



Universität für Bodenkultur Wien

Erfassung von relevanten Vegetationsstrukturen für Biber (*Castor fiber*)

Methoden der Fernerkundung im Vergleich

Masterarbeit

Zur Erlangung des akademischen Grades Master of Science (M.Sc.)

in Wildtierökologie und Wildtiermanagement

vorgelegt von:

Anne Schlegel

betreut von:

Univ.-Prof. Dr. Clement Atzberger
Institut für Vermessung, Fernerkundung und Landinformation (IVFL)

Dipl.-Ing. Dr. Markus Immitzer, M.Sc.
Institut für Vermessung, Fernerkundung und Landinformation (IVFL)

Josephin Böhm, M.Sc.
Institut für Wildbiologie und Jagdwirtschaft (IWJ)

Wien, 12.08.2019

Zusammenfassung

Zur Ableitung der Habitatqualität von Biber-Revieren ist die Landbedeckung ein wichtiger Faktor. Für ein solches Vorhaben wurden mögliche Datensätze und Methoden der Fernerkundung auf ihre Eignung und Unterschiede am Beispiel eines reich strukturierten Gewässerabschnittes getestet. Fernerkundungsdaten eignen sich zum einen für eine manuelle Abgrenzung der Landbedeckung durch eine Kartierung vor Ort oder durch eine visuelle Bildinterpretation. Zum anderen kann auch eine semi-automatisch Klassifizierung durchgeführt werden, die sich vor allem bei großen Flächen anbietet. Neben den manuellen Methoden wurde eine objektbasierte Klassifikation (OBIA) mit dem Random Forest Algorithmus angewendet. Als Datengrundlage standen ein Orthophoto des Landes Niederösterreichs (NÖ) mit einer räumlichen Auflösung von 0,2 m und ein Orthophoto durch eine UAV-Befliegung mit einer räumlichen Auflösung von 0,03 m zur Verfügung. Zudem wurden verschiedene Vegetationshöhenmodelle, verschiedene Texturen (SFS, Haralick) sowie der NDVI in die Klassifikation mit einbezogen. Als Untersuchungsgebiet wurde ein etwa 3 km langer Abschnitt am Marchfeld-Kanal in NÖ gewählt.

Bei der Integration der verschiedenen Daten für die OBIA ergab die Kombination aus der Spektralinformation mit einem Vegetationshöhenmodell und der SFS-Textur das beste Ergebnis. Bei gleicher Anzahl an Trainingsdaten wurde für das Orthophoto des Landes NÖ eine Klassifikationsgenauigkeit (Overall Accuracy, OA) von rund 79 % erreicht, bei dem Orthophoto der UAV-Befliegung eine OA von 88 %. Eine OBIA erzielt bei einer sehr hohen Auflösung für einen reich strukturierten Lebensraum also gute Ergebnisse.

Die OBIA des Orthophotos des NÖ kommt den manuellen Methoden sehr nah. Die OBIA der UAV-Aufnahme zeigt wiederum einen signifikanten Unterschied zu der Kartierung vor Ort und der visuellen Bildinterpretation. Gründe dafür könnten die sehr hohe räumliche Auflösung und der damit verbundene feine Segmentierungs- bzw. Klassifikationsgrad sein.

Abstract

Land cover is an important factor for deriving the habitat quality of beaver territories. For such a project, possible data sets and methods of remote sensing were tested for their suitability and differences using the example of a richly structured water section. On the one hand, Remote sensing data are suitable for a manual classification of the land cover by mapping on-site or by a visual image interpretation, and on the other hand they are suitable for a semi-automatic classification, which is particularly suitable for large areas. In addition to the manual methods, an object based image analysis (OBIA) with the Random Forest algorithm was applied. As data basis an Orthophoto of Lower Austria with a spatial resolution of 0,2 m and an Orthophoto by a UAV flight with a spatial resolution of 0,03 m were available. Furthermore, different vegetation elevation models, different textures (SFS, Haralick) as well as NDVI were included in the classification. An approximately 3 km long section of the Marchfeld Canal in Lower Austria was selected as the study area.

When integrating the various data for OBIA, the combination of spectral information with a vegetation elevation model and the SFS texture produced the best result. With the same number of training data, a classification accuracy (Overall Accuracy, OA) of about 79% was achieved for the Orthophoto of Lower Austria, and an OA of 88% for the Orthophoto of the UAV flight. Thus, an OBIA achieves good results at a very high resolution for a richly structured habitat.

The OBIA of the Orthophoto of Lower Austria comes very close to the manual methods. The OBIA of the UAV image again shows a significant difference to the mapping on site and the visual image interpretation. Reasons for this could be the very high spatial resolution and the associated fine degree of classification.

Danksagung

An dieser Stelle möchte ich all jenen danken, die durch ihre fachliche und persönliche Unterstützung zum Gelingen dieser Masterarbeit beigetragen haben. Mein großer Dank gilt vor allem an Josephin Böhm und Markus Immitzer für die intensive Betreuung, Anregungen und Korrekturen und an Professor Clement Atzberger für das Ermöglichen der Arbeit.

Des Weiteren möchte ich mich beim Bundesforschungszentrum für Wald in Wien sowie beim Land Niederösterreich dafür bedanken, dass mir die Fernerkundungsdaten zur Verfügung gestellt wurden. Mein Dank gilt auch an Stefan Lederbauer für die UAV-Befliegung des Untersuchungsgebietes und an Sebastian Böck für die Unterstützung bei dem Klassifizierungsprozess.

Ebenso gilt mein Dank meiner Familie, die mich während des Studiums in all meinen Entscheidungen unterstützt hat und mir mit Rat und Tat zur Seite stand.

Inhaltsverzeichnis

1. Einleitung	1
2. Exkurs: Grundlagen der Luftbildauswertung	5
2.1 Visuelle Bildinterpretation.....	5
2.2 Digitale Bildauswertung.....	6
2.2.1 Grundprinzip der Multispektral-Klassifizierung	8
3. Methode.....	11
3.1 Untersuchungsgebiet.....	11
3.2 Datengrundlage	14
3.2.1 Technische Eigenschaften des unbemannten Luftfahrzeuges.....	16
3.2.2 Datenaufbereitung	16
3.3 Visuelle Bildinterpretation (manuell)	17
3.4 Digitale Bildauswertung (objektbasierte Klassifikation).....	19
3.4.1 Segmentierung	19
3.4.2 Trainingsdaten.....	20
3.4.3 Klassifizierung mittels Random Forest	22
3.5 Statistischer Vergleich der Methoden	23
3.6 Objektbasierte Baumartenklassifikation	25
4. Ergebnisse	26
4.1 Objektbasierte Klassifikation: Orthophoto.....	26
4.2 Objektbasierte Klassifikation: UAV-Aufnahme.....	29
4.3 Vergleich der Datensätze bei gleicher Anzahl an Trainingsdaten	31
4.4 Ergebniskarten (kleines Untersuchungsgebiet)	32
4.5 Vergleich der Methoden anhand der Landbedeckungsklassen (χ^2 -Test).....	38
4.5.1 Ergebnisse des großen Untersuchungsgebietes	38

4.5.2	Ergebnisse des kleinen Untersuchungsgebietes	39
4.6	Baumartenklassifikation	39
4.6.1	Großes Untersuchungsgebiet.....	39
4.6.2	Kleines Untersuchungsgebiet.....	40
5.	Diskussion.....	41
6.	Fazit.....	48
	Literaturverzeichnis	49
	Anhang.....	52
I.	Input in RStudio: RandomForest.....	52
II.	Kreuztabellen (χ^2-Test) für den Methodenvergleich: Großes Gebiet	56
III.	Kreuztabellen (χ^2-Test) für den Methodenvergleich: Kleines Gebiet	58
	Eidesstattliche Erklärung.....	61

Abkürzungsverzeichnis

ALS	Airborne Laserscanning
BEV	Bundesamt für Eich- und Vermessungswesen
BM	Bildmatching
DGM	Digitales Geländemodell
DOM	Digitales Oberflächenmodell
GIS	Geoinformationssystem
LSMSS	Large Scale Mean Shift Segmentierung
nDOM	Normalisiertes Oberflächenmodell (oder: Vegetationshöhenmodell)
NDVI	Normierter differenzierter Vegetationsindex
NIR	Nahe Infrarot
NÖ	Niederösterreich
OA	Overall Accuracy (Gesamtgenauigkeit)
OBIA	Object based image analysis (objektbasierte Bildanalyse)
PA	Producer's Accuracy (Produzentengenauigkeit)
RF	Random Forest
SD	Standardabweichung
UA	User's Accuracy (Nutzergenauigkeit)
UAV	Unmanned aerial vehicle (Unbemanntes Luftfahrzeug)

1. Einleitung

Informationen, die mit Hilfe von Fernerkundungssystemen gewonnen werden, sind seit den letzten Jahren von steigender Bedeutung. Zunächst wurden sie überwiegend vom Militär für Spionagezwecke genutzt, bald darauf wurde aber auch der Nutzen für wissenschaftliche und kommerzielle Anwendungen erkannt, um Prozesse auf der Erdoberfläche und in der Atmosphäre wahrzunehmen. Als Standardverfahren werden Fernerkundungssysteme inzwischen für Wetterbeobachtungen und Umweltmonitorings genutzt (de Lange 2013).

Die Entwicklung der letzten Jahre zu einer sehr hohen räumlichen Auflösung von unter 10 m² sowie einer sehr hohen spektralen Auflösung öffnen neue Möglichkeiten für ökologische Fragestellungen. Es werden daher zunehmend Fernerkundungsdaten im Bereich der Ökologie und Ressourcen-Management genutzt (Pettorelli et al. 2014).

Zur Auswertung der Daten können verschiedene Methoden genutzt werden, die sich durch ihre unterschiedlichen Eigenschaften auszeichnen. So vollbringt das menschliche Sehvermögen eine hohe Leistung bei der Wahrnehmung von Bildstrukturen, Texturen und Formen sowie bei der Analyse von Zusammenhängen. Hier sind Menschen gegenüber Computerverfahren im Vorteil. Hingegen können Grauwerte und Flächengrößen nur ungenau wahrgenommen werden oder unterliegen einer optischen Täuschung, hier ist eine digitale Bildauswertung durch ein Computerverfahren besser geeignet. Voraus sind Computerverfahren den Menschen auch bei der Analyse von multispektralen Daten, wobei die verschiedenen Objektklassen anhand von Messdaten durch Multispektralscanner unterschieden werden. Dies ist durch die verschiedenen Reflexionseigenschaften von Boden, Vegetation und Gewässer möglich (Albertz 2009).

Der Nutzen von Fernerkundungsdaten ist groß, aber das Potential wird auch durch verschiedene Probleme gemindert. Zwar sind mittlerweile zum Beispiel einige Satellitenbilder für regionale und globale Maßstäbe kostenfrei erhältlich, aber der Großteil ist es noch nicht. Weitere Kostenfaktoren sind z.B. die Software und qualifiziertes Personal, wodurch eine Anwendung oft gehindert wird (Pettorelli et al. 2014). Der Trend zeigt aber, dass die Fernerkundung Wissenschaftlerinnen und Wissenschaftlern der Ökologie und Biologie durch zunehmend freizugängliche Daten, Open-Source-Softwares und Tools (z.B. Quantum GIS, GRASS, R und Orfeo

Toolbox) zugänglicher gemacht wird und es eine immer größere Bedeutung erlangt (Corbane et al. 2015).

In den letzten Jahren zeigt sich zudem ein zunehmendes Interesse für UAVs (unmanned aerial vehicles). UAVs zeichnen sich im Vergleich zu bemannten Flugzeugen, die eine ähnlich hohe räumliche Auflösung von ca. 3 cm² erfassen, v.a. durch eine hohe Flexibilität und preisgünstigere Anwendung aus. Sie kommen daher bei verschiedenen Monitorings, bei denen eine sehr hohe räumliche Auflösung benötigt wird, häufig zur Anwendung. Dieses können Monitorings von schwer zugänglichen Flächen, Waldentwicklungen, Wildtieren und von landwirtschaftlichen Bereichen sein (Ventura et al. 2018). UAVs eignen sich v.a. für kleinere bis mittlere Areale (einige 10 ha) (Lindstaedt, Kersten 2018).

Mit sehr hoch auflösenden Fernerkundungsbildern, wie die von UAVs, können zudem bessere Klassifikationsergebnisse erreicht werden. Gemäß Immitzer et al. (2016) und Ma et al. (2017) lässt sich zwischen der Klassifikationsgenauigkeit und der räumlicher Auflösung ein Zusammenhang feststellen.

Zur Klassifizierung von hochaufgelösten Luftbildern hat sich die objektbasierte Bildanalyse (object based image analysis, OBIA) in den letzten Jahren durchgesetzt (Blaschke et al. 2014; Ma et al. 2017). Die pixelbasierte Methode, die bei mittel- und geringauflösenden Bildern eingesetzt wird, ist oft ungeeignet für die Klassifizierung sehr hochauflösender Daten. Da mit zunehmender räumlicher Auflösung die Varianz der Spektralwerte innerhalb der Landbedeckungsklassen zunimmt, wird die spektrale Trennung zwischen ihnen erschwert. Im Gegensatz zur pixelbasierten Methode wird bei der OBIA nicht nur die Spektralinformation genutzt, um Pixel zu gruppieren, sondern z.B. auch die Form und Zusammenhänge zwischen Objekten (Blaschke et al. 2014; Ventura et al. 2018).

Der Random Forest (RF) Algorithmus zeigt die beste Ausführung einer OBIA (Ma et al. 2017). Der RF gilt als erfolgreichste Methode des maschinellen Lernens und zeichnet sich durch Merkmale wie Einfachheit, Effizienz, Robustheit und Genauigkeit aus (Hänsch, Hellwich 2017).

Die vorliegende Arbeit hat das Ziel, einen Vergleich von Methoden und Fernerkundungsdaten zur Analyse vorzufindender Landbedeckung und verfügbarer Nahrungspflanzen für Eurasische Biber (*Castor fiber*), als Qualitätskriterien des Habitats, vorzunehmen. Im Fokus liegt hierbei

die voraussichtlich unterschiedliche Genauigkeit der Methoden. Die verschiedenen Vorgehensweisen sollen miteinander verglichen und deren Vor- und Nachteile aufgezeigt werden. Hierbei finden die neuen Potentiale und Erkenntnisse im Bereich der Fernerkundung Anwendung.

Der Anlass der Arbeit ist ein angedachtes Forschungsvorhaben am Institut für Wildbiologie und Jagdwirtschaft an der Universität für Bodenkultur. Hierfür bestehen die Überlegungen, mehrere Biber-Reviere (ca. 30 - 40 Gebiete) in Niederösterreich (NÖ) auf ihre Habitatqualität hin zu bewerten. Die Bewertungen sollen bis 2006 zurückführen. Für das Forschungsprojekt ist es daher interessant, mit welcher Methode und mit welchem Datensatz ein bestmögliches Ergebnis erreicht werden kann.

Getestet werden neben der Kartierung vor Ort als Evaluierungsmethode, eine visuelle Bildinterpretation sowie eine semi-automatische Bildauswertung durch eine objektbasierte Klassifikation. Als Datengrundlage dienen ein Orthophoto des Landes NÖ, ein Orthophoto einer UAV-Befliegung sowie unterschiedliche Höhenmodelle. Neben einer hohen Auflösung und dem Bedarf vergangene und gegenwärtige Zustände zu untersuchen, besteht der Anspruch, Methoden anzuwenden, deren Kostenaufwand möglichst gering ist. Der Einsatz eines UAVs soll aufgrund der sehr hohen räumlichen Auflösung der aufgenommenen Bilder zusätzlich getestet werden, auch wenn vergangene Zustände nicht zu untersuchen sind.

Als Studiengebiet wurde ein Abschnitt des Marchfeldkanals zwischen Deutsch-Wagram und der Schnellstraße S1 in NÖ gewählt. Der Abschnitt ist ca. 3 km lang (Flusslauf) und geht von jedem Uferrand 30 m in die Breite. Es zeichnet sich durch eine relative heterogene Struktur aus, neben einer dichten Gehölzstruktur verschiedenster Arten am Ufersaum bestehen auch Sukzessionsbereiche und offene Flächen. Der Kanal ist des Weiteren von Begleitwegen und landwirtschaftlichen Flächen umgeben.

Die Ausdehnung des Studiengebietes ist an dem Verhalten vom Biber angepasst, der sich in der Regel bis zu 30 m vom Uferrand entfernt (Janiszewski 2012). Die zu erhebenden Landbedeckungsklassen wurden aufgrund der Nahrungsphysiologie des Bibers festgelegt. Biber leben im Frühling und Sommer überwiegend von frischen grünen Pflanzen in der Nähe vom Wasserkörper, dazu zählen Gräser, Kräuter, Wasserpflanzen und Ackerfrüchte (Zahner et al. 2005; Scheikl 2015). Im Herbst intensivieren sie das Fällern von Gehölzen. Bevorzugt werden Weich-

holzgehölze, wie Weiden (*Salix spp.*), Pappeln (*Populus spp.*) und Schwarz-Erlen (*Alnus glutinosa*) (Janiszewski 2012; Kemnade et al. 2002; Vorel et al. 2015). Bäume mit einem Stammdurchmesser von bis zu 10 cm werden besonders oft gefällt (Kemnade et al. 2002; Sieber 2002; Janiszewski 2012). Die hohe Präferenz von Bibern für Weiden und Pappeln besteht vermutlich wegen der besseren Verdaulichkeit. Weiden zeichnen sich zudem dadurch aus, dass sie schnell nachwachsen und einen höheren Anteil an Nährstoffen besitzen im Vergleich zu anderen Gehölzen (Vorel et al. 2015).

Folgende Forschungsfragen sollen in der vorliegenden Arbeit beantwortet werden:

1. Mit welchem Datensatz (Spektralinformation, Vegetationshöhenmodell, Textur, NDVI) lässt sich das genaueste Klassifikationsergebnis erzielen?
2. Ergeben sich Unterschiede in den Flächenanteilen der Landbedeckungsklassen je nach angewendeter Methode (visuelle Bildinterpretation, Kartierung vor Ort, objektbasierte Klassifikation)?
3. Lassen sich die bevorzugten Nahrungspflanzen vom Biber durch eine objektbasierte Klassifikation unterscheiden?
4. Welche Vor- und Nachteile besitzen die angewendeten Methoden für das Forschungsvorhaben?

2. Exkurs: Grundlagen der Luftbildauswertung

Das folgende Kapitel soll ein technisches Hintergrundwissen zum Verständnis der angewendeten Methode vermitteln.

Zum Auswerten von Orthophotos werden zwei wesentliche Methoden unterschieden. Zum einen die „visuelle Bildinterpretation“, bei der die Auswertung manuell durch eine Person erfolgt. Hier werden durch die menschlichen Fähigkeiten Inhalte eines Bildes wahrgenommen und Zusammenhänge erkannt. Die rechnerische Verarbeitung, um gewünschte Informationen zu extrahieren, wird hingegen als „digitale Bildauswertung“ verstanden (Albertz 2009).

