Detailansicht eines Gebietsbereiches mit als Wein klassifizierten Anbauflächen mit komplexeren Anbaumustern. Links: RF-Klassifikation. Rechts: Google-Bilddaten (GOOGLE 2017).

6 Diskussion

6.1 Einordnung unterschiedlicher Validierungsmethoden

In der vorliegenden Arbeit wurden unterschiedliche Maße zur Überprüfung der Klassifikationsgenauigkeiten verwendet, um deren Vor- und Nachteile abschätzen zu können. Die prinzipiell abhängige Out-Of-Bag-Fehlerrate ist nur unter schwer zu erreichenden Eigenschaften der Trainingsdaten hinsichtlich Größe, Repräsentativität, Proportionalität und räumlicher Verteilung geeignet, um die Genauigkeit des Models in Bezug auf die Klassifikation zu beurteilen (MILLAR & RICHARDSON 2015:8509). In der Praxis ist die Kreuzvalidierung unter Verwendung von zurückgehaltenen Trainingsdaten eine häufig genutzte Vorgehensweise um Genauigkeitswerte zu erzeugen. Liegen die Trainingsdaten allerdings wie in dieser Arbeit als Pixelcluster vor, so führt dies zwangsläufig zu einer räumlichen Autokorrelation. Die Zufallsauswahl der Test-Cluster für die Validierung erfolgt weiterhin innerhalb der zuvor vom Nutzer nicht zufällig ausgewählten Trainingsdaten. Diese Einschränkungen ergeben in der Praxis eine bedeutende Differenz der ermittelten Genauigkeitswerte zwischen Kreuzvalidierung und rein zufälliger Stichprobe die in der vorgestellten Analyse etwa 30% beträgt (Kapitel 5.3.2).

6.2 Untersuchungs- und Stichprobendesign

Ein optimales Stichprobendesign für Random Forest-Anwendungen zeichnet sich nach MILLARD & RICHARDSON (2015) durch ein unabhängiges, proportionales und möglichst wenig autokorreliertes Sampling aus. Dies ist in der Praxis nur durch die zufällige Verteilung von Einzelproben über das gesamte Untersuchungsgebiet möglich und wird in der Anwendung, insbesondere bei heterogenen Untersuchungsgebieten mit einer hohen Anzahl an Klassen ein kaum zu verwirklichender Idealzustand bleiben (MILLARD & RICHARDSON 2015:8509). In der Praxis haben Anwender meist nur eine begrenzte

Menge an Referenzdaten zur Verfügung. Zeitlicher Aufwand für Geländeerhebungen oder Interpretation von sehr hochauflösenden Bilddaten muss weiterhin begrenzt bleiben. Es besteht daher stets eine Tauschhandel-Situation zwischen Qualität und Quantität von Trainingsdaten.

Da ein randomisiertes Stichprobendesign zur Erhebung von Trainingsdaten in der Praxis meist kein realisierbares Szenario darstellt, wird es in den meisten Fällen durch eine nutzerabhängige Auswahl vermeintlich repräsentativer Referenzflächen, passend für das ausgearbeitete Klassifikationssystem, ersetzt. Durch diese Vorgehensweise gelangt jedoch ein höheres Maß an Subjektivität in den Prozess der Datensammlung, was alle folgenden Arbeitsschritte und Ergebnisse mit einem gewissen Fehler behaftet. Einflussfaktoren sind hier räumliche Autokorrelation, Vermeidung von Randpixeln (Problem der „harten" Klassifikation) unausgewogene Klassenanteile innerhalb der Trainingsdaten, Mangel an echter Repräsentativität oder der Vernachlässigung von Nicht-Zielklassen.

Nicht zuletzt stellt selbstverständlich auch die ausschließlich indirekte, d.h. aus Bilddaten und Literaturreferenzen abgeleitete, Akquise von Trainings- und Testdaten ohne eigene *in-situ*-Gebietskenntnis einen Unsicherheitsfaktor dar.

Die Diskrepanz zwischen der in Form von Kreuzvalidierung ermittelten Fehlerrate und der durch unabhängiges Sampling ermittelten Genauigkeit der RF-Klassifikation spiegelt auch die Distanz zwischen Realität und den genutzten Trainingsdaten wider. Sie zeigt deutlich, wie wichtig und zugleich anspruchsvoll das Erzeugen von repräsentativen Stichproben ist.

6.3 Random Forest-Klassifikation und Variablenauswahl

Die Verwendung des Random Forest-Klassifikators konnte, unter den bisher genannten Einschränkungen, wirksam auf die Sentinel-2 Daten angewendet werden. Dabei ermöglichte es die Methode, nicht nur die Sensor-Daten der Optik, sondern auch wertvolle Hilfsdaten und Datenderivate in den Klassifikationsprozess einzubeziehen. Random Forest-Modelle stellen allerdings insofern Black-Box-Anwendungen dar, dass ihr Entscheidungsprozess durch die hohe Anzahl an Entscheidungsbäumen und zufälliger Generierung (jedes RF-Modell ist geringfügig anders) kaum nachzuvollziehen ist. Im Gegensatz zu anderen Klassifikatoren des maschinellen Lernens können Random Forests dennoch in begrenztem Maße interpretiert werden. Grund dafür sind die geringe Anzahl an Eingabeparametern und die Möglichkeit zur Betrachtung von verschiedenen Ausgabestatistiken. Die vergleichsweise kurze Rechenzeit ermöglicht zudem iterative Klassifikationen aus deren Ergebnissen auf den Einfluss einzelner Änderungen am Modell geschlossen werden kann. Auf diese Weise kann ein „bestmögliches" Modell zur Schätzung von den Trainingsdaten auf den Rest der Bildszene ermittelt werden.

