

Autor: Justin Catau

***Ein Vergleich von Verfahren zu Landbedeckungsklassifikationen
mittels Künstlicher Intelligenz***

MASTERARBEIT

zur Erlangung des akademischen Grades

Master of Science

in der Studienrichtung Nachhaltige Stadt- und Regionalentwicklung

eingereicht an der

Universität Graz

Umwelt-, Regional- und Bildungswissenschaftliche Fakultät

Gutachter: Wolfgang Sulzer, Ao.Univ.-Prof. Mag. Dr.rer.nat
Institut für Geographie und Raumforschung

Co-Betreuung: Michael Wurm, Mag. Dr.rer.nat.
Institut für Geographie und Raumforschung

2023

Zusammenfassung

Der Nutzen *Künstlicher Intelligenz* sorgt gegenwärtig für Paradigmenwechsel. Auch in der Fernerkundung nehmen Verfahren der *Künstlichen Intelligenz*, spezifisch *Deep Learning*, eine zunehmend übergeordnete Rolle ein. Die Anwendung von *Deep Learning* auf hoch aufgelösten *Rapid Eye* Satellitendaten zum Zweck der Landbedeckungsklassifikation wird mithilfe vom bestehenden *Digitalen Landbedeckungsmodell für Deutschland* gezeigt. Anhand des Bundeslandes Bayern werden Trainingsdaten für das künstliche neuronale Netzwerk generiert, trainiert, validiert und getestet. Ein Vergleich von *Deep Learning* und *Shallow Learning* Methoden – *K-Nearest Neighbor* und *Random Forest* – jeweils eingebunden in pixelbasierten und objektbasierten Verfahren in zwei Softwarepaketen – *Arcgis Pro* und *eCognition* – zeigt wie sich unterschiedliche Methodenkombinationen auf die Klassifikationsgüten der Landbedeckungen auswirkt. Als Resultat dieses quantitativen und qualitativen Vergleichs zeigt sich in dieser Arbeit, dass *Deep Learning* Methoden in der pixelbasierten Umgebung von *Arcgis Pro*, unter Berücksichtigung der zuverlässigsten *Deep Learning* Hyperparameter, die besten Klassifikationsgüten erzielen.

Abstract

The use of *Artificial Intelligence* is currently causing a paradigm shift. *Artificial Intelligence*, specifically *Deep learning*, is also playing an increasingly important role in remote sensing. The application of deep learning on high-resolution *Rapid Eye* satellite image data for the purpose of land cover classifications will be demonstrated using the existing labeled vector data of Germany, the *Digitales Landbedeckungsmodell für Deutschland*. Based on the federal state of Bavaria, training data for the artificial neural network is generated, trained, validated and tested. A comparison of *Deep Learning* and *Shallow Learning* methods – *K-Nearest Neighbor* and *Random Forest* – in pixel-based and object-based environments in two software packages – *Arcgis Pro* and *eCognition* – shows how different method combinations affect the classification qualities of land cover. As a result of this quantitative and qualitative comparison, this scientific work shows that *Deep Learning* methods achieve the best classification qualities in the pixel-based environment of *Arcgis Pro*, considering the most proven *Deep Learning* hyperparameters.

Danksagung

ICH BEDANKE MICH HERZLICH BEI ALLEN DIE ES MIR ERMÖGLICHT HABEN, DIESE
MASTERARBEIT IN DIE TAT UMZUSETZEN.

BESONDERS BEI

MEINER MUTTER, DIE STETS ALS HOFFNUNGSSPENDERIN FUNGIERTE

MEINEM VATER, DEM GEDULDIGSTEN MENSCHEN DER WELT

MEINEM BRUDERHERZ, VON DEM ICH MIR STETS ETWAS ABSCHAUEN KANN

MEINEN BETREUERN Mag. DR.RER.NAT. MICHAEL WURM UND AO.UNIV.-PROF. MAG.
DR.RER.NAT. WOLFGANG SULZER, DIE SICH STETS DIE ZEIT FÜR KONSTRUKTIVES FEEDBACK
NAHMEN UND MIR DIE GELEGENHEIT BOTEN, DIE MASTERARBEIT IN KOOPERATION MIT
DEM DEUTSCHEN ZENTRUM FÜR LUFT- UND RAUMFAHRT ZU VERFASSEN UND SOMIT AUCH
MEIN INTERESSE FÜR KÜNSTLICHE INTELLIGENZ UND DAS UNERKLÄRLICHE GEWECKT
HABEN.

Inhaltsverzeichnis

Zusammenfassung.....	i
Abstract	i
Danksagung	ii
Inhaltsverzeichnis.....	iii
Abbildungsverzeichnis.....	iv
Tabellenverzeichnis	v
Abkürzungsverzeichnis.....	vi
1 Einleitung.....	1
1.1 Forschungsziel	2
1.2 Forschungsstand.....	4
1.3 Methodik und verwendete Software	8
2 Grundlagen	11
2.1 Künstliche Intelligenz.....	14
2.2 Klassifikationen in der Fernerkundung.....	20
2.3 Rapid Eye Satellitenaufnahmen	24
2.4 Digitales Landbedeckungsmodell Deutschland.....	27
3 Experimentelles Setup.....	34
3.1 Trainingsgebiete	35
3.2 Modelltraining.....	43
3.3 Klassifikation.....	47
3.3.1 Anwendung in Arcgis Pro	48
3.3.2 Anwendung eCognition	50
4 Ergebnisse.....	54
5 Conclusio	80
5.1 Beantwortung der Forschungsfragen.....	80
5.2 Schlussbetrachtung	83
Quellenverzeichnis	vii
Anhang	xv

Abbildungsverzeichnis

Abbildung 1: Anzahl Publikationen mit Stichwort 'Deep Learning' auf Web of Science in den letzten 20 Jahren.....	6
Abbildung 2: Schematische Darstellung des Ablaufs der Methodik.....	8
Abbildung 3: Klassifikation, Objekterkennung und Segmentierungen am Beispiel einer Rapid Eye Szene.....	12
Abbildung 4: Unterteilung des maschinellen Lernprozesses in überwachtes und unüberwachtes Lernen.....	14
Abbildung 5: Künstliche Intelligenz und deren Formen.....	16
Abbildung 6: Darstellung von konventionellen Machine Learning Klassifikationsverfahren.....	17
Abbildung 7: Darstellung der Deep Learning Funktionsweise.....	19
Abbildung 8: Spezifische Spektralsignaturen der Klassen Wasser, Vegetation und Boden.....	22
Abbildung 9: Rapid Eye Satellitensystem.....	25
Abbildung 10: Rapid Eye Aufnahmen aus dem Jahr 2015.....	26
Abbildung 11: Bayern Referenzdatei der Landbedeckung unterteilt in den 7 vorkommenden Hauptklassen.....	29
Abbildung 12: Vergleich einer Satellitenszene und des vektorisierten DLM-DE Datensatzes.....	33
Abbildung 13: Aufteilung des Datensatzes.....	35
Abbildung 14: Leistungssteigerung durch mehr Trainingsdaten in der Deep Learning Anwendung....	36
Abbildung 15: Darstellung des Exportordners und des Metadatei-Formats beider Softwareprogramme.....	40
Abbildung 16: Funktionsweise eines Convolutional Neural Networks.....	44
Abbildung 17: U-Net Architektur.....	45
Abbildung 18: Güte der Lernkurve in der Theorie.....	46
Abbildung 19: Schematische Darstellung der pixelbasierten Klassifikation in Arcgis Pro.....	49
Abbildung 20: Anwendung der pixelbasierten Klassifikation in Arcgis Pro.....	49
Abbildung 21: Schematische Darstellung der objektbasierten Klassifikation in eCognition.....	51
Abbildung 22: Heatmaps als Zwischenschritt zur objektbasierten Klassifikation in eCognition.....	52
Abbildung 23: Anwendung der objektbasierten Klassifikation in eCognition.....	53
Abbildung 24: Übersicht der 7 Auszüge zu den Ergebnissen.....	56
Abbildung 25: Ergebnisse der Landbedeckungsklassifikation in LBM2 Darstellung - Szene 1.....	59
Abbildung 26: Ergebnisse der Landbedeckungsklassifikation in LBM1 Darstellung - Szene 1.....	60
Abbildung 27: Ergebnisse der Landbedeckungsklassifikation in LBM2 Darstellung - Szene 2.....	62
Abbildung 28: Ergebnisse der Landbedeckungsklassifikation in LBM1 Darstellung - Szene 2.....	63
Abbildung 29: Ergebnisse der Landbedeckungsklassifikation in LBM2 Darstellung - Szene 3.....	65
Abbildung 30: Ergebnisse der Landbedeckungsklassifikation in LBM1 Darstellung - Szene 3.....	66
Abbildung 31: Ergebnisse der Landbedeckungsklassifikation in LBM2 Darstellung - Szene 4.....	68
Abbildung 32: Ergebnisse der Landbedeckungsklassifikation in LBM1 Darstellung - Szene 4.....	69
Abbildung 33: Ergebnisse der Landbedeckungsklassifikation in LBM2 Darstellung - Szene 5.....	71
Abbildung 34: Ergebnisse der Landbedeckungsklassifikation in LBM1 Darstellung - Szene 5.....	72
Abbildung 35: Ergebnisse der Landbedeckungsklassifikation in LBM2 Darstellung - Szene 6.....	74
Abbildung 36: Ergebnisse der Landbedeckungsklassifikation in LBM1 Darstellung - Szene 6.....	75
Abbildung 37: Ergebnisse der Landbedeckungsklassifikation in LBM2 Darstellung - Szene 7.....	77
Abbildung 38: Ergebnisse der Landbedeckungsklassifikation in LBM1 Darstellung - Szene 7.....	78

Tabellenverzeichnis

Tabelle 1: Vergleich Softwareprogramme - ArcGis Pro und eCognition	10
Tabelle 2: Nennenswerte Eigenschaften der verwendeten Hardware	11
Tabelle 3: Gegenüberstellung von Machine Learning und Deep Learning	20
Tabelle 4: Bänder und Spektralbereiche Rapid Eye-Sensor.	27
Tabelle 5: Klassifikationsschema des Landbedeckungsmodells Deutschland 2015	30
Tabelle 6: DLM-DE nach den Hauptklassen für das Bundesland Bayern	38
Tabelle 7: DLM-DE nach den Subklassen für das Bundesland Bayern	38
Tabelle 8: Indizes für zusätzlichen Informationsgewinn	41
Tabelle 9: Auswahl an Haralick Features.....	42
Tabelle 10: κ -Werte und deren Aussagen über Übereinstimmungen	55
Tabelle 11: Ergebnisse der Overall Accuracy und der κ -Werte nach Methode	57
Tabelle 12: Szene 1 - LBM2 – Producer- und User Accuracies pro Klasse und Methode.....	58
Tabelle 13: Szene 1 – LBM1 – Producer- und User Accuracies pro Klasse und Methode.....	58
Tabelle 14: Szene 2 - LBM2 – Producer- und User Accuracies pro Klasse und Methode.....	61
Tabelle 15: Szene 2 – LBM1 – Producer- und User Accuracies pro Klasse und Methode.....	61
Tabelle 16: Szene 3 - LBM2 – Producer- und User Accuracies pro Klasse und Methode.....	64
Tabelle 17: Szene 3 – LBM1 – Producer- und User Accuracies pro Klasse und Methode.....	64
Tabelle 18: Szene 4 - LBM2 – Producer- und User Accuracies pro Klasse und Methode.....	67
Tabelle 19: Szene 4 – LBM1 – Producer- und User Accuracies pro Klasse und Methode.....	67
Tabelle 20: Szene 5 - LBM2 – Producer- und User Accuracies pro Klasse und Methode.....	70
Tabelle 21: Szene 5 – LBM1 – Producer- und User Accuracies pro Klasse und Methode.....	70
Tabelle 22: Szene 6 - LBM2 – Producer- und User Accuracies pro Klasse und Methode	73
Tabelle 23: Szene 6 – LBM1 – Producer- und User Accuracies pro Klasse und Methode.....	73
Tabelle 24: Szene 7 - LBM2 - Producer und User Accuracies pro Klasse und Methode.....	76
Tabelle 25: Szene 7 – LBM1 - Producer und User Accuracies pro Klasse und Methode.....	76

Abkürzungsverzeichnis

ATKIS	Amtliches Topographisch-Kartographisches Informationssystem
CLC	Corine Land Cover
CNN	Convolutional Neural Networks
DL	Deep Learning
DLM-DE	Digitales Landbedeckungsmodell für Deutschland
DLR	Deutsches Zentrum für Luft- und Raumfahrt
FCN	Fully Convolutional Network
GIS	Geoinformationssystem
GPU	Graphics Processing Unit
KI	Künstliche Intelligenz
LB	Landbedeckung
LN	Landnutzung
LBM1	Landbedeckungsmodell mit 26 Klassen
LBM2	Landbedeckungsmodell mit 7 Klassen
LCC	Land Cover Classification
ML	Machine Learning
OBIA	Object Based Image Analysis
OA	Overall Accuracy
PA	Producer Accuracy
RF	Random Forest
SL	Shallow Learning
UA	User Accuracy

Als Anmerkung ist noch festzuhalten, dass die Fernerkundung und deren Fachbegriffe stark von der englischen Sprache durchdrungen sind. Um sprachliche Widersprüche zu vermeiden und den Lesefluss aufrechtzuerhalten, wurden Fachbegriffe dem Original überlassen, sofern keine sinngemäße Übersetzung besteht (vgl. Fischer u. Hofer 2011, S. 8f).

1 Einleitung

Die Fernerkundung und die Abbildung der Erdoberfläche in Form von Karten sind bedeutende Bestandteile der Geographie, die es uns gemeinsam ermöglichen, natürliche und gesellschaftliche Prozesse der physischen Umwelt näher zu verstehen. Luft- und Satellitenbilder liefern wichtige Informationen zu landschaftlichen und sozialökologischen Veränderungen. Zudem bietet die Fernerkundung eine Basis an, mit welcher der anthropogene Einfluss im komplexen Mensch-Umwelt Gefüge überwacht und damit auch auftretende globale Herausforderungen zeitnah erkannt werden können (vgl. Albertz 2007, S. 173).

Historisch betrachtet sind Karten seit der Sesshaftwerdung des Menschen von Relevanz, wobei es sich um erste Versuche handelte, seinen Besitz mittels einfacher Geometrie und Astronomie zu verorten. Der praktische Nutzen solcher Karten war anfangs noch recht simpel, aber für die Entwicklung der Gesellschaft und für die Entfaltung des menschlichen Weltbildes unverzichtbar. Geographie ist bis heute ein Bindeglied zwischen Natur- und Geisteswissenschaften und durch interdisziplinäres Handeln charakterisiert. Durch Innovationen in der Erfassung der Erdoberfläche konnten immer mehr und mehr Informationen gewonnen werden, sodass das Band zwischen Informatik und Geographie gestärkt wurde (vgl. Grosjean 2013, S. 9f und Wagner 2013, S. 18). Digitalisierung und neue Technologien wie Massenspeicher und hochauflösende Satellitenaufnahmen ermöglichen es, die Erdoberfläche in kurzer Zeit aufzunehmen. Um auch einen Vorteil daraus zu ziehen, muss ein Mittel gefunden werden, die Rohdaten für den menschlichen Verstand auszuwerten. Die Automatisierung in der Verarbeitung und auch die Generalisierung der Abbildung sind wichtige Mittel, um große Datenmengen und die darin verborgenen Informationen nutzbar zu machen. Generell wird hierbei von Big-Data-Analysen gesprochen (vgl. Gore 1999, S. 528f).

In der Fernerkundung gibt es dabei verschiedene Methoden, um Geoinformationen auszuwerten. Besonders die Klassifikation der Landbedeckung ist ein unterstützendes Mittel, um Land- und Wasseroberflächen vereinfacht darzustellen und zu untersuchen. Dabei handelt es sich um ein relatives-, soziales Konstrukt, welches mittels Standardisierung international für unterschiedliche Fragestellungen genutzt werden kann (vgl. Comber et al. 2005, S. 8ff und Jipp 2021, S. 13). Klassifikationen werden jedoch in zahlreichen Ländern aufwändig durch

visuelle Interpretation von Luft- und Satellitenbildern bestimmt, weshalb eine Standardisierung erschwert wird. Nur wenige Länder verwenden bereits halb- automatische Klassifikationsverfahren unter Zuhilfenahme von *Künstlicher Intelligenz*. Fortschritte in der Anwendung von *Künstlicher Intelligenz* könnten die Klassifikationsverfahren bezüglich Automatisierung und Standardisierung modernisieren und den Nutzen der Landbedeckungsklassifikation erhöhen (vgl. Büttner et al. 2021, S. 16).

1.1 Forschungsziel

Künstliche Intelligenz, insbesondere *Deep Learning* Methoden, offenbaren sich zunehmend als ideales Werkzeug, um Klassifikationen unterschiedlicher Art durchzuführen. Der Fokus dieser wissenschaftlichen Arbeit liegt auf Landbedeckungsklassifikationen. Die Anwendung von *Deep- und Machine Learning* Algorithmen in zwei ausgewählten kommerziellen Softwareprogrammen – *Arcgis Pro* und *eCognition* – soll einen Einblick gewähren, welche Klassifikationsverfahren in der Geographie und Datenverarbeitung besonders geeignet sind. Primär die zunehmende Quantität an Fernerkundungsdaten verlangt neue methodische Perspektiven ab, um die Verfügbarkeit an qualitativ hochwertigen Landbedeckungsklassifikationen sicherzustellen. Es ist von hoher Bedeutung für die Wissenschaft, zu erkennen, welche Genauigkeiten für Klassifikationsergebnisse mittels *Deep Learning* erzielbar sind. Diese Ergebnisse betreffen auch die verwendete Nomenklatur und deren Generalisierung und offenbaren zudem, wo innerhalb des Klassifikationsschemas mit Einbußen der Genauigkeit zu rechnen ist. Mit einem Vergleich der Klassifikationsverfahren soll gezeigt werden, wie Landbedeckungsklassifikationen gezielt mit *Künstlicher Intelligenz* erstellt werden können.

Annahmen die dazu Bezug nehmen sind, dass es Unterschiede in der Anwendung und Performanz der verwendeten Programme, bezüglich der Anwendung von *Deep Learning* Algorithmen, gibt und dass signifikante Unterschiede zwischen den Ergebnissen existieren. Das Forschungsziel dieser Masterarbeit ist diesen Annahmen angelehnt und versucht folgende Fragen zu beantworten:

- **Welche Genauigkeiten für Landbedeckungsklassifikationsergebnisse lassen sich mit den zwei ausgewählten kommerziellen Softwareprogrammen und *Deep Learning* erreichen?**
- **Welche Kombination aus Methode und Softwareprogramm eignet sich besser für Landbedeckungsklassifikationen und inwiefern trifft das auf die Klassifikationsgüte einzelner Klassen nicht zu?**
- **Welche Hyperparameter im *Deep Learning* eignen sich, um die Klassifikationsgenauigkeiten zu erhöhen?**

Diese Forschungsarbeit ist wie folgt aufgebaut. Im nächsten Kapitel 1.2 wird der Forschungsstand erläutert. In diesem erfolgt eine kurze Vorstellung des *Deutschen Zentrums für Luft und Raumfahrt* und des *Bundesamtes für Kartographie und Geodäsie*, den zuständigen Organisationen für Landbedeckungsklassifikationen in der Bundesrepublik Deutschland. Darauf folgend wird ein Überblick gegeben, wie *Künstliche Intelligenz* und insbesondere *Deep Learning* international und länderspezifisch genutzt werden. Neben der Erstellung von Landbedeckungsklassifikationen werden auch einzelne Anwendungsgebiete der *Objekterkennung* betrachtet, um zu realisieren welche Möglichkeiten durch *Deep Learning* geboten werden. Kapitel 1.3 beschreibt die methodische Herangehensweise und die verwendete Software. In Kapitel 2 folgen Grundlagen der *Künstlichen Intelligenz* und Fernerkundung und des Weiteren wird auf die verwendeten Satelliten- und Referenzdaten eingegangen. Den Hauptteil machen Kapitel 3 und Kapitel 4 aus, in denen der Arbeitsablauf bzw. die Ergebnisse präsentiert werden. Zum Schluss folgt das Fazit mit der Beantwortung der Forschungsfragen.

1.2 Forschungsstand

Das 21. Jahrhundert ist von globalen Transformationsprozessen geprägt. Einerseits vom technischen Fortschritt und der Digitalisierung, andererseits von sich ändernden Zuständen auf der Erdoberfläche. Diese Prozesse dienen als Antrieb der Fernerkundung und tragen zu einem dynamischen Forschungsstand bei, der folgend betrachtet wird.

Dies lässt sich anhand der sich im Orbit befindenden Satelliten zeigen. Am 4. Oktober 1957 wurde der erste künstliche Satellit in die Erdumlaufbahn gebracht. Im Jahr 1959 folgte die erste Satellitenaufnahme der Erde (vgl. Stengel 2017, S. 215 und Angermann et al. 2021, S. 71). Im Jahr 2022 [Stand Mai 2022] befinden sich laut dem *United Nations Office for Outer Space Affairs* 7204 künstliche Objekte, darunter überwiegend Satelliten, im Orbit der Erde (vgl. United Nations Office for Outer Space Affairs 2022).

Bei dieser Anzahl an Erdbeobachtungssystemen sind Strukturen und Organisationen notwendig, welche für die Datenverarbeitung und Distribution zuständig sind.

Das *Deutsche Zentrum für Luft und Raumfahrt* (DLR), mit dem in dieser Masterarbeit kooperiert wird, ist grundlegend am Management nationaler und europäischer Programme beteiligt. Erdbeobachtungsdaten werden vom DLR empfangen, verarbeitet und weiterverteilt. Neben der Satellitenkontrolle und der Luft- und Raumfahrt stehen auch Projekte im Fokus, welche zeitgenössische Herausforderungen zu Verkehr, Sicherheit, Energie und zahlreichen weiteren Themen erforschen (vgl. Deutsches Zentrum für Luft- und Raumfahrt 2013, S. 5).

Das *Bundesamt für Kartographie und Geodäsie* (BKG) ist an der Verarbeitung der gewonnenen Daten beteiligt. Das Resultat ist das *Digitale Landbedeckungsmodell für Deutschland* (DLM-DE) welches unter anderem dem Bund als Hilfsmittel dient, thematisch verschiedene Aufgaben und Ziele zu verfolgen. Dadurch ist es für unterschiedliche Anwendungen von Interesse. Das Landbedeckungsmodell enthält flächenhafte Informationen zur gesamten Staatsfläche, wobei das *Amtliche Topographisch-Kartographische Informationssystem* (ATKIS) die geometrische Basis bildet. Angaben zur Landbedeckung und Landnutzung werden zudem nach Vorbild der europäischen Nomenklatur von *Corine Land Cover* (CLC) standardisiert, sodass eine kontinuierliche Landbedeckungsklassifikation Europas gewährleistet werden kann. Während das DLM-DE seit dem Jahr 2009 alle drei Jahre aktualisiert wird, erfolgt ein Update der CLC im 6-Jahres-Takt.

Umweltbezogenen Daten kommt zunehmend eine höhere Bedeutung zu, weshalb es wichtig ist bestehende und neue Daten auf lokaler, regionaler und auch internationaler Ebene zu vereinheitlichen und zu aktualisieren, um die Bereitstellung und Nutzung zu erleichtern. Auf der europäischen Ebene wird die Errichtung einer Infrastruktur für Geodaten, sowohl für bereits existierende als auch für neu generierte Daten, durch Richtlinien der *Infrastructure for Spatial Information in the European Community* (INSPIRE) festgelegt. Dies soll der Effektivität und Wirtschaftlichkeit dienen. Des Weiteren werden umweltbezogene Daten für ganz Europa dank des Copernicus-Programms der Öffentlichkeit frei zugänglich gemacht (vgl. Hovenbitzer et al. 2015, S. 145f und Bundesamt für Kartographie und Geodäsie 2022).