2.1 Visuelle Bildinterpretation

Bei der visuellen Bildinterpretation lassen sich zwei Stufen des Interpretationsprozesses voneinander unterscheiden. Zunächst das direkte Erkennen von Strukturen, wie Straßen, Flüsse und Felder, welches überwiegend durch die Erfahrungen des Beobachters erfolgt. Daraus folgt das Interpretieren, wobei durch die erkannten Objekte Schlussfolgerungen gezogen werden können, dabei spielen fachspezifische Vorkenntnisse und Erfahrungen eine Rolle (Albertz 2009). So lässt sich z.B. assoziieren/interpretieren, dass die Straße, die über einen Fluss führt, eine Brücke sein muss.

Zum Interpretieren von Luftbilddaufnahmen werden meist folgende Eigenschaften betrachtet (Albertz 2009; Lillesand et al. 2015):

- Farbton
- Form/Gestalt
- Textur (Frequenz von Farbtonänderungen)
- Größe (im Verhältnis zum Maßstab)
- Muster (räumliche Anordnung der Objekte)
- Schatten

Neben dem Luft- oder Satellitenbild sind weitere Unterlagen zu dem Gebiet bedeutend, um das Vorwissen des Betrachters zu erweitern, insbesondere sind topographische und thematische Karten relevant. Im Idealfall wird sich zunächst in einer Vorinterpretation mit dem Bildmaterial vertraut gemacht, eine Gliederung des Gebietes erstellt und Bereiche ausgewählt,

die im Gelände untersucht werden sollen. Die Geländeerkundung, wenn sie erforderlich erscheint, sollte vor der Detailinterpretation erfolgen. Dadurch sollen regionale Besonderheiten und eventuell „Schlüsselinformationen“ gewonnen werden. In der Detailinterpretation werden die Flächen, die in der Vorinterpretation als wichtig erachtet wurden, im Detail betrachtet, dazu zählt das Erkennen von Objekten und die Erkenntnisse mit vorhandenem Kartenmaterial zu vergleichen. Durch eine weitere Geländebegehung sind eventuelle Unsicherheiten und offene Fragen zu klären. Die zu interpretierenden Objekte werden zu einem Interpretationsschlüssel zusammengestellt. Dieser ist jeweils auf die Fragestellung auszurichten und außerdem von dem Bildmaßstab und eventuell von der Jahreszeit abhängig (Albertz 2009).

Ein Interpretationsschlüssel hilft, die Informationen auf der Karte zu evaluieren. Dieser kann entweder aus einer Kollektion von kommentierten Beispielbildern oder einer wörtlichen Darstellung bestehen, welches nach einem Ausschlussprinzip aufgebaut wird, sodass man Schritt für Schritt zum Ergebnis gelangt (Lillesand et al. 2015).

2.2 Digitale Bildauswertung

Die Verfahren der Fernerkundung nutzen für eine digitale Bildinterpretation physikalische Strahlungsvorgänge in der Atmosphäre, um Informationen zu einer bestimmten Fragestellung abzuleiten. Elektromagnetische Strahlung des sichtbaren Lichtes, des nahen Infrarots (NIR) und der Wärmestrahlung im Infrarotbereich und anderer nicht sichtbarer Strahlung, die von den Objekten auf der Erde (z.B. Wiese, Wald etc.) oder in der Atmosphäre (z.B. Wolken) emittiert oder reflektiert werden, werden erfasst. Jedes Objekt emittiert und reflektiert auf unterschiedliche Weise, je nach Art und Beschaffenheit sowie Zustand des Objektes. Aufgrund des spezifischen Strahlungs- oder Reflexionsverhalten ist es somit möglich, die unterschiedlichen Objekte zu identifizieren (de Lange 2013). Für viele Oberflächenarten lassen sich dadurch charakteristische Reflexionskurven angeben, dessen Kenntnis für die Praxis von großer Bedeutung sind (Abb. 1) (Albertz 2009).

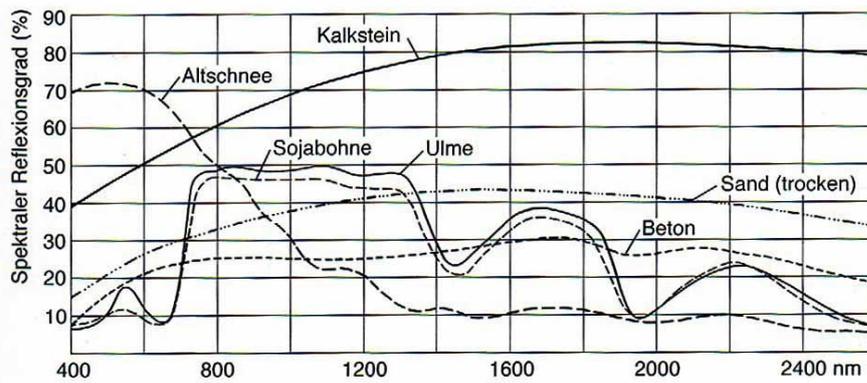


Abb. 1: Reflexionsverhalten ausgewählter Oberflächen auf der Erde (Albertz 2009).

Grüne Pflanzen weisen ein prägnantes Reflexionsverhalten auf (Abb. 1). Im sichtbaren Licht wird durch chlorophyllhaltige Blattpigmente blaues und rotes Licht weitgehend absorbiert, grünes Licht wird jedoch weniger absorbiert und mehr reflektiert, weshalb uns Blätter grün erscheinen. Im Übergangsbereich des sichtbaren Lichtes zum NIR kommt es zu einem starken Anstieg der Reflexion. Die Infrarot-Strahlung wird an den Zellwänden und luftgefüllten Hohlräumen der Blätter mehrfach gespiegelt und dadurch überwiegend reflektiert (Colwell et al. 1963, zitiert in Albertz 2009). Diese Erscheinung hängt eng mit der Wasserversorgung der Pflanze und anderen Vitalitätsfaktoren zusammen. Die Reflexionskurve unterliegt daher vielfältigen Variationen (Albertz 2009).

Für die Fernerkundung sind die Spektralbereiche des elektromagnetischen Spektrums im sichtbaren Licht, im Infrarot und auch im Mikrowellenbereich (Radar) von Bedeutung. Die Spektralbereiche sind nicht scharf zu trennen und gehen ineinander über, daher ist nur eine grobe Einteilung möglich. Das sichtbare Licht hat einen Wellenlängenbereich von etwa 0,4 bis 0,7 μm . Das Infrarot wird unterteilt in das nahe, kurzwellige, mittlere und in das ferne Infrarot (Thermalstrahlung). Dahinter folgt der Mikrowellenbereich, welcher ab 1 mm beginnt (Abb. 2) (de Lange 2013).

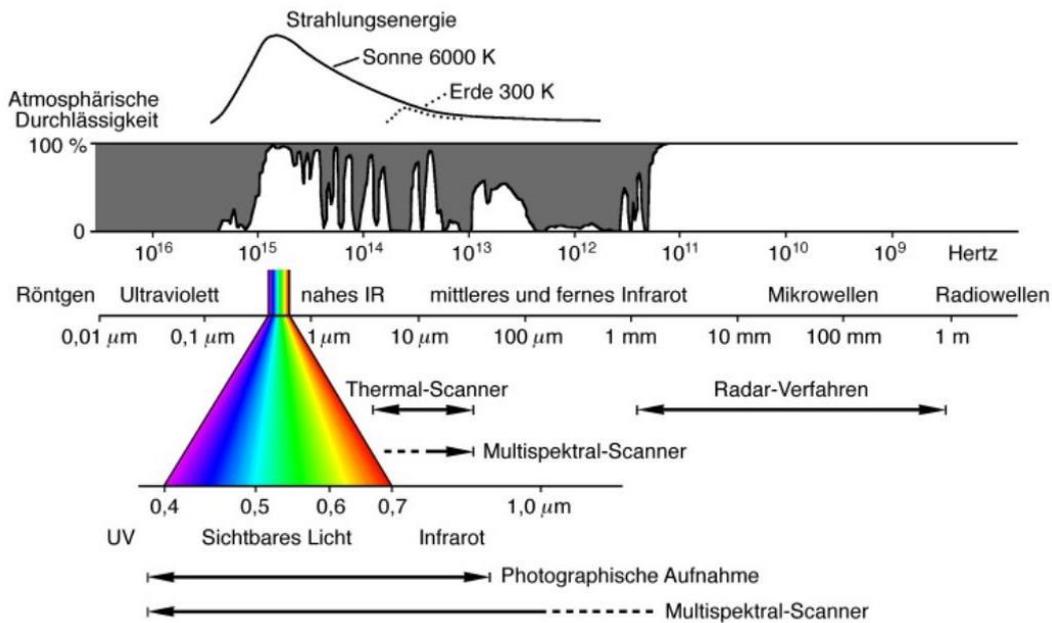


Abb. 2: Elektromagnetisches Strahlungsspektrum (Albertz 2009).

Die reflektierte Strahlung der Sonne sowie die emittierte Wärmestrahlung werden in der Fernerkundung durch Aufnahmesysteme (Sensoren) gemessen. Jeder Sensor erfasst einen bestimmten Frequenzbereich elektromagnetischer Strahlung. Die Intervalle der elektromagnetischen Strahlung, die ein Sensor erfasst, werden in der Fernerkundung als Kanäle bezeichnet (de Lange 2013).

Für die Beurteilung der Leistungsfähigkeit eines Aufnahmesystems sind v.a. die folgenden vier Merkmale relevant (de Lange 2013):

- Die räumliche Auflösung → Größe eines Pixels auf dem Boden in Meter
- Die spektrale Auflösung → Anzahl der Kanäle und erfasste Wellenlängenbreite
- Die radiometrische Auflösung → Intensitätsstufen zur Erfassung der Helligkeitsunterschiede (Anzahl der Grauwerte)
- Die temporale Auflösung → Aufnahmehäufigkeit

2.2.1 Grundprinzip der Multispektral-Klassifizierung

Bei digitalen Bildern besteht die Möglichkeit, den Inhalt durch numerische oder statistische Verfahren auszuwerten. Von Bedeutung ist v.a. die rechnergestützte Klassifikation, wodurch z.B. Landbedeckungstypen durch das Auswerten mehrerer Kanäle identifiziert werden können (de Lange 2013).

Die folgende Abbildung verdeutlicht die Klassifikationsstrategie, die durch das unterschiedliche Reflexionsverhalten der Objekte möglich ist. Optimal liegen die Objekte (Pixel) in verschiedenen und in deutlich voneinander getrennten Bereichen des mehrdimensionalen Merkmalsraumes, welcher durch die Reflexionswerte der Kanäle definiert ist (Abb. 3). Durch Klassifikationsverfahren ist es möglich, die Punktwolken der Pixel mit ähnlichen Eigenschaften zu identifizieren und z.B. bestimmten Landbedeckungstypen zu zuordnen (de Lange 2013).

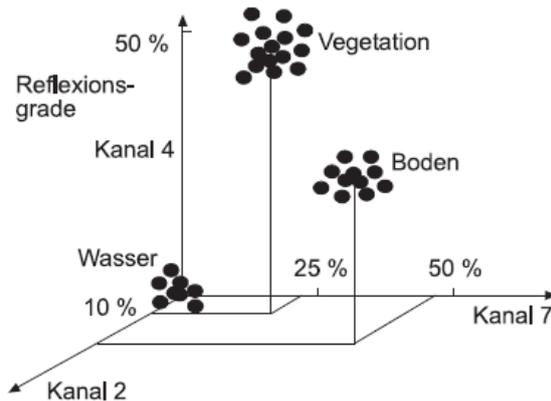


Abb. 3: Darstellung von Pixeln zu drei Landbedeckungstypen im dreidimensionalen Raum (de Lange 2013).

Zu den Klassifikationsverfahren werden die unüberwachte und die überwachte Klassifikation unterschieden. In dieser Arbeit wird die überwachte Klassifikation durchgeführt, auf die im Folgenden näher eingegangen wird.

Vorab sind die Landbedeckungsklassen anhand von Signaturkurven zu bestimmen, dieses erfolgt „überwacht“ durch bekannte Oberflächentypen einzelner Testflächen, sogenannte Trainingsgebiete. Bei der Klassifikation wird von einem charakteristischen Reflexionsverhalten, wie zuvor beschrieben, ausgegangen, sodass es anhand der Signaturkurven möglich ist, bestimmte Landbedeckungen zu identifizieren. Die Signaturkurven sind für jedes Untersuchungsgebiet neu zu bestimmen, da sie sich für eine Oberfläche je nach Jahreszeit oder Atmosphärenzustand ändern. Ein Trainingsgebiet sollte in der Landbedeckung möglichst homogen sein und ein Referenzwert der Landbedeckung, z.B. durch eine vorherige Kartierung, sollte vorliegen. Die Signaturkurven dieser Trainingsgebiete definieren die gesuchten Reflexionsklassen oder Musterklassen. Dafür wird zunächst ein Startpixel gewählt, dessen Bedeutung bekannt ist. Aus diesem Startpixel ergibt sich eine größere Fläche an Pixeln, wenn sie hinsichtlich der Spektralwerte homogen sind. Der Nachbarpixel muss somit ein „Homogenitätskriterium“

erfüllen. Räumliche Vorkenntnisse und Geschick sind für die Auswahl der Trainingsgebiete notwendig. Im weiteren Schritt erfolgt eine Zuordnung der Trainingsgebiete zu den Musterklassen. Für diese Zuweisung sind verschiedene Algorithmen möglich (z.B. Minimum-Distanz-Klassifikation, Maximum-Likelihood-Klassifikation) (de Lange 2013).

Die beschriebene Methode wird pixelbasierte Methode genannt. In der vorliegenden Arbeit wird die objektbasierte Methode angewendet, dabei werden im Gegensatz zur pixelbasierten Klassifizierung nicht nur Pixel zusammengefasst, die in ihrem Spektralbereich homogen sind, sondern weitere Merkmale werden berücksichtigt.

Der Prozess einer objektbasierten Methode erfolgt in zwei wesentlichen Schritten (Lillesand et al. 2015):

1. Segmentierung des Bildes in diskrete Objekte
2. Klassifikation dieser Objekte

Unter der Segmentierung wird die Gruppierung benachbarter Pixel zu Pixelgruppen aufgrund von Ähnlichkeitskriterien z.B. in der Textur oder Spektralsignatur verstanden (Neubert and Blaschke 2004). Dieses Verfahren ähnelt dem menschlichem, visuellem interpretieren von Bildern, welches anhand der Farbe, Textur, Größe etc. erfolgt (Lillesand et al. 2015). Die Größe der Objekte ist einer der Hauptparameter, welcher das Segmentierungsergebnis beeinflusst (Lillesand et al. 2015). Dabei gibt es allerdings kein richtig oder falsch, es ist vielmehr vom Anwendungszweck und dem Auswertungsmaßstab abhängig (Neubert, Blaschke 2004).

Ist ein Bild segmentiert, gibt es viele Merkmale, die Objekte zu klassifizieren. Es lassen sich grob zwei Gruppen unterscheiden. Zum einen die Merkmale, wie die spektralen Eigenschaften, Textur etc. und zum anderen die räumliche Zusammengehörigkeit zwischen den Objekten. Zum Beispiel ist ein Objekt mit einer linearen Form, einer spektralen Signatur ähnlich zum Asphalt, einer glatten Textur und mit einem topografischen Zusammenhang zu anderen Straßen, wahrscheinlich auch eine Straße (Lillesand et al. 2015).

3. Methode

3.1 Untersuchungsgebiet

Das Untersuchungsgebiet verläuft entlang des Marchfeldkanals in NÖ. Es befindet sich westlich von Deutsch-Wagram und endet unmittelbar an der Schnellstraße S1 (ca. 3 km Flusslauf). Das Untersuchungsgebiet reicht von jeder Uferseite 30 m in die Breite, da Biber sich in der Regel max. 30 m vom Uferrand weg bewegen (Janiszewski 2012). Es umfasst eine Flächen­größe von ca. 305.000 m². Die Ufersäume sind durch eine dichte Gehölzstruktur verschieden­ter Arten geprägt. Der südliche Ufersaum entlang des gestreckten Kanalabschnittes hat eine Breite von ca. 12 m und wurde mit einem Niveauunterschied von ca. drei Metern als Hochwasserschutzdamm angelegt. Der Ufersaum ist durch einen Schotterweg begrenzt. Der nördliche Ufersaum hat eine Breite von ca. 6 m und wird durch einen begrünten Weg begrenzt. Im Bereich des Südufers, in der Mitte des Untersuchungsgebietes, befindet sich ein Stillgewässer, das von einer dichten Gehölzvegetation umsäumt ist. Im östlichen Bereich des Gebietes befindet sich ein Wehr. Die Durchgängigkeit wurde durch eine naturnahe Fischaufstiegshilfe wieder hergestellt. Die Fischtreppe hat einen geschwungenen Verlauf und besitzt breite und engere Gewässerabschnitte. Das Ufer ist in diesem Bereich durch eine sehr dichte Gehölzstruktur geprägt. Zudem gibt es dort, zwischen Ufersaum und Bahntrasse, offene Bereiche mit einer krautigen Vegetation sowie Sukzessionsbereiche mit v.a. Silber-Pappeln. Das Untersuchungsgebiet endet bevor der Kanal in den Rußbach mündet. Am anderen Ende des Gebietes im Nordwesten besteht eine große Fläche mit jungen Gehölzen. Zum einen durch Bepflanzungen verschiedener Baumarten sowie durch Sukzession von v.a. Weiden und Silber-Pappeln. In diesem Bereich nähert sich der Seyringer Graben, der weiter parallel entlang des Marchfeldkanals verläuft und im östlichen Bereich nach dem Wehr in den Kanal mündet. Der Seyinger Graben hat eine Breite von ca. 2 -3 m und verläuft in einem trapezförmigen, begrünten (Gräser, Röhricht) Profil. Gehölze entlang des Seyringer Grabens treten nur vereinzelt auf (Abb. 4).

Die UAV-Aufnahme konnte aufgrund der örtlichen Bedingungen (Strommasten, Autobahn) nur im östlichen Bereich des Untersuchungsgebietes, wo sich das Wehr und die Fischtreppe befinden, durchgeführt werden. Dieser Bereich wird in Abb. 4 durch einen roten Kreis aufgezeigt und wird fortlaufend als „kleines Untersuchungsgebiet“ bezeichnet, die gesamte Untersuchungsfläche dahingegen als „großes Untersuchungsgebiet“. Die Fläche des kleinen Gebietes umfasst ca. 49.000 m².