Feature Selection und Variablenwichtigkeit

Die Ergebnisse aus 5.2 und 5.3.1 zeigen, dass die Variablenreduzierung zu einer Verringerung der Fehlerrate um mehr als 10% im Vergleich zur Klassifikation mit allen erzeugten Variablen geführt hat. Dies unterstreicht die Notwendigkeit einer Reduzierung hochdimensionaler Datensätze im Vorfeld der Klassifikation und bestätigt die Wirkung des sogen. Hughes-Phänomens (HUGHES 1968), nach dem eine erhöhte Dimensionalität zugleich erhöhte Anforderungen an das beschreibende Modell stellt. Da die in dieser Arbeit verwendete Datenmenge im Vergleich zu anderen Analysen eher gering ist (vgl. GHOSH et al. 2014:51) muss auch von einem Einfluss fehlleitender Informationen innerhalb des Datensatzes ausgegangen werden. Im Zuge der Variablenauswahl wurden diese Informationen zunehmend aus dem Datensatz entfernt.

Da die in dieser Arbeit verwendeten Methoden zur *Feature Selection* direkt oder indirekt auf den verwendeten Trainingsdaten basieren, hängt der Erfolg dieser Methode stark von der Qualität dieser Daten ab. Die Varianz der vollständigen Variablen ist nicht berücksichtigt worden. Möglichkeiten dazu

bieten beispielsweise Hauptkomponentenanalysen (z.B. BERBEROGLU et al. 2007:332) oder ebenfalls modellunabhängige Wrapper-Methoden (z.B. KURSA & RUDNICKI 2010).

Einschränkungen des verwendeten Ansatzes wurden auch in der Interpretierbarkeit der Wichtigkeitsmaße aus der RF-Klassifikation ausgemacht. Die Statistiken von MDA und MDG ergeben unter Umständen wenig verlässliche oder gar fehlleitende Variablenrangfolgen. STROBL et al. (2008) zeigen, dass die genannten Wichtigkeitsmaße nicht frei von Störeinflüssen sind. Dieser Umstand wird in Studien mit dem Hintergrund der Bildverarbeitung jedoch weitgehend unberücksichtigt gelassen. Sowohl die Technik des Stichprobensubsamplings in Form von Bootstrap, als auch die Skalierung der Variablen haben Anteil am Fehlereintrag in die Messwerte. Für RF-Klassifikation im Bereich der Bioinformatik präsentierten etwa STROBL et al. (2008) oder ALTMANN et al. (2010) Verfahren, um diesen Störeinflüssen zu begegnen und die Wichtigkeitsmaße in Messwerte mit höherer Reliabilität zu transformieren. Diese in R verfügbaren Algorithmen konnten, aufgrund ihres hohen Anspruchs an die Rechenleistung, in dieser Untersuchung nicht auf die geostatistischen Variablen angewendet werden.

Auch die bereits unter 6.2 erwähnte Verzerrung, die durch räumlich korrelierte Daten in die Schätzung des OOB-Fehlers eingetragen wird, kann zu einer Fehleinschätzung bei der Variablenauswahl führen. Folge kann dabei etwa die Reduzierung des Datensets über den Zustand der bestmöglichen Genauigkeit hinaus sein (CÁNOVAS-GARCÍA et al. 2017:11). Diesem Effekt wurde während der Analyseschritte der vorliegenden Arbeit durch die Durchführung zusätzlicher Validierung zumindest teilweise entgegengewirkt.

Schlussfolgernd lässt sich sagen, dass ein blindes Vertrauen in die Wichtigkeitsmaße zu falschen Entscheidungen bei der Variablenauswahl führen kann. Dies kann auch für die vorliegende Untersuchung nicht ausgeschlossen werden. Zur Verhinderung solcher Fehlentscheidungen wurden Kenntnisse zu Korrelation der Variablen aus der Literatur, sowie deren empirisch belegte Bedeutungen in der Landbedeckungsklassifikation herangezogen und die zusätzliche Überprüfung der Genauigkeit vorgenommen (vgl. 4.6).

6.4 Informationsgehalt für mediterrane Terrassenlandschaften

Aussagekraft der Ergebnisse

Die Ergebnisse der klassenspezifischen Genauigkeiten und die Interpretation der Fehlklassifikationen aus der Konfusionsmatrix (s. 5.4) lassen Aussagen über die Schwächen des Klassifikationssystems und problematische Bedeckungsklassen zu. So zeigt sich, dass variantenreiche Bedeckungsklassen, insbesondere Macchie (MAC), mit Überschneidungen zu fast jeder der anderen Vegetationsklassen, aber auch Olivenhaine und -brachen (OLI), der Grund für zahlreiche Fehlklassifikationen sind. Heterogene Eigenschaften dieser Klassen, wie die Artenzusammensetzung und Wuchshöhe der Macchien oder unterschiedliche Ausprägung des Unterwuchses von Olivenhainen bedingen eine klasseninterne Variabilität, die nur schwer in den Trainingsdaten abgebildet werden kann.

Höhere Sicherheiten bei der Klassifikation weist die Klasse der durch Baumheide geprägten Flächen (ERI) auf. Mithilfe vegetationsökologischer Erkenntnisse bestehender Studien von RICHTER (1989) und LINGENHÖHL (2005) lässt sich diese Klasse außerdem mit den mittelalten Brachestadien im Alter von 15 bis 30 Jahren nach Aufgabe der Bewirtschaftung in Verbindung bringen.

Eine bedeutende Rolle am Anteil der Fehlerrate scheinen Mischpixel, bedingt durch die räumliche Auflösung der Bilddaten, einzunehmen. Deutlich wird dies durch die Fehlklassifikationen, bei denen statt Infrastruktur oder vegetationslosen Flächen Vegetationsklassen mit hohem Reflexionsanteil offener Bodenfläche, wie SPR oder WEI, ausgewiesen werden. Aufgrund der insgesamt eher geringen Gesamtgenauigkeit von <55% wurde auf eine Auswertung der Flächenanteile der einzelnen Klassen verzichtet.

Dennoch kann auf Terrassenflächen der Wechsel von Weinbau und Brachen, im Sinne einer Unterscheidung zwischen kultivierten und längere Zeit nicht kultivierten Flächen, grob herausgearbeitet werden. Die räumliche Auflösung von 10 m stellt letztendlich eine deutliche Limitierung für präzise Aussagen dar.