Big-Data-Analysen wurden in den letzten Jahren vor allem durch *Deep Learning* geprägt. Die Anwendungsbereiche sind unterschiedlich und reichen von Bildanalysen bis hin zu Spracherkennung und autonomen Fahren. Künstliche neuronale Netzwerke, spezifischer *Deep Learning*, ermöglichen es Merkmale eines Bildes zu extrahieren und Bildklassifikationen sowie Objektidentifizierungen durchzuführen (vgl. Cresson 2020, S. IX). *Semantische Segmentierung*, auch *Semantic Labeling* oder *Image Segmentation*, ist der Prozess, welcher die Attribuierung jedes einzelnen Pixels eines Bildes zu einer Klasse vornimmt. Das ist das Grundelement einer Landbedeckungsklassifikation mit *Deep Learning* (vgl. Tuia et al. 2021, S. 46). Die Fernerkundung profitiert grundsätzlich durch Fortschritte in der *Künstlichen Intelligenz*. Besonders die Analyse von hyperspektralen, hochauflösenden Aufnahmen unterschiedlichster Zeitfolgen kann durch *Deep Learning* verbessert werden. Allerdings ist eine Erprobung der Methoden unausweichlich. Die Implementierung von *Deep Learning* in Geoinformationssystemen spielt dabei einen entscheidenden Faktor (vgl. Cresson 2020, S. IX).

Wie Abbildung 1 zeigt, ist *Künstliche Intelligenz*, spezifisch *Deep Learning*, fächerübergreifend hoch im Trend. Besonders in den letzten fünf Jahren wurden zahlreiche wissenschaftliche Beiträge publiziert, welche dies belegen. Vor allem die Verbreitung von *Convolutional Neural Networks* durch LeCun et al. (2015) trugen dazu bei.

**WEB OF SCIENCE PUBLIKATIONEN NACH JAHREN
STICHWORT „DEEP LEARNING“**

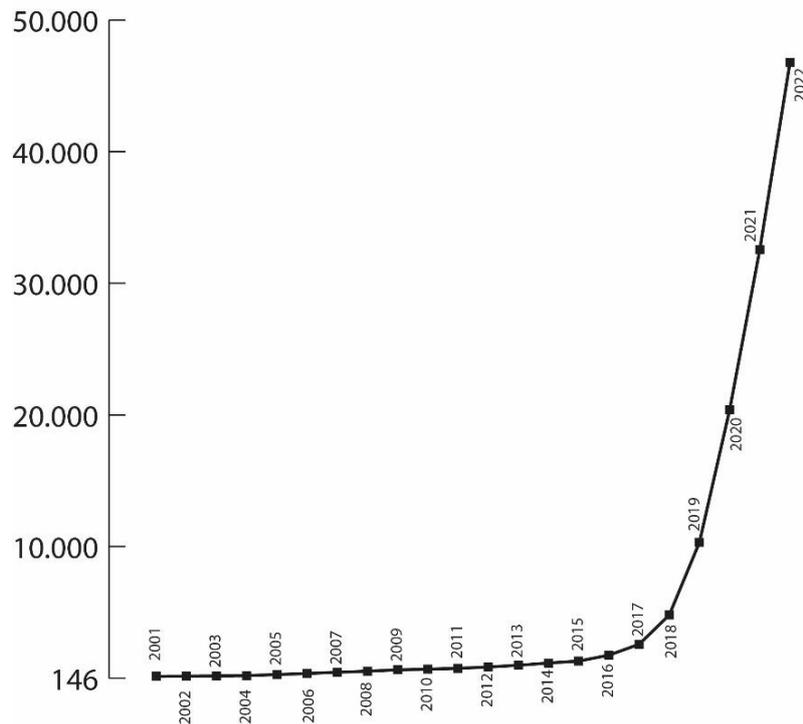


Abbildung 1: Anzahl der Publikationen unter dem Stichwort 'Deep Learning' auf Web of Science in den letzten 20 Jahren. Quelle: verändert nach Clarivate 2022.

In der Fernerkundung hat die Anwendung von *Deep Learning* vor allem auf die *Semantische Segmentierung* und *Objekterkennung* einen wichtigen Einfluss, da dadurch Veränderungen der Erdoberfläche – anhand von Satelliten- und Luftbildern – gut dargestellt werden können. Es gibt zahlreiche Anwendungsmöglichkeiten und Beispiele.

In der *Objekterkennung* spielt vor allem die Lokalisierung unterschiedlicher Objekte eine Rolle. Mahmoud et al. (2019) haben beispielsweise in der Anwendung künstlich neuronaler Netzwerke eine Möglichkeit gefunden, Objekte wie Flugzeuge, Schiffe, Sportplätze etc. zu identifizieren und zu lokalisieren. Lima et al. (2021) haben darin spezifisch ein Mittel gefunden, um illegale Swimmingpools in Portugal zu ermitteln und damit steuerrechtliche Grundlagen und Lizenzen zu überprüfen, welche das Finanzamt unterstützen. Patel et al. (2022) andererseits nutzen neuronale Netzwerke zur Überprüfung und Verortung des nautischen Verkehrs. Dies soll illegale Aktivitäten eindämmen und für Sicherheit und Kontrolle des Seeverkehrs sorgen. Li et al. (2018) nutzen *Deep Learning* für Verkehrsplanung im städtischen Gebiet und können mit der Methode der *Objekterkennung* Fahrzeuge lokalisieren. Die Methode der *Objekterkennung* mit *Deep Learning* eignet sich somit, um auf dynamische

und sich schnell ändernde Gegebenheiten, wie sich bewegende Objekte, zu reagieren, bei denen schnelle Handlungen erwünscht sind.

Semantische Segmentierungen eignen sich im Vergleich dazu, Landbedeckungsklassifikationen und Veränderungen der Erdoberfläche zu klassifizieren, welche weniger dynamisch sind. Besonders die Volksrepublik China hat seit 1980 große Fortschritte in der Spektroskopie und Anwendung hyperspektraler Daten gemacht, weshalb es nicht verwunderlich ist, dass ein Großteil dieser Literatur bzw. nennenswerte Autor:innen hier ihren Ursprung haben. Die Gründe für diesen rasanten Aufstieg sind vielfältig. Das Flächenausmaß des Landes an sich und die rasante wirtschaftliche Entwicklung des Landes und damit einhergehende Veränderungen der Umwelt sind jedoch wesentliche Faktoren, welche auch die Entwicklung der Fernerkundung im Bereich von *Deep Learning* begünstigten (vgl. Gong 2012, S. 2784f und Tong et al. 2014, S. 70).

Autor:innen wie Liang et al. (2020), Cheng et al. (2020), Ma et al. (2019), Yuan et al. (2020), Tong et al. (2020) und Wang et al. (2021) sind einige Beispiele für Publikationen zum Thema Landbedeckungsklassifikationen aus China. Khan et al. (2021) und Said et al. (2022) zeigen Beispiele aus Saudi-Arabien, wo neuronale Netzwerke unter anderem zur Überwachung von Desertifikation und Stadtplanung eingesetzt werden. Wurm et al. (2019) und Wurm et al. (2021) sehen darin eine Möglichkeit Baustrukturen zu erkennen und zu klassifizieren und informelle Strukturen aufzudecken. Ein Beispiel einer Landbedeckungsklassifikation in Europa liefert Pollatos et al. (2020). Darin werden griechische Inseln mit Copernicus Aufnahmen anhand der Corine Nomenklatur und *Deep Learning* klassifiziert.

Die Möglichkeiten von *Semantischen Segmentierungen* reichen von Landbedeckungsklassifikationen bis hin zu diversen thematischen Karten. Vortrainierte Modelle sind meist nicht universell einsetzbar bzw. mit Ungenauigkeiten verbunden, da geographische Unterschiede berücksichtigt gehören. Der Unterschied dieser wissenschaftlichen Arbeit zu genannten Werken liegt somit darin, eine Methode zur Landbedeckungsklassifikation spezifisch für Deutschland mit *Deep Learning* anhand von *Rapid Eye* Daten und dem bestehenden DLM-DE zu erstellen.

1.3 Methodik und verwendete Software

Die gewählte Methodik, um die Forschungsziele zu erreichen, kann in vier Hauptteile gegliedert werden. Die erste Aufgabe besteht darin, Trainingsgebiete für das *Deep Learning* Modell zu erstellen. Der zweite Schritt besteht darin, das Modell zu trainieren und gegebenenfalls auch zu programmieren, um auf spezifische Bedürfnisse eingehen zu können. Schritt Nummer drei ist es, das Modell in Form von Landbedeckungsklassifikationen anzuwenden. Der letzte Teil behandelt die Testung bzw. Evaluierung der resultierenden Klassifikationen. Die mittels *Deep Learning* entstehenden Klassifikationen werden dazu parallel mit in der Fernerkundung gebräuchlichen *Machine Learning* Algorithmen, hier *K-Nearest Neighbor* und *Random Forest* (Breiman 2001), verglichen. In Abbildung 2 sind die behandelten Themen nochmals dargestellt.

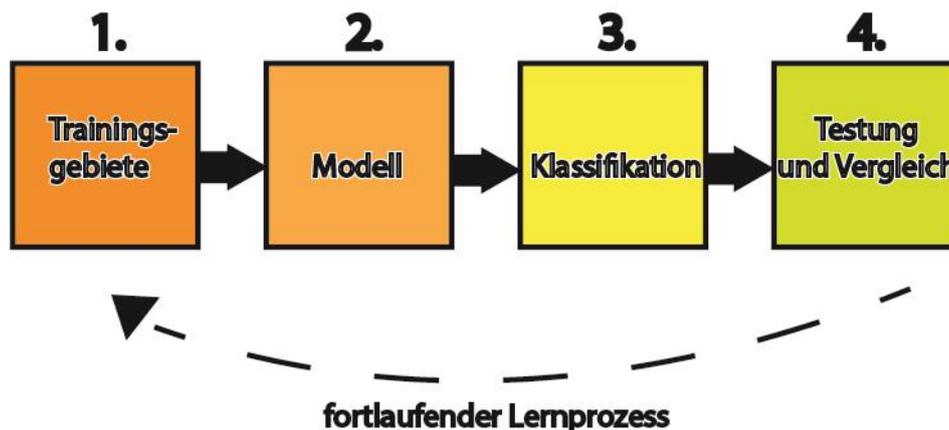


Abbildung 2: Schematische Darstellung des Ablaufs der Methodik. Quelle: eigene Darstellung.

Da neben dem Ergebnis auch die Anwendung in Geoinformationssystemen (GIS) im Vordergrund steht, wird die oben beschriebene Methodik parallel in zwei verschiedenen Softwarepaketen – *Arcgis Pro* und *eCognition* – prozessiert, welche sich in der Anwendung vor allem durch ihren pixelbasierten bzw. objektbasierten Klassifikationsansatz unterscheiden. Sowohl *Arcgis Pro* als auch *eCognition* bieten unter anderem *Deep Learning* Funktionen an und sind im Bereich der *Semantischen Segmentierung* sehr fortschrittlich. Generell ist *Deep Learning* in vergleichbaren GIS-Softwarepaketen, trotz einer breiten *Machine Learning* Integrierung, relativ ungeläufig. Zudem sind beide genannten Anbieter in der Fernerkundung

etabliert bzw. stark nachgefragt, sodass den Anwender:innen ein freier Zugang zu *Deep Learning* Instruktionen sichergestellt und auch vermittelt wird. Aus diesen Gründen eignen sich besonders die zwei genannten Softwarepakete, für den Vergleich dieser Untersuchung. Es ist zu berücksichtigen, dass es weitere kommerzielle Geoinformationssysteme gibt, welche *Deep Learning* implementieren, jedoch für die weitere Untersuchung nicht näher betrachtet werden (vgl. Cresson 2020, S. 8).

Arcgis Pro von *Esri* – hier Version 2.9 – ist womöglich die weitläufigste kommerzielle Software zur Verarbeitung von Geoinformationen. Diese kann vor allem durch eine Vielzahl an Tools in Bereichen der Kartographie, Bildklassifikation, Raster-/ Vektoranalyse, einer Online-Integration und intuitiven Editierung punkten (vgl. GISGeography 2022a). Die Veröffentlichung im Jahr 2015, sollte eine schrittweise Ablösung der veralteten *ArcMap* Software einleiten. Durch eine Python Implementierung wird ein flexibles Arbeiten ermöglicht. Visualisierungen und Analysen sind sowohl in 2D als auch 3D möglich (vgl. Esri 2022a). Besonders die Fähigkeit Bildklassifikationen durchzuführen, ist für diese Arbeit ausschlaggebend. Zur Auswahl stehen überwachte (= „*supervised*“) und unüberwachte (= „*unsupervised*“) Klassifikationen, die wiederum in objektbasierte und pixelbasierte Klassifikationen unterteilt werden. Die Form der pixelbasierten Klassifikation hat sich in der Anwendung bewährt, weshalb sich die fortführende Untersuchung in *Arcgis Pro* auf pixelbasierte Klassifikationen beschränkt. Zwar werden ebenso objektbasierte Klassifikation unterstützt, es stehen aber weniger Optionen zur Verfügung als in vergleichbaren Softwarepaketen (vgl. GISGeography 2022b).

Die von *Trimble* zur Verfügung gestellte Software, *eCognition Developer* – hier Version 10.2 – , kann durch langjährige Erfahrung im Bereich der objektbasierten Klassifikation überzeugen. Durch Nachahmung des menschlichen Verstandes wird versucht Semantik und Datenanalyse zu verbessern. Durch die Betrachtung des Kontextes und der Beziehungen der Objekte zueinander können Eigenschaften wie Textur, Farbe, Form und Größe zu einer Klassifikation im Raum herangezogen werden (vgl. Trimble 2022).

Beide Softwarepakete haben eine *Deep Learning* Anwendung implementiert, die zur jeweiligen Bildklassifikation herangezogen werden können. Die Möglichkeiten, die mit *Deep Learning* in Geoinformationssystemen einhergehen, sind vielfältig und werden von beiden

Anbietern gepriesen (Singh 2019). Die grundlegenden Ansätze sind dieselben, jedoch gibt es Unterschiede (siehe Tabelle 1), die in der Anwendung zu beachten sind.

Tabelle 1: Vergleich Softwareprogramme - Arcgis Pro und eCognition. Quelle: verändert nach Trimble (2022) und Esri (2022b).

	Arcgis Pro	eCognition Developer
Räumliche Domäne	pixelbasiert	objektbasiert
Dateninput	8bit	8bit oder 32bit
Framework	PyTorch, Keras, TensorFlow, CNTK	TensorFlow, Keras
Anzahl Bänder	max. 3	mehr als 3 möglich
Python Implementierung	Ja	Nein
Unterstütztes Format vortrainierter Modelle	.emd (=Esri model definition file) und .dlpk (=Deep- Learning-Modellpakete)	TensorFlow SavedModel

Die Software ist ein entscheidender Punkt. Sowohl in der Fernerkundung als auch in der *Deep Learning* bzw. Informatik Domäne. Die Anwendung ist vom jeweiligen Hintergrundwissen beider Bereiche geprägt. Eine Einführung neuer Prozesse und Algorithmen erfordert somit Einblicke in beide Domänen (vgl. Cresson 2020, S. 8f).

Zur Unterstützung der genannten Softwarepakete stehen unterschiedliche Programmier-Bibliotheken wie *Pytorch*, *Keras* oder *TensorFlow* zur Verfügung. Diese können extern oder intern genutzt werden und eine Verbesserung des Arbeitsprozesses nach sich bringen, da in diesen Systemroutinen enthalten sind, welche an die kompilierte Software angebunden werden können (vgl. Fischer u. Hofer 2011, S. 110).

Anzumerken ist noch, dass neben der verwendeten Software, die zur Verfügung stehende Hardware die Geschwindigkeit des Arbeitsprozesses mitbeeinflusst. Nicht ohne Grund ist die Entstehung und Entwicklung *Künstlicher Intelligenz* stark mit dem Fortschritt in der Technik verwoben. Große Datenmengen und wie in der Fernerkundung eingesetzte Bilder, mit mehreren tausend Pixeln, beanspruchen beim Bearbeiten viel Arbeitsspeicher. In dieser Arbeit werden beispielsweise Ausschnitte des Untersuchungsgebietes betrachtet, welche aus

mehreren Millionen von Pixeln bestehen. Leistungsstarke Hardware kann viel Zeit ersparen und ist deshalb neben Knowhow, Datenverfügbarkeit, Software und auch Zeitmanagement ein zu beachtender Faktor, der die Wirtschaftlichkeit und den Erfolg der Untersuchung beeinflussen kann. Diesbezüglich sind in Tabelle 2 die Eigenschaften der verwendeten Hardware aufgelistet. Da es sich hierbei nicht um eine High-End Hardware handelt, muss mit Leistungsbeeinträchtigungen gerechnet werden. Die damit erbrachten Ergebnisse sind somit auch relativ zu betrachten (vgl. Cresson 2020, S. 13f und Camps-Valls et al. 2021, S. 68).

Tabelle 2: Nennenswerte Eigenschaften der verwendeten Hardware. Quelle: eigene Darstellung.

Prozessor	AMD Ryzen 5 5600H-Prozessor (bis zu 4,20 GHz)
Arbeitsspeicher	16 GB
Graphics Processing Unit (GPU)	NVIDIA Geforce RTX 3060 – 6 GB

2 Grundlagen

Die *Semantische Segmentierung*, die Zuweisung einer Klasse zu einem Pixel, hat ihren Ursprung in der *Künstlichen Intelligenz* und im maschinellen Lernen bzw. in der Informatik, einer Wissenschaft, die sich vorwiegend mit der systematischen Verarbeitung und Speicherung von Informationen beschäftigt. Aufgrund dessen, dass Methoden der Fernerkundung an Methoden des maschinellen Lernens angeknüpft sind, ist es sinnvoll, zuerst *Künstliche Intelligenz* zu definieren und nachfolgend die Schnittstellen mit der Fernerkundung aufzuzeigen (vgl. Fischer u. Hofer 2011, S. 430 und TensorFlow 2022). Die Einsatzgebiete sind sehr vielfältig und umspannen nicht nur Fachgebiete der Geographie und Fernerkundung, sondern werden beispielsweise auch in der Zellforschung angewendet, um gesunde von beschädigten Zellen zu unterscheiden. Oftmals ist es so, dass ursprüngliche Fachbegriffe aus der Informatik genutzt und abgeändert werden. Umso wichtiger ist es, einen Überblick zu geben, was Klassifikationen in der Geographie bewirken und inwiefern eine Unterscheidung zwischen Kategorien der *Image Segmentation* wie *Object Detection*, *Semantic Segmentation*, *Image Classification* und *Instance Segmentation* (siehe Abbildung 3) nötig ist. Die Anwendung von *Deep Learning* zu Landbedeckungsklassifikationen hebt das interdisziplinäre Arbeiten zwischen Informatik und Geographie hervor (vgl. Esri 2022c).

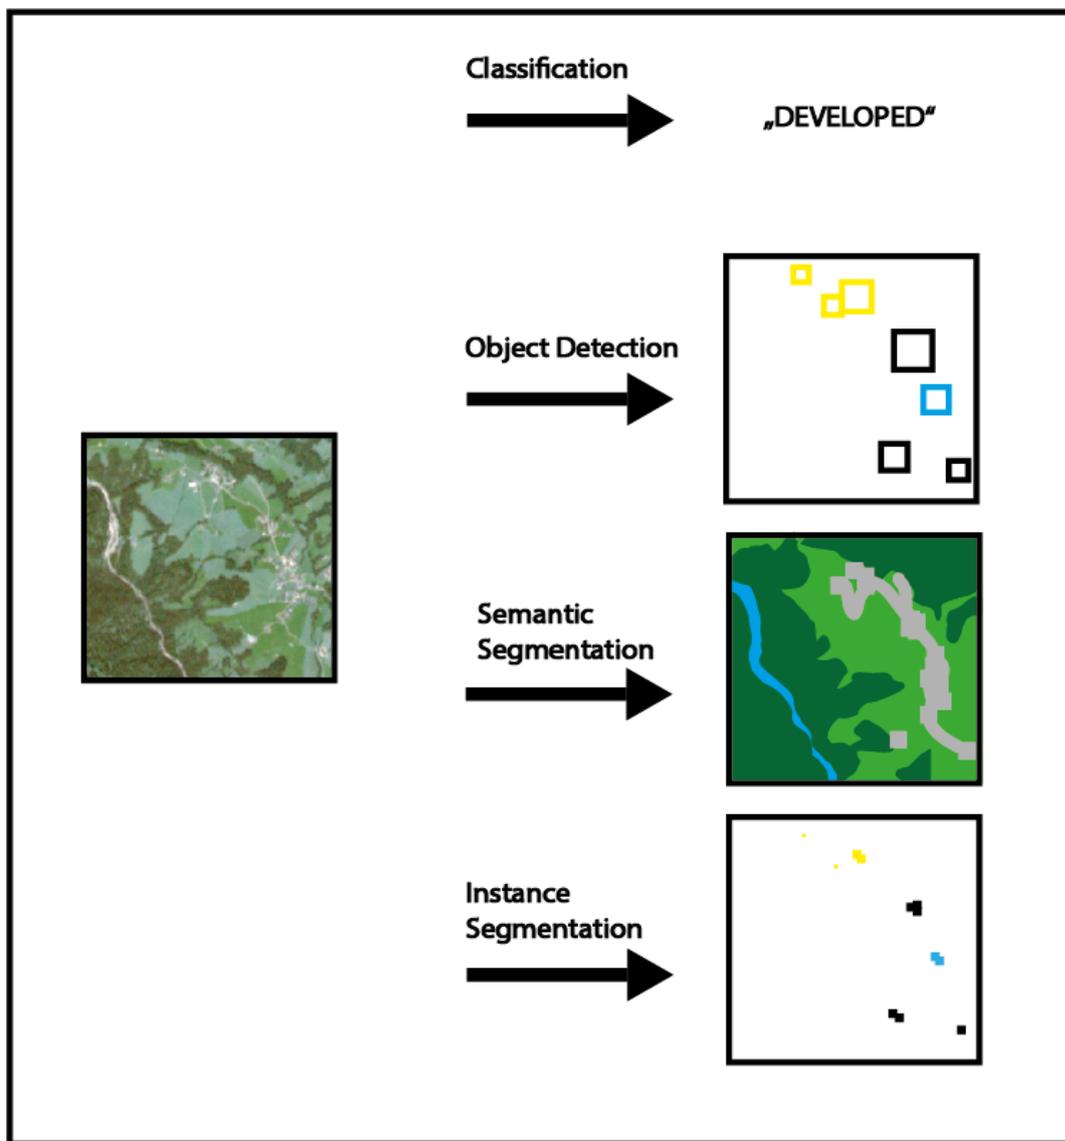


Abbildung 3: Klassifikation, Objekterkennung und Segmentierungen am Beispiel einer Rapid Eye Szene. Quelle: verändert nach Maxwell et al. 2021, S. 7.

Abbildung 3 zeigt somit möglichen Output, der mit Methoden der *Künstlichen Intelligenz* möglich ist. Der Output ist in jedem Fall von der Fragestellung abhängig. Die Formen des Outputs können dabei nach der simplen Etikettierung einer Szene mit einer Klasse — *Classification* —, der *Objekterkennung* und dem Hervorheben einzelner Objektklassen mit Polygonen — *Object Detection* —, dem farblichen Hervorheben der einzelnen Pixel einer *Objekterkennung* — *Instance Segmentation* — und der Klassifikation jedes einzelnen Pixels — *Semantic Segmentation* — variieren. Neben der Form des Outputs ist in der Informatik auch der Input entscheidend. Bei der unüberwachten bzw. überwachten Klassifikation (siehe

Abbildung 4) wird indirekt nach Grad der Automatisierung des Lernprozesses unterschieden, welcher wiederum von den Kenntnissen zum Untersuchungsgebiet abhängt. Mit einer überwachten Klassifikation ist gemeint, dass der Klassifikation zugrundeliegenden Algorithmen durch bekannte Trainingsgebiete ein Rahmen zur Orientierung der Klassenbildung gegeben wird. Mit der Wahl der Trainingsgebiete für jede einzelne Klasse besteht menschlicher Einfluss. Ein gewisses Grundwissen über das Untersuchungsgebiet ist notwendig. Die gesetzten Klassen sind von Anfang an bekannt und sind mit denen der Endklassifikation identisch. Bei einer unüberwachten Klassifikation wiederum, wird anhand iterativer Verfahren festgestellt wie viele Klassen aus den Daten extrahiert werden können. Es ist auch möglich die Anzahl der gebildeten Cluster selbst zu bestimmen und anschließend zu interpretieren. Allgemein ist kein besonderes Vorwissen zum Trainingsgebiet nötig. Oftmals handelt es sich bei unüberwachten Klassifikation um Vorläufer der eigentlichen Klassifikation. Menschlicher Einfluss ist somit auch hier ein potenzieller Faktor. Für die Aggregation der Klassen bzw. für die Clusterbildung gibt es mehrere methodische Ansätze. Durch statistische Kenngrößen und Distanzen zwischen den gebildeten Klassen können Zugehörigkeiten und Wahrscheinlichkeiten berechnet werden. Als Abschluss zu dieser Thematik lässt sich festhalten, dass gängige Klassifikationen, ob auf *Deep Learning* oder *Machine Learning* beruhend, einen überwachten Lernprozess durchlaufen (vgl. Albertz 2007, S. 158-162).