Der Marchfeldkanal wurde zwischen 1986 und 2004 errichtet. Er wurde v.a. aus wasserwirtschaftlichen Interessen erbaut, er soll die Wasserversorgung und den Hochwasserschutz sicherstellen sowie die Wasserqualität verbessern, da das Gebiet durch Dürre aber auch durch Hochwasser geprägt ist. Durch eine naturnahe Bauweise erfüllt er zusätzlich ökologische und touristische Zielsetzungen (Betriebsgesellschaft Marchfeldkanal 2018).

Der Marchfeldkanal bietet sich in diesem Bereich aufgrund der heterogenen Struktur als Studiengebiet gut an. Alle Landbedeckungsklassen, die auch für das angedachte Forschungsvorhaben erhoben werden sollen, sind dort zu finden. Zudem kommen dort nachweislich Biber vor, sodass von geeigneten Bedingungen entlang der Ufer für den Biber ausgegangen werden kann.

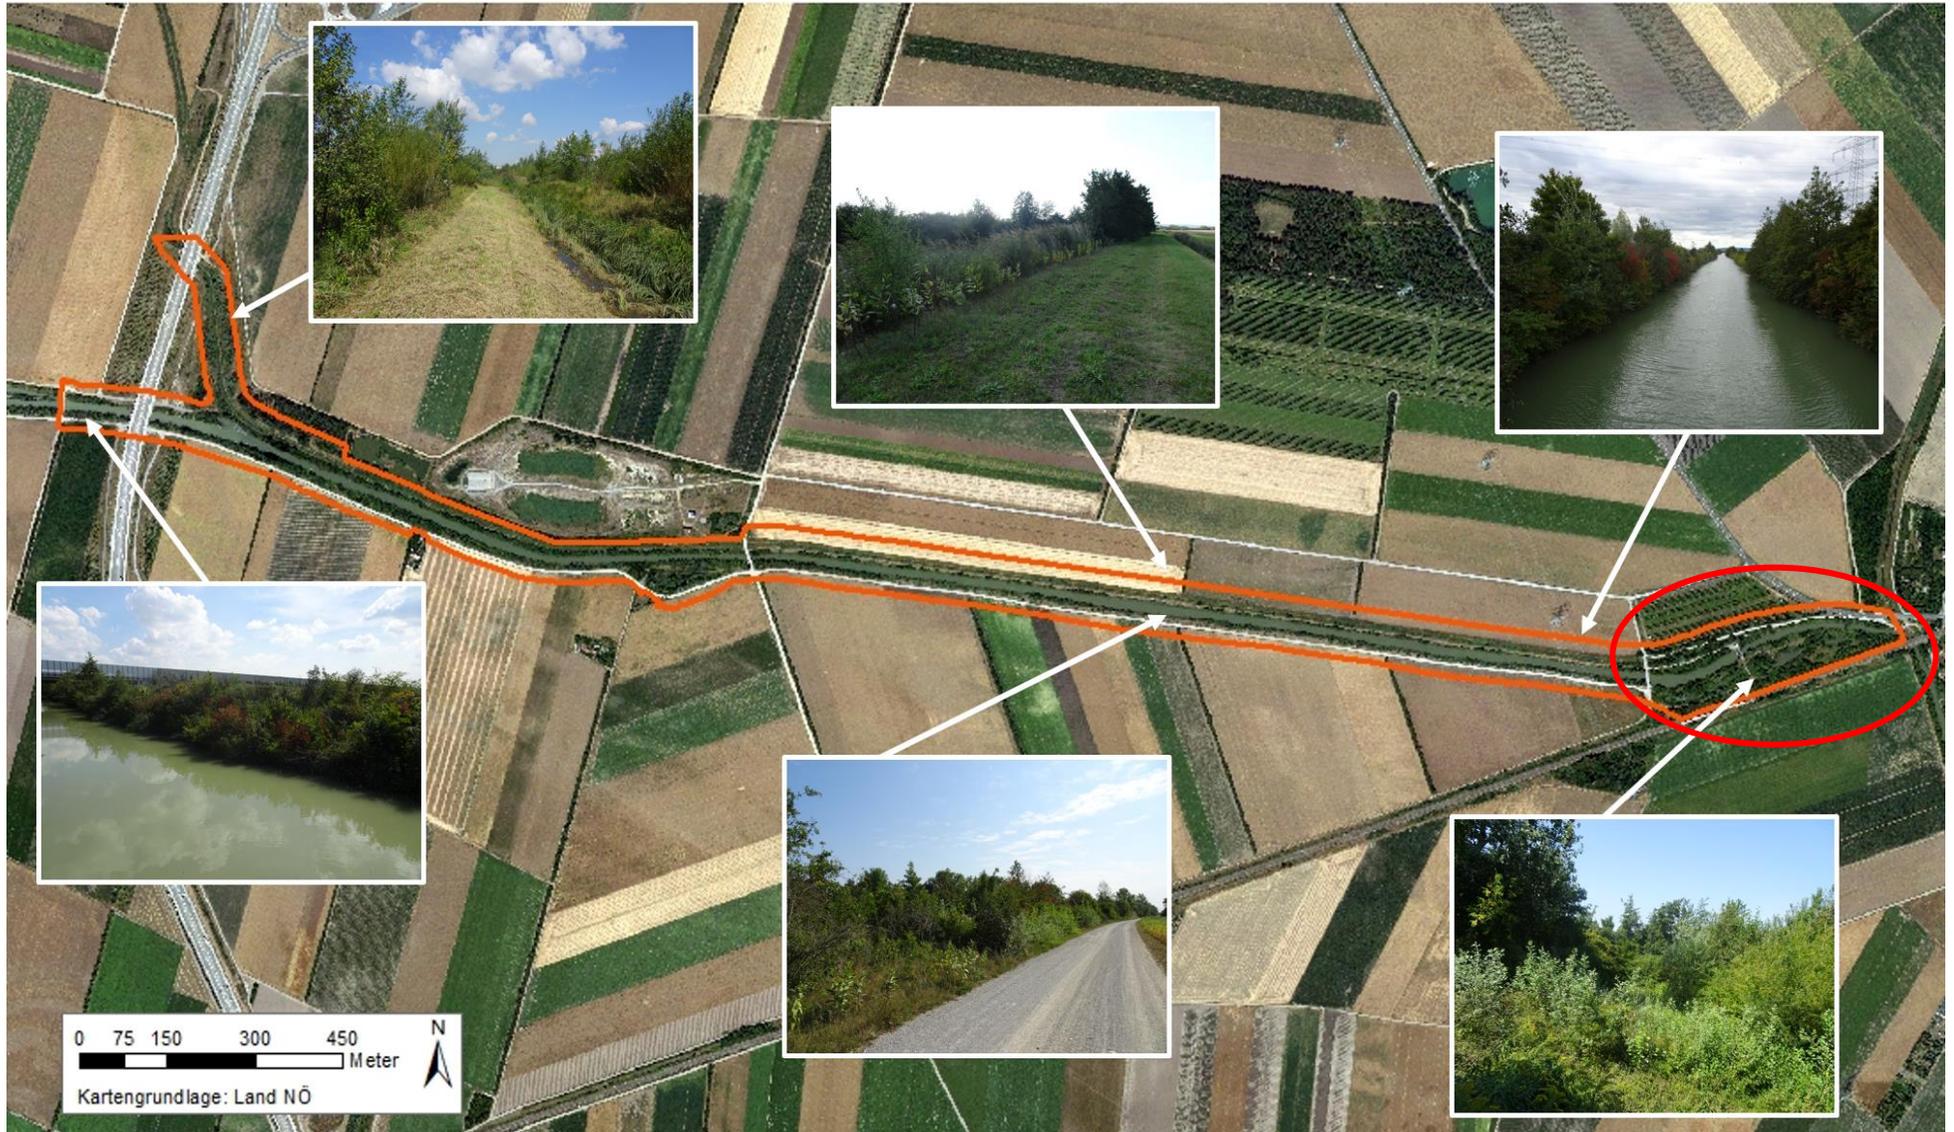


Abb. 4: Untersuchungsgebiet mit verorteten Fotos. Großes Untersuchungsgebiet = orange Grenze, kleines Untersuchungsgebiet = innerhalb roter Grenze (Kartengrundlage: Orthophoto, Land NÖ).

3.2 Datengrundlage

Für die Charakterisierung der Landbedeckung, durch visuelle Bildinterpretationen und objektbasierte Klassifikationen, wurden verschiedene Daten zur Verfügung gestellt (Tab. 1).

Vom Land NÖ wurden kostenfrei ein Orthophoto aus dem Jahr 2015 (fortführend als „Orthophoto“ genannt), entstanden durch eine Luftbildbefliegung eines bemannten Systems, ein Digitales Geländemodell (DGM) und ein Digitales Oberflächenmodell (DOM) aus dem Jahr 2011/12, jeweils durchgeführt durch ein Airborne Laserscanning (ALS) bereitgestellt (fortführend als „DGM (ALS)“ und „DOM (ALS)“ genannt).

Ein weiteres DOM, welches durch photogrammetrische Prozesse über ein Bildmatching-Algorithmus (BM) aus den Luftbildern des Landes NÖ des Jahres 2015 generiert wurde, wurde kostenfrei durch das Bundesforschungszentrum für Wald in Wien zur Verfügung gestellt (fortführend als „DOM (BM)“ genannt). Erhalten wurde eine Punktwolke.

Anhand einer UAV-Befliegung des kleinen Untersuchungsgebietes im Sommer 2018 entstand ein Orthophoto (fortführend als „UAV-Aufnahme“ genannt) und ein Normalisiertes digitales Oberflächenmodell bzw. ein Vegetationshöhenmodell (nDOM) (fortführend als „nDOM (UAV)“ genannt). Die Befliegung und die Datengenerierung wurden vom Institut für Vermessung, Fernerkundung und Landinformation (IVFL) in Wien durchgeführt.

Tab. 1: Genutzte Datengrundlage für das große Untersuchungsgebiet (Beispielausschnitt: Maßstab 1:500).
ALS = Airborne Laserscanning, BM = Bildmatching.

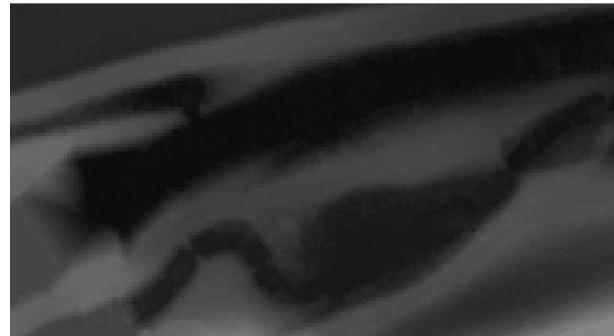
Orthophoto

- 4 Kanäle (RGBI)
- 0,2 m x 0,2 m
- Quelle: Land NÖ
- Aufnahmejahr: 2015



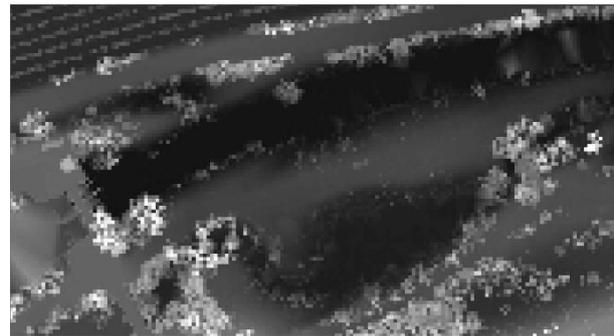
DGM (ALS)

- 1 m x 1 m
- Quelle: Land NÖ
- Aufnahmejahr: 2011/12



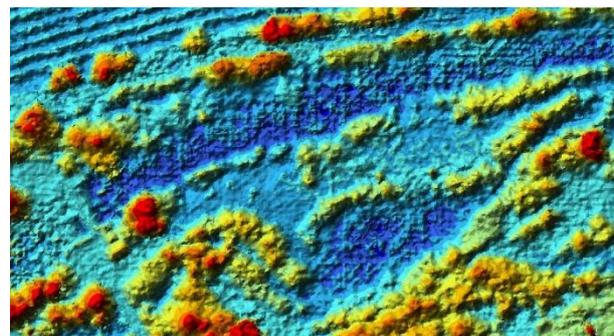
DOM (ALS)

- 1 m x 1 m
- Quelle: Land NÖ
- Aufnahmejahr: 2011/12



DOM (BM)

- 1 m x 1 m
- Quelle: Bundesforschungszentrum für Wald, Wien
- Aufnahmejahr: 2015



Tab. 2: Genutzte Datengrundlage für das kleine Untersuchungsgebiet, entstanden durch eine UAV-Befliegung (Beispielausschnitt: Maßstab 1:500).

UAV-Aufnahme

- 6 Kanäle (RGBI)
- 0,03 m x 0,03 m
- Quelle: IVFL (BOKU), Wien
- Aufnahmejahr: 2018



nDOM (UAV)

- 0,03 m x 0,03 m
- Quelle: IVFL (BOKU), Wien
- Aufnahmejahr: 2018



3.2.1 Technische Eigenschaften des unbemannten Luftfahrzeuges

Das UAV des Types DJI S900 (modifiziert) hat eine Geschwindigkeit von 0-8 m/s und eine Flugzeit von 15 min pro Akkusatz. Die gesetzlich maximal erlaubte Flughöhe beträgt 150 m. Auf dem UAV ist u.a. eine Multispektralkamera montiert, deren Aufnahmen für die vorliegende Arbeit genutzt wurden. Die Kamera verfügt über sechs Spektralkanäle. Von denen befinden sich vier im sichtbaren Spektralbereich: Blau (450 nm), Grün (530 bzw. 560 nm) und Rot (675 nm). Der Red-Edge Kanal befindet sich bei 730 nm und der NIR-Kanal bei 850 nm. Die einzelnen Spektralkanäle sind sehr schmalbandig und weisen somit sehr enge Sensitivitätsbereiche auf.



Abb. 5: Genutztes UAV (Immitzer 2018)

Anhand der Datengrundlage wurden weitere Daten generiert und aufbereitet. Mit Hilfe der Software ArcMap (Version 10.4.1) wurden folgende Schritte durchgeführt:

3.2.2 Datenaufbereitung

Aus der Punktwolke des Bundesforschungszentrums für Wald in Wien wurde ein Digitales Oberflächenmodell (DOM) erstellt. Hierfür musste lediglich die Punktwolke gerastert werden

(*ArcToolbox: Conversion Tools → to Raster → LAS to Raster*) (fortführend als „DOM (BM)“ genannt).

Es wurden nDOMs berechnet, die sich aus der Differenz eines DOMs und eines DGMs ergeben (*ArcToolbox: Raster Calculator → "DOM" - "DGM"*). Die Vegetationshöhen sind dadurch relativ zum Boden erkennbar. Es wurden das DOM von dem ALS-Verfahren und das DOM von dem BM-Verfahren genutzt. Als DGM beider nDOMs wurde das DGM aus dem ALS-Verfahren angewendet. Fortführend werden die generierten nDOMs als „nDOM (ALS)“ und „nDOM (BM)“ genannt.

Des Weiteren wurde ein Normalisierter differenzierter Vegetationsindex (NDVI) aus den Spektralinformationen (Orthophoto, UAV-Aufnahme) generiert (*ArcMap unter: Image Analysis*). Der Index ist ein Maß für die Vitalität der Vegetation. Für die Berechnung werden die Bänder im roten und NIR Wellenlängenbereich verwendet. Hier ist der Unterschied der reflektierten Strahlung besonders groß, wenn eine hohe Vitalität der Vegetation vorherrscht (Albertz 2009). Die Formel zur Berechnung lautet: $(\text{NIR} - \text{Rot}) / (\text{NIR} + \text{Rot}) = \text{NDVI}$.

Mit Hilfe der Open Source Software Orfeo Toolbox (Version 5.0.0) wurden Texturen anhand der Spektralinformation (Orthophoto, UAV-Aufnahme) berechnet. Zum einen wurden zwei Haralick-Texturen erstellt, die simple und advanced Version (*Feature Extraction → Haralick Texture Extraction*). Zum anderen sollte auch die SFS-Textur getestet werden (*Feature Extraction → SFS Texture Extraction*).

3.3 Visuelle Bildinterpretation (manuell)

Die manuelle Erfassung der Landbedeckung erfolgte anhand des Orthophotos (Luftbildbefliegung 2015), dazu gehören die folgenden Methoden:

- Visuelle Bildinterpretation (ohne Geländebegehung)
- Visuelle Bildinterpretation + nDOM (ohne Geländebegehung)
- Visuelle Bildinterpretation + Kartierung vor Ort (Sommer 2018)

Die Abgrenzung der Landbedeckungsklassen erfolgte nach den Zielklassen und Regeln, die in der folgenden Tab. 3 beschrieben sind. Die Abgrenzung und Visualisierung der Objekte bzw. Zielklassen wurde in ArcMap durchgeführt.

Tab. 3: Interpretationsschlüssel mit Definitionen für die manuelle Abgrenzung der Landbedeckungsklassen.

<p>BAUM</p>  <p>ausgebildete Krone, deutlicher Schattenwurf, akrotoner Wuchs, ab 5 m Höhe definitiv Baum</p>	<p>RÖHRICHT (=Schilfrohr, Rohr-Glanzgras, Rohrkolben)</p>  <p>dichter Bewuchs in Wassernähe, kein Schattenwurf, Höhe bis ca. 1,5 m</p>
<p>STRAUCH/SUKZESSION</p>  <p>verwischte Textur, geringer Schattenwurf, basitoner Wuchs, bis max. 5 m Höhe</p>	<p>ACKER</p>  <p>mit oder ohne Frucht, rechteckige Form</p>
<p>KRAUTIGE VEGETATION/GRAS</p>  <p>Mehrere Farben: grau, grün und braun</p>	<p>WASSER</p>  <p>glatte Textur, einfarbig blau/grau</p>
<p>UNBEFESTIGTER WEG</p>  <p>Grasfläche mit Fahr- oder Tritts Spuren</p>	<p>SCHOTTER</p>  <p>Hellgrauer/weißer Farbton</p>
<p>SCHOTTERWEG MIT GRÜNSTREIFEN</p>  <p>Hellgrauer/weißer Farbton der Fahrspur, Grasstreifen in der Mitte (grün/braun)</p>	<p>ASPHALT</p>  <p>dunkelgrauer Farbton</p>
<p>GEBÄUDE</p>  <p>Eckiges Objekt</p>	<p>BAUWERK/SONSTIGES</p>  <p>z.B. Wehr oder nicht definierbares Objekt</p>

Die visuelle Bildinterpretation erfolgte ohne einer vorangegangenen Geländebegehung, da die Interpretation des Orthophotos ohne voreingenommen zu sein, durchgeführt werden sollte.