Um Zustand und Veränderung von Terrassenlandschaften präzise zu erfassen mag es hilfreich sein, die Verbreitung der anthropogenen Terrassenstrukturen genau zu kennen. Auf diese Weise könnten Auswertungen auf eben jene Landschaftsbereiche beschränkt und so Störeinflüsse reduziert werden. In jüngerer Vergangenheit wurden Anstrengungen zur Kartierung der Terrassenflächen in den Cinque Terre und ganz Italien mit GIS- und Fernerkundungsmethoden unternommen (TAROLLI et al. 2014, 2015, SOFIA et al. 2014, SPANÒ et al. 2018).

Grenzen der pixelbasierten Klassifikation

Mit zunehmender räumlicher Auflösung von Bilddaten geraten pixelbasierte Klassifikationsmethoden zunehmend an ihre Grenzen. In Anpassung daran wurden sogenannte objektbasierte Klassifikationsansätze, auch als *Object-Based Image Analysis* (OBIA) bezeichnet, entwickelt. Bei diesen Methoden stellen nicht Bildpixel die zu klassifizierenden Elemente dar, sondern zuvor durch den Prozess der Segmentierung extrahierte Objekte in Form von Pixelclustern (BLASCHKE 2010:3, DURO et al. 2012, PUISSANT et al. 2014). Die bekanntesten Softwarelösungen zum Durchführen von objektbasierter Bildklassifikation sind kostenpflichtige Anwendungen wie eCognition oder PCA Geomatica. Dennoch sind Algorithmen zur Segmentierung auch in Open-Source oder zumindest freier Software verfügbar. Ein Beispiel ist etwa die ORFEO-Toolbox, die sowohl in QGIS als auch in SNAP integriert werden kann. BAISANTRY et al. (2017) vergleichen verschiedene Open-Source und Freeware-Anwendungen mit dem kommerziellen eCognition und kommen zu dem Schluss, dass alle nichtkommerziellen Produkte im Vergleich zu eCognition schlechtere Ergebnisse in der Bildsegmentierung produzieren oder nur über sehr geringe Auswahlmöglichkeiten verfügen (BAISANTRY et al. 2017:2). Jüngere Ansätze, wie etwa das R Package SegOptim (GONÇALVES et al. 2019) zur Verbesserung des Segmentierungsvorgangs und anschließender Klassifikation, führen jedoch zu einer zunehmenden Verbesserung von Open-Source-Möglichkeiten zur objektbasierten Bildklassifikation.

BELGIU & CSILLIK (2018) nutzen R und Random Forest erfolgreich zur Klassifizierung von Segmentierten Sentinel-2-Bilddaten. Zur Segmentierung nutzen sie jedoch ebenfalls eCognition und testen die Klassifikation ausschließlich in Gebieten mit größeren landwirtschaftlichen Nutzflächen (BELGIU & CSILLIK 2018:509). DURO et al. (2012) hingegen können in einer vergleichenden Studie keine signifikante Verbesserung der Klassifikationsgenauigkeit im Vergleich zu pixelbasierter Vorgehensweise feststellen, wenn objektbasierte Bildklassifikation auf Spot-5-Bilddaten mit 10x10 m räumliche Auflösung angewendet wird (DURO et al. 2012:271). Diese Einblicke verstärken wiederum die Annahme, dass die Verwendung von Sentinel-2-Bilddaten in kleinräumig fragmentierten Untersuchungsgebieten wie den Cinque Terre auch mit objektorientierten Methoden nicht zu befriedigenden Ergebnissen führen können, wenn sie eine trennscharfe Betrachtung von mosaikartigen Nutzungsmustern zum Ziel haben. Im Falle der Cinque Terre heißt das, dass auch durch objektbasierte Klassifikation eine Betrachtung der relevanten landwirtschaftlichen Parzellen, trotz vermutlich visuell einheitlicherem Charakter des Ergebnisses, nicht mit erhöhter Genauigkeit zu rechnen ist. Die Chance einer ausreichend detaillierten Beobachtung von Terrassenflächen durch die in absehbarer Zeit zur Verfügung stehenden und für den Anwender kostenlosen Bilddaten muss an dieser Stelle in Frage gestellt werden.

6.5 Verbesserungspotenzial und Ausblick

Eine Möglichkeit zur Beschränkung der oben genannten Einflüsse ist die Reduzierung der Größe des Untersuchungsgebietes. Diese Maßnahme kann die Anzahl der Klassen verringern und die Repräsentativität der Trainingsdaten für den jeweiligen Bildausschnitt erhöhen. Gerade bei einer spezifischen Fragestellung kann dies als ein sinnvoller Schritt erscheinen. Für die Cinque Terre wäre etwa eine Ausmaskierung aller nichtterrassierten Gebietsabschnitte vorstellbar, wodurch Klassen mit geringer Bedeutung für die Fragestellung möglicherweise gänzlich aus dem Klassifikationssystem entfallen würden.

Zum Erreichen des notwendigen Detaillierungsgrades ist dennoch ein Ausweichen auf höherauflösende und damit kostenpflichtige Datensätze unumgänglich. Auf dem Gebiet von optischen Fernerkundungsdaten höchster räumlicher Auflösungsstufen haben in den vergangenen Jahren sehr hochauflösende Datenprodukte, engl. *very high resolution* (VHR), von kommerziellen Fernerkundungssatelliten, wie etwa IKONOS, Pléiades, QuickBird oder WorldView eine qualitativ vergleichbare Alternative zu modernen Luftbildaufnahmen geschaffen. Mit einer geometrischen Auflösung im Meterbereich in multispektralen Bildkanälen und der Möglichkeit zur nachträglichen Erhöhung der Auflösung dieser Bänder durch Pansharpening ermöglichen diese Datensätze eine detailreiche Betrachtung der Erdoberfläche (HEISIG et al. 2015). Terrassenparzellen von wenigen Metern Breite, wie sie in den Cinque Terre existieren, stellten in diesen Bilddaten eigene Pixelansammlungen dar, ohne in hohem Maße mit angrenzenden Bedeckungseigenschaften zu verschwimmen.