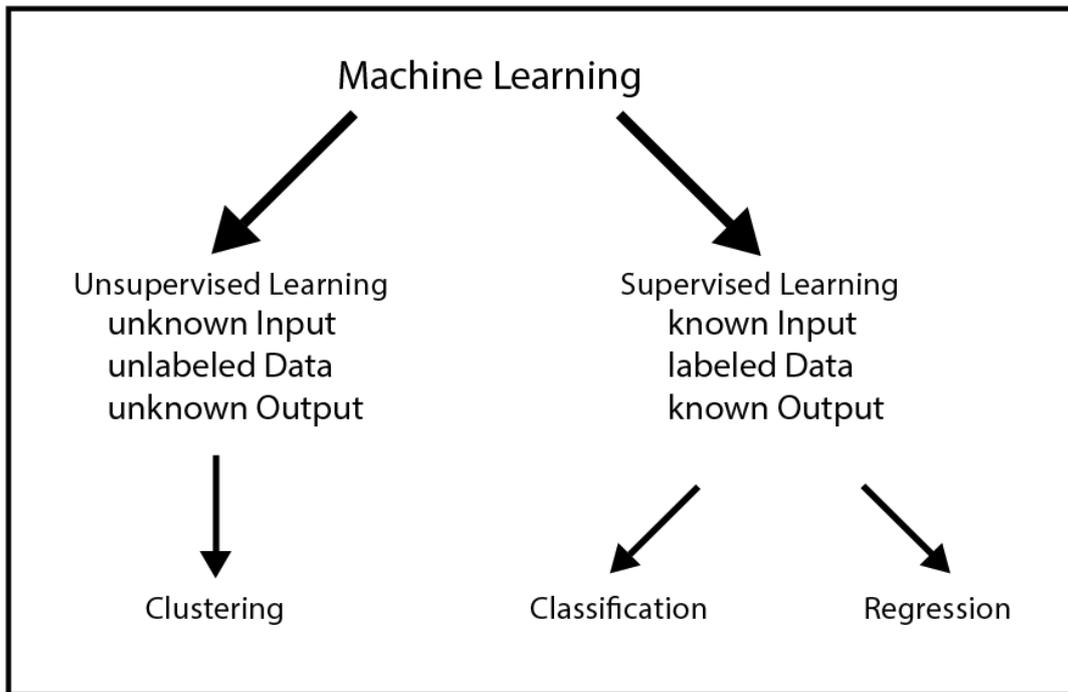


Abbildung 4: Unterteilung des maschinellen Lernprozesses in überwachtes und unüberwachtes Lernen. Quelle: verändert nach LeCun et al. 2015, S. 436-439 und Aery u. Ram 2017, S. 91.

2.1 Künstliche Intelligenz

In diesem Kapitel soll unter anderem beschrieben werden was *Künstliche Intelligenz* (KI) ist. KI ist ein Begriff, der im Jahr 1956 geprägt wurde. Gedanken zur *Künstlichen Intelligenz* gab es jedoch bereits viel früher und das aus mehreren Blickwinkeln. So war die griechische Philosophie bereits der erste Impuls, der sich mit Wissen und deren Ursprung beschäftigte. Als einer der Urväter der griechischen Philosophie zählt Platon (geb. 428 v.Chr.). Mathematik wurde angewendet, um die Fragen, welche aus dem philosophischen Denken hervorgingen, zu beantworten. Zahlen, Berechnungen, Wahrscheinlichkeiten, Algorithmik und Logik geben Aufschlüsse darüber, wie Informationen verarbeitet und Entscheidungen getroffen werden sollen (vgl. Russel u. Norvig 2003, S. 5-9).

Was Intelligenz ist, lässt sich auch nur auf einer philosophischen Ebene, welches am besten durch ein Zitat eines der renommiertesten Forscher in diesem Gebiet, R. J. Sternberg (geb. 1949), festgehalten werden kann.

„Intelligence is the cognitive ability of an individual to learn from experience, to reason well, to remember important information, and to cope with the demands of daily living“ (Sternberg, zitiert nach Campesato 2020, S. 2).

Im 19. Jahrhundert richteten Neurologie und Psychologie ihren Fokus auf die Funktionsweise des Gehirns und damit auch auf den Zusammenhang zwischen Reizen und der darauffolgenden Handlung, sprich dem Verhalten von Mensch und Tier. 1956 wurde der Grundstein für die moderne KI gelegt. Dieser wurde durch den Fortschritt in den Computerwissenschaften und John McCarthy (geb. 1927) geschaffen, dem es gelungen ist ein Programm zu schreiben, welches durch rationales Denken Probleme lösen und Entscheidungen fällen konnte, was bis dato exklusiv dem Menschen zugesprochen wurde. Intelligenz wird als Fähigkeit des Menschen definiert, rational zu denken und zu handeln. KI wiederum befasst sich mit künstlichen, intelligenten Agenten, die mithilfe von Input – in der Fernerkundung hauptsächlich Bilddaten aus der Umwelt – Entscheidungen treffen können (vgl. Russel u. Norvig 2003, S. 1-17).

Algorithmen und Lernprozesse sind auch für KI ausschlaggebend, um Entscheidungen zu treffen und Problemstellungen zu lösen. Was griechische Philosophen durch mathematische Prozesse und Algorithmik beantworten wollten, ist dem Lernprozess der KI sehr ähnlich.

„Algorithmen sind präzise Handlungsanweisungen, um Probleme, die innerhalb verschiedener Kontexte auftauchen, mit Hilfe allgemeiner Schemata zu lösen“ (Trogemann 2010, S. 159).

Wie sich die Lernprozesse in der KI unterscheiden, lässt sich am deutlichsten an der Unterscheidung zwischen *Machine Learning* (ML) und *Deep Learning* (DL) zeigen (siehe Abbildung 5). ML und DL als Subkategorien der KI beschreiben dabei die Kapazitäten der intelligenten Agenten problemspezifische Aufgaben durch autonomes Denken und Lernen zu lösen. Der Lernprozess besteht darin Trainingsdaten aufzunehmen, zu analysieren und schließlich anzuwenden. Diese Prozesse gehen nahezu autonom vonstatten, worin auch der größte Vorteil liegt. (vgl. Janiesch et al. 2021, S. 685ff).

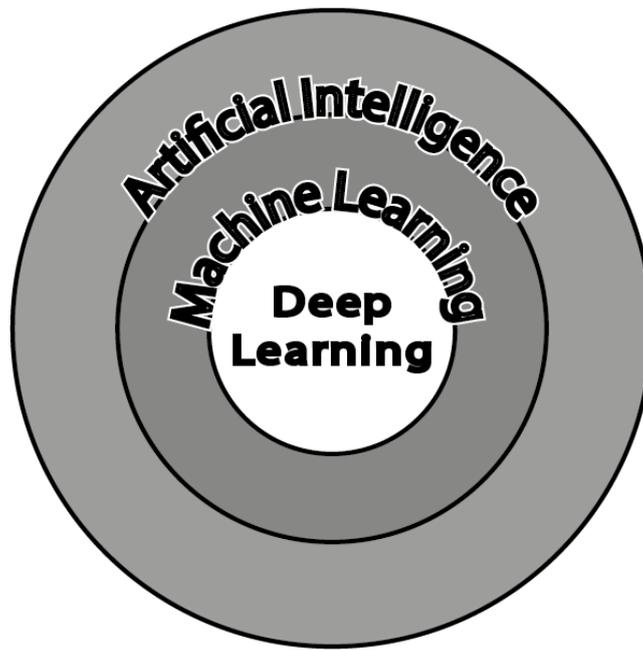


Abbildung 5: Künstliche Intelligenz und deren Formen. Machine Learning und Deep Learning sind Formen Künstlicher Intelligenz (engl. Artificial Intelligence), wobei DL eine Form von ML ist. Quelle: verändert nach Goodfellow et al. 2016, S. 9.

Charakteristisch für ML sind die bereits erwähnten Algorithmen. Zu diesen zählen z.B. *lineare Regression*, das *K-Nearest Neighbor*-, *Maximum Likelihood*-, *Minimum Distance*-, *Support Vector Machines Verfahren*, *Entscheidungsbäume* bzw. *Random Forest Verfahren*. Abbildung 6 zeigt eine Auswahl der genannten Methoden vereinfacht dar. Bei diesen Verfahren handelt es sich mit Ausnahme der *linearen Regression* um Klassifikationsverfahren. Der Input für die Berechnungen erfolgt aus einer Feature-Extraktion, welche extern durch die Wahl der Trainingsgebiete erfolgt. Spektral- und Texturwerte, Formen und zahlreiche andere Merkmale dienen als Mittel, Objekte durch unterschiedliche statistische Kenngrößen, Wahrscheinlichkeits- oder Distanzberechnungen einer Klasse zuzuordnen. Besonders *K-Nearest Neighbor*- und *Random Forest* Verfahren sind etablierte Mittel der Klassifikation, was die Entscheidung begründet, diese für den Vergleich heranzuziehen (vgl. Albertz 2007 S. 159f und Campesato 2020, S. 18f).

Folglich eine kurze Erklärung zu den Funktionsweisen dieser zwei Verfahren. *Random Forest* — die programmspezifische Bezeichnung in *eCognition* ist *Random Trees* — beschreibt eine Kombination aus Entscheidungsbäumen, welche mithilfe von Regeln Objektklassen abgrenzen bzw. bestimmen können. Das Wachstum der Bäume und deren Entscheidungsäste ergibt sich

durch zufällig generierte Vektoren, welche untereinander unabhängig sind, jedoch in jedem Entscheidungsbaum des *Random Forests* gleich verteilt sind. Die Klasse, die am häufigsten aus diesen Entscheidungsbäumen resultiert, wird für die Klassenzuweisung herangezogen (vgl. Breiman 2001, S. 5). Der *K-Nearest Neighbor* Algorithmus betrachtet eine ‚k‘-Anzahl an bekannten Nachbarn eines Pixels. Die Entscheidung zu welcher Klasse ein Pixel dazugehört, kann entweder auf Basis der Mehrheitsentscheidung oder der Distanz getroffen werden (vgl. Cunningham u. Delany 2007, S. 1f).

Konventionelle Machine Learning Klassifikationsverfahren

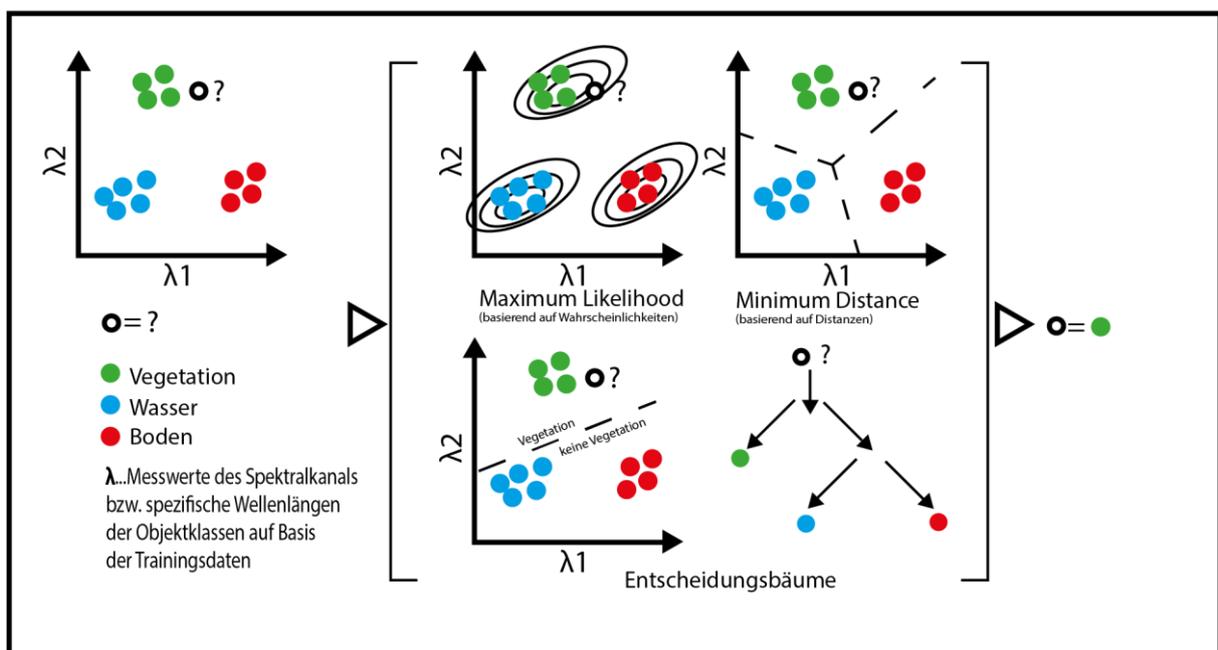


Abbildung 6: Darstellung von konventionellen Machine Learning Klassifikationsverfahren. Quelle: verändert nach Albertz 2007, S. 159ff.

Die Charakteristik von ML besteht in der Anwendung von Algorithmik, um Strukturen und Objekte zu erkennen. Die Rechenwege sind bekannt, sodass der Werdegang des Inputs zum Output nachvollziehbar ist. Aus diesem Grund spricht man bei ML-Prozessen basierend auf Algorithmik und ohne Vorhandensein neuronaler Netzwerke (siehe Abbildung 6) von *Shallow Learning* (SL) Prozessen. Dabei handelt es sich um das Pendant zu DL, und beschreibt ‚seichte‘ Prozesse, welche sich zur Lösung einfacherer Aufgabenstellungen eignen. Diese Begrifflichkeit eignet sich besser zur Differenzierung, da DL eine Subkategorie von ML ist. *Artificial Neural Networks* (ANN) sind als eine Weiterentwicklung von ML anzusehen, welchen es möglich ist,

auch komplexere Aufgabenstellungen zu lösen, indem biologische neuronale Netzwerke imitiert werden. Dadurch lassen sich auch komplexere, nicht lineare Aufgabenstellungen lösen (vgl. Janiesch et al. 2021, S. 685ff).

Grundsätzlich spricht man erst von DL, wenn *Hidden Layer* – das Vorhandensein neuronaler Knoten –, zusätzlich zu Input- und Output Layer verwendet werden. Sprich wenn ein mehrschichtiges, tiefes Lernen erfolgen kann. Die genaue Grenze zwischen den Bezeichnungen SL und DL ist jedoch nicht standardisiert. In Abbildung 7 ist ein solches neuronales Netzwerk mit zwei *Hidden Layer* vereinfacht dargestellt. In dieser Arbeit wird angenommen, dass DL ab der Verwendung von zwei *Hidden Layer* repräsentiert wird. In diesen befinden sich die Kernelemente des neuronalen Netzwerkes, die Neuronen. In den Neuronen sind Gewichtungswerte und systematische Fehlerwerte vordefiniert, welche als Parameter einer Aktivierungsfunktion dienen. Bei dieser Aktivierungsfunktion handelt es sich um nicht-lineare Funktionen (z.B. *Relu, Sigmoid, Tanh etc.*). Generell lassen sich mit nicht-linearen Funktionen komplexere Aufgabestellungen lösen als mit linearen Funktionen, welche durch ihre Linearität beschränkt werden. Nichtsdestotrotz wird die Funktionsweise des Neurons und der Aktivierungsfunktion in Abbildung 7 anhand einer der linearen Regression ähnlichen Funktion beschrieben. Überschreitet das Ergebnis der verwendeten Aktivierungsfunktion einen definierten Schwellenwert, erfolgt ein Output bzw. Input an die Neuronen im nächsten Layer (vgl. Kavlakoglu 2020 und Janiesch et al. 2021, S. 685ff). Neben der Aktivierungsfunktion ist auch die Anzahl an *Hidden Layer* ein entscheidender Faktor. Je mehr Features aus dem Input für das Training des Modells extrahiert werden können, umso sinnhafter ist es, die Zahl der *Hidden Layer* zu erhöhen. Im ersten Layer werden vor allem Kanten, deren Orientierung und Lage ermittelt. Die folgenden Layer ermitteln des Weiteren die vorkommenden Anordnungen der Kanten und versuchen diese schrittweise zu gruppieren und deren Zusammenhänge zu erkennen. Somit wird der Output des Modells mit jedem zusätzlichen *Hidden Layer* abstrakter und schwieriger nachzuvollziehen, jedoch eignet sich das Modell zur Lösung komplexerer Aufgabenstellungen (vgl. LeCun 2015, S. 436).

Deep Learning mit neuronalen Netzwerken

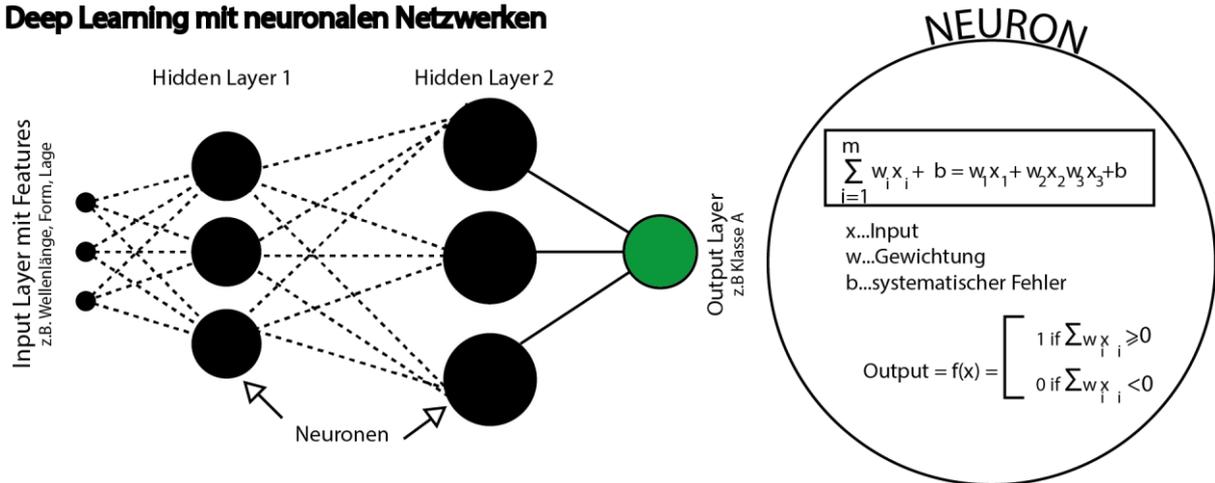


Abbildung 7: Darstellung der Deep Learning Funktionsweise. Quelle: verändert nach Dastres u. Soori 2021, S. 14f und Kavlakoglu 2020.

Ebenso gibt es in der *Deep Learning* Anwendung mehrere Architekturen. Diese beschreiben in welcher Art und Weise das Modell aufgebaut ist, auf welchen Input es reagiert und wie es funktioniert. Diese wurden entwickelt, um für spezifische Datensätze den besten Erfolg zu garantieren, da je nach Aufgabenstellung, auch das Training des Modells optimiert werden muss. Zu solchen Architekturen zählen beispielsweise *U-Net*, *Residualnetzwerke* (Resnet), *Fast Region-based Convolutional Networks* (Fast R-CNN) oder *„You Only Look Once“* (YOLO). Alle basieren auf dem traditionellen Gedanken mehrschichtiger neuronaler Netzwerke (vgl. LeCun et al. 2015).

Zusammenfassend zur KI lässt sich festhalten, dass sowohl DL- als auch ML-Algorithmen durch autonomes Denken und Entscheiden Landbedeckungsklassifikationen durchführen können. Während SL-Algorithmen auf menschliche Anweisungen angewiesen sind – Merkmals-Extrahierung –, um möglichst präzise zu arbeiten, gelingt es jenen basierend auf neuronalen Netzwerken, den Input selbst zu gewichten und zu analysieren. Dadurch können in der Big-Data-Analyse Fortschritte erzielt werden. Jedoch gibt es auch nennenswerte Vor- und Nachteile zwischen ML und DL, welche in Tabelle 3 aufgelistet sind.

Tabelle 3: Gegenüberstellung von Machine Learning und Deep Learning. Quelle: verändert nach Microsoft 2022.

Machine Learning	Deep Learning
Benötigt wenig Daten	Benötigt viele Daten
Relative Unabhängigkeit von high-end Hardware und Rechenleistung	Abhängigkeit von high-End Hardware und Rechenleistung
Genaue Merkmals-Extrahierung durch Anwender:innen nötig	Autonomes extrahieren und Lernen der Merkmale
Geringer Zeitaufwand	Hoher Zeitaufwand
Nur numerischer Output	Output vielfältiger
Beschränkte Lernkapazitäten	Höhere Lernkapazitäten

2.2 Klassifikationen in der Fernerkundung

Die Klassifikation in der Fernerkundung ist eine von vielen Methoden der Auswertung, um Informationen aus Luft- und Satellitenbildern abzuleiten. Diese können zur Bestimmung geometrischer Größen oder sogar zur Untersuchung vielfältiger wirtschaftlicher und gesellschaftlicher Beziehungen zur Erdoberfläche herangezogen werden. Die drei Hauptschritte der Auswertung von Geoinformationen sind visuelle Interpretation, photogrammetrische Auswertung und digitale Bildauswertung, wobei visuelle Interpretation und Wahrnehmung hervorzuheben sind, da sie das menschliche Pendant zur Verwendung von KI bilden. Allein beim Erkennen von Strukturen und Objekten, als auch bei der Interpretation, kann es zu subjektiven Einflüssen kommen, welche die Ergebnisse der Forschung mitbeeinflussen. Diese Subjektivität ist den unterschiedlichen Erfahrungen und regionalen Kenntnissen zuzuschreiben, wie Personen die Umwelt auf Luft- und Satellitenbildern erkennen. Visuelle Reize werden unter gegebenen Umständen jedoch gleich aufgenommen. Von der Reizaufnahme ausgehend durchläuft das menschliche Gehirn in wenigen Millisekunden mehrere Phasen, bis schließlich die wahrgenommenen Informationen verarbeitet werden. Unterschiedliche Farben, Kontraste, Helligkeiten und vor allem Texturen, komplexe Muster und Strukturen können vom menschlichen Gehirn herangezogen werden, um flächenhafte bzw. räumliche Gliederungen durchzuführen. Das menschliche Gehirn ist somit auch in der Lage äußerst diverse Flächen im Detail zu erkennen und zu unterscheiden. Nichtsdestotrotz müssen Entscheidungen getroffen werden, die dem menschlichen Gehirn

schwerfallen. Sei es durch minimale Erscheinungsunterschiede, welche für das menschliche Auge schwer bzw. nicht zu erfassen sind, oder durch Unsicherheiten und Unstimmigkeiten in der Definition und Kategorisierung der Objekte. Intelligente Agenten können solche Entscheidungen abnehmen und objektiv treffen (vgl. Albertz 2007, S. 121-141).

Eine Bildinterpretation kann auf kein bestimmtes Regelwerk festgelegt werden. Es ist jedoch ratsam systematisch vorzugehen. Grundsätzlich geht man vom Großen ins Kleine bzw. von einer Vor- in eine Detailinterpretation. Dabei können mehrere Interpretationsstufen eines Interpretationsschlüssel durchlaufen werden, was wiederum vom Anwendungsziel abhängig ist (vgl. ebd., S. 139-141).