Für die Methode „Visuelle Bildinterpretation + nDOM“ wurde zur besseren Ablesbarkeit der Vegetationshöhen eine Schummerung (Hillshade) in ArcMap erstellt und das nDOM mit einer Transparenz von 50 % über die Schummerung gelegt. Strukturelle Details werden somit ersichtlicher (s. Abb. 6). Die Interpretation des nDOMs erfolgte mit der Regel, dass jede Vegetationsstruktur ab 5 m definitiv „Baum“ ist. Bei Höhen unter 5 m wurde anhand der vorherigen

visuellen Interpretation zwischen den Klassen „Baum“ und „Strauch/Sukzession“ abgewogen, welche Klasse zutreffender ist.

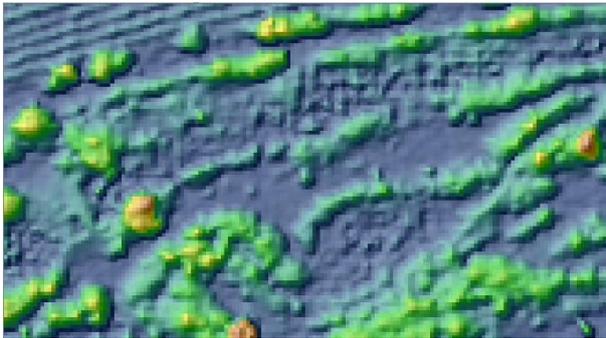


Abb. 6: nDOM mit Schummerung (Beispielausschnitt: Maßstab 1:500)

Bei der Methode „Visuelle Bildinterpretation + Kartierung vor Ort“ wurde für ein vergleichbares Ergebnis auch hier der Kronenbereich kartiert. Das Kartieren von kleinflächigen Strukturen stellte sich als schwierig dar, da ein genaues Verorten in der Karte (Maßstab 1:1000) nicht möglich war. Daher wurde die Regel aufgestellt, dass mindestens 70 % der abgegrenzten Fläche entweder „Baum“ oder „Strauch/Sukzession“ sein musste. Als Definition für einen Baum wurde ein akrotoner Wuchs, für Strauch dahingegen ein basitoner Wuchs, festgelegt. Das Einzeichnen der vorgefundenen Landbedeckungsklassen erfolgte für eine schnellere Durchführbarkeit auf der Ergebniskarte der vorangegangenen visuellen Bildinterpretation. So musste die bestehende Karte ggf. lediglich verbessert werden.

3.4 Digitale Bildauswertung (objektbasierte Klassifikation)

3.4.1 Segmentierung

Um eine OBIA ausführen zu können, ist zunächst eine Segmentierung durchzuführen. Dies erfolgte anhand der Orfeo Toolbox mit der Large Scale Mean Shift Segmentierung (LSMSS) (step 1 bis 4). Die LSMSS benötigt die Angabe von drei Parametern:

- Spatial Radius h_s (räumliche Distanz zwischen den Klassen)
- Range Radius h_r (spektrale Differenz zwischen den Klassen)
- Minimum Segment Size m_s (Verschmelzen von kleineren Segmenten)

Für h_s wurde $\frac{1}{2}$ der Standardabweichung und für h_r wurde $\frac{1}{4}$ der Standardabweichung des NIR-Kanals genutzt (Tab. 4). Der NIR-Kanal wurde gewählt, da dies der Kanal mit der höchsten

Standardabweichung ist. Diese Regelung hat sich bei Einzmann et al. (2017) als geeignet bewiesen und ergab auch hier ein gutes Segmentierungsergebnis.

Tab. 4: Segmentierungsparameter bei der LSMSS

Datensatz	spatial radius (hs)	range radius (hr)	minimum size (ms)
Orthophoto	16	8	60 (24 m ²)
UAV-Aufnahme	33	16,5	250 (22,5 m ²)

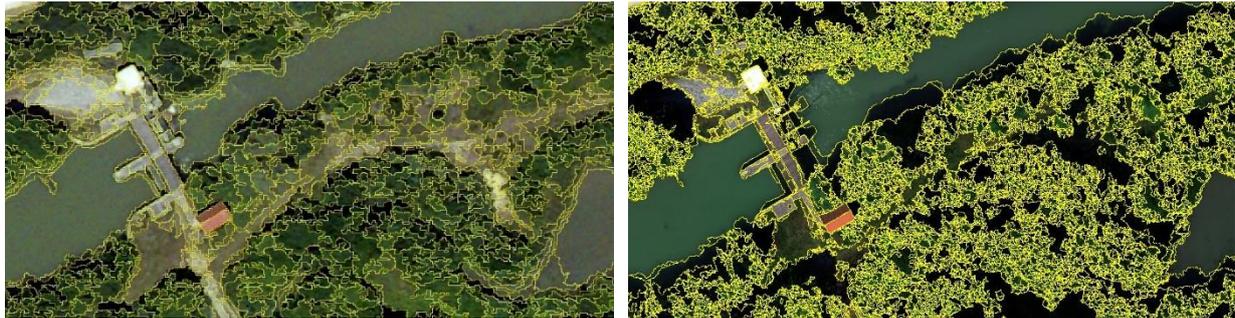


Abb. 7: Segmentierung vom Orthophoto (l.) und von der UAV-Aufnahme (r.) (Beispielausschnitte: Maßstab 1:500)

3.4.2 Trainingsdaten

Zum Trainieren des Klassifizierungsalgorithmus werden Trainingsdaten benötigt, deren Klassen bekannt sind. Diese konnten anhand der Ergebnisse der visuellen Interpretation und der Kartierung vor Ort festgelegt werden. Die Zuweisung der Trainingsdaten erfolgte in ArcMap anhand der Polygone der zuvor beschriebenen Segmentierung.

Die zuvor beschriebenen Landbedeckungsklassen der visuellen Bildinterpretation und der Kartierung vor Ort mussten teilweise für die OBIA von eher Landnutzungsklassen, die die manuelle Kartierung erleichterte, in Landbedeckungsklassen angepasst werden. Die Klasse „Feld“ wurde für eine weitere Differenzierung der Spektralwerte weiter unterteilt in „Feld Getreide“ und „Feld grün“. Die Klasse „Unbefestigter Weg“ entfällt bei der OBIA bzw. wird der Klasse „krautige Vegetation/Gras“ hinzugefügt, da bei einem unbefestigten Weg, der aus Gras besteht, vermutlich keine deutlichen Spektralunterschiede vorhanden sind. Die Klasse „Schotterweg mit Grünstreifen“ wurde differenziert in „Schotter“ und „krautige Vegetation/Gras“. Zudem wurde die Klasse „Schatten“ hinzugefügt, da diese Spektralwerte ansonsten keiner eindeutigen Klasse zugewiesen werden könnten. Die beiden Klassen „Gebäude“ und „Bauwerk/Sonstiges“ wurden in eine Klasse „Gebäude/Bauwerk“ zusammengefügt.

Für das Orthophoto wurden 100 Trainingsdaten, außer für die Klassen „Feld grün“ und „Feld Getreide“, festgelegt. Für diese beiden Klassen war es aufgrund der großen Segmente nicht möglich, mehr Trainingsdaten zu bestimmen.

Für die UAV-Aufnahme konnten aufgrund der geringeren erfassten Fläche des Untersuchungsgebietes lediglich 10 bis 60 Trainingsgebiete festgelegt werden (Tab. 5).

Tab. 5: Anzahl an Trainingsdaten pro Landbedeckungsklasse (Orthophoto, UAV-Aufnahme)

Landbedeckungsklassen	Anzahl Trainingsdaten	
	Orthophoto	UAV-Aufnahme
Baum	100	60
Strauch/Sukzession	100	60
Krautige Vegetation/Gras	100	40
Röhricht	100	10
Feld Getreide	32	2
Feld grün	32	0
Wasser	100	10
Schotter	100	40
Asphalt	100	10
Gebäude/Bauwerk	100	29
Schatten	100	40
Σ	964	301

Um die Klassifizierungsergebnisse besser miteinander vergleichen zu können, ist eine gleiche Anzahl an Trainingsdaten pro Klassen notwendig. Deswegen wurden in einem weiteren Durchlauf die Trainingsdaten der UAV-Aufnahme ebenfalls für das Orthophoto angewendet. Da die beiden Datengrundlagen aber eine unterschiedliche Segmentierung besitzen, musste die Zuweisung der Trainingsdaten neu erfolgen. Hierzu wurden zunächst die Trainingspolygone der UAV-Aufnahme als Punktshps umgewandelt, um dann in einem weiteren Schritt mit einem Auswahlverfahren (*Select* → *Select by Location*) die Polygone des Orthophotos auszuwählen, die einen Punkt des Punktshps beinhalten. Den ausgewählten Polygonen wurde im weiteren Schritt jeweils der Attributwert der Landbedeckungsklasse der UAV-Trainingsdaten zugewiesen.

3.4.3 Klassifizierung mittels Random Forest

Die Ausführung der Klassifizierung erfolgte mit der Open Source Software RStudio (Version 3.5.0) durch das Package Random Forest (RF) nach Breiman (2001). Die genutzten Codierungen für den Input in RStudio sind im Anhang I aufgeführt und näher erläutert.

RF gehört zu der Gruppe der überwachten Lernverfahren (Machine Learning), bei dem für das Training ein Trainingsdatensatz benötigt wird. RF kombiniert Entscheidungsbäume und Ensemble-Lernen. Das Ensemble-Lernen versucht nicht ein einzig optimales Modell zu erstellen, sondern kombiniert mehrere Modelle, was oftmals zu einer besseren Vorhersageleistung führt (Hänsch, Hellwich 2017).

Der RF-Algorithmus erfolgt durch ein Bootstrap-Verfahren, dabei wird eine zufällige Anzahl an Bootstrap-Stichproben gezogen (Probenahme mit Zurücklegen). Für jede Stichprobe an Variablen wächst dann ein Klassifikationsbaum (Liaw, Wiener 2002). An jedem Verzweigungspunkt eines Baumes wird erneut eine Teilmenge von Variablen zufällig gezogen, unter diesen Variablen werden dann die besten ausgewählt (Immitzer et al. 2012; Liaw, Wiener 2002). Es entsteht somit eine sehr große Anzahl an verschiedenen Klassifikationsbäumen. Die Klassifizierung erfolgt, indem die Mehrheit der Klassifikationsergebnisse aller konstruierten Entscheidungsbäume gewählt wird. Das Ergebnis wird schließlich über eine out-of-bag-Validierung geprüft. Dafür werden die Daten herangezogen, die pro Baum bei dem Bootstrap-Verfahren nicht genutzt wurden. Die beteiligten Entscheidungsbäume werden dafür mit den wahren Klassenlabeln (Trainingsdaten) verglichen. Dies ergibt eine Schätzung der Fehlklassifizierungsrate (Immitzer et al. 2012).

Anhand der out-of-bag-Validierung wurde eine Klassifikationsmatrix (Confusion Matrix) kalkuliert. Das Ergebnis enthält Werte zur Producer's accuracy (Produzentengenauigkeit, PA), welche das Verhältnis von korrekt klassifizierten Objekten zu den Referenzdaten einer Klasse angibt sowie zur User's accuracy (Nutzergenauigkeit, UA), welche das Verhältnis von korrekt klassifizierten Objekten zu der Gesamtzahl der klassifizierten Stichproben aufzeigt. Zudem erhält man einen Wert für die Overall Accuracy (Gesamtgenauigkeit, OA) und einen Wert für Kappa. Die OA gibt Auskunft über das Verhältnis aller korrekt klassifizierten Objekte zu dem gesamten Stichprobenumfang (Ventura et al. 2018). Anhand des Kappa-Koeffizienten wird der Anteil an Übereinstimmung, der über den Zufall hinausgeht, angezeigt. Es wird dabei die Dif-

ferenz der Anteile von tatsächlich beobachteter und aufgrund von Zufall erwarteter Übereinstimmung berechnet. Der maximal erreichbare Wert ist 1 (bei vollkommener Übereinstimmung) (Grouven et al. 2007).

Nach (Landis, Koch 1977) können für den Kappa-Wert folgende Interpretationskategorien genutzt werden:

- ≤ 0 = schlechte (poor)
- 0 - 0,20 = geringe (slight)
- 0,21–0,40 = ausreichende (fair)
- 0,41–0,60 = mittelmäßige (moderate)
- 0,61–0,80 = beachtliche (substantial)
- 0,81–1,00 = (fast) vollkommene ((almost) perfect) Übereinstimmung

RF hat im Vergleich zu den anderen Methoden viele Vorteile, es kann z.B. jeglichen Datentyp verarbeiten, kann problemlos mit hochdimensionalen Eingaberäumen und beliebig vielen Klassen umgehen, ist schnell im Training und Anwendung, verhältnismäßig einfach zu programmieren und liefert robuste Ergebnisse (Breiman, Cutler o. J.; Hänsch, Hellwich 2017), weshalb es sich für eine Anwendung in dieser Arbeit gut eignet.

3.5 Statistischer Vergleich der Methoden

Die Methoden wurden anhand der Anteile (in %) jeder Landbedeckungsklasse miteinander verglichen. Hierfür mussten zunächst einige Überarbeitungen der Daten erfolgen:

Die Klasse „Schatten“, die bei den manuellen Methoden nicht erfasst wurde, musste bei den Ergebnissen der OBIA in ArcMap entfernt werden. Die Schatten-Polygone sind hierfür zu markieren und mit dem Tool Eliminate (unter Data Mangement) in der ArcToolbox anhand der benachbarten Polygone zu verschmelzen. Dies erfolgte mit der Regel, dass jedes Schatten-Polygon die Klasse von dem Polygon mit der längsten benachbarten Grenze zugewiesen bekam. Dieses Ergebnis wurde im weiteren Schritt mit der Untersuchungsgebietsgrenze verschnitten (Funktion Clip).

Die Unterschiede zwischen den Methoden sowie zwischen den Klassen wurden mit einem Chi-Quadrat-Test (χ^2 -Test) mit einem Signifikanzniveau (α) von 5 % untersucht. Der χ^2 -Test eignet sich, um relative Häufigkeiten miteinander zu vergleichen. Für den Test muss die Bedingung

erfüllt sein, dass alle erwarteten Häufigkeiten min. einen Wert von 1 und 80 % von ihnen min. ein Wert von 5 besitzen (Clauß et al. 2002). Um diese Bedingung zu erfüllen sowie das Problem, dass sich die Klassen zwischen manueller Methode und der OBIA teilweise unterscheiden, mussten die Klassen daher teilweise zusammengefasst bzw. neu benannt werden. Bei dem großen Untersuchungsgebiet sind es nun sieben Klassen und bei dem kleinen Gebiet fünf Klassen (Tab. 6).

Tab. 6: Die zusammengefassten Landbedeckungsklassen für den χ^2 -Test. In den Klammern sind die zuvor klassifizierten Landbedeckungsklassen enthalten, die der neuen Klasse hinzugefügt wurden.

Klassen für großes Gebiet	Klassen für kleines Gebiet
krautige Vegetation/Gras (krautige Vegetation/Gras, Unbefestigter Weg)	krautige Vegetation/Gras (krautige Vegetation/Gras, Unbefestigter Weg, Feld, Röhricht)
Röhricht	
Strauch/Sukzession	Strauch/Sukzession
Baum	Baum
Feld (Feld grün, Feld Getreide)	
Wasser	Wasser
(überwiegend) versiegelte Fläche (Gebäude, Bauwerk/Sonstiges, Schotterweg mit Grünstreifen, Asphalt, Schotter)	(überwiegend) versiegelte Fläche (Gebäude, Bauwerk/Sonstiges, Schotterweg mit Grünstreifen, Asphalt, Schotter)

Die Auswertung erfolgte mit einer Kontingenztabelle. Folgende Formel wird hier benötigt:

$$\chi^2 = \sum_{i=1}^r \sum_{j=1}^c \frac{(fo_{i,j} - fe_{i,j})^2}{fe_{i,j}},$$

r = rows (Zeilen), c = columns (Spalten)

fo = beobachteter Wert, fe = erwarteter Wert

Der erwartete Wert fe ergibt sich aus dem Produkt von Rand-Zeilensummen und Rand-Spaltensummen dividiert durch die Gesamtsumme (Zöfel 1992, zitiert in Kempster et al. 2018).

Nach berechnen der Formel, wird das Ergebnis χ^2 mit $\chi^2_{(df, 1-\alpha)}$ (kritischer Wert) verglichen (Clauß et al. 2002). Wenn $\chi^2 \geq \chi^2_{(df, 1-\alpha)}$, wird die Nullhypothese (H_0) abgelehnt. Die Anzahl df der Freiheitsgrade ergibt sich aus: $df = (r - 1) * (c - 1)$.

Folgende H_0 wurde getestet:

H_0 : Es besteht kein signifikanter Unterschied zwischen den beiden jeweils miteinander verglichenen Methoden.

3.6 Objektbasierte Baumartenklassifikation

Des Weiteren sollte getestet werden, ob sich die vom Biber bevorzugten Gehölze durch eine objektbasierte Klassifikation bestimmen lassen. Hierfür wurden zunächst die Bäume händisch in ArcMap abgegrenzt, deren Art aufgrund der Kartierung vor Ort bekannt war. Es wurde nicht die Segmentierung der Landbedeckungsklassen genutzt, da die Segmente/Objekte zu fein sind und jeweils nicht die ganze Krone umschließen.

Die folgende Tab. 7 zeigt die unterschiedenen Baumartenklassen sowie die Anzahl an Trainingsdaten je nach Datensatz. Die Klasse „Pappel“ umfasst alle Pappelarten außer die Art Silber-Pappel und die Klasse „Weide“ umfasst alle Arten außer die Silber-Weide. Die Silber-Pappel und die Silber-Weide wurden auf Artniveau klassifiziert, da sie sich durch die silbernen Blätter optisch stark von den anderen Arten der jeweiligen Gattung unterscheiden. Die Durchführung der Klassifizierung erfolgte ebenfalls mit dem RF-Algorithmus in RStudio.

Tab. 7: Die unterschiedenen Baumarten und die Anzahl an Trainingsdaten pro Baumartenklasse je nach Datengrundlage.

Baumartenklassen	Anzahl Trainingsdaten	
	Orthophoto	UAV-Aufnahme
Silber-Pappel	22	9
Pappel	7	3
Silber-Weide	12	9
Weide	18	3
Schwarz-Erle	27	2
Σ	86	26

4. Ergebnisse

4.1 Objektbasierte Klassifikation: Orthophoto

Die Integration verschiedener Datensätze zu der Spektralinformation des Orthophotos mit vier Kanälen und einer räumlichen Auflösung von 0,2 m, um die OA zu verbessern, ergab folgendes Ergebnis:

Die Texturinformationen durch die SFS-Textur erzielt, dass sich die OA um ~ 5%-Punkte erhöht. Die Textur Haralick simple und die Haralick advanced erzielen keine deutliche Erhöhung.