Eine mögliche Alternative zu VHR-Satellitenbilddaten oder flugzeuggestützten Luftbildaufnahmen stellt das durch den Einsatz von *unmanned aerial vehicles* (UAVs) erzeugte Bildmaterial dar. Die Flugobjekte ermöglichen die gezielte Beobachtung von kleinräumigeren Arealen mit optischen Sensorsystemen und der Erzeugung von digitalen Geländemodellen mittels Stereo-Photogrammetrie oder LiDAR-Technik (AJAYI et al. 2017, BAKUŁA et al. 2017, GUO et al. 2017). Die im Drohnenflug akquirierten Datensätze können zur hochauflösenden Bildklassifikation genutzt werden, insbesondere, wenn die Systeme mit einem IR-Kanal ausgestattet sind. Ihre Eigenschaften stellen den Anwender jedoch auch vor neue Herausforderungen im Bereich der Bildkorrektur oder dem Umgang mit Schattenwurf (LALIBERTE et al. 2011, MILAS et al. 2017, YU et al. 2016).

7 Fazit

Multispektrale Sentinel-2-Satellitenbilddaten aus dem Copernicus-Programm der ESA bieten eine neue Qualität frei zugänglicher und flächendeckender Bilddaten in Bezug auf räumliche Auflösung und Wiederholungsrate. Diesen Datenprodukten kommt in näherer Zukunft so eine bedeutende Rolle zur Beantwortung unterschiedlichster Forschungsfragen zu.

In dieser Studie wurden Sentinel-2-Daten genutzt, um eine überwachte Landbedeckungsklassifikation für ein heterogenes, mediterranes Untersuchungsgebiet mit hoher Reliefenergie zu erproben. Ziele der Untersuchung waren die Überprüfung der Anwendbarkeit und Erfolgsaussichten der verwendeten Methode, sowie die Nutzbarkeit und Aussagekraft der genutzten Daten. Arbeitsschritte der Datenverarbeitung wurden ausschließlich durch die Verwendung von Open-Source-Softwareanwendungen durchgeführt, um eine adaptierbare und möglichst uneingeschränkt reproduzierbare Methodik zu verwenden. Durch die Verfügbarkeit unterschiedlicher offener Softwarepakete stehen vielfältige Möglichkeiten zur Verarbeitung und Analyse der Daten bereit.

Mit neueren Klassifikatoren wie Random-Forest sind Methoden des maschinellen Lernens auch in Open-Source-Anwendungen zugänglich und können, z.B. durch die Nutzung in R, selbst zu systematischen Analysen herangezogen werden. In dieser Arbeit konnte die pixelbasierte Klassifikation mit dem Random Forest-Klassifikator durch die Hinzunahme von Hilfsdaten und Datenderivaten, sowie durch

die durchgeführte Terrainkorrektur um mindestens 12% verbessert werden. Diese Verbesserung konnte durch Daten erreicht werden, die für die meisten Gebiete der Erde zu Verfügung stehen. Von besonderem Wert sind dabei digitale Höhendaten. Vor dem Hintergrund der erlangten Ergebnisse wird jedoch empfohlen Texturmaße, wie GLCM-Variablen, innerhalb einer zielorientierten Praxisanwendung zu vernachlässigen. Der Zugewinn durch diese Variablen ist in Relation zu dem mit ihnen in Verbindung stehenden Arbeitsaufwands eher gering.

Die Leistungsfähigkeit des verwendeten Random Forest-Ansatzes kann, im Hinblick auf die diskutierten Potenziale, keineswegs als ausgeschöpft bezeichnet werden. Es existieren Möglichkeiten, um den Klassifikationsprozess an verschiedenen Stellen des Arbeitsablaufes zu verbessern. Dazu zählen, neben der Wahl wirkungsvollerer Methoden zur Variablenauswahl, auch die Möglichkeiten im Bereich der Bildverbesserung. Zusätzliche Datensätze, etwa LiDAR-Derivate, könnten helfen, schwer trennbare Bedeckungsklassen besser zu unterscheiden. Mit der Random Forest-Methode wären diese Datensätze zudem leicht einzubinden.

Für die Erforschung mediterraner Terrassenlandschaften wie den Cinque Terre steht der dort stattfindende Nutzungswandel im Zentrum vieler Fragestellungen. Das Fortschreiten des Nutzungswandels und die Möglichkeiten zum Management dieser Entwicklung werden entscheidenden Einfluss auf die biologische Vielfalt und die geohydrologische Stabilität der terrassierten Gebiete haben. Vor diesen Anforderungen muss auch der Informationsgehalt der hier präsentierten Landbedeckungsklassifikation betrachtet werden. Denn einerseits lässt die mehr oder weniger geringe Gesamtgenauigkeit des Ergebnisses eine für viele Fragestellungen unzureichende Verlässlichkeit vermuten, andererseits konnte die prinzipielle Trennung von Weinbau und Brachflächen auf terrassierten Hängen herausgearbeitet werden. Nach Meinung der Autoren könnte ein Veränderungsmonitoring, welches lediglich die Frage nach dem relativen Anteil der ungenutzten zu genutzten Terrassenabschnitten beantworten soll, auf Grundlage von Sentinel-2-Bilddaten umgesetzt werden.

Neben den, in Abschnitt 6 diskutierten, methodischen Limitationen, die auch aus der Einschränkung einer fehlenden *in-situ*-Begehung resultiert, stellt vor allem die räumliche Auflösung eine Begrenzung des Detaillierungsgrades dar. Auch mit den hochauflösenden und frei zugänglichen Bilddaten der Sentinel-2-Satelliten können die fragmentierten Verhältnisse auf den, nur wenige Meter breiten, Terrassenflächen des Untersuchungsgebietes allenfalls nur begrenzt erfasst werden.