Das Auswertverfahren durch den Menschen und seine kognitiven Leistungen ist jedoch je nach erstrebenswertem Resultat mühselig und zeitraubend. Deswegen werden digitale Bildauswertungen, auch maschinelles Sehen, zur Hilfe herangezogen, um Bildinhalte möglichst automatisiert und objektiv in unterschiedlichsten Computerverfahren zu identifizieren. Wie dies funktioniert wurde bereits im vorangegangenen Kapitel im Detail erklärt. Die Stärken der *Künstlichen Intelligenz* liegen darin, dass Grauwerte präzise analysiert werden können. Hier kommen der Klassifikation vor allem die Reflexionseigenschaften bzw. die spezifischen Spektralsignaturen der Objekte und deren Oberflächen zugute, welche in der Fernerkundung für jedes einzelne Pixel durch multispektrale Sensoren ermittelt werden können. Abbildung 8 zeigt beispielsweise die spezifischen Spektralsignaturen von Boden, Vegetation und Wasser. Wellenlänge, Reflexionsgrad und Objektflächen stehen in direktem Zusammenhang zueinander. Die Messwerte können dreidimensional wiedergegeben werden. Jede Objektklasse zeigt dabei Unterschiede in den Spektralbereichen. Diese können unterschiedlich stark ausgeprägt sein. Nichtsdestotrotz ist es möglich anhand der spektralen Merkmale Zuweisungen zu generieren, welche bildhaft in Form thematischer Karten wiedergegeben werden (vgl. ebd., S. 154ff).

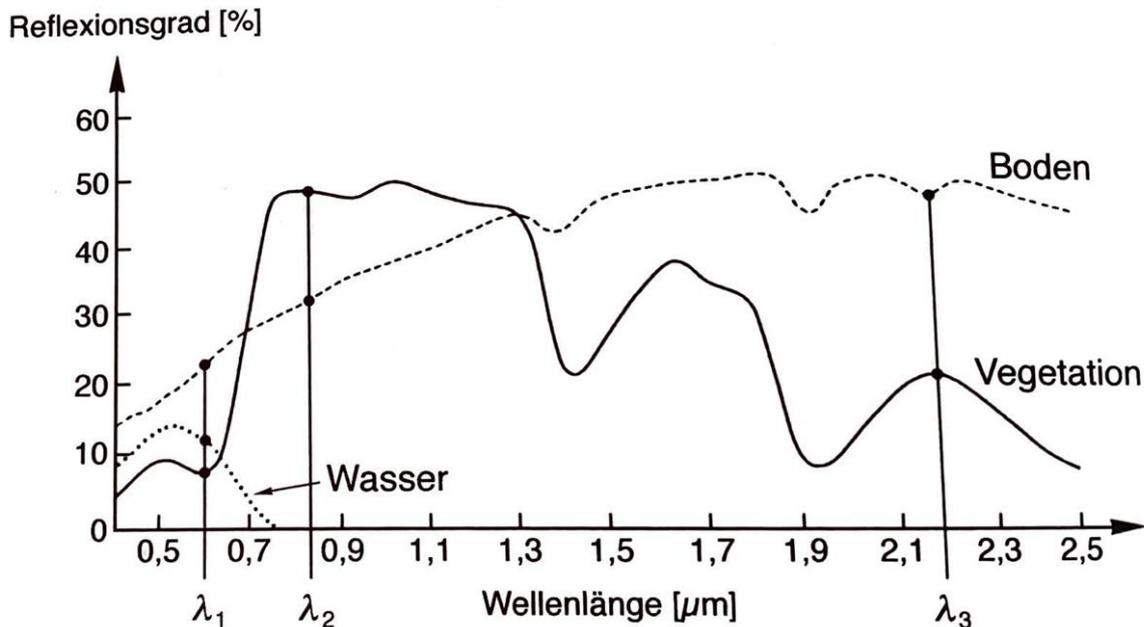


Abbildung 8: Spezifische Spektralsignaturen der Klassen Wasser, Vegetation und Boden. Quelle: Albertz 2007, S. 156.

Des Weiteren wird in der Fernerkundung zwischen überwachten und unüberwachten (siehe Abbildung 4), pixelbasierten und objektbasierten Klassifikationen unterschieden. Diese Klassifikationen erfolgen durch charakteristische Merkmale, die ein Bildelement aufweist. Die Klassen – in diesem Fall denen des DLM-DE gleichgesetzt – weisen unterschiedliche Reflexionseigenschaften auf, die im besten Fall klar abgegrenzt werden können (vgl. Albertz 2007, S. 158-162).

Weiters stehen für die Klassifikation von Satellitendaten zwei verschiedene Ansätze zur Verfügung. Die pixelbasierte Klassifikation entstand in den 1970er Jahren als Antwort auf die zahlreichen im Umlauf befindenen Satellitensysteme und dem damit einhergehenden übermäßigen Datengewinn. Nach weiterem Fortschritt in der Fernerkundung wurden neue Systeme entwickelt, die mit höheren Auflösungen konfrontiert wurden (vgl. Blaschke 2010, S. 2).

Bei einer pixelbasierten Klassifikation, auch *Semantische Segmentierung* oder *Image Segmentation* (siehe Abbildung 3), werden die Pixel als kleinste Bildelemente isoliert verglichen und gekennzeichnet. Diese Betrachtung greift auf die unterschiedlichen Grauwerte und Spektralwerte jedes einzelnen Pixels zurück. Eine pixelbasierte Klassifikation ist im Informatik Kontext als *Segmentierung* einzustufen (vgl. Salehi et al. 2012, S. 2263).

Im Gegensatz dazu werden bei den verwendeten objektbasierten Klassifikationen die Nachbarschaften der Pixel berücksichtigt und Objektgruppen bzw. Segmente gebildet. Die *Segmentierung* kann auf Basis unterschiedlicher Homogenitätskriterien – räumliche und spektrale Eigenschaften – stattfinden und verläuft nach dem Prinzip, dass benachbarte Pixel mit hoher Wahrscheinlichkeit der gleichen Klasse angehören. Ein Algorithmus untersucht dabei, welche dieser Nachbarn zusammengehören (vgl. Koch et al. 2003, S. 197 und Turner et al. 2021, S. 52f). Während eine *Segmentierung* im geographischen Kontext die Objektgruppierung mehrerer Pixel bezeichnet, handelt es sich im informatischen Kontext um die Zuweisung aller Pixel zu einem Merkmal und beschreibt somit die Klassifikation im geografischen Kontext. Der Begriff der Bildklassifikation wird in der Informatik verwendet, um das Bild als Gesamtes zu bestimmen. Klassifikationen in der Fernerkundung sind somit stets *Image Segmentations* (vgl. Wu et al. 2019, S. 584).

Beide Klassifikationsverfahren weisen Vor- und Nachteile auf, welche hier kurz erläutert werden, da beide auch für den weiteren Untersuchungsprozess relevant sind. Unterschiedliche Klassifikationsverfahren erzielen unterschiedliche Ergebnisse und das gehört berücksichtigt. Besonders die objektbasierte Bildanalyse zeichnet sich durch eine der menschlichen Wahrnehmung ähnlichen homogenen Objektgruppierung aus. Aufgrund der hohen Auflösungen, die aktuelle Satellitensysteme erreichen können, ist auch unter denselben Klassen ein hoher Grad an Heterogenität möglich. Eine Objektgruppierung ermöglicht es durch eine Homogenisierung, sich nicht im Detail zu verlieren und bringt andererseits auch einen höheren Grad der Generalisierung mit sich, was im höheren Ausmaß mit Informationsverlust gleichzusetzen ist. Die pixelbasierte Klassifikation wiederum ist von Vorteil, um erwähnte Generalisierungen zu minimieren. Aufgrund dessen, dass dieses Verfahren auf Basis der einzelnen Pixel funktioniert, ist das Erscheinungsbild der Klassifikation viel heterogener, was sich auch in der körnigen Textur zeigt (vgl. Koch et al. 2003, S. 195).

Es zeigt sich, dass die Klassifikation in der Fernerkundung eng mit der Anwendung von KI verwoben ist. Wie das in die Praxis umgesetzt wird, wird in den folgenden Kapiteln thematisiert. Die Datengrundlage ist jedoch noch ein ausschlaggebendes Element, ohne das eine KI nicht lernfähig ist und somit auch keine Klassifikation durchgeführt werden kann. Darum beschäftigt sich das nächste Unterkapitel mit den verwendeten Daten.

2.3 Rapid Eye Satellitenaufnahmen

Wie bereits im Forschungsstand erläutert, sind Satellitenaufnahmen unerlässlich, um globalen Wandel und Veränderungen der Erdoberfläche in kurzer Zeit zu dokumentieren. Die Rohdaten müssen jedoch verarbeitet werden, um beispielsweise als thematische Karte eine Aussagekraft zu erhalten. Deshalb liegt das Hauptaugenmerk dieses Unterkapitels darauf, die verwendeten Daten genauer zu beschreiben. Dadurch soll verständlich gemacht werden, was in der Fernerkundung und besonders im Klassifikationsverfahren durch geeignete Satellitenaufnahmen möglich ist. Die Form, in der die Ausgangsdaten vorliegen, beeinflusst die Art und den Aufwand der Vorprozessierung und somit auch die Ergebnisse. Zudem ist es für den *Deep Learning* Algorithmus grundlegend, Trainingsgebiete zu generieren, anhand derer das Modell lernt, die Landbedeckung zu klassifizieren. Dabei wird auf bestehende Landbedeckungsmodelle des BKG zurückgegriffen. Ein grundlegendes Verständnis der Referenzdatei ist nicht nur wichtig, um das Ergebnis zu interpretieren, sondern unterstützt zudem den Prozess der Klassifikation.

Die in dieser Arbeit verwendeten Satellitenaufnahmen entstammen dem *Rapid Eye* Erdbeobachtungssatellitensystem. Dieses wurde am 29. August 2008 in Baikonur, Kasachstan, für eine nominelle Betriebszeit von sieben Jahren gestartet. Die Inbetriebnahme sollte die Datenverfügbarkeit an hochauflösende Fernerkundungsdaten für kommerzielle Zwecke verbessern. Thematische Karten für unterschiedliche Anwendungen basieren auf solchen Satellitenbildern. Die Vielseitigkeit spiegelt sich auch darin wider, dass das *Rapid Eye* Projekt sowohl von staatlichen als auch privaten Akteuren finanziert wurde. Auch wenn das System am 28. März 2020 deaktiviert wurde, wird weiterhin ein Zugang zu Archivdaten zur Verfügung gestellt. *Rapid Eye* Produkte werden in verschiedenen Levels angeboten, welche unterschiedlichen Verarbeitungsstufen – Bildkorrekturen und Orthorektifizierungen – entsprechen (vgl. DLR 2022 und ESA 2022).

Abbildung 9 soll das *Rapid Eye*-System und deren Funktionsweise darstellen. Das Satellitensystem besteht aus fünf Satelliten, welche komplett identisch sind. Die Satellitenmassen betragen jeweils 150kg. Die Größe eines Satelliten entspricht einem 1-Kubikmeter Würfel. Die Orbitalebene der fünf Satelliten sind ebenso identisch und aufeinander abgestimmt. Diese sind sonnensynchron und haben eine Orbitalhöhe von 630

km. Die Inklination des Orbits, sprich die Neigung der Orbitalebene zum Äquator der Erde, beträgt $97,9^\circ$ (vgl. ESA 2022).

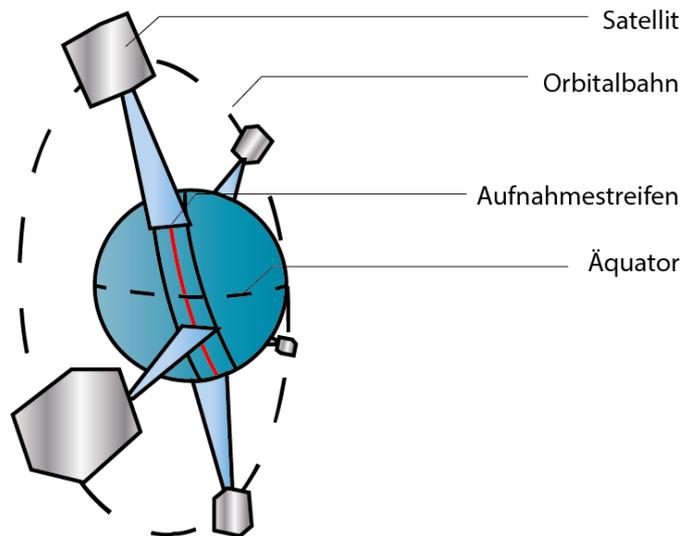


Abbildung 9: Rapid Eye Satellitensystem. Quelle: verändert nach DLR, 2022.

Mit *Rapid Eye* Satelliten können Streifen mit einer Breite von 77 km aufgenommen werden. Die Szenenlänge eines Satelliten kann bis zu 1.500 km betragen, wobei die Begrenzung auf den integrierten Datenspeicher zurückzuführen ist. Aufgrund dessen, dass der Massenspeicher begrenzt ist, erfolgt falls nötig ein Austausch mit einer Bilddaten-Empfangsstation in Svalbard, Norwegen. Pro Tag können so 5 Mio. Quadratkilometer der Erdoberfläche erfasst werden. Die in dieser Arbeit verwendeten Szenen liegen als Kacheln mit einer Kantenlänge von 25 km vor. Gemeinsam mit der hohen zeitlichen Wiederholungsrate, lassen sich große Teile und Veränderungen der Erdoberfläche festhalten, was in der modernen Fernerkundung einen besonderen Stellenwert hat (vgl. Planet Labs 2016, S. 6f). In Abbildung 10 ist die Abdeckung eines Ausschnittes der Bundesrepublik Deutschland durch das Satellitensystem im Jahr 2015 dargestellt, welche für die Untersuchung herangezogen wird. Es handelt sich dabei um Bayern, das flächengrößte Bundesland Deutschlands.

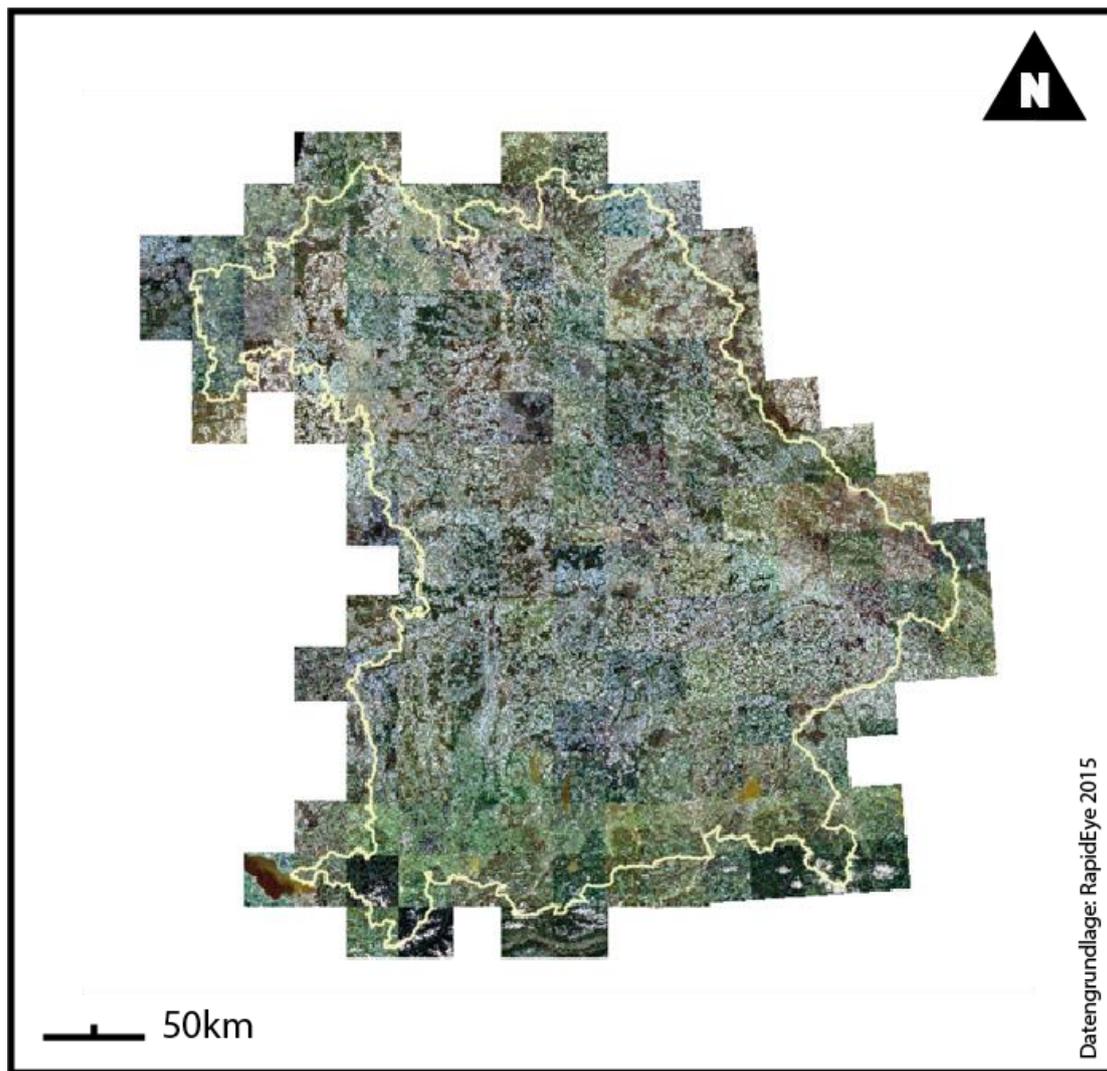


Abbildung 10: Rapid Eye Aufnahmen aus dem Jahr 2015. Dargestellt wird das Bundesland Bayern. Quelle: eigene Darstellung; Datengrundlage: Rapid Eye Level-3A.

Nadir-Aufnahmen – Aufnahmen eines Geländepunktes lotrecht zum Aufnahmesystem – von ein und demselben Gebiet sind alle fünfzehn Tage möglich, wobei Off-Nadir-Aufnahmen täglich möglich sind. Die *Rapid Eye* Satellitenkonstellation überquert den Äquator täglich um ungefähr 11 Uhr vormittags der Lokalzeit. Das bedeutet keineswegs, dass das Satellitensystem statisch ist. Es kann auf beliebige Punkte der Erdoberfläche ausgerichtet werden. So kann beispielsweise auch auf Kundenwünsche eingegangen werden, was zur Folge hat, dass einige Gebiete häufiger aufgenommen werden als andere. Die Datenverfügbarkeit unterschiedlicher Gebiete kann durchaus variieren. An diesem Punkt lässt sich zudem festhalten, dass die verwendeten Bilddaten, aufgrund der unterschiedlichen Aufnahmezeiten, unterschiedliche Lichtverhältnisse aufweisen können, was unter anderem auch in Abbildung 10 ersichtlich ist (vgl. DLR 2022).

Die *Rapid Eye* Satelliten sind mit optischen Kameras des Modells *Jena-Optronik Spaceborne Scanner-56* ausgestattet, dessen Sensoren Aufnahmen im multispektralen Bereich ermöglichen. Die spektrale Auflösung setzt sich aus fünf Bändern zusammen, welche die in Tabelle 4 angeführten Wellenbereiche abdecken (vgl. Planet Labs 2016, S. 6).

Tabelle 4: Bänder und Spektralbereiche Rapid Eye-Sensor. Quelle: verändert nach Planet Labs 2016, S. 6.

Bandbezeichnung	Spektralbereich (nm)
Blau	440 – 510
Grün	520 – 590
Rot	630 – 685
Red Edge	690 – 730
Nahinfrarot (NIR)	760 – 850

Neben dem spektralen Aufnahmebereich des Sensors gibt es weitere Kennwerte, die für Klassifikationen mit Satellitenbildern berücksichtigt werden müssen. Die geometrische Auflösung beträgt 6,5 m, wobei diese durch eine Orthorektifizierung auf 5 m gesampelt wird. Durch diese hohe räumliche Auflösung ist es möglich detailreiche thematische Karten zu erstellen. Den Kamerasensoren ist es möglich 4.096 Graustufen (12bit) aufzunehmen, wodurch die Daten meist im 16bit Format vorliegen. Dadurch ist es möglich die Heterogenität der Szenen ausreichend wiederzugeben. Wie bereits in Kapitel 2.1 beschrieben, sind spektrale Merkmale für digitale Auswertungen unerlässlich (vgl. ebd.).

2.4 Digitales Landbedeckungsmodell Deutschland

Das DLM-DE gibt die topographische Realität Deutschlands generalisiert in Vektorformat wieder, wobei die Aspekte der Landbedeckung und Landnutzung aufgegriffen werden. Eine hohe räumliche als auch zeitliche Auflösung der Geoinformationen, hier Landnutzung und Landbedeckung, sollen das Land-Monitoring allgemein verbessern, weshalb eine Weiterentwicklung der Klassifikationsprozesse stets im Vordergrund steht. Durch bestehende Erfahrungen, die mit vergangenen Klassifikationen einhergehen, kann bereits der Aufwand reduziert und Zeit gespart werden (vgl. Arnold 2012, S. 56f und Bundesamt für Kartographie und Geodäsie 2018, S. 5).

Das bestehende Landbedeckungsmodell basiert auf Vektordaten der Landesvermessung, auch ATKIS genannt, welche fortlaufend aktualisiert werden. Dieser Geodatenatz beinhaltet Geoinformationen zu unterschiedlichsten Sektoren wie Umwelt, Land- und Forstwirtschaft, Gewässerschutz und sonstigen raumplanerischen Tätigkeiten. Die Stärken des Landbedeckungsmodells liegen somit in der Organisation und in der Übersichtlichkeit verschiedenster Themen und Aufgabenstellungen. Das bereits vorgestellte *Rapid Eye* Satellitensystem und dessen Aufnahmen werden aktuell zur Überprüfung und Korrektur des Ausgangsdatensatzes verwendet. Aufgrund des vorhandenen Wissens zur Landbedeckung ist es plausibel, darauf neue Methoden aufzubauen und *Rapid Eye* Daten bzw. generell Bilddaten mehr in autonome Herangehensweisen zu berücksichtigen. Eine Klassifikation kann mithilfe von neuronalen Netzwerken und bestehenden Trainingsgebieten bzw. einem Wissenstransfer auf menschliche Interaktionen verzichten. Als Trainingsgebiete und Referenz dienen die flächenhaften Objektarten, die für ganz Deutschland vorhanden sind. Dabei handelt es sich deutschlandweit um einige Millionen Polygonflächen, welche in 7 Hauptklassen und 31 Subklassen der Landbedeckung eingeteilt sind. Für Bayern (siehe Abbildung 11) entspricht das 1,38 Mio. aufgenommenen Polygonen, welche auf 7 Hauptklassen (LBM2) und 26 Subklassen (LBM1) (siehe Tabelle 5) aufgeteilt sind. In dieser Arbeit werden diese des Weiteren als LBM1 und LBM2 bezeichnet. Es ist offensichtlich, dass Klassen fehlen, da ein Bundesland im Landesinneren beispielsweise keinen Meerzugang hat und somit auch nicht alle Klassen innehaben kann. Geographische Gegebenheiten variieren auch innerhalb der Landesgrenzen. Bei der Wahl der Trainingsdaten ist zu berücksichtigen, dass alle vorkommenden Klassen inkludiert sind. Beim Zielgebiet selbst kann nur unter gegebenen Bedingungen ausgegangen werden, dass alle Klassen enthalten sind. In der Praxis funktioniert das Modell auch, wenn nicht alle trainierten Klassen im Zielgebiet vorkommen (vgl. Hovenbitzer et al. 2015, S. 146f).