Die Integration eines nDOMs zu der Spektralinformation bewirkt eine deutliche Zunahme der OA um 7-8 %-Punkte. Die Zusatzinformation durch ein nDOM erzielt also ein besseres Ergebnis als die alleinige Integration der Texturinformation. Die beiden nDOMs (ALS, BM) erzielen ein beinahe identisches Ergebnis.

Werden ein nDOM und die SFS-Textur integriert, erhöht sich die OA weiter um wenige Prozentpunkte. Die Kombination nDOM (BM) + SFS-Textur ergibt unter allen Varianten das beste Ergebnis für die OA. Die zusätzliche Hinzunahmen des NDVIs erzielt keinen höheren Wert für OA (Tab. 8).

Tab. 8: Integration verschiedener Datensätze zur Spektralinformation des Orthophotos.

nDOM (BM) = nDOM durch Bildmatching-Datensatz,

nDOM (ALS) = nDOM durch Airborne Laserscanning-Datensatz.

Spektralinformation (RGBI)	OA [%]
(Nur Spektralinformation	79.36)
+ Textur Haralick simple	80.08
+ Textur Haralick advanced	80.91
+ Textur SFS	84.13
+ nDOM (BM)	86.51
+ nDOM (ALS)	87.97
+ nDOM (BM) + Textur SFS	89.21
+ nDOM (ALS) + Textur SFS	88.07
+ nDOM (BM) + Textur SFS + NDVI	89.11

Die folgende Tab. 9 zeigt die Klassifikationsmatrix des Ergebnisses der Datenkombination Spektralinformation + nDOM (BM) + SFS Textur + NDVI. Es wurde für alle Landbedeckungsklassen ein gutes Klassifikationsergebnis erzielt. Dies wird bei einem Blick auf die PA, die das Verhältnis von korrekt klassifizierten Objekten zu den Trainingsdaten einer Klasse wiedergibt, deutlich. Lediglich für die Klasse „Feld Getreide“ wurden von insgesamt 32 Trainingsdaten nur 22 korrekt klassifiziert, das entspricht einer PA von ca. 69%. Für die Klasse „Feld grün“ konnten ebenfalls nur 32 Trainingsdaten erhoben werden, hiervon wurden aber 29 richtig klassifiziert (PA von ca. 91 %). Der Wert für Kappa liegt über 0.80 (80%), das Klassifizierungsergebnis ist nach der Einteilung von Landis und Koch (1977) also als sehr gut einzustufen.

Ergebnisse

Tab. 9: Klassifikationsmatrix der Landbedeckung anhand Spektralinformation (Orthophoto) + Zusatzinformationen (nDOM, SFS-Textur und NDVI)
(UA = User's Accuracy, PA = Producer's Accuracy, OA = Overall Accuracy).

	Baum	Strauch/ Sukzes.	krautige Veg./Gras	Röhricht	Feld Getreide	Feld grün	Schatten	Schotter	Asphalt	Gebäude/ Bauwerk	Wasser	Σ	UA [%]
Baum	94	5	1	1	0	0	2	0	0	0	0	103	91.26
Strauch/ Sukzession	3	82	7	8	0	0	0	0	0	0	1	101	81.19
krautige Veg./Gras	2	5	85	0	4	1	0	4	0	1	2	104	81.73
Röhricht	1	6	1	90	0	1	0	0	0	0	0	99	90.91
Feld Getreide	0	0	1	0	22	0	0	1	0	0	0	24	91.67
Feld grün	0	0	0	1	0	29	0	0	0	0	0	30	96.67
Schatten	0	2	0	0	0	1	97	0	0	2	1	103	94.17
Schotter	0	0	1	0	5	0	0	86	7	3	1	103	83.50
Asphalt	0	0	0	0	0	0	1	4	92	5	0	102	90.20
Gebäude/ Bauwerk	0	0	0	0	0	0	0	5	0	87	0	92	94.57
Wasser	0	0	4	0	1	0	0	0	1	2	95	103	92.23
Σ	100	100	100	100	32	32	100	100	100	100	100	964	
PA [%]	94.00	82.00	85.00	90.00	68.75	90.63	97.00	86.00	92.00	87.00	95.00	OA [%]	89.11
												Kappa	0.88

4.2 Objektbasierte Klassifikation: UAV-Aufnahme

Zu der Spektralinformation des Orthophotos der UAV-Aufnahme wurden ebenfalls verschiedene Zusatzinformationen integriert. Es zeigt sich ein ähnliches Ergebnis, wie zuvor bei dem Orthophoto mit geringerer räumlicher Auflösung und weniger Kanälen beschrieben. Die Haralick-Texturen wurden hier nicht mehr getestet, da sie bei dem anderen Orthophoto keine Erhöhung der OA erzielten. Das höchste Klassifikationsergebnis wird bei der Kombination der Spektralinformation mit nDOM + SFS Textur (+ NDVI) erzielt. Der Unterschied mit oder ohne NDVI ist marginal (Tab. 10).

Tab. 10: Integration verschiedener Datensätze zur Spektralinformation der UAV-Aufnahme

Spektralinformation	OA [%]
(Nur Spektralinformation	76.74)
+ Textur SFS	79.40
+ nDOM	86.38
+ nDOM + Textur SFS	87.38
+ nDOM + Textur SFS + NDVI	87.71

Die folgende Tab. 11 zeigt die Klassifikationsmatrix mit der Integration von allen Zusatzinformationen (nDOM + SFS-Textur + NDVI). Bei allen Klassen mit min. 40 Trainingsdaten wurde ein sehr gutes Klassifikationsergebnis erzielt. Ebenfalls erreichten die Klassen „Asphalt“ und „Wasser“ trotz geringer Anzahl an Trainingsdaten (10 Stück) ein gutes Ergebnis. Die Klasse „Röhricht“ erzielte mit ebenfalls 10 Trainingsdaten allerdings ein geringes Klassifikationsergebnis. Die Klasse „Feld Getreide“ hat kein Ergebnis erlangt. Dies liegt an der sehr geringen Anzahl an Trainingsdaten (2 Stück). Aufgrund der kleinen Untersuchungsfläche konnten für diese Klasse nicht mehr Daten erhoben werden. Der Wert für Kappa liegt bei dieser Klassifikation ebenfalls über 0.80, weshalb auch das Ergebnis sehr zufriedenstellend ist.

Ergebnisse

Tab. 11: Klassifikationsmatrix der Landbedeckung anhand Spektralinformation (UAV-Aufnahme) + Zusatzinformationen (nDOM, SFS-Textur und NDVI)

	Baum	Strauch/ Sukzes.	krautige Veg./Gras	Röhricht	Feld Getreide	Schatten	Schotter	Asphalt	Gebäude/ Bauwerk	Wasser	Σ	UA [%]
Baum	52	5	0	1	0	0	0	0	0	0	58	89.66
Strauch/ Sukzession	8	53	0	5	0	0	0	0	0	0	66	80.30
krautige Veg./Gras	0	1	37	0	0	0	2	0	0	0	40	92.50
Röhricht	0	0	1	4	0	0	0	0	0	0	5	80.00
Feld Getreide	0	0	0	0	0	0	0	0	0	0	0	0.00
Schatten	0	1	0	0	0	38	0	0	0	2	41	92.68
Schotter	0	0	2	0	1	0	36	0	2	0	41	87.80
Asphalt	0	0	0	0	0	0	1	9	0	0	10	90.00
Gebäude/ Bauwerk	0	0	0	0	1	0	1	1	27	0	30	90.00
Wasser	0	0	0	0	0	2	0	0	0	8	10	80.00
Σ	6	60	40	10	2	40	40	10	29	10	301	
PA [%]	86.67	88.33	92.50	40.00	0.00	95.00	90.00	90.00	93.10	80.00	OA [%]	87.71
											Kappa	0.86

4.3 Vergleich der Datensätze bei gleicher Anzahl an Trainingsdaten

Bei gleicher Anzahl an Trainingsdaten sowie gleicher Kombination von Datensätzen (Spektralinformation + SFS Textur+ nDOM + NDVI) zeigt sich, dass die Klassifizierung des Orthophotos eine geringere OA als bei der UAV-Aufnahme, die eine höhere Auflösung besitzt, erzielt (Tab. 12). Die Ergebnisse der OA unterscheiden sich um rd. 9 %-Punkte.

Tab. 12: Vergleich der Klassifizierungsergebnisse beider Datensätze bei gleicher Anzahl an Trainingsdaten

Klasse	n Training	Orthophoto		UAV-Aufnahme	
		UA [%]	PA [%]	UA [%]	PA [%]
Baum	60	79.69	85.00	89.66	86.67
Strauch/Sukzes.	60	75.00	75.00	80.30	88.33
krautige Veg./Gras	40	68.29	70.00	92.50	92.50
Röhricht	10	62.50	50.00	80.00	40.00
Feld Getreide	2	0.00	0.00	0.00	0.00
Schatten	40	90.48	95.00	92.68	95.00
Schotter	40	80.00	80.00	87.80	90.00
Asphalt	10	88.89	80.00	90.00	90.00
Gebäude/Bauwerk	29	84.00	72.41	90.00	93.10
Wasser	10	75.00	90.00	80.00	80.00
		OA [%]	78.74		87.71
		Kappa	0.75		0.86

4.4 Ergebniskarten (kleines Untersuchungsgebiet)

Auf den folgenden Seiten sind die Ergebniskarten der einzelnen Methoden im kleinen Untersuchungsgebiet für die Bestimmung der Landbedeckung dargestellt (Abb. 8 bis Abb. 11). Die Methoden visuelle Interpretation und Kartierung vor Ort sind sich sehr ähnlich. Bei der visuelle Interpretation + nDOM sind dahingegen einzelne Strukturen deutlicher herausgearbeitet und der Anteil an „Strauch/Sukzession“ ist sichtlich höher.

Die OBIA des Orthophotos zeigt eine gute Übereinstimmung mit der Kartierung vor Ort. Ein paar Objekte wurden statt als „krautige Vegetation/Gras“ falsch als „Röhricht“ klassifiziert sowie bei den Klassen „Schotter“ und „Gebäude/Bauwerk“ gibt es falsche Klassifizierungen. Ansonsten hat die Klassifizierung optisch ein gutes Ergebnis erzielt. Bei der OBIA der UAV-Aufnahme haben sich ebenfalls Probleme bei diesen Klassen ergeben. Zudem fällt auf, dass die Klassifizierung hier viel feiner erfolgte. Einzelnen Baumkronen lassen sich deutlich erkennen, wohingegen bei der Klassifizierung des Orthophotos die Bäume eher als Baumgruppen ohne einen Strauch-/Sukzessionsanteil zu erkennen sind.



Abb. 8: Ergebniskarte der visuellen Bildinterpretation (Aufnahmejahr 2015)



Abb. 9: Ergebniskarte der visuellen Bildinterpretation + nDOM (Aufnahmejahr 2015, 2011/12)



Abb. 10: Ergebniskarte der Kartierung vor Ort (Erhebung 2018)



Abb. 11: Ergebniskarte der OBIA des Orthophotos (Aufnahmejahr 2015)

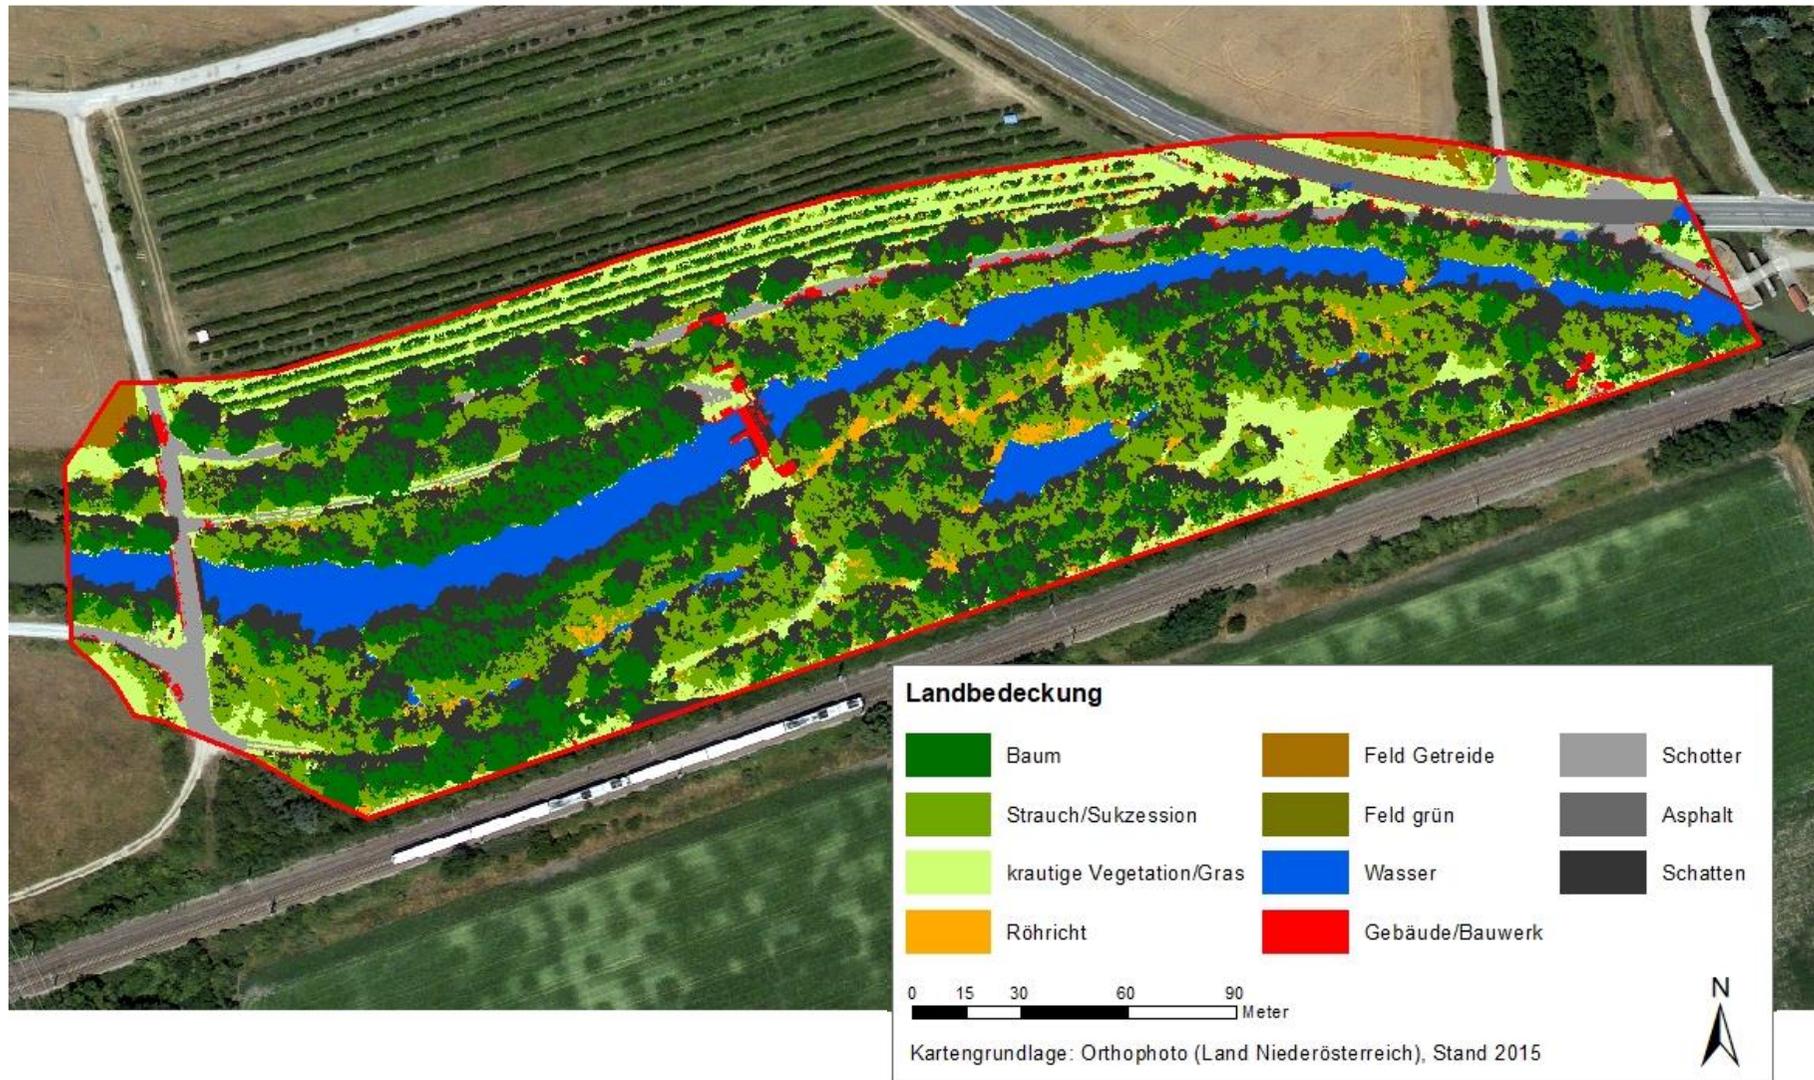


Abb. 12: Ergebniskarte der OBIA der UAV-Aufnahme (Aufnahmejahr 2018) (im Hintergrund für Kartendarstellung: Orthophoto 2015)

4.5 Vergleich der Methoden anhand der Landbedeckungsklassen (χ^2 -Test)

4.5.1 Ergebnisse des großen Untersuchungsgebietes

Für das große Untersuchungsgebiet ergibt sich ein kritischer Wert von 12.592 ($\chi^2_{6; 0.95}$).

H_0 : Es besteht kein signifikanter Unterschied zwischen den beiden jeweils miteinander verglichenen Methoden.

Bei optischer Betrachtung der Flächenanteile der Landbedeckungsklassen zeigen lediglich die Vegetationsklassen einen ersichtlichen Unterschied, vor allem die Klassen „Strauch/Sukzession“ und „Baum“, weshalb die folgenden Abbildungen lediglich die Vegetationsklassen zeigen (Abb. 13, Abb. 14).

Statistisch lassen sich keine signifikanten Unterschiede zwischen den angewendeten Methoden in dem großen Untersuchungsgebiet feststellen. Die Kreuztabellen des χ^2 -Testes von den Methoden mit den höchsten Unterschieden zueinander sind im Anhang II zu finden.