Größeres Potential zur Verbesserung der Klassifikation bieten demgegenüber objektbasierte Klassifikationsansätze. Diese können bestimmten Nachteilen der pixelbasierten Bildklassifikation entgegenwirken und höhere Genauigkeiten erzeugen. Da die Random Forest-Klassifikation auch auf Bildsegmente statt auf Pixel angewendet werden kann, ist es prinzipiell möglich, die in dieser Studie verdeutlichten Vorteile des Random-Forest-Algorithmus in objektbasierten Klassifikationsverfahren zu nutzen. Als Schwachstelle deutet sich in diesem Bereich jedoch an, dass die Entwicklung effektiver Segmentierungsalgorithmen im Open-Source-Bereich weiter vorangetrieben werden muss, um mit kommerziellen Anwendungen mithalten zu können. Dennoch kann auch das Ergebnis einer potentiellen nicht-pixelbasierten Klassifikation, bei gleichbleibender räumlicher Auflösung der Bilddaten, nicht den Anforderungen eines Untersuchungsgebietes wie dem Nationalpark Cinque Terre und seiner speziellen Problemstellung gerecht werden. Soll der Landnutzungswandel in heterogenen Landschaften mit kleinräumig wechselnder Landbedeckung und -nutzung in ausreichendem Detaillierungsgrad, wie er etwa für die landwirtschaftlichen Parzellen der Terrassenlandschaften nötig wäre, dokumentiert werden, so ist ein Ausweichen auf höherauflösende Bilddatensätze nicht zu umgehen. Trotz ihrer fortschrittlichen Eigenschaften stoßen Sentinel-2-Datensätze bei einer derartigen Fragestellung an ihre Grenzen. Sehr hochauflösende Datensätze in Form von kommerziellen Satellitenbilddaten sowie Flugzeug- oder Drohnengestützte Aufnahmesysteme erfüllen diese Anforderungen an die räumliche Auflösung. Gleichzeitig bringen auch sie neue Herausforderungen mit sich.

Literatur

AGNOLETTI, M., EMANUELI, F., MAGGIARI, G. & PRETI, F. (2012): Paesaggio e dissesto indriogeologico: Il disastro ambientale del 25 ottobre 2011 nelle Cinque Terre / Landscape and hydrogeological risk. The environmental disaster of 25 october 2011 in Cinque Terre. In: AGNOLETTI, M., CARANDINI, A. & SANTORO, A. (Hrsg.). Studi e ricerche / Essays and researches: Biennale internazionale dei beni culturali ed ambientali / Inter-national Biennial of Cultural and Environmental Heritage. Florenz: Fondazione Florens, 25–46.

AJAYI, O.G., SALUBI, A.A., ANGBAS, A.F. & ODIGURE, M.G. (2017): Generation of accurate digital elevation models from UAV acquired low percentage overlapping images. – International Journal of Remote Sensing 19, 8, 1–22.

ALTMANN, A., TOLOŞI, L., SANDER, O. & LENGAUER, T. (2010): Permutation importance: a corrected feature importance measure. – Bioinformatics 26, 10, 1340–1347.

ARNÁEZ, J., LANA-RENAULT, N., LASANTA, T., RUIZ-FLAÑO, P. & CASTROVIEJO, J. (2015): Effects of farming terraces on hydrological and geomorphological processes. A review. – CATENA 128, 122–134.

ASCHBACHER, J. & MILAGRO-PÉREZ, M.P. (2012): The European Earth monitoring (GMES) programme: Status and perspectives. – Remote Sensing of Environment 120, 3–8.

BAISANTRY, M., SHUKLA, D.P. & BANSAL, G. (2017): Evaluation of object-based image analysis software for segmentation in remote sensing applications. – AGILE 2017 - Wageningen, May 9-12, https://agile-online.org/conference_paper/cds/agile_2017/posters/120_PosterAbstract_in_PDF.pdf (Zugriff: 2017-21-03).

BAKUŁA, K., SALACH, A., ZELAYA WZIĄTEK, D., OSTROWSKI, W., GÓRSKI, K. & KURCZYŃSKI, Z. (2017): Evaluation of the accuracy of lidar data acquired using a UAS for levee monitoring: Preliminary results. – International Journal of Remote Sensing 16, 8, 1–17.

BARTHA, G. & KOCSIS, S. (2011): Standardization of geographic data: The European INSPIRE directive. – European Journal of Geography 2, 2, 79–89.

BEEKHUIZEN, J. & CLARKE, K.C. (2010): Toward accountable land use mapping: Using geocomputation to improve classification accuracy and reveal uncertainty. – International Journal of Applied Earth Observation and Geoinformation 12, 3, 127–137.

BELGIU, M. & CSILLIK, O. (2018): Sentinel-2 cropland mapping using pixel-based and object-based time-weighted dynamic time warping analysis. – Remote Sensing of Environment 204, 509–523.

BELGIU, M. & DRĂGUŢ, L. (2016): Random forest in remote sensing: A review of applications and future directions. – ISPRS Journal of Photogrammetry and Remote Sensing 114, 24–31.

BERBEROGLU, S., CURRAN, P.J., LLOYD, C.D. & ATKINSON, P.M. (2007): Texture classification of Mediterranean land cover. – International Journal of Applied Earth Observation and Geoinformation 9, 3, 322–334.

BIVAND, R., KEITT, T. & ROWLINGSON, B. (2017): rgdal: Bindings for the 'geospatial' data abstraction library. R package version 1.2-16, https://CRAN.R-project.org/package=rgdal.

BLASCHKE, T. (2010): Object based image analysis for remote sensing. – ISPRS Journal of Photogrammetry and Remote Sensing 65, 1, 2–16.

BOEHNER, J., KOETHE, R., CONRAD, O., GROSS, J., RINGELER, A. & SELIGE, T. (2002): Soil regionalisation by means of terrain analysis and process parameterisation. In: MICHELI, E., NACHTERGAELE, F., MONTANA-

RELLA, L. (Hrsg.). Soil classification 2001: Contributions tor the International Symposium "Soil Classification 2001", 8 - 12 October 2001, Velence, Hungary. European Soil Bureau research report 7. Luxembourg: Office for Official publications of the European Communities, 213–222.

BOULESTEIX, A.-L., JANITZA, S., KRUPPA, J. & KÖNIG, I.R. (2012): Overview of random forest methodology and practical guidance with emphasis on computational biology and bioinformatics. – Wiley Interdisciplinary Reviews: Data Mining and Knowledge Discovery 2, 6, 493–507.

BRANDOLINI, P. (2017): The outstanding terraced landscape of the Cinque Terre coastal slopes (Eastern Liguria). In: SOLDATI, M. & MARCHETTI, M. (Hrsg.). Landscapes and Landforms of Italy. World Geomorphological Landscapes. Cham: Springer, 235–244.