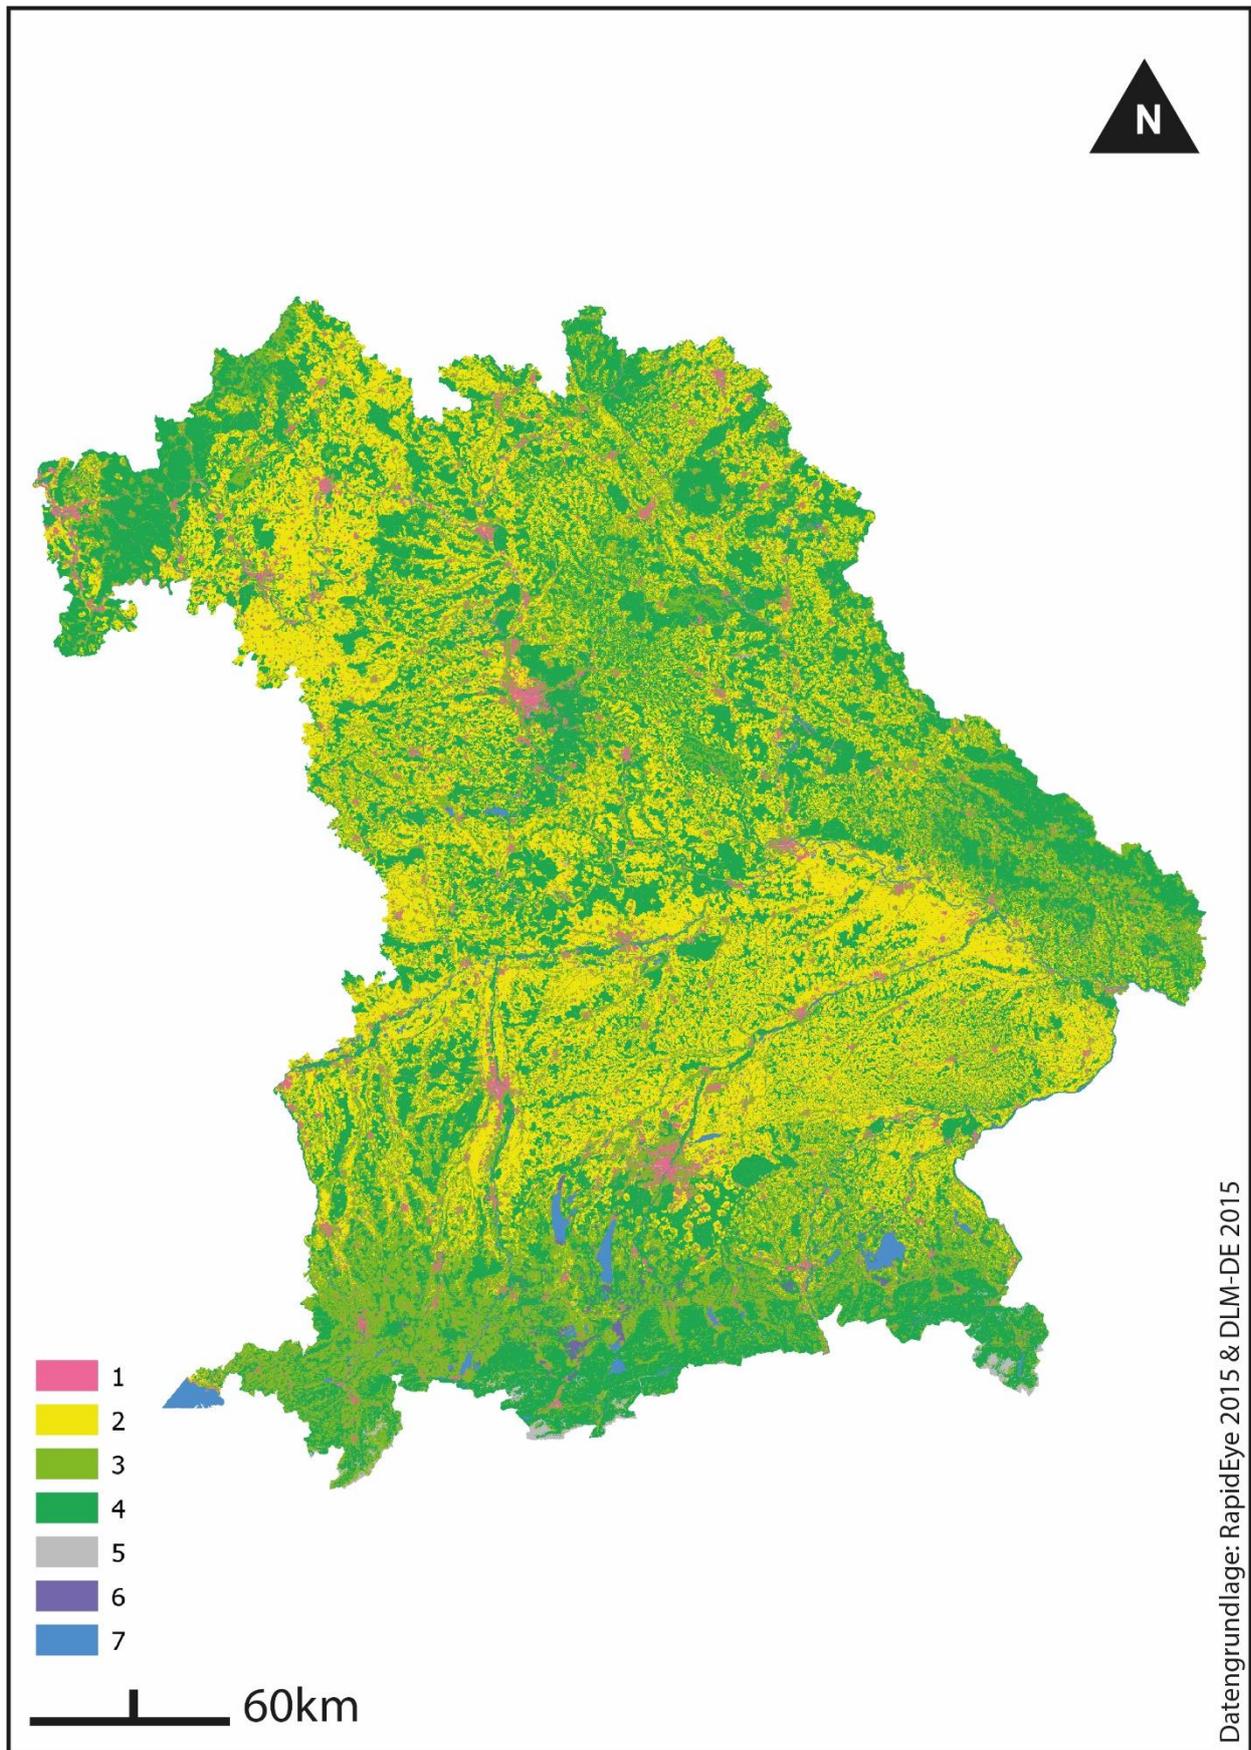


Abbildung 11: Bayern Referenzdatei der Landbedeckung unterteilt in den 7 vorkommenden Hauptklassen. Das verwendete Farbschema ist angelehnt an Tabelle 5. Quelle: eigene Darstellung; Datengrundlage: Landbedeckungsmodell 2015.

Tabelle 5: Klassifikationsschema des Landbedeckungsmodells Deutschland 2015. Das verwendete Farbschema findet sich in den Kartierungen wieder. Quelle: verändert nach Bundesamt für Kartographie und Geodäsie 2022.

Bestehende Kategorien des Digitalen Landbedeckungsmodells Deutschland

Klasse		Landbedeckung (LB)
1	Bebauung	B110
	Anlagen	B121
	Versiegelte gebäudelose Flächen	B122
	Mischflächen (regelmäßige Struktur)	B242
2	Ackerland	B211
	Weinbau	B221
	Obst- und Beerenobstbau	B222
	Hopfen	B224
3	homogenes Grünland	B231
	inhomogenes Grünland	B321
	Grasland mit Bäumen	B233
4	Zwergsträucher (Heide)	B322
	Büsche, Sträucher	B324
	Aufforstung	B310
	Laubbäume	B311
	Nadelbäume	B312
	Nadel- und Laubbäume	B313
5	Sand, Steine, Erde	B330
	Fels	B332
	Brandfläche	B334
	Schnee (permanent) und Eis	B335
6	Sumpf	B411
	Moor	B412
	Sumpf mit Büschen/Bäumen <50%	B413
	Moor mit Büschen/Bäumen <50%	B414
7	Watt	B423
	Wasserlauf	B511
	Wasserfläche	B512
	Lagune	B521
	Mündungstrichter	B522
	Offenes Meer	B523

Klasse 1: Bebaute und versiegelte Flächen gehören zu den anthropogen am meisten strapazierten Landbedeckungsformen. Ob Wohn- oder Verkehrsstrukturen, Asphalt und Beton sind die wichtigsten Merkmalsträger. Von Mischflächen ist die Rede, wenn sich mindestens drei Bedeckungsklassen, bedingt durch die räumliche Auflösung der Datengrundlage -Satelliten- oder Luftbilder- nicht voneinander abgrenzen lassen, wobei dabei mindestens eine Fläche den versiegelten bzw. verbauten Flächen angehören muss (vgl. Bundesamt für Kartographie und Geodäsie 2018, S. 10-14).

Klasse 2: Wie in Abbildung 4 festzustellen ist, ist Landwirtschaft sehr großräumig. Ackerland, Weinbau, Obst- und Beerenobstbau und auch Hopfen zählen zu den in Deutschland vorkommenden Landbedeckungen. Diese können unterschiedliche Charakteristika aufweisen, welche zur Klassifikation herangezogen werden. Die Bewirtschaftung der Flächen erfolgt in unterschiedlich großen Parzellen mit unterschiedlichen Plantagenstrukturen, welche in Abhängigkeit zu den angebauten Nutzpflanzen entstehen. Während Ackerland sehr dominant vorhanden ist, treten Klassen wie Hopfen oder Weinbau nur vereinzelt auf (vgl. ebd., S. 15-18).

Klasse 3: Auch Grünflächen gehören in Bayern zur dominanten Landbedeckung. Diese erstrecken sich über das ganze Bundesland und können unterschiedliche Erscheinungsbilder vorweisen. Homogenen Grünflächen mit geschlossenem Grasbestand und wiederkehrenden Kolonisierungs-Tätigkeiten durch den Menschen, wie Mäharbeiten oder Weidewirtschaft, stehen inhomogenen Grünflächen entgegen, welche unregelmäßigere Erscheinungsbilder und erste Schritte einer natürlichen Sukzession in Form von Busch- und Staudenvegetation zeigen (vgl. ebd., S. 19-22).

Klasse 4: Nimmt diese Sukzession natürlich, oder durch Aufforstung zu, ergibt sich über Stufen der Heidelandschaften mit Zwergsträuchern, Busch- und Strauchvegetationen eine Landbedeckung die im mitteleuropäischen Kontext als Wald wahrgenommen wird. Dieser kann sich im unterschiedlichen Ausmaß aus Nadel- und/oder Laubbaumbeständen zusammensetzen und eine charakteristische Landbedeckung hervorrufen (vgl. ebd., S. 23-28).

Klasse 5: Nimmt die Vegetation andererseits ab, sodass sich erdige, sandige und unversiegelte Aufschlüsse der Erdoberfläche bilden, spricht man andererseits von offenen Flächen, welche beispielsweise natürlich durch Erosionsprozesse, als auch anthropogen durch Rodung, Deponie- und Lagertätigkeiten entstehen können. Die sind nur selten vom Menschen

überprägt und sind durch deren Lage, beispielsweise im Hochgebirge, nur schwer zugänglich. Felsen, Eis, Schnee, Sand, Schotter oder Brandflächen sind solche Erscheinungen der Klasse 5 (vgl. ebd., S. 29-33).

Klasse 6: Durch fehlenden Abfluss kann es vorkommen, dass Böden ganzjährig überflutet sind, was ganz besondere Biotope entstehen lässt. Die Rede ist von Feuchtgebieten wie Mooren und Sümpfen, die sich durch eine nahezu vollständig baumlose Erdoberfläche und durch einen gehemmten pflanzlichen Stoffkreislauf charakterisieren (vgl. ebd., S. 34-37).

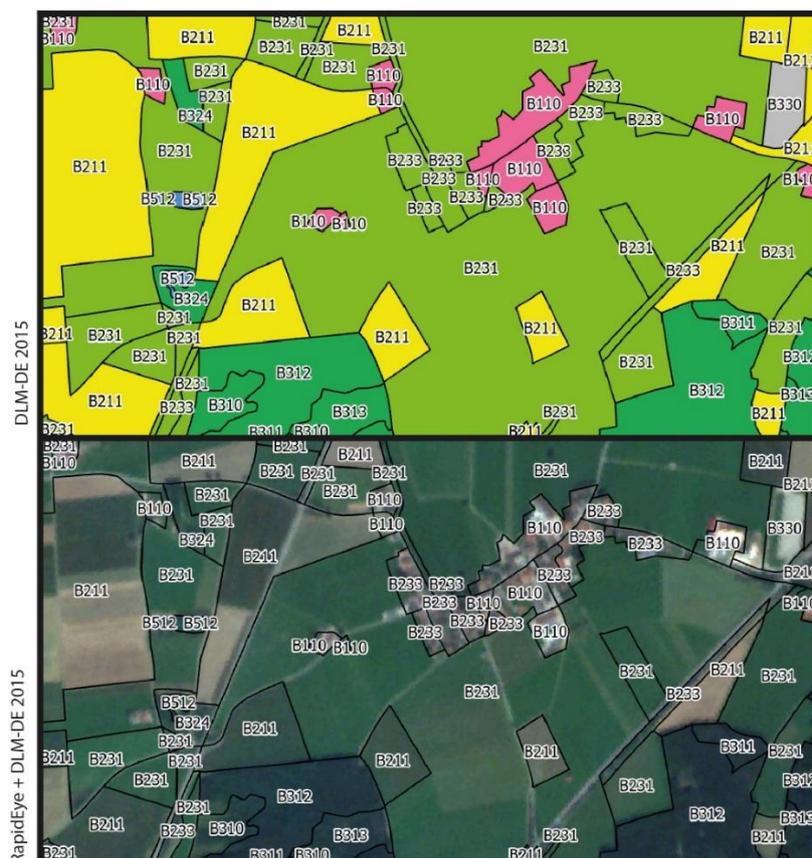
Klasse 7: Wasserflächen und Wasserläufe, ob natürlich oder künstlich, sind die in Bayern heimischen Landbedeckungen des Gewässertyps. Lagunen, Mündungstrichter und Watts sind durch die räumliche Ferne zum offenen Meer selbst irrelevant (vgl. ebd., S. 38-43).

Das DLM-DE unterscheidet zudem, anders als die CLC-Klassifikation (siehe Anhang 1), zwischen Landbedeckung (LB) und Landnutzung (LN) (siehe Anhang 2), um die Landoberfläche so genau wie möglich wiedergeben zu können, was auch mehr Flexibilität in der Datenakquise mit sich bringt. Die Angabe von LN und LB in Kombination gibt die Erdoberfläche genauer wieder als eine der Kategorisierungen allein. Die Kategorisierung nach LN kann zwar auch zur Klassifikation herangezogen werden, jedoch ist zu berücksichtigen, dass auf eine Zuordnung in der LN mehrere der LB kommen. Eine isolierte Landbedeckungsklassifikation nach dem Attribut der LN ist als möglich zu betrachten. Die daraus resultierenden Ergebnisse sind jedoch mit Rücksicht zu interpretieren, da die Erdoberfläche stark vereinfacht wiedergegeben wird. Eine Klassifikation nach LB gibt diese zwar auch sehr vereinfacht wieder, jedoch wird hier im Vorhinein weniger Interpretationsarbeit investiert. Im Allgemeinen sind Kategorien der Landbedeckung genauer definiert und am Orthofoto leichter festzustellen. Folglich ist es für den Menschen aufwändiger die LN zu interpretieren als die LB, da diese von mehreren Faktoren abhängt und subjektive Vorkenntnisse eher eine Rolle spielen. Diese präanalytische Fehlerquelle ist zu berücksichtigen, weshalb die vorhanden LB-Attribuierung als Grundlage dient, Modelle zu trainieren und anzuwenden. Ein weiterer Vorteil des DLM-DE besteht darin, dass LN und LB anhand einer Kreuztabelle (siehe Anhang 3) an das CLC-Schema angepasst werden können, welche bekanntlich keine strikte Unterscheidung zwischen Nutzung und Bedeckung vorsieht (vgl. Hovenbitzer et al. 2015, S. 146f).

Exkurs Mensch-Umwelt Interaktionen

Bei der Beziehung zwischen Menschen und Natur handelt es sich um einen dynamischen Prozess. Dieser spiegelt sich überwiegend darin, wie der materielle Raum vom Menschen kolonisiert bzw. eingenommen und zu seinen Gunsten transformiert wird. Die Verschmelzung von Natur- und Kulturlandschaft ist bereits seit dem Neolithikum im Gange und wird von der Sozialen Ökologie integrativ untersucht. Auf der Erdoberfläche zu beobachten und somit auch für die Fernerkundung messbar, sind Landbedeckung und Landnutzung wichtige Indizien für Veränderungen in diesem Gleichgewicht (vgl. Fischer-Kowalski u. Haberl 1997, S. 10).

In Abbildung 12 ist ein Ausschnitt des DLM-DE 2015 Vektordatensatzes zu erkennen. Dieser ist mit *Rapid Eye* Aufnahmen aus dem Jahr 2015 hinterlegt. Dieses Beispiel soll verbildlichen, inwiefern die Referenzdatei der Realität entspricht.



3 Experimentelles Setup

Wie bereits im Kapitel 1.3 dargestellt besteht der Arbeitsprozess aus vier grundlegenden Teilen. Um eine Landbedeckungsklassifikation mittels *Machine Learning* bzw. *Deep Learning* durchzuführen, sind folgende Punkte zu beachten:

- Erstellung der Trainingsgebiete
- Erstellung des Modells
- Durchführung der Klassifikation
- Bewertung der Klassifikation

Für den weiteren Prozess ist es notwendig, den in Kapitel 2.4 vorgestellten Datensatz weiter zu untergliedern. Der Datensatz wird hierfür in drei Teile (siehe Abbildung 13) im Verhältnis 60% Training: 20% Validierung: 20% Test aufgeteilt, um das Modell gleichmäßig zu trainieren und zu validieren. Das Verhältnis kann variieren, es soll aber zur Kenntnis genommen werden, dass ein gutes Modell viele Trainingsgebiete abverlangt und somit den Hauptteil des Datensatzes beansprucht. Aus diesen Überlegungen ergibt sich das verwendete Verhältnis. Für Validierungs- und Testdatensatz muss berücksichtigt werden, dass deren Resultat ebenso aussagekräftig bleiben. Validierung unterscheidet sich hierbei grundsätzlich von der Testung und wird benötigt, um das Modell epochenweise zu überprüfen und dementsprechend anzupassen. Die Testung sollte an Daten erfolgen, die nicht zum Training herangezogen werden, um eine Aussage über die Qualität des Modells anhand von unberührten Daten treffen zu können (vgl. Cresson 2020, S. 12).

Durch Genauigkeitsbewertungen (= „*Accuracy Assessments*“), werden anschließend die Endklassifikation und das Modell überprüft, was der Testung gleichgesetzt wird (vgl. Jia et al. 2021, S. 186). In diesem Kapitel sollen diese Arbeitsschritte ausführlich wiedergegeben werden. Für ein besseres Zeitmanagement wurden diverse Einstellungen und Hyperparameter an einer Auswahl des Trainingsdatensatzes heuristisch erprobt. Mit dem jeweils daraus resultierenden, bestmöglichen Einstellungsset – *Arcgis Pro* und *eCognition* – wurde eine Klassifikation am gesamten Ausmaß des Bundeslandes durchgeführt. Die Schritte sind in den Anhängen 4-11 zu finden und werden folgend aufgegriffen.

AUFTEILUNG DES DATENSATZES

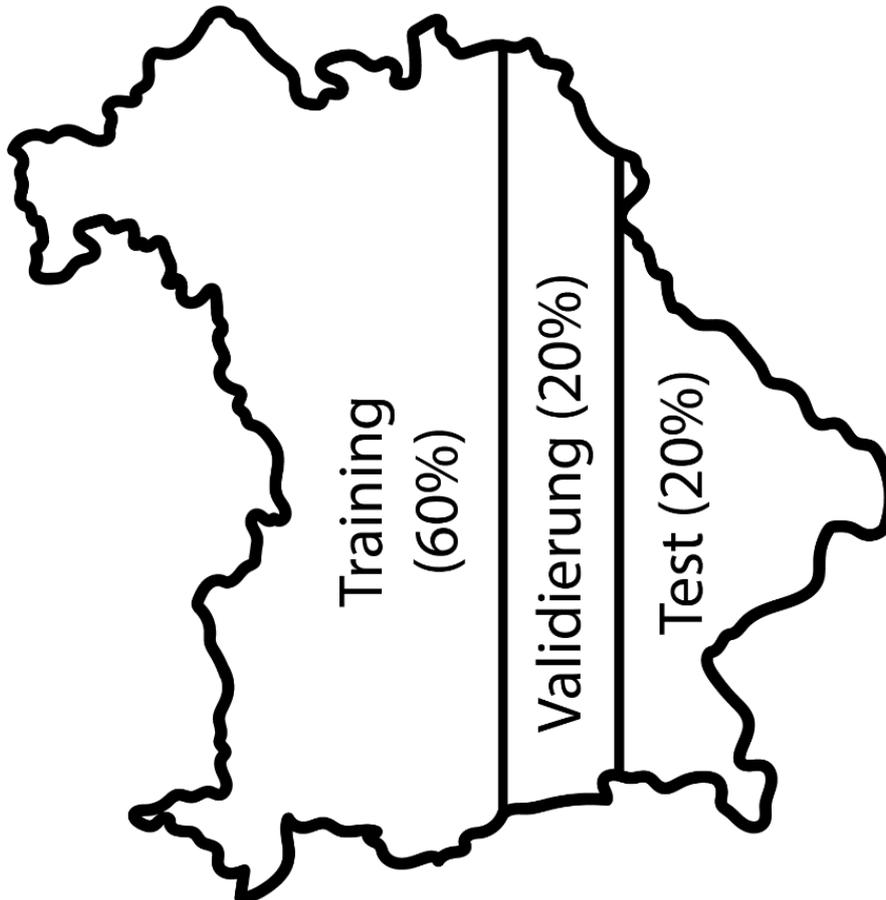


Abbildung 13: Aufteilung des Datensatzes. Quelle: eigene Darstellung.

3.1 Trainingsgebiete

Trainingsgebiete bzw. Samples werden benötigt, um eine KI auf bestimmte Aufgabenbereiche zu trainieren. Diese sind grundlegend am Ergebnis verantwortlich und müssen sorgfältig gewählt werden. Ob *Shallow-* oder *Deep Learning*, *Machine Learning* basiert auf vorhandenes Wissen, welches beispielsweise durch das DLM-DE gegeben ist und in Unterkapitel 2.4 vorgestellt wurde. Solche bestehenden Vektorlayer können herangezogen werden, sodass diese nicht separat extrahiert werden müssen. Die Klassen sind gegeben und werden als unveränderliche Parameter betrachtet. Einflussfaktoren wie Definition und Interpretation der Klassen sind somit nicht weiters relevant. Einzig gering auftretende Klassen mit ähnlichen

Merkmale wurden des Weiteren für Testung der Methode zusammengefasst, um die Wahrscheinlichkeit der Fehlklassifikation zu minimieren. Für die Endklassifikation wurden jeweils alle Subklassen bzw. Hauptklassen verwendet. Aus einem Vergleich dieser zeigt sich, welche Klassen durch eine Zusammenschließung eine Begünstigung erfahren. Grundsätzlich gilt, dass je mehr Samples pro Kategorie vorhanden sind, umso bessere Genauigkeitsbewertungen im Möglichen liegen (vgl. Jia et al. 2021, S. 189ff). Ein generelles Merkmal der DL-Anwendung ist, dass mit einer zunehmenden Menge an Trainingsdaten – im vierstelligen Bereich – sich auch die Ergebnisse der Klassifikation verbessern, während bei ML die Ergebnisse bereits nach einer zweistelligen Sampleanzahl stagnieren (siehe Abbildung 14). Dies ist der limitierten Verarbeitung von Rohdaten konventioneller ML-Algorithmen zuzuschreiben. DL gelingt es auf mehreren Ebenen Informationen zu abstrahieren und daraus selbständig zu lernen (vgl. LeCun et al. 2015 und Alyafeai u. Ghouti 2019, S. 13).