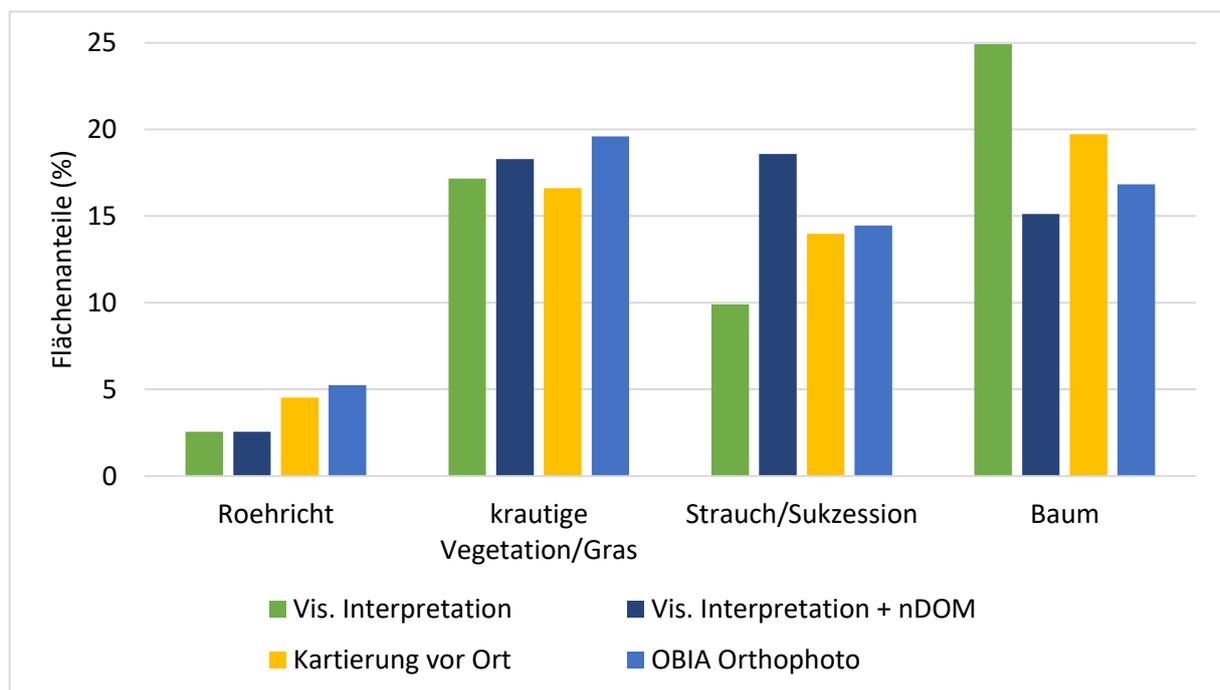


Abb. 13: Flächenanteile der Vegetationsklassen und die im großen Untersuchungsgebiet angewendeten Methoden im Vergleich. „OBIA Orthophoto“ zeigt das Ergebnis bei Nutzung aller Zusatzinformationen.

4.5.2 Ergebnisse des kleinen Untersuchungsgebietes

Für das kleine Untersuchungsgebiet ergibt sich ein kritischer Wert von 9.488 ($\chi^2_{4; 0.95}$).

Bei Betrachtung des Balkendiagrammes fällt auf, dass die visuelle Interpretation der Kartierung vor Ort als Evaluierungsmethode am stärksten ähnelt, gefolgt von der OBIA Orthophoto (Abb. 14).

Die Durchführung des χ^2 -Test ergab, dass sich lediglich die Methode OBIA UAV-Aufnahme zu der Kartierung vor Ort ($\chi^2 = 12.11$) und der visuellen Interpretation ($\chi^2 = 14.06$) signifikant unterscheidet. Die anderen Methoden weisen keine signifikanten Unterschiede zueinander auf (Anhang III).

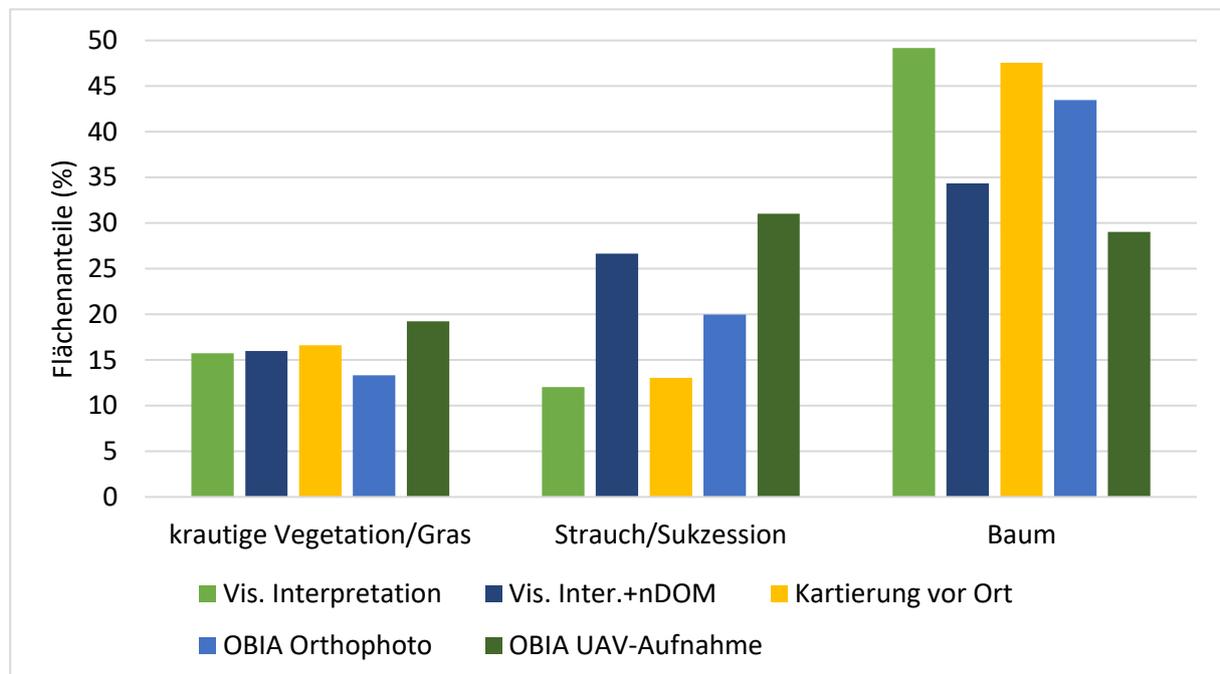


Abb. 14: Flächenanteile der Vegetationsklassen und die im kleinen Untersuchungsgebiet angewendeten Methoden im Vergleich. „OBIA Orthophoto“ und „OBIA UAV-Aufnahme“ zeigen das Ergebnis bei Nutzung aller Zusatzinformationen.

4.6 Baumartenklassifikation

4.6.1 Großes Untersuchungsgebiet

Auf der großen Studienfläche, die für das Orthophoto erhoben wurde, konnte eine höhere Anzahl an Trainingsdaten erfasst werden. Das Klassifizierungsergebnis ist daher deutlich besser. Die Klassen „Schwarz-Erle“, „Silber-Pappel“ und „Weide“ ergaben hier ein gutes Ergebnis. Es ist aber darauf hinzuweisen, dass die beiden Klassen „Silber-Weide“ und „Pappel“ eine geringere Anzahl an Trainingsdaten besitzen (s. Tab. 13).

Tab. 13: Klassifikationsmatrix der Baumartenklassifizierung anhand des Orthophotos mit höherer Anzahl an Trainingsdaten (großes Gebiet). (P = Pappel, SP = Silber-Pappel, W = Weide, SW = Silber-Weide, SE = Schwarz-Erle).

	P	SP	W	SW	SE	Σ	UA [%]
P	1	1	0	0	0	2	50.00
SP	0	15	1	6	0	22	68.18
W	3	1	13	2	3	22	59.09
SW	0	3	2	3	0	8	37.50
SE	3	2	2	1	24	32	75.00
Σ	7	22	18	12	27	86	
PA [%]	14.29	68.18	72.22	25.00	88.89	OA	65.12%

4.6.2 Kleines Untersuchungsgebiet

Auf der kleinen Studiengebietsfläche konnte nur eine sehr geringe Anzahl an Trainingsdaten für die gewünschten Baumarten gesammelt werden, weshalb sich keine hohen Werte der OA ergaben.

Beim Vergleich der Baumartenklassifizierung UAV-Aufnahme und Orthophoto bei gleichen Trainingsdaten (s. Tab. 14 und Tab. 15) zeigt sich, dass die Klassifizierung der UAV-Aufnahme ein besseres Ergebnis erzielt, die OA ist hier mit einem Unterschied von rund 23 Prozentpunkten deutlich höher. Für die Klassen „Silber-Pappel“ und „Silber-Weide“ konnten die meisten Trainingsdaten erhoben werden. Für diese Klassen ergeben sich daher auch die höchsten Ergebnisse für die PA und UA.

Tab. 14: Klassifikationsmatrix der Baumartenklassifizierung anhand der UAV-Aufnahme (kleines Gebiet).

	P	SP	W	SW	SE	Σ	UA [%]
P	1	0	1	0	1	3	33.33
SP	0	5	0	3	0	8	62.50
W	1	0	0	0	1	2	0.00
SW	0	4	2	6	0	12	50.00
SE	1	0	0	0	0	1	0.00
Σ	3	9	3	9	2	26	
PA [%]	33.33	55.56	0.00	66.67	0.00	OA	46.15%

Tab. 15: Klassifikationsmatrix der Baumartenklassifizierung anhand des Orthophotos mit selben Trainingsdaten wie UAV-Aufnahme.

	P	SP	W	SW	SE	Σ	UA [%]
P	1	0	1	0	1	3	33.33
SP	0	1	0	5	0	6	16.67
W	0	0	1	1	1	3	33.33
SW	1	8	1	3	0	13	23.08
SE	1	0	0	0	0	1	0.00
Σ	3	9	3	9	2	26	
PA [%]	33.33	11.11	33.33	33.33	0.00	OA	23.08%

5. Diskussion

Anhand der festgelegten Forschungsfragen der vorliegenden Arbeit sollen die Ergebnisse im Folgenden diskutiert werden:

Mit welchem Datensatz (Spektralinformation, Vegetationshöhenmodell, Textur, NDVI) lässt sich das genaueste Klassifikationsergebnis erzielen?

Die OBIA, durchgeführt mit dem RF-Algorithmus, erzielte für das Orthophoto (4 Kanäle) sowie für das Orthophoto der UAV-Aufnahme (6 Kanäle) bereits bei der alleinigen Nutzung der Spektralinformation ein gutes Klassifizierungsergebnis. Durch die Integration der Spektralinformation mit einem nDOM und der SFS-Textur konnte die höchste OA erreicht werden. Wobei aber das nDOM die bedeutendere Zusatzinformation ist. Hierdurch ist es möglich, dass Objekte mit einer ähnlichen Spektralinformation, wie bei den Klassen „Baum“ und „Strauch/Sukzession“, voneinander differenziert werden können. Die Spektralinformation sowie die Höheninformation durch ein nDOM sind anhand dieser Ergebnisse die wichtigsten Datensätze für eine OBIA.

Gemäß Ma et al. (2017) erzielen UAVs im Vergleich zu verschiedenen Satellitentypen mit einer etwas geringeren Auflösung (z.B. SPOT-5, QuickBird, IKONOS und WorldView-2) die höchste Klassifikationsgenauigkeit, die im Mittel bei ca. 86 % liegt. Ebenfalls konnte Immitzer et al. (2016) bei einem Vergleich von Satelliten einen Zusammenhang zwischen der Klassifikationsgenauigkeit und der räumlicher Auflösung feststellen.

In der vorliegenden Arbeit konnte für die UAV-Aufnahme in Kombination mit dem nDOM eine OA von 87 %, vergleichbar zu den Ergebnissen von Ma et al. (2017), erreicht werden. Auch hier zeigt sich, dass die UAV-Aufnahme (0,03 m) im Vergleich zum erworbenen Orthophoto mit einer geringeren räumlichen Auflösung (0,2 m) bei gleicher Anzahl an Trainingsdaten ein höheres Klassifikationsergebnis erzielt. Es besteht ein Unterschied von ca. 9 %-Punkten.

Ergeben sich Unterschiede in den Flächenanteilen der Landbedeckungsklassen je nach angewendeter Methode (visuelle Bildinterpretation, Kartierung vor Ort, objektbasierte Klassifikation)?

Bei dem Vergleich der Flächenanteile der Landbedeckungsklassen jeder Methode zeigt sich, dass lediglich die Ergebnisse der OBIA der UAV-Aufnahme statistisch auffällig sind. Signifikante Unterschiede bestehen zu den Methoden Kartierung vor Ort und visuelle Bildinterpretation.

Die anderen Methoden unterscheiden sich auf der kleinen wie auch auf der großen Fläche nicht signifikant voneinander.

Die OBIA des Orthophotos erzielt zwar eine schlechtere OA als die OBIA der UAV-Aufnahme, kommt dem Ergebnis der Kartierung vor Ort aber trotzdem sehr nah. Es ist eigentlich zu erwarten, dass die OBIA der UAV-Aufnahme der Kartierung vor Ort am ähnlichsten ist, da beide Erfassungen im Sommer 2018 erfolgten. Das Orthophoto ist bereits aus dem Jahr 2015. Das Ergebnis der UAV-Aufnahme müsste daher, im Vergleich zur Analyse des Orthophotos, ein Zuwachs an Bäumen aufweisen, das Gegenteil ist aber der Fall.

Mögliche Erklärungen können dafür sein, dass die Klassifizierung des Orthophotos mit einem nDOM erfolgte, welches eine geringere Pixelgröße von 1 m besitzt. Zudem ist hier die Segmentierung der Objekte aufgrund der geringeren Auflösung des Orthophotos gröber. Bei der Kartierung vor Ort ist zu beachten, dass die Regel getroffen wurde, dass min. 70 % der abgegrenzten Fläche „Baum“ oder „Strauch/Sukzession“ sein mussten, wodurch sich auch hier weniger feine Abgrenzungen ergeben haben können. Die OBIA der UAV-Aufnahme muss daher nicht fehlerhaft sein, sondern ist eventuell feiner bzw. genauer, weshalb der Anteil von „Strauch/Sukzession“ höher ist.

Lassen sich die bevorzugten Nahrungspflanzen vom Biber durch eine objektbasierte Klassifikation unterscheiden?

Bei der Baumartenklassifizierung erzielte bei gleicher Anzahl an Trainingsdaten ebenfalls die UAV-Aufnahme im Vergleich zum Orthophoto die höhere OA. Wegen der geringen Studiengröße konnte nur eine geringe Anzahl an Trainingsdaten erhoben werden. Zudem besteht eine unterschiedliche Anzahl an Trainingsdaten je nach Klasse, weshalb eine eindeutige Aussage zur Klassifizierbarkeit der Baumarten nicht möglich ist. Das Ergebnis anhand des Orthophotos mit einer höheren Anzahl an Trainingsdaten ist allerdings befriedigend (OA = 65.12 %). Bei einer höheren Anzahl an Trainingsdaten ist es daher denkbar, dass sich die fünf Baumarten gut voneinander unterscheiden lassen.

Nach Waser und Straub (2015) zeigen verschiedene Studien, dass bei einer räumlichen Auflösung von 10 bis 30 m im Durchschnitt eine OA von 69 % bei bis zu zwölf Baumarten und eine OA von knapp 84 % bei maximal drei Baumarten erreicht wird. Die OA erhöht sich demnach, umso weniger Baumarten voneinander unterschieden werden. Eine OA von über

85 % wird bei der Kombination von hyperspektralen Aufnahmen mit ALS erreicht (Waser und Straub 2015).

Welche Vor- und Nachteile besitzen die angewendeten Methoden für das Forschungsvorhaben?

Jede Methode bzw. Datensatz besitzt ihre Vor- und Nachteile (s. Tab. 16 und Tab. 17), wie die Ergebnisse der vorliegenden Arbeit gezeigt haben.

Eine visuelle Interpretation eines Orthophotos hat z.B. den Vorteil, dass ein geringes technisches Wissen notwendig ist. Es kann im Büro ohne große Einarbeitungszeit die Auswertung vollzogen werden. Es eignet sich aufgrund der reinen manuellen Arbeitsweise primär für kleinere Flächen. Der Nachteil ist v.a., wenn wie bei der vorliegenden Arbeit, keine Geländebegehung im Vorhinein stattfindet, dass es zu Fehlinterpretationen kommen kann. Das Ergebnis ist daher abhängig von den Erfahrungen der ausführenden Person. Zudem können kleine Strukturen übersehen oder bei geringer Auflösung nicht erfassbar sein.

Das zusätzliche Heranziehen eines nDOM verbessert das Verständnis der interpretierenden Person für das Gelände. Hohe und niedrige Objekte lassen sich dadurch gut voneinander differenzieren. Jedoch besteht die Gefahr, dass sich zu sehr auf die Höhen beschränkt wird und dadurch z.B. Merkmale der Textur zu wenig beachtet werden.

Mit der Kartierung vor Ort kann ein sehr hoher Detailgrad (hohe Anzahl an Klassen) des aktuellen Zustandes erhoben werden. Ein großer Nachteil ist der hohe Zeitaufwand durch die Geländearbeit plus der Visualisierung im Büro, weshalb die Methode ebenfalls eher für kleinere Gebiete zu empfehlen ist. Ein weiterer Nachteil ist, dass vermutlich jede Person trotz eines gut ausgearbeiteten Kartierschlüssels, unterschiedlich genau arbeitet. Es bestehen also individuelle Unterschiede in der Kartierungsgenauigkeit.

Bei einer semi-automatischen Klassifizierung durch einen objektbasierten Ansatz besteht der große Vorteil in dem hohen Automatisierungsgrad und in der geringen Geländearbeit, weshalb sich diese Methode vor allem für größere Gebiete eignet. Bei der Geländearbeit müssen lediglich Trainingsdaten erhoben werden. Nachteile sind, dass ein technisches Verständnis und Wissen zu dem Ablauf der Klassifizierungsprozesse notwendig ist. Sie benötigt also eine viel längere Einarbeitungszeit als die Kartierung vor Ort oder die visuelle Bildinterpretation.

Zudem wird das Klassifizierungsergebnis von einigen Faktoren beeinflusst. Eine große Bedeutung haben die Qualität und Anzahl der Trainingsdaten, die Anzahl an Klassen, die unterschieden werden sollen sowie die Fein- bzw. Grobheit der Segmentierung.

Bei der Segmentierung ist zu beachten, dass es bei zu groben Segmenten zu einer Untersegmentierung kommt. Dies wirkt sich negativ auf das Klassifizierungsergebnis aus. Ebenfalls sollte die Auswahl der Trainingsdaten sorgfältig erfolgen. Es sollten homogene, klassenreine Objekte gewählt werden. Zudem hat die Anzahl an Trainingsdaten einen signifikanten Einfluss auf das Klassifizierungsergebnis, dieses verbessert sich mit zunehmender Anzahl an Trainingsdaten. Und ebenfalls hat die Anzahl an unterschiedlichen Landbedeckungsklassen einen Einfluss, umso mehr Klassen unterschieden werden, desto schlechter fällt das Klassifizierungsergebnis aus (Li et al. 2016; Ma et al. 2015; Ma et al. 2017).