BREIMAN, L. (2001): Random Forests. – Machine Learning 45, 1, 5–32.

CÁNOVAS-GARCÍA, F., ALONSO-SARRÍA, F., GOMARIZ-CASTILLO, F. & OÑATE-VALDIVIESO, F. (2017): Modification of the random forest algorithm to avoid statistical dependence problems when classifying remote sensing imagery. – Computers & Geosciences 103, 1–11.

CARL, T. & RICHTER, M. (1989): Geoecological and morphological processes on abandoned vine-terraces in the Cinque Terre (Liguria). – Geoökodynamik X, 2/3, 125–158.

CEVASCO, A., BRANDOLINI, P., SCOPESI, C. & RELLINI, I. (2013): Relationships between geo-hydrological processes induced by heavy rainfall and land-use: The case of 25 October 2011 in the Vernazza catchment (Cinque Terre, NW Italy). – Journal of Maps 9, 2, 289–298.

CLAUSI, D.A. (2002): An analysis of co-occurrence texture statistics as a function of grey level quantization. – Canadian Journal of Remote Sensing 28, 1, 45–62.

CONGALTON, R.G. (1991): A review of assessing the accuracy of classifications of remotely sensed data. – Remote Sensing of Environment 37, 1, 35–46.

CONRAD, O., BECHTEL, B., BOCK, M., DIETRICH, H., FISCHER, E., GERLITZ, L., WEHBERG, J., WICHMANN, V. & BÖHNER, J. (2015): System for Automated Geoscientific Analyses (SAGA) v. 2.1.4. – Geoscientific Model Development 8, 7, 1991–2007.

CRAIG DOBSON, M., ULABY, F.T. & PIERCE, L.E. (1995): Land-cover classification and estimation of terrain attributes using synthetic aperture radar. – Remote Sensing of Environment 51, 1, 199–214.

DRUSCH, M., DEL BELLO, U., CARLIER, S., COLIN, O., FERNANDEZ, V., GASCON, F., HOERSCH, B., ISOLA, C., LABERINTI, P., MARTIMORT, P., MEYGRET, A., SPOTO, F., SY, O., MARCHESE, F. & BARGELLINI, P. (2012): Sentinel-2: ESA's optical high-resolution mission for GMES operational services. – Remote Sensing of Environment 120, 25–36.

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.

EFRON, B. (1979): Bootstrap Methods: Another Look at the Jackknife. – The Annals of Statistics 7, 1, 1–26.

FALCUCCI, A., MAIORANO, L. & BOITANI, L. (2007): Changes in land-use/land-cover patterns in Italy and their implications for biodiversity conservation. – Landscape Ecology 22, 4, 617–631.

FOWLER, P. (2002): World heritage cultural landscapes, 1992–2002: A review and prospect. – Cultural landscapes: The challenges of conservation, 16–31.

GHIMIRE, B., ROGAN, J., GALIANO, V.R., PANDAY, P. & NEETI, N. (2012): An evaluation of bagging, boosting, and random forests for land-cover classification in Cape Cod, Massachusetts, USA. – GIScience & Remote Sensing 49, 5, 623–643.

GHOSH, A., FASSNACHT, F.E., JOSHI, P.K. & KOCH, B. (2014): A framework for mapping tree species combining hyperspectral and LiDAR data: Role of selected classifiers and sensor across three spatial scales. – International Journal of Applied Earth Observation and Geoinformation 26, 49–63.

GISLASON, P.O., BENEDIKTSSON, J.A. & SVEINSSON, J.R. (2006): Random Forests for land cover classification. – Pattern Recognition Letters 27, 4, 294–300.

GONÇALVES, J., PÔÇAS, I., MARCOS, B., MÜCHER, C. A. & HONRADO, J. P. (2019): SegOptim—A new R package for optimizing object-based image analyses of high-spatial resolution remotely-sensed data. – International Journal of Applied Earth Observation and Geoinformation 76, 218–230.

GOUNARIDIS, D., APOSTOLOU, A. & KOUKOULAS, S. (2015): Land cover of Greece, 2010: A semi-automated classification using random forests. – Journal of Maps 2, 1–8.

GUO, Q., SU, Y., HU, T., ZHAO, X., WU, F., LI, Y., LIU, J., CHEN, L., XU, G., LIN, G., ZHENG, Y., LIN, Y., MI, X., FEI, L. & WANG, X. (2017): An integrated UAV-borne lidar system for 3D habitat mapping in three forest ecosystems across China. – International Journal of Remote Sensing 5, 1–19.

HALL-BEYER, M. (2017a): GLCM texture: A tutorial. v. 3.0, https://prism.ucalgary.ca/handle/1880/51900 (Stand: 2017-03) (Zugriff: 2017-03-15).

HALL-BEYER, M. (2017b): Practical guidelines for choosing GLCM textures to use in landscape classification tasks over a range of moderate spatial scales. – International Journal of Remote Sensing 38, 5, 1312–1338.

HANSEN, M.C., DEFRIES, R.S., TOWNSHEND, J.R.G. & SOHLBERG, R. (2000): Global land cover classification at 1 km spatial resolution using a classification tree approach. – International Journal of Remote Sensing 21, 6-7, 1331–1364.

HAO, Y., BROWN, M. & HARDING, J. (2014): GIS for all: exploring the barriers and opportunities for underexploited GIS applications. – OSGEO Journal 13, 19–28.

HARALICK, R.M., SHANMUGAM, K. & DINSTEIN, I. (1973): Textural features for image classification. – IEEE Transactions on Systems, Man, and Cybernetics SMC-3, 6, 610–621.

HEISIG, H., JÖRG, P.C., LEITERER, R., WYSS, F. & ZESIGER, M. (2015): Satellitenbilddaten: Neueste Sensoren, erleichterter Datenzugang und innovative Produkte. – Geomatik Schweiz 9, 325–330.

HIJMANS, R.J. (2017): raster: Geographic data analysis and modelling. R package version 2.6-7., https://CRAN.R-project.org/package=raster.