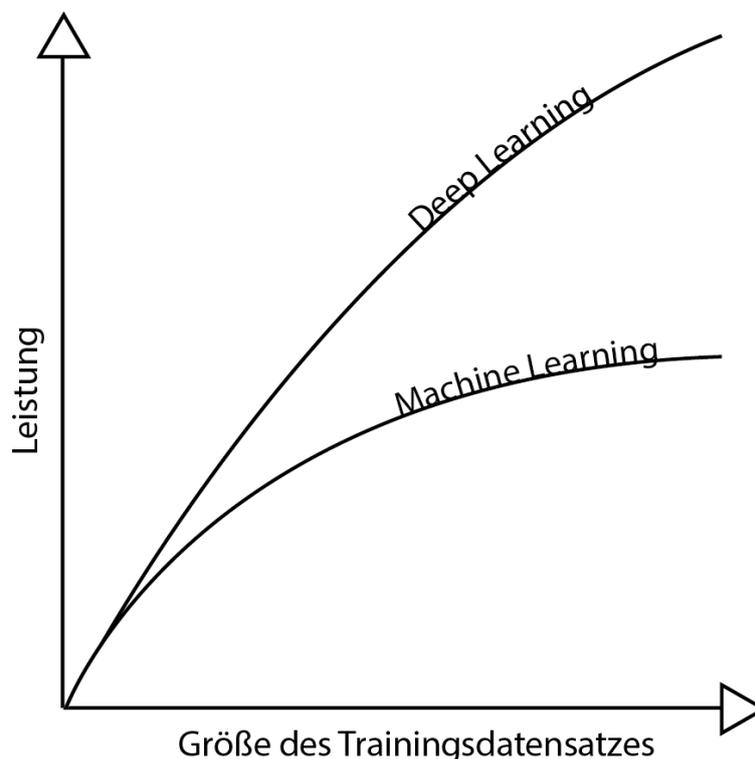


Abbildung 14: Leistungssteigerung durch mehr Trainingsdaten in der Deep Learning Anwendung. Quelle: verändert nach Alyafeai u. Ghouti 2019, S. 13.

Die Ausgewogenheit zwischen den einzelnen Klassen ist von hoher Bedeutung, da ansonsten die vorwiegenden Gruppen überklassifiziert und somit bevorzugt werden. Die Rede ist von einer *Imbalance* des Datensatzes (vgl. Johnson u. Khoshgoftaar 2019, S. 2). Generell ist darauf zu achten ein Gleichgewicht zu finden. Dies hilft ein gutes Modell zu trainieren. Bei der Validierung des Modells zeigt sich schließlich, ob der Trainingsdatensatz gut gewählt wurde. Zu wenig Samples bahnen ein sogenanntes *Overfitting* an. Ein Phänomen, welches den Zustand beschreibt, dass das Modell zu sehr an die vorhandenen Daten fixiert ist und eine Varianz nicht toleriert. Auch wenn der Datensatz beschränkt ist, ist es möglich die enthaltene Information zu vermehren. Dieser Vorgang wird als *Augmentation bezeichnet*. Durch Überlappung, Rotation, Durchmischen der Samples und durch die Verwendung kleinerer Sampleausmaße lässt sich ein Datensatz limitiert verbessern (vgl. Shorten u. Khoshgoftaar 2019, S. 3ff). Die Tabellen 6 und 7 geben die Landbedeckung Bayerns nach Haupt- bzw. Subklassen wieder. Dabei werden Verhältnisse und Ausmaß bezüglich der Diversität der Landbedeckung sichtbar. Unter anderem soll geklärt werden, welche Klassen sinnvoll sind bzw. auch signifikant klassifiziert werden können. Besonders die Hauptklassen 5, 6 und 7 haben im Bundesland Bayern ein relativ geringes Vorkommen. Die Stichprobenauswahl ist somit eine zusätzliche Herausforderung für die Landbedeckungsklassifikation, da der Datensatz in der Praxis nur äußerst selten ausbalanciert vorliegt. Möglichkeiten einen nicht balancierten Datensatz ins Gleichgewicht zu bringen sind unter anderem *Oversampling*, die *Augmentation* der unterrepräsentierten Klassen, oder *Undersampling*, die zufällige Verringerung der überrepräsentierten Klassen. Vor allem *Oversampling* sollte dabei mehr Beachtung geschenkt werden, da *Deep Learning* grundsätzlich einen größeren Datensatz benötigt. Aufgrund dessen, dass diese Forschungsarbeit insbesondere eine effiziente, direkte und möglichst automatisierte Landbedeckungsklassifikation mittels KI anstrebt, wurde davon abgesehen, die Datensätze zu manipulieren. *Oversampling* und *Undersampling* würden zwar Optionen bieten, die Datensätze und Modelle zu verbessern, jedoch bringen diese auch eigene Fehlerquellen mit sich, welche von der anfänglichen Problemstellung abweichen. Es wurde somit ein möglichst praxisnaher Weg gewählt, indem die Stichproben nicht auf die Anzahl der Samples, sondern auf die Flächen bezogen werden, welche sich wiederum als Trainings-, Validierungs- und Testdatensatz wiederfinden (vgl. Stoll 2020, S. 236).

Table 6: DLM-DE nach den Hauptklassen für das Bundesland Bayern. Quelle: eigene Darstellung; Datengrundlage: DLM-DE 2015.

Klasse	Polygone	Pixel	Fläche [m ²]	Fläche [%]
1	338.420	111.320.078	2.783.001.950	3,94%
2	109.367	867.501.053	21.687.526.325	30,69%
3	524.696	724.672.307	18.116.807.675	25,64%
4	324.130	1.053.314.338	26.332.858.450	37,26%
5	17.103	17.669.217	441.730.425	0,63%
6	5.558	8.616.422	215.410.550	19,75%
7	61.951	43.618.420	1.090.460.500	1,54%

Table 7: DLM-DE nach den Subklassen für das Bundesland Bayern. Quelle: eigene Darstellung; Datengrundlage: DLM-DE 2015.

Klasse	Polygone	Pixel	Fläche [m ²]	Fläche [%]
B110	265.057	91.455.911	2.286.397.775	3,24%
B121	27.473	9.024.382	225.609.550	0,32%
B122	35.979	7.008.106	175.202.650	0,25%
B242	9.911	3.831.679	95.791.975	0,14%
B211	103.045	856.354.971	21.408.874.275	30,30%
B221	815	2.785.684	69.642.100	0,10%
B222	2.584	2.024.682	50.617.050	0,07%
B224	2.923	6.335.716	158.392.900	0,22%
B231	248.321	556.395.468	13.909.886.700	19,68%
B321	8.839	33.167.042	829.176.050	1,17%
B233	267.536	135.109.797	3.377.744.925	4,78%
B322	1.529	8.024.753	200.618.825	0,28%
B324	20.646	9.612.653	240.316.325	0,34%
B310	32.786	38.836.980	970.924.500	1,37%
B311	82.065	184.800.224	4.620.005.600	6,54%
B312	92.478	542.117.740	13.552.943.500	19,18%
B313	94.626	269.921.988	6.748.049.700	9,55%
B330	15.608	13.584.727	339.618.175	0,48%
B332	1.465	4.041.167	101.029.175	0,14%
B334	-	-	-	0,00%
B335	30	43.323	1.083.075	0,15%
B411	2.861	1.623.200	40.580.000	0,06%
B412	1.828	5.637.254	140.931.350	0,20%
B413	205	201.197	5.029.925	0,71%
B414	664	1.154.771	28.869.275	0,04%
B423	-	-	-	0,00%
B511	5.621	13.175.374	329.384.350	0,47%
B512	56.330	30.443.046	761.076.150	1,08%
B521	-	-	-	0,00%
B522	-	-	-	0,00%
B523	-	-	-	0,00%

Deep Learning: Modelle sind darauf abgestimmt Objekte und Strukturen zu erkennen, welche ebenso für das menschliche Auge sichtbar sind (vgl. Alouta u. Hess 2021). Deshalb ist ebenso die Auswahl der verwendeten Bänder entscheidend. Statistisch betrachtet erzielen neuronale Netzwerke, welche anhand multispektraler Daten trainiert wurden, signifikant bessere Ergebnisse (vgl. Senecal et al. 2019, S. 5). Ein weiterer Faktor ist die Größe der extrahierten Trainingsgebiete. Diese sind passend der verwendeten Modellarchitektur zu wählen. Die einen funktionieren besser mit kleineren (z.B. 32x32 Pixel), die anderen mit größeren (z.B. 320x320 Pixel) Bilddimensionen. Je nach Architektur gilt es somit zu beachten, dass das Modell die Gesamtstruktur nicht richtig wahrnimmt, falls die Samples zu klein ausfallen. Sind diese andererseits zu groß, werden kleinstrukturierte Landschaftsflächen vernachlässigt. Verantwortlich für dieses Phänomen sind verwendete Filter und die daraus resultierenden abnehmenden Breiten und Höhen der Bildausschnitte während jeder Schicht des neuronalen Netzwerkes. Zudem beeinflusst die Dimension des Eingabebildes die Dimension der verwendeten Filter, denn diese werden mit jedem weiteren *Hidden Layer* kleiner. Dies kann beispielsweise verursachen, dass das Modell nicht richtig funktioniert (vgl. Hamwood et al. 2018, S. 3052-3055).

Zusammenfassend lässt sich festhalten, dass bei der Generierung der Trainingsgebiete folgende Parameter veränderbar sind:

- Augmentation
- Bänderkombination
- Klassen

Wie diese Kombinationen umgesetzt wurden, ist in den Anhängen 4 und 5 für beide Softwarepakete enthalten. Während für SL-Klassifikationen unterschiedliche Merkmale als Informationsträger extrahiert werden müssen, schafft es ein Modell basierend auf neuronalen Netzwerken selbständig Kriterien und Gewichtungen zu setzen. Zu berücksichtigen ist, dass *Arcgis Pro* nur drei Bänder berücksichtigt, wohingegen *eCognition* mit mehrbändigen Trainingsgebieten arbeiten kann und somit in dieser Hinsicht nicht derart limitiert ist. Die Metadatei-Formate beider Softwareprogramme unterscheiden sich ebenso (siehe Abbildung 15). Wie die Bildausschnitte gespeichert und gelabelt sind, hängt von der verwendeten Architektur und vom Zweck (ob *Semantische Segmentierung* oder *Objekt Detektion*) ab. Beide

Softwareprogramme geben die Samples dementsprechend konfiguriert aus, was es andererseits erschwert, vorhandene Samples zwischen den Softwareprogrammen zu transferieren. Dies wirkt sich in der Größe des eingenommenen Speicherplatzes durch die nötigen Datensätze aus, falls mit mehr als einem Softwareprogramm gearbeitet wird.

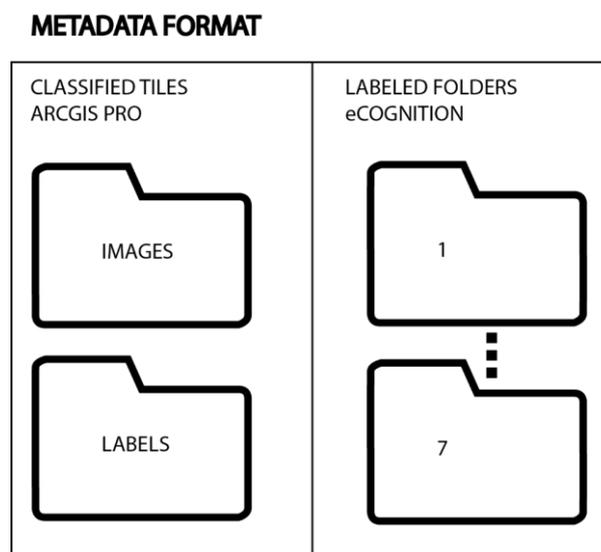


Abbildung 15: Darstellung des Exportordners und des Metadatei-Formats beider Softwareprogramme. Quelle: eigene Darstellung.

Vergleich Machine Learning: Die Klassifikation mit *Random Forest* oder *K-Nearest Neighbor* Algorithmen benötigt anders als jene mit neuronalen Netzen, nur eine geringe Anzahl an Samples, um ein Leistungsmaximum zu erreichen (siehe Abbildung 14). Basierend auf dieser Überlegung und auf die Erkenntnisse anderer Forschungsarbeiten, wurden für diese Art der Klassifikation 50 zufällige Samples pro Klasse generiert, anhand derer die jeweiligen Modelle trainiert wurden (vgl. Colditz 2015, S. 9675). Die verwendeten Klassen gleichen jenen, die auch für die *Deep Learning* Modelle verwendet wurden. Der wohl größte Unterschied zwischen der ML- und der DL-Anwendung ist die Abhängigkeit der Merkmalsextraktion von der Anzahl an Bändern und der beinhaltenden Information. Die Erstellung verschiedenster Indizes (siehe Tabelle 8), Textur-Layer oder einer Hauptkomponentenanalyse bieten zusätzliche Information, mit der die Möglichkeit besteht, Objekte weiter zu differenzieren und das Klassifikationsergebnis zu verbessern.

Tabelle 8: Indizes für zusätzlichen Informationsgewinn. Quelle: verändert nach Esri 2022d.

INDICES	
NDVI	$= ((\text{NIR} - \text{Red}) / (\text{NIR} + \text{Red}))$
NDWI	$= (\text{Green} - \text{NIR}) / (\text{Green} + \text{NIR})$
Green NDVI	$= (\text{NIR} - \text{Green}) / (\text{NIR} + \text{Green})$
Red-Edge NDVI	$= (\text{NIR} - \text{RedEdge}) / (\text{NIR} + \text{RedEdge})$
SAVI	$= ((\text{NIR} - \text{Red}) / (\text{NIR} + \text{Red} + \text{L})) \times (1 + \text{L})$
TSAVI	$= (s * (\text{NIR} - s * \text{Red} - a)) / (a * \text{NIR} + \text{Red} - a * s + X * (1 + s^2))$
MSAVI	$= (1/2) * (2(\text{NIR}+1) - \sqrt{(2*\text{NIR}+1)^2 - 8(\text{NIR}-\text{Red})})$
PVI	$= (\text{NIR} - a*\text{Red} - b) / (\sqrt{1 + a^2})$
VARI	$= (\text{Green} - \text{Red}) / (\text{Green} + \text{Red} - \text{Blue})$
SR	$= \text{NIR} / \text{Red}$
Red-Edge SR	$= \text{NIR} / \text{RedEdge}$
MTVI2	$= 1.5 * (1.2 * (\text{NIR} - \text{Green}) - 2.5 * (\text{Red} - \text{Green})) \sqrt{((2 * \text{NIR} + 1)^2 - (6 * \text{NIR} - 5\sqrt{(\text{Red})}) - 0.5)}$
RTVlcore	$= (100 * (\text{NIR} - \text{RedEdge}) - 10 * (\text{NIR} - \text{Green}))$
CI-Red Edge	$= ((\text{NIR} / \text{RedEdge}) - 1)$
CI-Green	$= ((\text{NIR} / \text{Green}) - 1)$
L...amount of green vegetation cover s...slope of the soil line a...soil line intercept X...adjustment factor that is set to minimize soil noise b...gradient of the soil line	

Ein Index eignet sich, um die Intensität bestimmter Merkmale wiederzugeben und wird auf Basis von zwei oder mehr Bändern, deren Reflexionseigenschaften und deren Beziehung zueinander als zusätzlicher Layer berechnet (vgl. Bannari et al. 1995, S. 96f). Die Textur wiederum beschreibt die räumliche Heterogenität bzw. Homogenität, welche durch Kontrastdifferenzierungen unterschiedlicher Objekte auf der Oberfläche wiedergegeben werden. Neben der Größe der Objekte haben auch Belichtungsverhältnisse, Beobachtungswinkel, Jahreszeit und schließlich der aufgenommene Spektralbereich Einfluss. Zudem haben kurze Wellenlängen einen raueren Charakter, wohingegen dieselbe Szene, aufgenommen im langen Wellenbereich, einen sanfteren Verlauf aufweist (vgl. Chuvieco 2016, S. 158). Um die Textur als zusätzlichen Informationsinput nutzen zu können, benötigt es einen weiteren Zwischenschritt. Die Extraktion beruht auf die sogenannte *Gray Level Co-occurrence matrix* der *Haralick Texture Extraction*, welche Pixelwerte und Relation im Raum berücksichtigt. Mit einfachen Berechnungen können so bis zu acht weitere Features (siehe Tabelle 9) extrahiert werden. Nichtsdestotrotz ist eine Kombination aus 2 Textur-Layer ausreichend, um signifikante Ergebnisse zu erzielen, was in der fortführenden Arbeit berücksichtigt wird (vgl. OTB-Cookbook 2018 und Lu et al. 2014, S. 8193).

Tabelle 9: Auswahl an Haralick Features. Quelle: verändert nach OTB-Cookbook 2018.

HARALICK TEXTURES
* Energy (texture uniformity)
* Entropy (measure of randomness of intensity image)
Correlation (how correlated a pixel is to its neighborhood)
Inverse Difference Moment (measures the texture homogeneity)
Inertia (intensity contrast between a pixel and its neighborhood)
Cluster Shade
Cluster Prominence
Haralick Correlation
* used for further investigation

Zusätzlich wird eine Hauptkomponentenanalyse an den Satellitenbildern angewendet, um Datenmengen zu reduzieren und daraus ein Maximum an Informationsgehalt zu erzielen. Am Beispiel von *Rapid Eye* Daten, lassen sich die fünf Bänder auf drei Hauptkomponenten reduzieren. Diese enthalten mehr als 90% der Informationen der Ursprungsbänder. Die Reduktion beruht darauf, dass korrelierende Variablen jedes einzelnen Bandes in einer Kovarianz-Matrix, durch Berechnung der Eigenwerte, zu Komponenten zusammengefasst werden (vgl. Estornell et al. 2013, S. 84f). Für SL-Klassifikatoren ist es somit möglich, Objekte basierend auf mehr als 25 Layer zu differenzieren. In Anhang 6 sind die überwachten Lernprozesse bzw. die Klassifikationen basierend auf *K-Nearest Neighbor* und *Random Forest* in beiden Softwarepaketen dargestellt und soll zum Vergleich der Prozesse dienen. Ein großer Vorteil der SL-Klassifikatoren liegt in der Handhabung und Übersichtlichkeit.

3.2 Modelltraining

Nach der Generierung der Samples besteht für *Semantische Segmentierung* mit DL der nächste Schritt darin, eine passende Modellarchitektur zu wählen, mit der die Klassifikation trainiert wird. Die Unterschiede liegen hier in den Details. Besonders für visuelle Aufgabenstellungen, zu denen auch Bildklassifikationen gehören, sind sogenannte *Convolutional Neural Networks (CNN)* geeignet. Diese sind auf einen Input mit mehrdimensionalen Anordnungen eingestellt, wie es bei einem Bild beispielsweise durch die unterschiedlichen Farbkanäle, Farbstufen bzw. Graustufen und Bilddimensionen gegeben ist. Dies kann als Matrix dargestellt werden (vgl. LeCun et al. 2015, S. 438). Wie in Abbildung 16 zu sehen ist, besteht jeder *Hidden Layer* aus zwei Prozessen. Das sind zum einen die *Convolution*, die Faltung, und zum anderen das *Pooling*, die Bündelung auf das Wesentliche. Der Prozess der *Convolution* beschreibt eine Kernel-Matrix bzw. einen Filter mit trainierbaren Gewichten und einstellbaren Größen, welche Spalte für Spalte und Zeile für Zeile das Input-Bild abtastet und Features extrahiert. Das bedeutet auch, dass die Neuronen des Netzwerkes nie mit dem gesamten Input konfrontiert werden, sondern nur mit Ausschnitten, welche den Filtern entsprechen, den sogenannten *rezeptiven Feldern* (= „*receptive fields*“) (vgl. Sewak et al. 2018, S. 51). Während jede zusätzliche Faltung die Höhen und Breiten des Inputbildes verringert, nimmt die Tiefe der Feature-Layer zu. Wie in Abbildung 16 zu sehen ist, vermehren sich durch die Faltung die Feature-Layer. Pro angewendeten Filter entsteht so ein *Feature-Layer* (= „*feature map*“). Die ersten Layer extrahieren vor allem einfache Merkmale wie Farben oder Kanten. Mit jedem zusätzlichen *Hidden Layer* nimmt die Komplexität der erkannten Merkmale zu. Im *Pooling* Schritt wird der Input bzw. der Output weiter reduziert, indem nur jene mit den höchsten Aktivierungs-Antworten weitergelassen werden. Diese Verringerung der räumlichen Dimension, das sogenannte *Downsampling*, ist typisch für CNN. Nach weiteren *Hidden Layer*, je nach Modell und Architektur, wird schließlich der finale Layer ausgegeben. Dieser enthält die Klassifikation und ist vollständig mit den Informationen, der vorangegangenen Layer, vernetzt (vgl. LeCun et al. 2015 und Turner et al. 2021, S. 204).

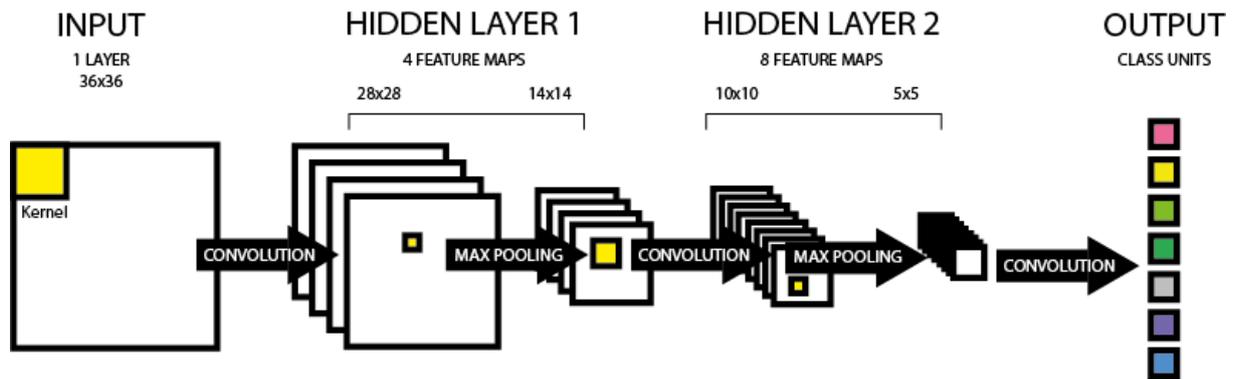


Abbildung 16: Funktionsweise eines Convolutional Neural Networks. Quelle: verändert nach Turner et al. 2021, S. 204.

Wie bereits in Kapitel 2.1 erwähnt, gibt es je nach Anwendung unterschiedliche Architekturen, welche den Aufbau des Modells definieren. Sei es die Anzahl der *Hidden Layer*, die Größe der Kernel-Filter, oder die verwendete Aktivierungsfunktion. Während das beschriebene CNN aus Abbildung 16 in *eCognition* Anwendung findet, gibt es in *Argis Pro* eine größere Auswahl. Besonders die *U-Net* Architektur (siehe Abbildung 17) eignet sich zur Analyse von Fernerkundungsdaten. Bestehend aus insgesamt 23 Convolutional-Layer und ursprünglich für medizinische Untersuchungen entwickelt, eignet sich jene Architektur auch für Landbedeckungsklassifikationen. Die Architektur entspricht einem modifizierten *Fully Convolutional Network (FCN)* wodurch es sich für mittlere Samplegrößen eignet und sich zudem nicht nur zur Klassifikation, sondern auch zur Lokalisierung von bestimmten Merkmalen eignet. Anders als ein CNN setzt sich ein FCN nicht nur aus einem *Downsampling*, sondern auch aus einem *Upsampling* Abschnitt zusammen. Diese sind in der modifizierten *U-Net* Architektur nahezu symmetrisch und geben die namensgebende Form der Architektur. Das bedeutet, dass nachdem die räumlichen Dimensionen des Inputs reduziert wurden, eine Skalierung auf die ursprüngliche Dimension erfolgt. Dadurch ist die Architektur nicht an eine fixe Eingabegröße des Inputs gebunden. Andererseits sind die Layer nicht miteinander verknüpft, sodass je *Convolution* nur der Kontext verwendet werden kann, der vollständig im Layer enthalten ist. Dies eignet sich zudem für große Bilddateien, da aufgrund der getrennten Bearbeitung die Grafikkarte weniger belastet wird (vgl. Ronneberger et al. 2015, S. 2f und Long et al. 2015, S. 2).