Die benötigte Anzahl an Trainingsdaten scheint zudem von der Auflösung der Datengrundlage bzw. Maße der Segmentierung abhängig zu sein. So wurde z.B. für die Klasse „krautige Vegetation/Gras“ beim Orthophoto (0,2 m) mit 100 Trainingsdaten eine PA von 85 % erreicht und bei der UAV-Aufnahme (0,03 m) mit lediglich 40 Trainingsdaten eine PA von 92,5 %. Zudem scheint die Anzahl an Trainingsdaten abhängig von der Größe homogener Segmente zu sein. So wurde z.B. bei der UAV-Aufnahme für die Klasse „Wasser“ mit 10 Trainingsdaten ein PA von 80 % erreicht, mit derselben Anzahl wurde allerdings für „Röhricht“ mit sehr kleinen Segmenten nur ein PA von 40 % erzielt. Stehen für eine Klasse nur sehr wenige Trainingsdaten zur Verfügung (< 10), wie dies bei der Klasse „Feld Getreide“ im kleinen Untersuchungsgebiet der Fall war, dann ist zu empfehlen, diese Klasse nicht zu berücksichtigen bzw. einer anderen Klasse zuzuordnen.

Tab. 16: Überblick der Eigenschaften der angewendeten Methoden zur Luftbildauswertung. Großer Haken = trifft zu, kleiner Haken = abhängig vom Datenmaterial bzw. der räumlichen Auflösung.

	Schnelle Ein- arbeitungszeit	Hoher Detailgrad	Wenig Geländearbeit	Hoher Auto- matisierungs- grad	Eignung bei großer Fläche
Visuelle In- terpretation	✓	✓	✓		
Kartierung vor Ort	✓	✓			
OBIA		✓	✓	✓	✓

Wird eine sehr hohe räumliche Auflösung benötigt und ist eine Befliegung durch ein bemann-tes Flugzeugsystem z.B. aus Kostengründen nicht möglich, kommen die Länder, bei denen die Daten erworben werden können, oder eine selbstdurchgeführte Befliegung mit einem UAV in Frage.

Wird die Datengrundlage erworben, erhält man je nach Gebietsgröße ein fertiges Produkt für einige 100 - 1.000 €. Vom Land NÖ hätte für den Raum Deutsch-Wagram das Paket mit DOM und DGM (1 m) 3.700 € gekostet und das Orthophoto (0,2 m) 460 €. Höhenmodelle mit einer Pixelgröße von 10 m sind allerdings kostenfrei für alle Länder in Österreich unter www.data.gv.at zu erhalten. Liegt das Untersuchungsgebiet allerdings zwischen zwei Blatt-schnitten, verdoppeln sich die Kosten. Ein großer Nachteil ist, dass der Aufnahmezeitpunkt des Untersuchungsgebietes nicht beeinflusst werden kann, die Befliegungen für Orthophotos und Höhenmodelle werden nur alle paar Jahre durchgeführt, es besitzt daher evtl. eine ge-ringe Aktualität. Für das Untersuchungsgebiet ist z.B. das Orthophoto von 2000, 2008, 2011, 2015 und 2018 (zur Zeit der Datenauswertung nicht verfügbar gewesen) über das Land NÖ erhältlich.

Führt man eine UAV-Befliegung selber durch, erhält man Luftbilder mit einer sehr hohen räumlichen Auflösung (ca. 0,03 m). UAVs sind inzwischen preisgünstig zu erwerben und kön-nen z.B. mit einer preisgünstigen Kompakt- oder Spiegelreflexkamera oder einer hochwertigen Multispektralkamera ausgestattet werden. Zur Auswertung stehen kostenfreie oder preis-günstige Softwares wie z.B. Agisoft zur Verfügung (Colomina, Molina 2014; Lindstaedt, Kersten 2018). Nachteile sind, dass für die Durchführung der Befliegung geschultes Personal benötigt wird und ein gewisser Planungsaufwand vorhanden ist. Eine Flugerlaubnis ist notwendig, das Wetter muss stimmen und der Ablauf der Befliegung muss vorher geplant werden. Die pho-togrammetrische Auswertung der Bildverbände zum Herstellen eines Orthophotos und eines DOMs ist rechenintensiv und kann mehr als 24 Stunden in Anspruch nehmen, zudem muss die anfallende Datenmenge (30-70 MB pro Bild) gespeichert und gewartet werden (Tscharf 2016). Für die Arbeitsschritte ist photogrammetrisches Expertenwissen zur Einstellung der Parame-ter wünschenswert bzw. erforderlich (Kersten, Lindstaedt 2017). Die Kosten können daher je nach Zeitaufwand für die Erhebung und Auswertung, abhängig von der Größe sowie Lage bzw. Entfernung der Untersuchungsfläche(n) (Fahrzeit), für das Personal sehr hoch werden.

Tab. 17: Überblick der Eigenschaften der Datengrundlagen (Orthophoto und Höhenmodell vom Vermessungsamt oder eine selbstdurchgeführte UAV-Befliegung).

	Gegenwart (flexibler Zeit- punkt)	Vergangenheit	Sehr hohe Auflösung (< 10 cm)	geringer Zeitaufwand
Vermessungsamt		✓		✓
UAV-Befliegung	✓		✓	

Für das Forschungsprojekt sollen mehrere Flächen mit einem hohen Detailgrad, voraussichtlich 30-40 Gebiete, die ca. eine Länge von 5-8 km besitzen sollen, untersucht werden. Es soll von 2006 bis in die Gegenwart immer der Zeitpunkt untersucht werden, an dem Individuen einer Biber-Population entnommen wurden, das zeitnahste Aufnahmejahr der Datengrundlage zu der Entnahme wäre also interessant.

Aufgrund der vielen und großen Flächen ist eine OBIA anhand eines Orthophotos in Kombination mit einem nDOM zu empfehlen. Zwar ist zunächst eine längere Einarbeitungszeit zu berücksichtigen, aber aufgrund des hohen Automatisierungsgrades wird diese Methode bei großen Untersuchungsflächen effizienter. Je nach Auflösung der Datengrundlage und Qualität der Trainingsdaten ist es zudem möglich, einen hohen Detailgrad, das heißt eine hohe Anzahl an Klassen, zu erfassen. Da auch vergangene Situationen analysiert werden sollen, müssen die Trainingsdaten allerdings durch eine visuelle Interpretation bestimmt werden, wodurch der Detailgrad womöglich eingeschränkt wird, da schwierige Klassen wie „Röhricht“ eventuell nicht sicher erkannt werden können.

Eine visuelle Bildinterpretation ist aufgrund des hohen Zeitaufwandes für das Vorhaben nicht zu empfehlen. Eine Kartierung vor Ort eignet sich ebenfalls nicht, da keine Kartierungen aus den vorherigen Jahren für die Untersuchungsflächen vorliegen, auf die zurückgegriffen werden kann, zudem wäre ebenfalls der Zeitaufwand zu hoch.

Als Datengrundlage sind Orthophotos und DOMs durch UAV-Befliegungen für das Forschungsvorhaben nicht geeignet, da bisher keine Befliegungen der geplanten Untersuchungsflächen stattgefunden haben und somit auch hier auf keine älteren Daten zurückgegriffen werden kann. Ein großer Nachteil von erworbenen Orthophotos und Höhenmodellen ist allerdings die evtl. geringe Aktualität, da die Befliegungen der Länder nur alle drei bis vier Jahre stattfinden.

Diese Daten sind für das Forschungsvorhaben daher ebenfalls nicht optimal, weshalb geprüft werden sollte, ob auch Satellitenaufnahmen geeignet sind und/oder die Forschungsfrage angepasst werden kann.

Bei der Auswahl eines Satellitensystems kommt es auf die konkrete Fragestellung und auf die finanziellen Mittel an, da bisher kein Satellit zeitlich, räumlich als auch spektral sehr hoch auflösende Daten ermöglichen kann. Kostenfreie Satellitenbilder wie Sentinel-2 oder Landsat-8 besitzen zwar nur eine geringe bis mittlere räumliche Auflösung (10 - 30 m), wiederum hat es den Vorteil, dass diese Satelliten regelmäßig aufnehmen und einen geringen zeitlichen Abstand zwischen zwei Aufnahmen desselben Gebietes haben (5 - 16 Tage). Satelliten mit einer sehr hohen räumlichen Auflösung unter 1 m nehmen in der Regel nicht permanent auf, sondern werden nach Kundenwunsch programmiert, was sehr hohe Kosten bedeutet (Förster, Frick 2015, Immitzer 2017). Sentinel-2 sendet seit 2015 und der erste Landsat-Satellit sendet seit 1972 die ersten Fernerkundungsbilder. Sentinel-2 erzielt gemäß Immitzer 2017 gute Ergebnisse bei der Landbedeckungsklassifizierung und Baumartenerkennung. Der Satellit WorldView-2 (räumliche Auflösung 2 m) erreicht ein noch besseres Ergebnis, die Kosten sind allerdings mit 30 USD /km² relativ hoch (Immitzer 2017).

Ist es denkbar, weniger Flächen zu untersuchen und das Projekt in die Zukunft hin zu entwickeln, ist eine UAV-Befliegung für das Vorhaben eine sehr geeignete Methode für die Datenbeschaffung. Es könnte z.B. so gestaltet werden, dass nur 10 Flächen untersucht werden und immer eine Befliegung stattfindet, nachdem ein Biber entnommen wurde. Würde dies über viele Jahre durchgeführt werden, hätte man ein Datenarchiv von sehr hoher Qualität. Diese Methode wäre allerdings mit sehr hohen Personalkosten verbunden.

Jede Methode bzw. jeder Datensatz besitzt Vor- und Nachteile. Vor allem der Faktor Kosten ist entscheidend bei der Auswahl der Methode und Datengrundlage. Die Kosten sind von verschiedenen Faktoren wie z.B. räumliche Auflösung, Gebietsgröße, Entfernung der Fläche(n) (Fahrzeit), Bedarf an Personal, abhängig, weshalb zunächst eine Kosten-Nutzenanalyse erfolgen sollte. Mögliche Kompromisse und eine Anpassung der Fragestellung sollten ebenfalls diskutiert werden.

6. Fazit

Aufgrund eines angedachten Forschungsvorhabens sollten mögliche Datensätze und Methoden hinsichtlich ihrer Eignung und Unterschiede zur Analyse der Landbedeckung und Gehölzarten am Beispiel eines reich strukturierten Gewässerabschnittes getestet werden.

Die Analyse der Landbedeckung und Gehölzarten ist ein wichtiger Faktor zur Bewertung der Habitateignung von Biber-Revieren. Dieser Faktor kann, wie die Ergebnisse gezeigt haben, gut durch Fernerkundungsdaten analysiert werden. Die beiden durchgeführten OBIA mit dem RF-Algorithmus anhand eines Orthophotos des Landes NÖ und durch eine UAV-Aufnahme ergaben für das Untersuchungsgebiet gute Ergebnisse. Die Methode der OBIA bietet sich an, wenn ein großes Gebiet analysiert werden soll, welches für eine visuelle Bildinterpretation bzw. Kartierung vor Ort zu aufwendig wäre. Die Methode ist daher für das Forschungsvorhaben zu empfehlen. Neben der Spektralinformation sollte zudem ein nDOM kombiniert werden, dadurch wird das Ergebnis deutlich verbessert.

Als Datengrundlage kommen für das Forschungsvorhaben zu erwerbende Orthophotos und Höhenmodelle über das Land NÖ in Frage, jedoch ist hier ein großer Nachteil, dass die Luftaufnahmen nur alle drei bis vier Jahre stattfinden. Satellitenaufnahmen könnten dahingegen besser für das Vorhaben geeignet sein.

Für eine vollständige Bewertung der Habitateignung sind weitere Faktoren zu berücksichtigen, wie die Uferbefestigung, Hangneigung und Wassertiefe. Dafür ist die alleinige Analyse von Fernerkundungsdaten nicht möglich. Dies kann z.B. durch Kartierungen vor Ort oder durch Informationen der Gewässerstrukturgüte erfolgen (vgl. Maringer, Slotta-Bachmayr 2006; Loaker 2011; Komposch 2014).

Literaturverzeichnis

- Albertz J. (2009): Einführung in die Fernerkundung: Grundlagen der Interpretation von Luft- und Satellitenbildern, 4. Auflage. WBG, Darmstadt.
- Betriebsgesellschaft Marchfeldkanal (2018): Das Marchfeldkanalprojekt in 5 Minuten. Verfügbar unter: <http://www.marchfeldkanal.at/mfkkurz/mfk11s03kurz.php> (aufgerufen am 28.10.2018).
- Blaschke T., Hay G.J., Kelly M., Lang S., Hofmann P., Addink E., Feitosa R.Q., van der Meer F., van der Werff H., van Coillie F., Tiede D. (2014): Geographic Object-Based Image Analysis – Towards a new paradigm. *ISPRS Journal of Photogrammetry and Remote Sensing* 87: 180–191. DOI: 10.1016/j.isprsjprs.2013.09.014
- Breiman L. (2001): Random Forest. *Machine Learning* 45: 5–32. DOI: 10.1023/A:1010933404324
- Breiman L., Cutler A. (o.J.): Random forests - classification description. Verfügbar unter: https://www.stat.berkeley.edu/~breiman/RandomForests/cc_home.htm (aufgerufen am 07.05.2019).
- Clauß G., Finze F.-R., Partzsch L. (2002): Statistik. Für Soziologen, Pädagogen, Psychologen und Mediziner, 4. Auflage. Wissenschaftlicher Verlag Harri Deutsch GmbH, Frankfurt am Main.
- Colomina I., Molina P. (2014): Unmanned aerial systems for photogrammetry and remote sensing: A review. *ISPRS Journal of Photogrammetry and Remote Sensing* 92: 79–97. DOI: 10.1016/j.isprsjprs.2014.02.013
- Corbane C., Lang S., Pipkins K., Alleaume S., Deshayes M., García M., Virginia E., Strasser T., Vanden Borre J., Toon S., Förster M. (2015): Remote sensing for mapping natural habitats and their conservation status - New opportunities and challenges. *International Journal of Applied Earth Observation and Geoinformation* 37: 7–16. DOI: 10.1016/j.jag.2014.11.005
- Einzmann K., Immitzer M., Böck S., Bauer O., Schmitt A., Atzberger C. (2017): Windthrow Detection in European Forests with Very High-Resolution Optical Data. *Forests* 8(21): 1–26. DOI: 10.3390/f8010021
- Förster M., Frick A. (2015): Fernerkundung als Hilfe im Naturschutz. Aktuelle Sensoren und Methoden angewandt auf Großschutzgebiete in Brandenburg. *Forum Geoökologie* 26(1): 22–25.
- Grouven U., Bender R., Ziegler A., Lange S. (2007): The kappa coefficient. *Deutsche medizinische Wochenschrift* (1946) 132(23): 65–68. DOI: 10.1055/s-2007-959046
- Hänsch R., Hellwich O. (2017): Random Forest. In: C. Heipke (Hrsg.): *Photogrammetrie und Fernerkundung*. Springer-Verlag, Berlin: 603–639.
- Immitzer M. (2017): Mapping Tree Species, Forest Calamities and Growing Stock using High Resolution Satellite Imagery – Possibilities and Limits. Dissertation.
- Immitzer M., Atzberger C., Koukal T. (2012): Tree species classification with Random forest

- using very high spatial resolution 8-band worldView-2 satellite data. *Remote Sensing* 4(9): 2661–2693. DOI: 10.3390/rs4092661
- Immitzer M., Vuolo F., Atzberger C. (2016): Verwendung von multispektralen Sentinel-2 Daten für die Baumartenklassifikation und Vergleich mit anderen Satellitensensoren. *Beiträge zur 36. Wissenschaftlich-Technischen Jahrestagung der DGPF* 25: 417–427. DOI: 10.13140/RG.2.1.2251.9288
- Janiszewski P. (2012): Characteristics of riparian trees and shrubs utilized by the European beaver (*Castor fiber*) in the Jamy Forest District. *Annales Universitatis Mariae Curie-Skłodowska. Sectio D: Medicina* XXX (4): 26–33. DOI: 10.2478/v10083-012-0028-7
- Kemnade G., Putz M., Steinhardt U., van Berlo M., Kaiser H. (2002): Bewertung von Biberhabitaten im niedersächsischen Elbetal. *Informationsdienst Naturschutz Niedersachsen* 1: 29–47.
- Kempton I., Nopp-Mayr U., Hausleithner C., Gratzner G. (2018): Tricky to track : comparing different tagging methods for tracing beech- nut dispersal by small mammals. *Ecological Research* 33(6): 1219–1231. DOI: 10.1007/s11284-018-1640-y
- Kersten T.P., Lindstaedt M. (2017): Photogrammetrie auf Knopfdruck - Auswertung und Resultate UAV-gestützter Bildflugdaten. *ZfV - Zeitschrift für Geodäsie, Geoinformation und Landmanagement* 142(1): 3–13. DOI: 10.12902/zfv-0145-2016
- Komposch B. (2014): Verbreitung und Bestand des Europäischen Bibers (*Castor fiber*, 1758) in der Steiermark (Österreich). *Linzer Biologische Beiträge* 46(2): 1277–1320.
- Landis J.R., Koch G.G. (1977): The Measurement Of Observer Agreement For Categorical Data. *Biometrics* 33: 159–174.
- de Lange N. (2013): *Geoinformatik in Theorie und Praxis*, 3. Auflage. Springer-Verlag, Berlin.
- Li M., Ma L., Blaschke T., Cheng L., Tiede D. (2016): A systematic comparison of different object-based classification techniques using high spatial resolution imagery in agricultural environments. *International Journal of Applied Earth Observation and Geoinformation* 49: 87–98. DOI: 10.1016/j.jag.2016.01.011
- Liaw A., Wiener M. (2002): Classification and Regression by randomForest. *R news* 2/3: 18–22. DOI: 10.1023/A:1010933404324
- Lillesand T.M., Kiefer R.W., Chipman J.W. (2015): *Remote Sensing and Image Interpretation*, 7. Auflage. John Wiley & Sons, Inc. U.S.
- Lindstaedt M., Kersten T.P. (2018): Zur Bedeutung von Passpunkten bei der Aerotriangulation UAV-basierter Bildflüge. In: *UAV 2018 – Vermessung mit unbemannten Flugsystemen*. DVW-Schriftenreihe. DVW e.V. Augsburg: 81–101.
- Loaker K. (2011): *Der Biber (Castor fiber) am Alten Rhein - Habitateignung und Konfliktpotential*. Universität für Bodenkultur, Wien.
- Ma L., Cheng L., Li M., Liu Y., Ma X. (2015): Training set size, scale, and features in Geographic Object-Based Image Analysis of very high resolution unmanned aerial vehicle imagery. *ISPRS Journal of Photogrammetry and Remote Sensing* 102: 14–27. DOI:

10.1016/j.isprsjprs.2014.12.026

- Ma L., Li M., Ma X., Cheng L., Du P., Liu Y. (2017): A review of supervised object-based land-cover image classification. *ISPRS Journal of Photogrammetry and Remote Sensing* 130: 277–293. DOI: 10.1016/j.isprsjprs.2017.06.001
- Maringer A., Slotta-Bachmayr L. (2006): A GIS-based habitat-suitability model as a tool for the management of beavers *Castor fiber*. *Acta Theriologica* 51(4): 373–382. DOI: 10.1007/BF03195184
- Neubert M., Blaschke T. (2004): Segmentierung von Fernerkundungsdaten als Grundlage zur Ableitung von Landschaftsstrukturmaßen. *IÖR Schriften*. 1–18.
- Pettorelli N., Laurance W.F., O’Brien T.G., Wegmann M., Nagendra, H., Turner W. (2014): Satellite remote sensing for applied ecologists: Opportunities and challenges. *Journal of Applied Ecology* 51(4): 839–848. DOI: 10.1111/1365-2664.12261
- Scheikl S. (2015): *Handbuch für Biberkartierer: Grundlagen und Methodik der Revierkartierung und Analyse von Biberzeichen* Universität für Bodenkultur Wien, Institut für Wildbiologie und Jagdwirtschaft.
- Sieber J. (2002): Populationsentwicklung und Habitatnutzung des Bibers in Niederösterreich (March/Thaya Auen). *Informationsdienst Naturschutz Niedersachsen* 1: 9–12.
- Tscharf A. (2016): Potentiale und Herausforderungen neuer Vermessungstechnologien im Bergbau – Der Einsatz unbemannter Flugkörper zur Erfassung von Geodaten. *BHM* 161(10): 481–487. DOI: 10.1007/s00501-016-0527-x
- Ventura D., Bonifazi A., Gravina M.F., Belluscio A. (2018): Marine Habitats Using Unmanned Aerial Vehicle (UAV) Imagery and Object-Based Image Analysis. DOI: 10.3390/rs10091331
- Vorel A., Válková L., Hamšíková L., Maloň J., Korbelová J. (2015): Beaver foraging behaviour: Seasonal foraging specialization by a choosy generalist herbivore. *Behavioral Ecology and Sociobiology* 69(7): 1221–1235. DOI: 10.1007/s00265-015-1936-7
- Waser L.T., Straub C. (2015): Baumartenerkennung mit optischen Fernerkundungsdaten - Stand und Perspektiven. *Forstliche Forschungsberichte München* (214): 65–75.
- Zahner V., Schmidbauer M., Schwab G. (2005): *Der Biber. Die Rückkehr der Burgherren*. Buch- und Kunstverlag, Oberpfalz.