HUANG, C., DAVIS, L.S. & TOWNSHEND, J.R.G. (2002): An assessment of support vector machines for land cover classification. – International Journal of Remote Sensing 23, 4, 725–749.

HUETE, A.R. (1988): A Soil-Adjusted Vegetation Index (SAVI). – Remote Sensing of Environment 25, 295–309.

HUGHES, G. (1968): On the mean accuracy of statistical pattern recognizers. – IEEE Transactions on Information Theory 14, 1, 55–63.

IMMITZER, M., VUOLO, F. & ATZBERGER, C. (2016): First Experience with Sentinel-2 Data for Crop and Tree Species Classifications in Central Europe. – Remote Sensing 8, 3, 166.

JENSEN, J.R. (2016[4]): Introductory digital image processing: A remote sensing perspective. Always learning. Glenview, Ill.: Pearson Education.

JOHANSEN, K., COOPS, N.C., GERGEL, S.E. & STANGE, Y. (2007): Application of high spatial resolution satellite imagery for riparian and forest ecosystem classification. – Remote Sensing of Environment 110, 1, 29–44.

KABIR, S., HE, D.-C., SANUSI, M.A. & WAN HUSSINA, W.M.A. (2013): Texture analysis of IKONOS satellite imagery for urban land use and land cover classification. – The Imaging Science Journal 58, 3, 163–170.

KEUCHEL, J., NAUMANN, S., HEILER, M. & SIEGMUND, A. (2003): Automatic land cover analysis for Tenerife by supervised classification using remotely sensed data. – Remote Sensing of Environment 86, 4, 530–541.

KURSA, M.B. & RUDNICKI, W.R. (2010): Feature selection with the Boruta Package. – Journal of Statistical Software 36, 11, 1–13.

LALIBERTE, A.S., GOFORTH, M.A., STEELE, C.M. & RANGO, A. (2011): Multispectral remote sensing from unmanned aircraft: Image Processing Workflows and Applications for Rangeland Environments. – Remote Sensing 3, 11, 2529–2551.

LASANTA-MARTÍNEZ, T., VICENTE-SERRANO, S.M. & CUADRAT-PRATS, J.M. (2005): Mountain Mediterranean landscape evolution caused by the abandonment of traditional primary activities: A study of the Spanish Central Pyrenees. – Applied Geography 25, 1, 47–65.

LIAW, A. & WIENER, M. (2002): Classification and regression by randomForest. – R News 2, 3, 18–22, http://CRAN.R-project.org/doc/Rnews/.

LINGENHÖHL, D. (2005): Die Biodiversität der Cinque Terre, Italien: Ihr Ausmaß, ihre Dynamik und ihr mögliches Management in einer traditionellen europäischen Kulturlandschaft (Dargestellt an Vegetation und Avifauna). Dissertation: Universität Erlangen Nürnberg.

LOUIS, J., DEBAECKER, V., PFLUG, B., MAIN-KNORN, M., BIENIARZ, J., MUELLER-WILM, U. & CADAU, E. & GASCON, F. (2016): Sentinel-2 Sen2Cor: L2A Processor for Users (2016). Proceedings 'Living Planet Symposium 2016'. Prague, Czech Republic.

MILAS, A.S., AREND, K., MAYER, C., SIMONSON, M.A. & MACKEY, S. (2017): Different colours of shadows: Classification of UAV images. – International Journal of Remote Sensing 34, 3, 1–17.

MILLARD, K. & RICHARDSON, M. (2015): On the importance of training data sample selection in random forest image classification: A Case Study in Peatland Ecosystem Mapping. – Remote Sensing 7, 7, 8489–8515.

MOORE, I.D., GRAYSON, R.B. & LADSON, A.R. (1991): Digital terrain modelling: a review of hydrogical, geomorphological, and biological applications. – Hydrological Processes 5, 1, 3–30.

MÜLLER-WILM, U., DEVIGNOT, O. & PESSIOT, L. (2017): Sen2Cor configuration and user manual: S2-PDGS-MPC-L2A-SUM-V2.4, http://step.esa.int/thirdparties/sen2cor/2.4.0/Sen2Cor_240_Documenation_PDF/S2-PDGS-MPC-L2A-SUM-V2.4.0.pdf (Zugriff: 2018-01-18).

NOWAK, B. (1987): Untersuchungen zur Vegetation Ostliguriens (Italien). Dissertationes botanicae Bd. 111. Berlin, Stuttgart: J. Cramer.

PEBESMA, E.J. & BIVAND, R.S. (2005): Classes and methods for spatial data in R. – R News 5, 2, https://cran.r-project.org/doc/Rnews/.

PUISSANT, A., ROUGIER, S. & STUMPF, A. (2014): Object-oriented mapping of urban trees using Random Forest classifiers. – International Journal of Applied Earth Observation and Geoinformation 26, 235–245.

R CORE TEAM (2017): R: A language and environment for statistical computing. Vienna, Austria: R Foundation for Statistical Computing.

RICCHETTI, E. (2000): Multispectral satellite image and ancillary data integration for geological classification. – Engineering and Remote Sensing 66, 4, 429–435.

RICHTER, M. (1989): Untersuchungen zur Vegetationsdynamik und zum Standortwandel in mediterranen Rebbrachen. Braun-Blanquetia 4: Camerino-Bailleul.

RICHTER, M. & BLOCK, M. (2001): Vielfalt in den Cinque Terre. Über den Niedergang einer Kulturlandschaft und die Rückkehr der Natur. – Geographische Rundschau 53, 40–47.

RILEY, S.J., GLORIA, S.D. de & ELLIOT, R. (1999): A terrain ruggedness index that quantifies topographic heterogeneity. – Intermountain Journal of Science 5, 1-4, 23–27.

RODRIGUEZ-GALIANO, V. & CHICA-OLMO, M. (2012): Land cover change analysis of a Mediterranean area in Spain using different sources of data: Multi-seasonal Landsat images, land surface temperature, digital terrain models and texture. – Applied Geography 35, 1-2, 208–218.

RODRIGUEZ-GALIANO, V.F., CHICA-OLMO, M., ABARCA-HERNANDEZ, F., ATKINSON, P.M. & JEGANATHAN, C. (2012a): Random Forest classification of Mediterranean land cover using multi-seasonal imagery and multi-seasonal texture. – Remote Sensing of Environment 121, 93–107.