U-NET ARCHITECTURE

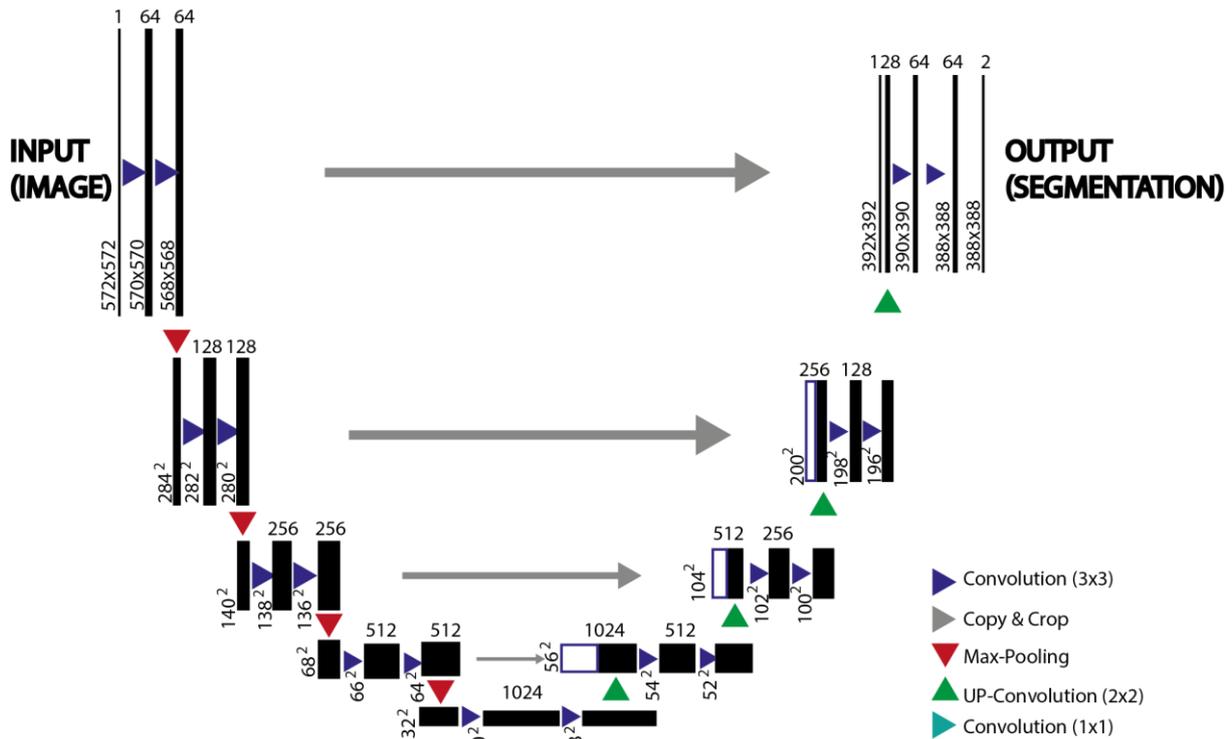


Abbildung 17: U-Net Architektur. Quelle: verändert nach Ronneberger et al. 2015, S. 2.

Zudem besteht die Möglichkeit das Modell durch *Backbone Modelle*, einer Art *Transfer Learning* zu konfigurieren. Das bedeutet, dass dadurch allgemeinbekannte Merkmale durch Modelle vortrainiert werden und an das spezifische Modell angepasst werden können. Mit dieser Herangehensweise hat das zu erstellende Modell eine gute Ausgangslage und muss nicht von Grund auf lernen. In *Pytorch* sind Modelle beispielsweise basierend auf *Residualnetzwerke* (RESNET) mit bis zu 152 Layer implementiert, die anhand eines Datensatzes, bestehend aus mehr als eine Million Bilder, bereits Basiswissen zur Extrahierung von Merkmalen haben (vgl. Esri 2022e).

Neben verwendeter Architektur und Anzahl der *Hidden Layer*, besteht die Möglichkeit die Lernfähigkeit des Modells durch die Anzahl an *Epochen*, Anpassung der *Lernrate* oder durch *Transfer Learning* zu steigern. Eine Epoche beschreibt den Durchgang eines Modells den es benötigt, um jeden einzelnen Sample des Trainingsdatensatzes einmal aufzufassen. Da es technisch nicht möglich ist, alle Samples gleichzeitig zu erfassen, werden *Epochen* in *Batches* und *Lernschritte* (= „*learning steps*“) unterteilt. Ein Batch beschreibt die Anzahl der Samples

die gleichzeitig, je nach Rechenkapazität der GPU, betrachtet wird. Diese kann unterschiedlich ausfallen. Für die verwendeten Softwarepakete eigneten sich Batch-Größen von 16 (für *Arcgis Pro*) bzw. 50 (für *eCognition*). Dies setzt wiederum voraus, dass mehrere Schritte benötigt werden, um batchweise eine Epoche zu generieren — darum ist die Rede von *Lernschritten* (vgl. Chollet 2021, S. 49 u. 74). Grundsätzlich funktioniert dieser Prozess des Trainings in den verwendeten Softwarepaketen nach dem gleichen Schema, jedoch funktioniert dieser im Falle von *Arcgis Pro* automatisierter. Dies zeigt sich besonders auch bei der Validierung der Batches. Eine Adjustierung der Gewichte ist in *Deep Learning* unverzichtbar, um das Modell bestmöglich zu trainieren. Dies geschieht durch den *Backpropagation Algorithmus*, einer Art Reflexion in der die vorangegangenen Neuronen betrachtet und Gradienten berechnet werden, mit denen folgend Gewichtungen und Fehlerwerte angepasst werden. Auf Basis der sogenannten *Verlustfunktion* (= „*loss function*“), in der die vorhergesagten Ergebnisse mit den Zielergebnissen verglichen werden, nehmen *Optimierer* (= „*optimizer*“) (z.B. *Adam*, *RMSProp* etc.) nach dem Gradientenverfahren Änderungen vor, welche das Modell anpassen und optimieren. Die *Lernrate* ist ein zusätzlicher Parameter dieses Gradientenverfahrens und ist für den Lernprozess mitentscheidend. Diese kann zudem einem fixen oder adaptiven Wert entsprechen. Das Ziel ist es die Lernkurve flach zu halten und die Verluste möglichst zu minimieren. In Abbildung 18 werden Lernkurven und der Zusammenhang mit der *Lernrate* gegenübergestellt (vgl. Goodfellow et al. 2016, S. 429f und Chollet 2021, S. 29).

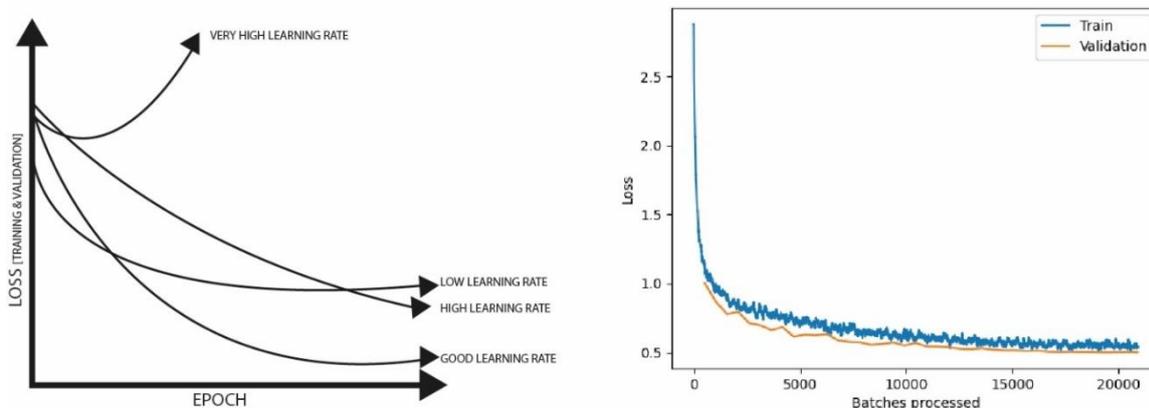


Abbildung 18: Güte der Lernkurve in der Theorie (links) im Vergleich zu einer Lernkurve in der Praxis (rechts). Quelle: verändert nach Apaydin et al. 2020, S. 10.

Nach Goodfellow et al. (2016) wird empfohlen, die *Lernrate* als Hyperparameter zu adjustieren, da dadurch mit wenig Zeitaufwand die signifikantesten Verbesserungen erzielt werden können. Mit großen *Lernraten* werden weniger *Epochen* benötigt, jedoch ist die Wahrscheinlichkeit die ideale Lernkurve zu verpassen groß. Andererseits besteht die Möglichkeit, dass kleine *Lernraten* steckenbleiben und die ideale Lernkurve nie erreichen. Eine adaptive *Lernrate* bietet somit mehr Flexibilität und eine höhere Wahrscheinlichkeit ein Gleichgewicht zwischen einem *Overfitting* bzw. *Underfitting* des Modells zu erreichen (vgl. Goodfellow et al. 2016, S. 429f und Chollet 2021, S. 29).

Wichtige Parameter, die mit dem Lernprozess eines Modells einhergehen, sind:

- Architektur
- Anzahl Hidden Layer
- Epochen und Lernrate
- Backbone Modelle und Transfer Learning

Wie das Training anhand dieser Parameter vollzogen wurde, ist in den Anhängen 7 und 8 (*jeweils für Arcgis Pro und eCognition*) zu sehen.

3.3 Klassifikation

Die Anwendung des Modells ist der letzte verbleibende Schritt, um zur Klassifikation zu gelangen. Diese ist abhängig davon, ob es sich um eine pixelbasierte, oder objektbasierte Klassifikation handelt und sogleich auch abhängig vom verwendeten Softwarepaket. Das Softwarepaket von *Arcgis Pro* ist bekanntlich auf pixelbasierten Klassifikationen spezialisiert. Die Software von *eCognition* eignet sich wiederum für *Segmentierungen* und objektbasierte Klassifikationen. Folglich unterscheiden sich in der Anwendung auch die Lösungswege, da beide der genannten Softwarepakete unterschiedliche Anforderungen haben, um aus dem Input einen Output zu generieren. Während die Erstellung der Samples und das Training des Modells in beiden Programmen zu Gunsten der *Deep Learning* Funktionsweise vergleichbar und generalisierbar sind, ist es für die Anwendung sinnvoll, die Schritte getrennt voneinander zu betrachten. Es folgt ein Vergleich der Anwendung zwischen *Arcgis Pro* und *eCognition*. Die

Shallow Learning Methoden sind in Anhang 6 für beide Softwareprogramme schematisch dargestellt. Nach einem heuristischen Verfahren (siehe Anhänge 9-11) wurden die besten Kombinationen, basierend auf der *Overall Accuracy*, ermittelt. Dabei wurden Bänderkombinationen, Anzahl der *Hidden Layer*, *Backbone Modelle*, *Epochen* und *Lernraten* getestet.

3.3.1 Anwendung in Arcgis Pro

Klassifikationen in *Arcgis Pro* sind durch übersichtliche Strukturen und Werkzeuge charakterisiert. Dies zieht sich auch in der Anwendung mit *Deep Learning* durch. Aufgrund dessen, dass die Klassifikation pixelbasiert abläuft und die Entscheidungsgrundlage auf das kleinste Element des Inputs, dem Pixel, basiert, sind keine Zwischenschritte — z.B. Objektsegmentierungen — erforderlich, um das Modell auf das zu klassifizierende Bild anzuwenden. Die erforderlichen Schritte sind in Abbildung 19 und 20 abgebildet und verbildlichen die direkte, unmittelbare Umsetzung der *Semantischen Segmentierung*. Abbildung 19 zeigt, dass ein Eingaberaster und eine Modelldefinition als Input für den Prozess ausreichend sind. Zusätzlich ist es möglich Parameter bzw. Argumente zu adjustieren, was jedoch optional ist. Abbildung 20 zeigt eine Gegenüberstellung des Eingaberasters (siehe Abbildung 20a) und der resultierenden Klassifikation (siehe Abbildung 20b).

Es ist hervorzuheben, dass keine weiteren Zwischenschritte notwendig sind. Zudem besteht auf der offiziellen *Esri* Homepage die Möglichkeit, vortrainierte *Deep Learning* Modelle zu gewissen Thematiken und Klassifikationen zu erhalten. Diese können die vorangehenden Schritte des Sampleexports und Trainings ersparen. Zu beachten ist jedoch, dass diese vortrainierten Modelle nicht an das spezifische Untersuchungsgebiet adjustiert sind — z.B. unterschiedliche geometrische und spektrale Auflösungen — und es zu Fehlermeldungen während des Prozesses kommen kann. Die *Arcgis Pro* Software punktet somit mit einem übersichtlichen Ablauf und einem umfangreichen, zur Verfügung gestellten Service (vgl. *Esri* 2022f).

ARCGIS PRO „CLASSIFY PIXELS USING DEEP LEARNING“ TOOL

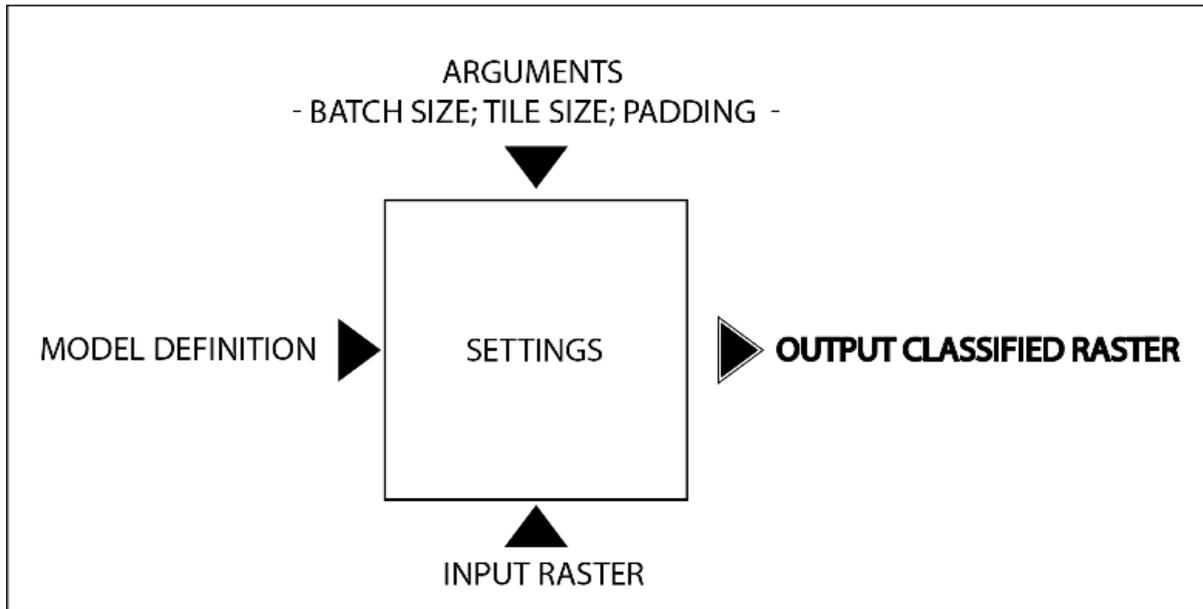


Abbildung 19: Schematische Darstellung der pixelbasierten Klassifikation in Arcgis Pro. Quelle: eigene Darstellung.

Anwendung Deep Learning Arcgis Pro

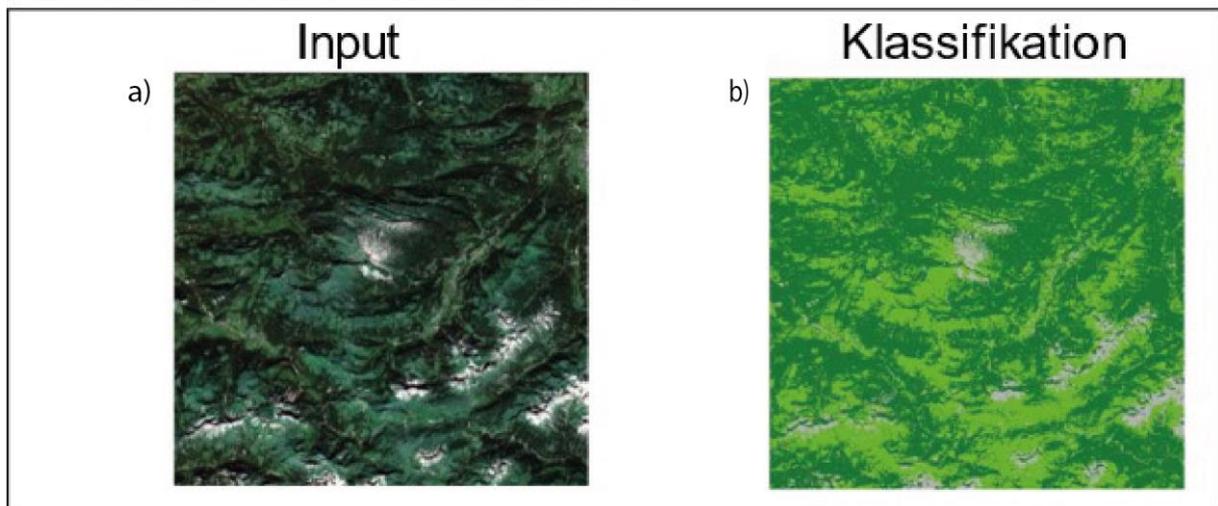


Abbildung 20: Anwendung der pixelbasierten Klassifikation in Arcgis Pro. Quelle: eigene Darstellung.

3.3.2 Anwendung eCognition

In *eCognition* ist DL andererseits nicht direkt für eine Klassifikation nutzbar. Vielmehr handelt es sich dabei um eine Kombination aus *Object Based Image Analysis* (OBIA) — objektbasiertes Klassifikationsverfahren — und CNN. Während die pixelbasierte Anwendung in *Arcgis Pro* die *Semantic Segmentation* direkt am Pixel ausübt, muss diese in der OBIA-Anwendung auf Objektsegmentierungen übertragen werden. Die Abbildungen 21-23 sollen diese Kombination aus OBIA und CNN verdeutlichen. Wie in Abbildung 21a gezeigt wird, erfolgt zuerst die Anwendung des CNN auf der Pixelebene. Als Input dienen Eingaberaster und das trainierte Modell. Als Output ergeben sich sogenannte *Heatmaps* (siehe Abbildung 22) — vergleichbar mit *Feature Maps* die aus der *Convolution* resultieren —, welche aus der Anwendung des künstlichen neuronalen Netzwerkes auf das zu klassifizierende Bild herausgehen. Pro Klasse wird eine solche *Heatmap* ausgegeben, welche die Wahrscheinlichkeit der Klassenzugehörigkeit auf der Erdoberfläche visualisiert. Blaue Werte symbolisieren niedrige Wahrscheinlichkeiten und rote Werte hohe Wahrscheinlichkeiten, wobei diese einem Wertebereich von 0 bis 1 zugeordnet werden. Anhand des Beispiels aus Abbildung 22 werden somit sieben zusätzliche Layer ausgegeben, welche zusammengefügt die Informationen bzw. die Entscheidungen der KI bezüglich der Klassifikation enthalten (vgl. Turner et al. 2021, S. 211f).

Bevor die Klassifikation auf der Objektebene durchgeführt wird, ist die Generierung einer *Segmentierung* nötig (siehe Abbildung 21b). Für die *Segmentierung* hochauflösender Bilddaten eignet sich besonders ein Bottom-up-Verfahren, wie beispielsweise eine *Multiresolution Segmentation* (Turner et al. 2021). Hierbei werden einzelne Pixel — mit ähnlichen Eigenschaften — zu Gruppen zusammengefasst. Diese kann bereits vor der Anwendung des *Deep Learning* Modells und der Ausgabe der *Heatmaps* erstellt werden, kann aber auch unmittelbar vor der Klassifikation generiert werden. Bei der Multiresolution gibt es verschiedene Parameter wie beispielsweise die Skalierung, die Form oder die Kompaktheit der Segmente. Diese müssen so gewählt werden, dass die in der Untersuchung betrachteten Klassen sinnvoll wiedergegeben werden (vgl. ebd., S. 52).

Die Klassifikation (siehe Abbildung 21c) der Objekte erfolgt schließlich auf Basis der Klassenzugehörigkeit, der *Membership Function*, welche mit den *Heatmaps* erstellt wurden. Infolgedessen werden Objekte den dementsprechenden Klassen zugeordnet. Die höchste

Wahrscheinlichkeit für die Zuordnung der Objekte setzt sich durch und bestimmt somit die Klassenzugehörigkeit. Wie sich somit (siehe Abbildung 23) zeigen lässt, sind in *eCognition* zwei Zwischenschritte nötig. Neben dem Eingaberaster (siehe Abbildung 23 a) werden zusätzlich eine *Segmentierung* (siehe Abbildung 23b) und *Heatmaps* (siehe Abbildung 23c) benötigt, um vom trainierten CNN zur Klassifikation zu (siehe Abbildung 23d) gelangen. Die DL-Anwendung in *eCognition* erfordert in dieser Hinsicht einen größeren Arbeitsaufwand.

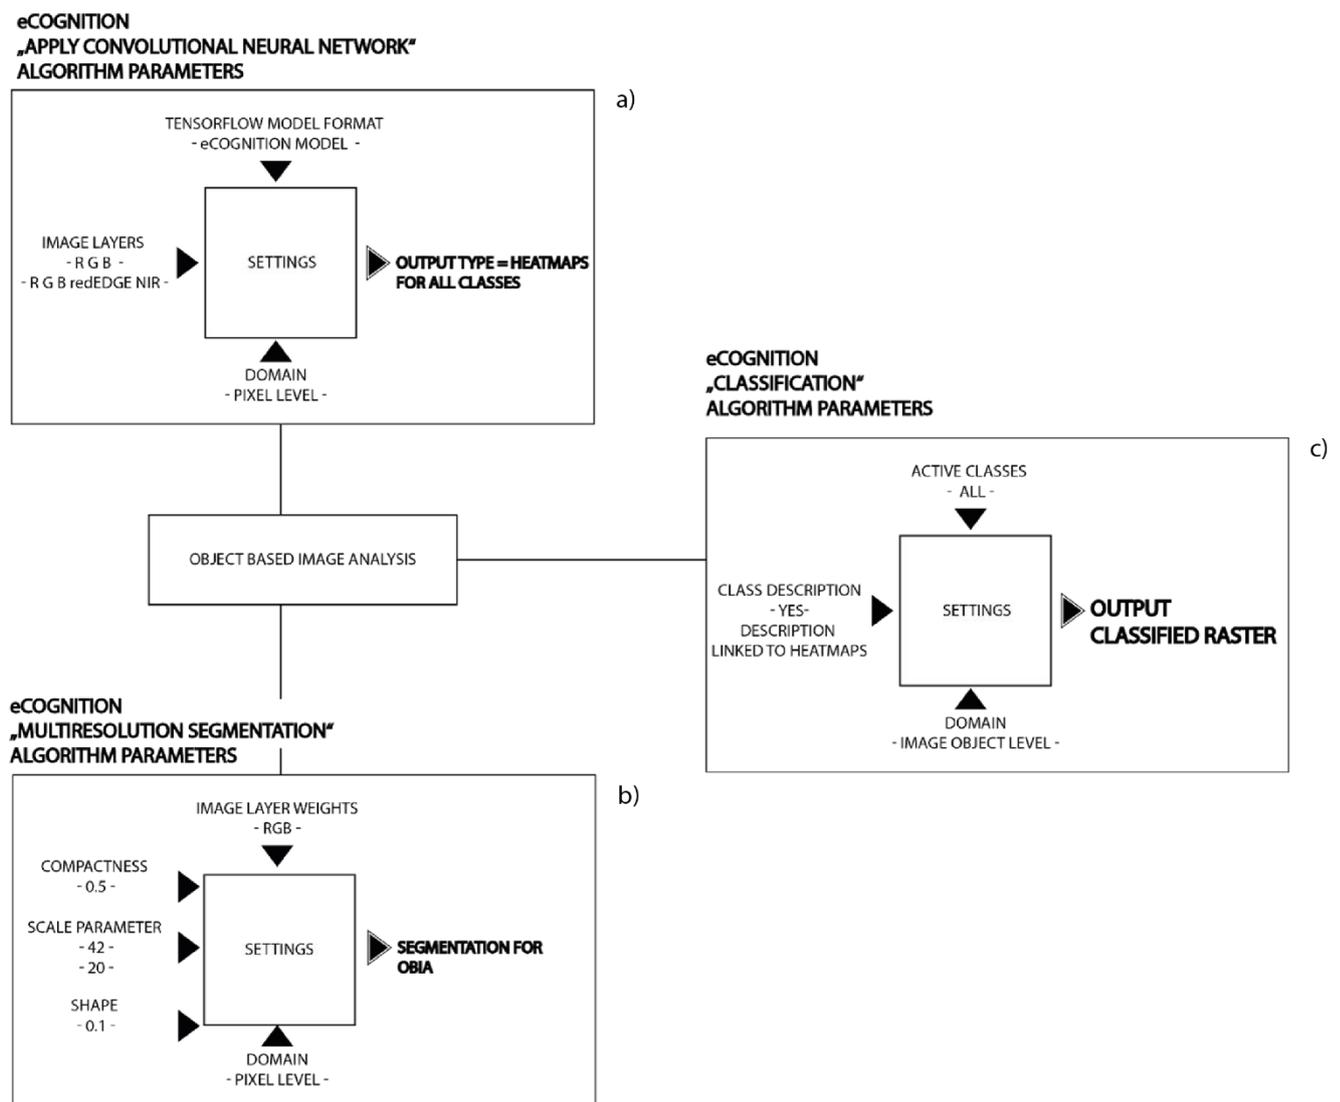


Abbildung 21: Schematische Darstellung der objektbasierten Klassifikation in eCognition. Quelle: eigene Darstellung.