Anhang

I. Input in RStudio: RandomForest

benötigte Pakete

```
install.packages('raster', dependencies = TRUE)
install.packages('matrixStats', dependencies = TRUE)
install.packages('randomForest', dependencies = TRUE)
install.packages('caret', dependencies = TRUE)
install.packages('rgdal', dependencies = TRUE)
library(raster)
library(sp)
library(matrixStats)
library(randomForest)
library(caret)
library(ggplot2)
library(lattice)
```

Speicherort zuweisen

```
setwd('D:/...')
```

"source" führt die beiden R-Skripts aus, in denen die Funktionen "zonalExtract" und "regionStats" definiert werden

```
source('Rscripts_UAV/Scripts/regionStats.R')
source('Rscripts_UAV/Scripts/zonalExtract.R')
```

"shapefile" aus dem "raster" Packet ermöglicht es Shapefiles in R zu laden

```
sf_path <- 'Training/Training.shp'
sf <- shapefile(sf_path)
```

"brick" aus dem "raster" Packet ermöglicht es (Multilayer)-Raster in R zu laden

```
multilayer_ras <- brick('Multilayer/Multilayer.tif')
multilayer_ras
```

Shapefile mit "gdal_rasterize" von Vektor in Raster umwandeln (wichtig: Shape benötigt ID-Spalte)

```
inname <- 'D:/.../Training.shp'
outname <- gsub(pattern = '.shp', replacement = '.tif', x = inname)
te <- paste(extent(multilayer_ras)[c(1,3,2,4)], collapse = ' ')
tr <- paste(res(multilayer_ras), collapse = ' ')
```

```
cmd0 <- sprintf('C:/OSGeo4W64/OSGeo4W.bat && gdal_rasterize -a ID -te %s -tr %s %s %s',
               te, tr, inname, outname)
system(cmd0)
```

Resampling des nDOM von 1m Auflösung auf 0,03m Auflösung für deckungsgleiche Pixel

```
inname <- 'D:/.../nDOM.tif'
outname <- gsub(pattern = '.tif', replacement = '_RESAMPLED.tif', x = inname)
```

```
te <- paste(extent(multilayer_ras)[c(1,3,2,4)], collapse = ' ')
tr <- paste(res(multilayer_ras), collapse = ' ')

cmd0 <- sprintf('C:/OSGeo4W64/OSGeo4W.bat && gdalwarp -te %s -tr %s %s %s',
               te, tr, inname, outname)
system(cmd0)

#nDSM Koordinatensystem zuweisen und minimale Höhe auf 0 setzen
nDSM_ras <- raster('nDOM/nDOM.tif')
crs(nDSM_ras) <- CRS('+proj=tmerc +lat_0=0 +lon_0=16.33333333333334 +k=1 +x_0=0
+y_0=-5000000 +ellps=bessel +units=m +no_defs')
nDSM_ras[nDSM_ras<0]<-0
nDSM_ras
writeRaster(nDSM_ras,
            filename= 'D:/.../nDOM_RESAMPLED_cor.tif')

# Reinladen der tifs
tex_SFS_ras <- raster('Textur/SFS_Textur.tif')
seg_ras <- raster('Training/Training.tif')
ndvi_ras <- raster('NDVI/NDVI.tif')
nDOM_ras <- raster('nDOM/nDOM_RESAMPLED_cor.tif')

# Layer (tifs) zusammenfügen
value_ras <- stack(multilayer_ras, nDOM_ras, tex_SFS_ras, ndvi_ras)

# Extrahierung der Pixelwerte pro Segment
extr <- zonalExtract(x = value_ras, z = seg_ras, minrows = 512, showProgress = TRUE)
save(extr, file='D:/.../extr.RData')

# Berechnen von Statistiken für jedes Segment
extr_stats <- regionStats(extr)
head(extr_stats)
save(extr_stats, file='D:/.../extr_stats.RData')

# Statistiken für Trainingspolygone
ref <- which(!is.na(sf$Class))
extr_stats_ref <- extr_stats[ref, ]

nas_ref <- rowAnyNAs(extr_stats_ref)
extr_stats_ref <- extr_stats_ref[!nas_ref, ]

sf_ref <- sf[ref, ]
sf_ref <- sf_ref[!nas_ref, ]

length(sf_ref)
dim(extr_stats_ref)
```

Erstellen des randomForest Modells und Confusion Matrix**## für die Datenauswahl im nächsten Schritt**

```
multi_col <- grep(colnames(extr_stats),pattern = "Multi")
multi_col
tex_col <- grep(colnames(extr_stats), pattern = "SFS")
tex_col
nDOM_col <- grep(colnames(extr_stats),pattern = "nDOM")
nDSM_col
ndvi_col <- grep(colnames(extr_stats),pattern = "NDVI")
ndvi_col
```

x = Statistik für jedes Segment + Auswahl gewünschter Datenkombination, y = Statistik der Trainingsdaten + Bezug auf Attributspalte der Trainingsdaten (Class), ntree = Anzahl der Bäume, die im Lauf wachsen sollen

```
rf_mod_multi <- randomForest(x = extr_stats_ref[,multi_col], y = as.factor(sf_ref$Class),
ntree = 1000,importance = TRUE)
rf_mod_multi
save(rf_mod_multi, file = 'D:/.../RF_multilayer.RData')
confusionMatrix(rf_mod_multi$predicted, rf_mod_multi$y)
```

```
rf_mod_multi_tex <- randomForest(x = extr_stats_ref[,c(multi_col,tex_col)], y = as.factor(sf_ref$Class), ntree = 1000,importance = TRUE)
rf_mod_multi_tex
save(rf_mod_multi_tex, file = 'D:/.../RF_multi_tex.RData')
confusionMatrix(rf_mod_multi_tex$predicted, rf_mod_multi_tex$y)
```

```
rf_mod_multi_nDOM <- randomForest(x = extr_stats_ref[,c(multi_col,nDOM_col)], y = as.factor(sf_ref$Class), ntree = 1000,importance = TRUE)
rf_mod_multi_nDOM
save(rf_mod_multi_nDSM, file = 'D:/.../RF_multi_nDOM.RData')
confusionMatrix(rf_mod_multi_nDOM$predicted, rf_mod_multi_nDOM$y)
```

```
rf_mod_multi_tex_nDOM <- randomForest(x = extr_stats_ref[,c(multi_col,tex_col,
nDOM_col)], y = as.factor(sf_ref$Class), ntree = 1000,importance = TRUE)
rf_mod_multi_tex_nDOM
save(rf_mod_multi_tex_nDOM, file = 'D:/.../RF_multi_tex_nDOM.RData')
confusionMatrix(rf_mod_multi_tex_nDOM$predicted, rf_mod_multi_tex_nDOM$y)
```

```
rf_mod_multi_tex_nDOM_ndvi <- randomForest(x = extr_stats_ref[,c(multi_col,tex_col,
nDOM_col, ndvi_col)], y = as.factor(sf_ref$Class), ntree = 1000,importance = TRUE)
rf_mod_multi_tex_nDOM_ndvi
save(rf_mod_multi_tex_nDOM_ndvi, file = 'D:/.../RF_multi_tex_nDOM_ndvi.RData')
confusionMatrix(rf_mod_multi_tex_nDOM_ndvi$predicted,
rf_mod_multi_tex_nDOM_ndvi$y)
```

Anwenden des Modells für die Kombination: Multilayer + SFS-Textur + nDOM + NDVI

```
nas <- rowAnyNAs(extr_stats)
```

```
rf_pred <- predict(object = rf_mod_multi_tex_nDOM_ndvi, extr_stats[!nas, ])
```

```
sf@data$Predict_LC <- NA
```

```
sf@data$Predict_LC[as.integer(names(rf_pred))] <- as.character(rf_pred)
```

```
shapefile(sf, file= 'D:/.../Klassi_UAV_multi_tex_nDOM_NDVI.shp')
```

II. Kreuztabellen (χ^2 -Test) für den Methodenvergleich: Großes Gebiet

Anhang 1: Kreuztabelle der Methoden Visuelle Interpretation und Visuelle Interpretation + nDOM

Klasse	Beobachtet (f_o)			Erwartet (f_e)		Chi-Quadrat		χ^2
	Vis. Interp.	Vis. Inter. +nDOM	SUMME	Vis. Interp.	Vis. Inter. +nDOM	Vis. Interp.	Vis. Inter. +nDOM	
Kr. Vegetation/Gras	18.95	20.08	39.02	19.51	19.51	0.02	0.02	
Röhricht	2.56	2.56	5.13	2.56	2.56	0.00	0.00	
Strauch/Sukz.	9.91	18.58	28.49	14.24	14.24	1.32	1.32	
Baum	24.91	15.12	40.03	20.02	20.02	1.20	1.20	
Feld	20.63	20.63	41.27	20.63	20.63	0.00	0.00	
Wasser	14.82	14.81	29.63	14.81	14.81	0.00	0.00	
(ü.w.) vers. Fläche	8.22	8.21	16.43	8.21	8.21	0.00	0.00	
SUMME	100.00	100.00	200.00	100.00	100.00	2.54	2.54	5.07

Anhang 2: Kreuztabelle der Methoden Klassifizierung Orthophoto und Visuelle Interpretation

Klasse	Beobachtet (fo)			Erwartet (fe)		Chi-Quadrat		
	Klassi. Ortho.	Vis. Inter.	SUMME	Klassi. Ortho.	Vis. Inter.	Klassi. Ortho.	Vis. Inter.	X²
<i>Kr. Vegetation/Gras</i>	19.60	18.95	38.55	19.27	19.27	0.01	0.01	0.01
<i>Röhricht</i>	5.24	2.56	7.80	3.90	3.90	0.46	0.46	0.92
<i>Strauch/Sukz.</i>	14.46	9.91	24.36	12.18	12.18	0.42	0.42	0.85
<i>Baum</i>	16.82	24.91	41.74	20.87	20.87	0.78	0.78	1.57
<i>Feld</i>	18.74	20.63	39.37	19.69	19.69	0.05	0.05	0.09
<i>Wasser</i>	15.21	14.82	30.02	15.01	15.01	0.00	0.00	0.01
<i>(ü.w.) vers. Fläche</i>	9.94	8.22	18.15	9.08	9.08	0.08	0.08	0.16
SUMME	100.00	100.00	200.00	100.00	100.00	1.80	1.80	3.60

df = 6, $\alpha = 0.05$, kritischer Wert (χ^2) = 12.592

H₀ wird beibehalten, es besteht kein signifikanter Unterschied.

Dies sind die Methoden mit dem größten Unterschied zueinander, die anderen Methoden auf dieser Fläche haben ein $\chi^2 < 2$.

III. Kreuztabellen (χ^2 -Test) für den Methodenvergleich: Kleines Gebiet

Anhang 3: Kreuztabelle der Methoden Klassifikation UAV und Visuelle Interpretation

Klasse	Beobachtet (fo)			Erwartet (fe)		Chi-Quadrat		χ^2
	Klassi. UAV	Vis. Interpre.	SUMME	Klassi. UAV	Vis. Interpre.	Klassi. UAV	Vis. Interpre.	
Kr. Vegetation/Gras	19.25	15.75	35.00	17.50	17.50	0.17	0.17	
Strauch/Sukz.	31.01	12.02	43.03	21.52	21.52	4.19	4.19	
Baum	29.04	49.17	78.21	39.10	39.10	2.59	2.59	
Wasser	13.14	14.10	27.25	13.62	13.62	0.02	0.02	
(ü.w.) vers. Fläche	7.56	8.96	16.52	8.26	8.26	0.06	0.06	
SUMME	100.00	100.00	200.00	100.00	100.00	7.03	7.03	14.06

Anhang 4: Kreuztabelle der Methoden Klassifikation UAV und Kartierung

Klasse	Beobachtet (fo)			Erwartet (fe)		Chi-Quadrat		χ^2
	Klassi. UAV	Kartierung	SUMME	Klassi. UAV	Kartierung	Klassi. UAV	Kartierung	
Kr. Vegetation/Gras	19.25	16.62	35.87	17.93	17.93	0.10	0.10	
Strauch/Sukz.	31.01	13.05	44.06	22.03	22.03	3.66	3.66	
Baum	29.04	47.55	76.59	38.29	38.29	2.24	2.24	
Wasser	13.14	13.97	27.11	13.56	13.56	0.01	0.01	
(ü.w.) vers. Fläche	7.56	8.81	16.37	8.19	8.19	0.05	0.05	
SUMME	100.00	100.00	200.00	100.00	100.00	6.05	6.05	12.11

Anhang 5: Kreuztabelle der Methoden Visuelle Interpretation und Visuelle Interpretation + nDOM

Klasse	Beobachtet (f_o)			Erwartet (f_e)		Chi-Quadrat		
	Vis. Interpre.	Vis. Inter. +nDOM	SUMME	Vis. Interpre.	Vis. Inter. +nDOM	Vis. Interpre.	Vis. Inter. +nDOM	χ^2
Kr. Vegetation/Gras	19.25	15.75	35.00	17.50	17.50	0.17	0.17	
Strauch/Sukz.	31.01	12.02	43.03	21.52	21.52	4.19	4.19	
Baum	29.04	49.17	78.21	39.10	39.10	2.59	2.59	
Wasser	13.14	14.10	27.25	13.62	13.62	0.02	0.02	
(ü.w.) vers. Fläche	7.56	8.96	16.52	8.26	8.26	0.06	0.06	
SUMME	100.00	100.00	200.00	100.00	100.00	7.03	7.03	14.06

df = 4, $\alpha = 0.05$, kritischer Wert = 9.488

H_0 wird abgelehnt, es besteht ein signifikanter Unterschied zwischen diesen Methoden.

Anhang 6: Kreuztabelle der Methoden Kartierung und Visuelle Interpretation + nDOM

Klasse	Beobachtet (fo)			Erwartet (fe)		Chi-Quadrat		
	Kartierung	Vis. Inter. +nDOM	SUMME	Kartierung	Vis. Inter. +nDOM	Kartierung	Vis. Inter. +nDOM	x ²
Kr. Vegetation/Gras	16.62	16.00	32.62	16.31	16.31	0.01	0.01	
Strauch/Sukz.	13.05	26.64	39.69	19.84	19.84	2.33	2.33	
Baum	47.55	34.34	81.89	40.94	40.94	1.07	1.07	
Wasser	13.97	14.09	28.06	14.03	14.03	0.00	0.00	
(ü.w.) vers. Fläche	8.81	8.93	17.74	8.87	8.87	0.00	0.00	
SUMME	100.00	100.00	200.00	300.00	100.00	3.40	3.40	6.80

Anhang 7: Kreuztabelle der Methoden Klassifikation Orthophoto und Klassifikation UAV

Klasse	Beobachtet (fo)			Erwartet (fe)		Chi-Quadrat		
	Klassi. Ortho	Klassi. UAV	SUMME	Klassi. Ortho	Klassi. UAV	Klassi. Ortho	Klassi. UAV	x ²
Kr. Vegetation/Gras	13.34	19.25	32.59	16.29	16.29	0.54	0.54	
Strauch/Sukz.	19.96	31.01	50.97	25.48	25.48	1.20	1.20	
Baum	43.48	29.04	72.52	36.26	36.26	1.44	1.44	
Wasser	14.98	13.14	28.12	14.06	14.06	0.06	0.06	
(ü.w.) vers. Fläche	8.25	7.56	15.81	7.90	7.90	0.01	0.01	
SUMME	100.00	100.00	200.00	100.00	100.00	3.25	3.25	6.49

H₀ wird beibehalten, es besteht kein signifikanter Unterschied dieser Methoden. Die restlichen Methoden haben ein $x^2 < 3$.

Eidesstattliche Erklärung

Ich erkläre eidesstattlich, dass ich die Arbeit selbständig angefertigt, keine anderen als die angegebenen Hilfsmittel benutzt und alle aus ungedruckten Quellen, gedruckter Literatur oder aus dem Internet im Wortlaut oder im wesentlichen Inhalt übernommenen Formulierungen und Konzepte gemäß den Richtlinien wissenschaftlicher Arbeiten zitiert, durch Fußnoten gekennzeichnet bzw. mit genauer Quellenangabe kenntlich gemacht habe.

Wien, 12.08.2019

Anne Schlegel