RODRIGUEZ-GALIANO, V.F., GHIMIRE, B., ROGAN, J., CHICA-OLMO, M. & RIGOL-SANCHEZ, J.P. (2012b): An assessment of the effectiveness of a random forest classifier for land-cover classification. – ISPRS Journal of Photogrammetry and Remote Sensing 67, 93–104.

ROGAN, J., FRANKLIN, J., STOW, D., MILLER, J., WOODCOCK, C. & ROBERTS, D. (2008): Mapping land-cover modifications over large areas: A comparison of machine learning algorithms. – Remote Sensing of Environment 112, 5, 2272–2283.

ROUSE, J., HAAS, R.H., SCHELL, J.A. & DEERING, D.W. (1974): Monitoring vegetation systems in the Great Plains with ERTS. – Proceedings, 3rd Earth Resource Technology Satellite (ERTS) Symposium 1, 48–62.

SANDNER, M. (2018): Landbedeckungsklassifikation anhand von Sentinel-2-Bilddaten und Open-Source-Software - Bewertung der Eignung für mediterrane Terrassenlandschaften am Beispiel des Nationalparks Cinque Terre (Italien). Masterarbeit. Univ. Hildesheim. Unveröff.

SINGLETON, A.D., SPIELMAN, S. & BRUNSDON, C. (2016): Establishing a framework for Open Geographic Information science. – International Journal of Geographical Information Science 30, 8, 1507–1521.

SNAP (2017): SNAP - ESA Sentinel Application Platform v6.0.

SOFIA, G., MARINELLO, F. & TAROLLI, P. (2014): A new landscape metric for the identification of terraced sites: The Slope Local Length of Auto-Correlation (SLLAC). – ISPRS Journal of Photogrammetry and Remote Sensing 96, 123–133.

SPANÒ, A., SAMMARTANO, G., CALCAGNO TUNIN, F., CERISE, S. & POSSI, G. (2018): GIS-based detection of terraced landscape heritage: comparative tests using regional DEMs and UAV data. – Applied Geomatics 10, 2, 77–97.

STROBL, C., BOULESTEIX, A.-L., KNEIB, T., AUGUSTIN, T. & ZEILEIS, A. (2008): Conditional variable importance for random forests. – BMC bioinformatics 9, 307.

TAROLLI, P., PRETI, F. & ROMANO, N. (2014): Terraced landscapes: From an old best practice to a potential hazard for soil degradation due to land abandonment. – Anthropocene 6, 10–25.

TAROLLI, P., SOFIA, G., CALLIGARO, S., PROSDOCIMI, M., PRETI, F. & DALLA FONTANA, G. (2015): Vineyards in terraced landscapes: New opportunities from lidar data. – Land Degradation & Development 26, 1, 92–102.

TASSETTI, A.N., MALINVERNI, E.S. & HAHN, M. (2010): Texture analysis to improve supervised classification in IKONOS imagery. In: WAGNER W. & SZÉKELY, B. (Hrsg.). ISPRS TC VII Symposium – 100 Years ISPRS, Vienna, Austria, July 5–7, 2010. IAPRS XXXVIII, 7A. Wien: Institute of Photogrammetry and Remote Sensing, 245–250.

TERRANOVA, R., ZANZUCCHI, G., BERNINI, M., BRANDOLINI, P., CAMPOBASSO, S., CLERICI, A., FACCINI, F., RENZI, L., VESCOVI, P. & ZANZUCCHI, F. (2006): Geologia, geomorfologia e vini del Parco Nazionale delle Cinque Terre (Liguria, Italia). – Bollettino della Società Geologica Italiana Speciale 6, 115–128.

TRAVIS, M.R., ELSNER, G.H., IVERSON, W.D. & JOHNSON, C.G. (1975): VIEWIT: Computation of seen areas, slope, and aspect for land-use planning. General technical report PSW-11. Berkeley, Calif.: Pacific Southwest Forest and Range Experiment Station.

VERBAS, C. (1978): Le Cinque Terre. – Studi e Ricerche di Geografia 1, 17–114.

XU, B. & GONG, P. (2007): Land-use/land-cover classification with multispectral and hyperspectral EO-1 data. – Photogrammetric Engineering & Remote Sensing 73, 8, 955–965.

YU, X., LIU, Q., LIU, X., LIU, X. & WANG, Y. (2016): A physical-based atmospheric correction algorithm of unmanned aerial vehicles images and its utility analysis. – International Journal of Remote Sensing 35, 108, 1–12.

Datenquellen

GOOGLE EARTH (2017): Bilddatensätze aus dem Bestand von Google Earth, https://www.google.com/earth/download/ge/ (Stand: 2017)

REGIONE LIGURIA (2017a): Geoportal der Region Ligurien: Modello Digitale del Terreno da CTR 1:5000, https://geoportal.regione.liguria.it/catalogo/mappe.html (Stand: 2017) (Zugriff: 2017-03-07).

REGIONE LIGURIA (2017b): Uso del Suolo Sc. 1:10000 – Ed. 2015, http://srvcarto.regione.liguria.it/geoviewer2/pages/apps/download/index.html?id=1735 (Stand: 2017) (Zugriff: 2017-03-07).

REGIONE LIGURIA (2017c): Ortofoto digitale ad infrarossi 2016 – Sc. 1:5000, WMS-Dienst, http://geoservizi.regione.liguria.it/geoserver/M1834/wms?version=1.3.0&request=getcapabilities (Stand: 2017) (Zugriff: 2017-03-07).

Anschrift der Autoren:

Moritz Sandner M.Sc.
moritz.sandner@uni-hildesheim.de

Prof. Dr. Martin Sauerwein
martin.sauerwein@uni-hildesheim.de

Institut für Geographie
Universitätsplatz 1
D-31141 Hildesheim

Robin Stadtmann M.Sc.
robin.stadtmann@lbeg.niedersachsen.de

Landesamt für Bergbau, Energie und Geologie (LBEG)
Stilleweg 2
D-30655 Hannover