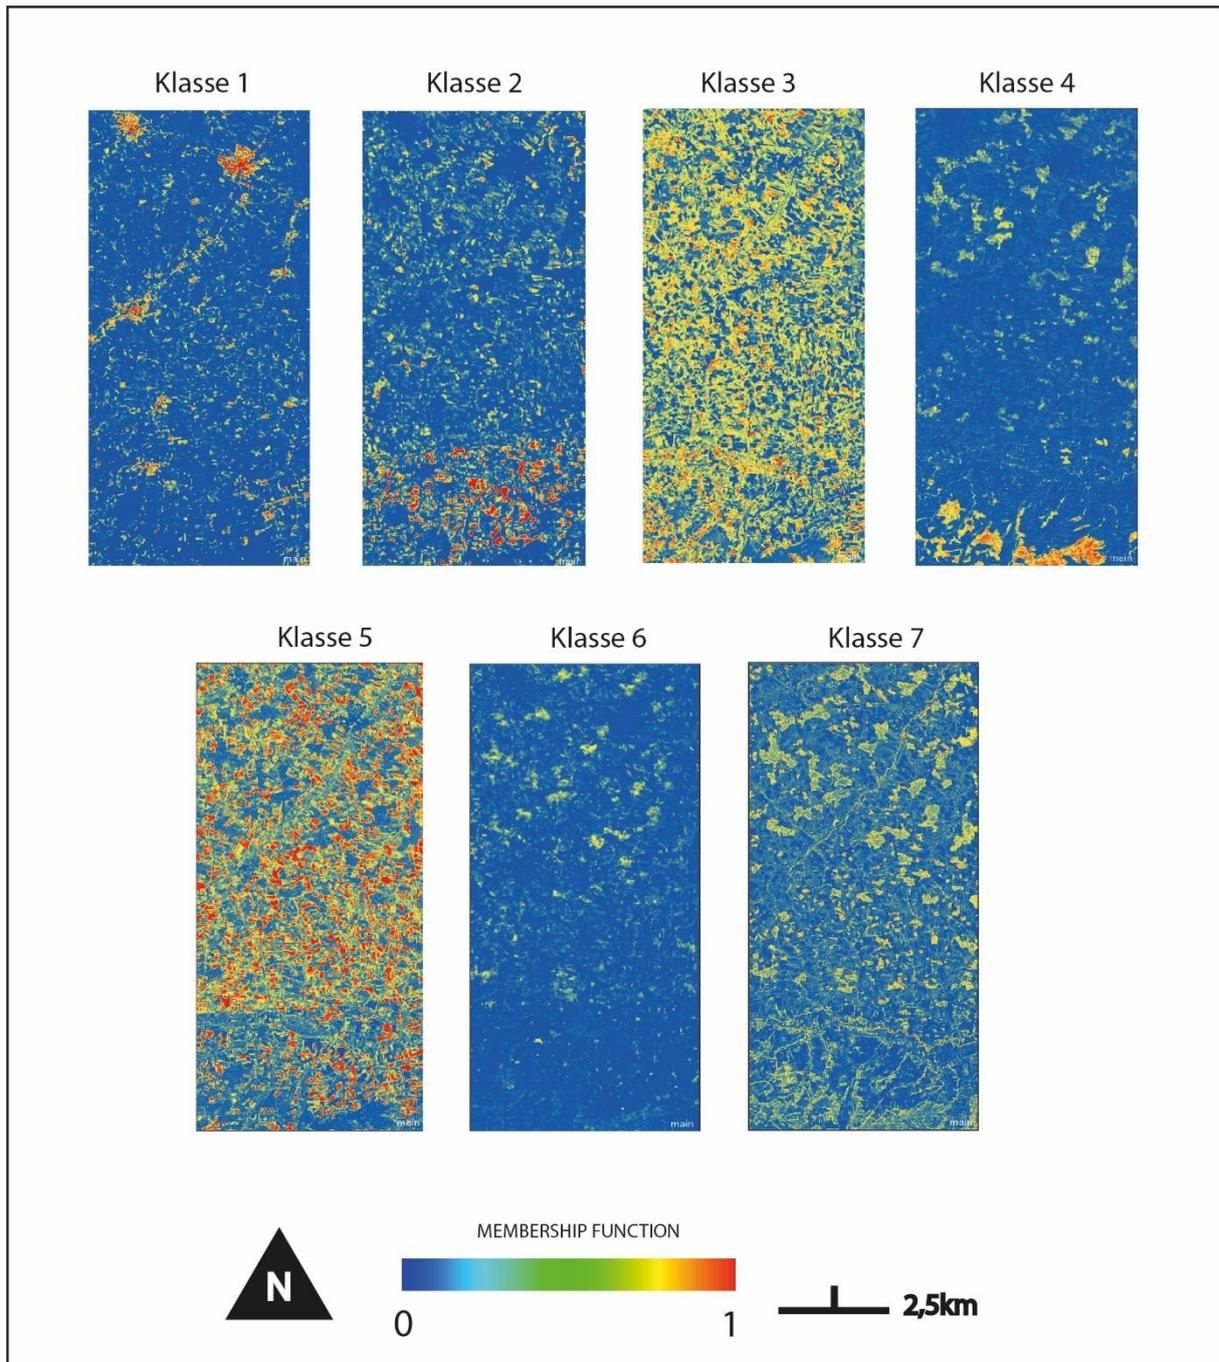


Abbildung 22: Heatmaps als Zwischenschritt zur objektbasierten Klassifikation in eCognition. Quelle: eigene Darstellung.

Anwendung Deep Learning eCognition

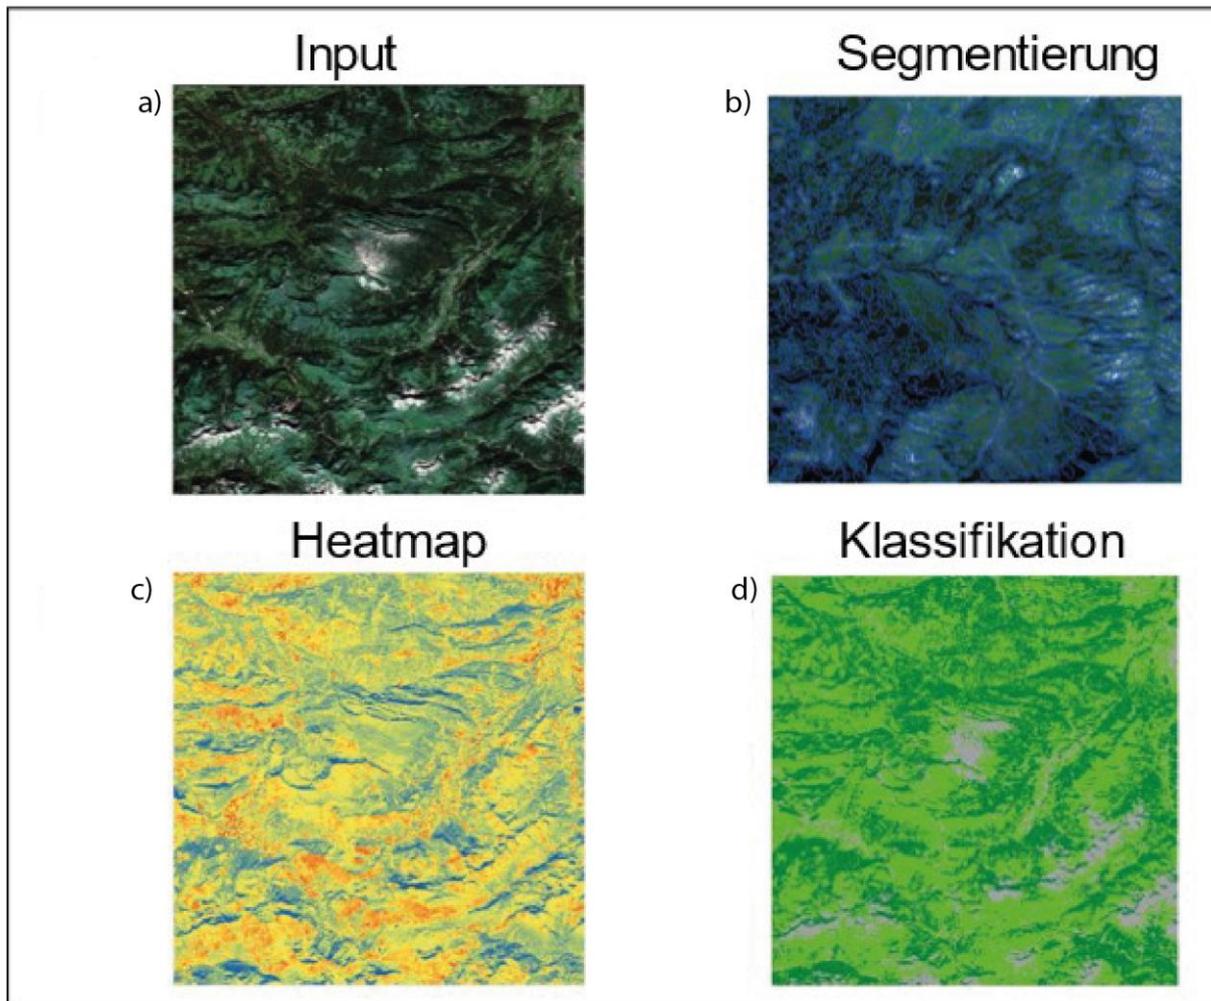


Abbildung 23: Anwendung der objektbasierten Klassifikation in eCognition. Quelle: eigene Darstellung.

4 Ergebnisse

Die Methodenkombinationen aus DL bzw. SL und pixelbasierten bzw. objektbasierten Verfahren wurden anhand der vorgestellten Herangehensweise in Kapitel 3 getestet. Anhand von sieben Szenen aus dem bereitgestellten Testgebiet (siehe Abbildung 24) werden die Ergebnisse bzw. die Genauigkeitsbewertungen der besten Methoden vorgestellt, wobei der *Random Forest* (RF) Algorithmus in der Testphase bessere Ergebnisse erzielte als der *K-Nearest Neighbor* Algorithmus und des Weiteren zum Vergleich mit den jeweiligen DL-Methoden herangezogen wird. Für die ausgewählten Szenen wurde geachtet, eine repräsentative Auswahl zu treffen und möglichst alle Klassen darzustellen.

Genauigkeitsbewertungen ermitteln dabei die Güte der Landbedeckungsklassifikation. Bei der *Overall Accuracy* (OA) handelt es sich, anders als bei internen Validierungen der trainierten Modelle, um eine unabhängige Variante der Testung bzw. Evaluierung, die für den Vergleich der Ergebnisse herangezogen wird. Der Genauigkeitswert wird dabei als relative Richtigkeit definiert, bei der ein klassifiziertes Bild und eine vermeintlich der Grundwahrheit entsprechenden Referenzdatei verglichen werden. Dies kann in einer Fehlermatrix, auch Konfusionsmatrix, dargestellt werden. Die OA ermittelt dabei den allgemeinen, klassenübergreifenden Genauigkeitswert. Neben der OA eignet sich auch der sogenannte Kappa-Koeffizient zur statistischen Bewertung der Klassifikationsgüte. Mit diesem wird überprüft, ob die Übereinstimmung von Zufallsereignissen geprägt ist. Die Werte des Kappa-Koeffizienten reichen von -1 bis 1, wobei 1 einer vollkommenen Übereinstimmung und einem Ausschließen von Zufallswerten entspricht, während niedrige und negative Werte eine schlechte Übereinstimmung darstellen. Tabelle 10 stellt die Übereinstimmung dar, die mit bestimmten κ -Wertebereichen einhergehen und dient als Hilfestellung die Klassifikationsergebnisse besser zu interpretieren (vgl. Altman 1991, S. 404f). Zudem soll die Hinzunahme von *Producer Accuracy* (PA) und *User Accuracy* (UA) einen quantitativen Vergleich der verwendeten Methodenkombinationen für die individuellen Klassen ermöglichen. Die PA wird berechnet, indem die Summe an richtig klassifizierten Pixeln – der betrachteten Klasse – durch die Summe an referenzierten Pixeln jener Klasse dividiert wird. Die PA gibt somit die Wahrscheinlichkeit an, mit der die Landbedeckung, welche in der Realität vorkommt, auch als solche klassifiziert wird. Die UA wird berechnet, indem die Summe an

richtig klassifizierten Pixeln – der betrachteten Klasse – durch die Summe an Pixeln, welche insgesamt jener Klasse zugeordnet werden, dividiert wird. Die UA gibt somit die Wahrscheinlichkeit an, mit welcher die Klassifikationsergebnisse der vermeintlichen Realität entsprechen. Basierend auf diesen Werten lassen sich Aussagen zu unter- bzw. überklassifizierten Landbedeckungen machen. Dies zeigt unter anderem, in welcher Hinsicht das Labeln der Trainingsdaten und das Zusammenfassen von Klassen für die *Deep Learning* Anwendung von Relevanz sind. In dieser Art lässt sich zusätzlich zur qualitativen Beschreibung auch ein quantitatives Maß ermitteln, mit dem die Genauigkeit von Landbedeckungsklassifikationen dargestellt werden kann (vgl. Janssen u. van der Wel 1994, S. 421ff).

Tabelle 10: κ -Werte und deren Aussagen über Übereinstimmungen. Quelle: verändert nach Altmann 1991, S. 404.

κ -Wert	Übereinstimmung
<0,20	sehr gering
0,21-0,40	gering
0,41-0,60	moderat
0,61-0,80	gut
0,81-1,00	sehr gut

Testgebiet

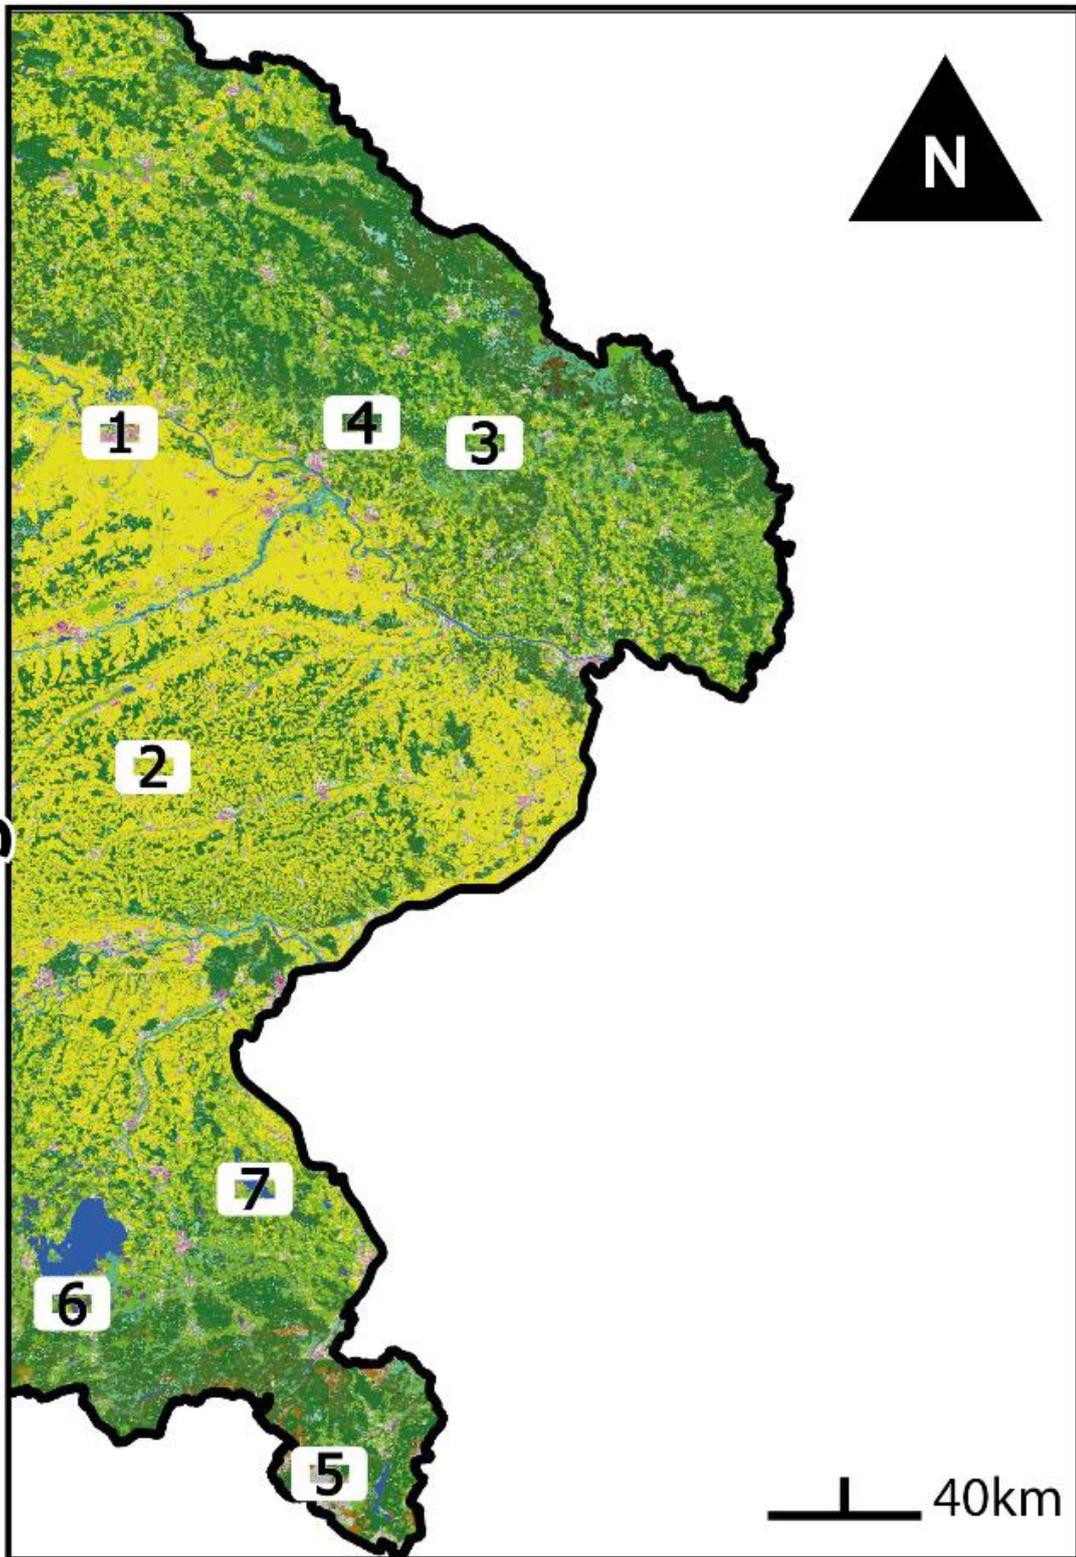


Abbildung 24: Übersicht der 7 Auszüge zu den Ergebnissen. Quelle: eigene Darstellung.

Des Weiteren werden die Ergebnisse präsentiert. Um sich einen Überblick über die Ergebnisse zu verschaffen, ist es sinnvoll die erreichten OA- und κ -Werte der Methoden (siehe Tabelle 11) zu betrachten. Die *Arcgis Pro Deep Learning* Methode hat dabei besserer Werte erzielen können als die verglichenen Methoden und ist hervorzuheben. Mit einer OA von 75% bzw. 84% und κ -Werten von 0,69 bzw. 0,77 liefert die *Arcgis Pro Deep Learning* Methode nach Altman (1991) gute bis sehr gute Ergebnisse. Die RF-Methode in *Arcgis Pro* erreicht im Gegensatz dazu nur OA-Werte von 34% (LBM1) bzw. 56% (LBM2) und κ -Werte von 0,27 (LBM1) bzw. 0,43 (LBM2) und weist somit nur geringe bis moderate Übereinstimmungen auf. Die *eCognition Deep Learning* Methode erreicht OA-Werte von 40% (LBM1) bzw. 62% (LBM2) und κ -Werte von 0,29 (LBM1) bzw. 0,45 (LBM2), welche nahezu mit der RF-Methode in *eCognition* gleichzusetzen sind. Diese erreichen OA-Werte von 43% (LBM1) bzw. 57% (LBM2) und κ -Werte von 0,34 (LBM1) bzw. 0,43 (LBM2), wobei es sich um geringe bis moderate Ergebnisse handelt.

Tabelle 11: Ergebnisse der Overall Accuracy und der κ -Werte nach Methode. Quelle: eigene Darstellung.

		Deep Learning [OA]	Deep Learning [κ]	Random Forest [OA]	Random Forest [κ]
Arcgis Pro	LBM1	75%	0,69	34%	0,27
	LBM2	84%	0,77	56%	0,43
eCognition	LBM1	40%	0,29	43%	0,34
	LBM2	62%	0,45	57%	0,43

Die folgenden Szenen sollen einen qualitativen Vergleich ermöglichen und werden folgend in den Abbildungen 25-38 dargestellt. Ein quantitativer Vergleich wird durch die Darstellung der OA-, PA- und UA-Ergebnisse der einzelnen Klassen in den Tabellen 12-25 ersichtlich. Für die Gegenüberstellung der Klassifikation und der Referenz wurde darauf geachtet, dass die Pixelgrößen — 5x5m — gleich sind und sowohl Pixelreihen als auch -spalten — 56024x22031 — die gleiche Anzahl haben. Es ist anzumerken, dass die Pixelanzahl im Output z.B. aufgrund von programminternen Rundungsfehlern variieren kann und somit insignifikante Abweichungen zwischen den Outputs der einzelnen Klassifikationen möglich sind. In den Anhängen 12-15 befinden sich die vollständigen Fehlermatrizen je Methode. Zudem befinden sich in den Anhängen 16-23 die Karten der Landbedeckungsklassifikationen, welche mit den verwendeten Methoden erstellt wurden. Zur Veranschaulichung des Vergleichs befinden sich in den Anhängen 24-27 Diagramme, welche die PA- und UA-Werte der einzelnen Klassen und Methoden miteinander vergleichen.

Szene 1 (siehe Abbildung 25 und Abbildung 26) enthält mit der Stadt Straubing und dem Fluss Donau zwei markante Landbedeckungen, auf die hier näher eingegangen wird.

Die Kombination aus pixelbasierter- und *Deep Learning* Methode liefern qualitativ und quantitativ gute Ergebnisse. Dies gilt für beide Darstellungen in LBM1 und LBM2. Sowohl die Klassen der fließenden Gewässer als auch die der versiegelten Siedlungsgebiete werden mit der *Arcgis Pro Deep Learning* Methode gut hervorgehoben. Ein Vergleich mit der Referenzszene zeigt, dass die KI die Trainingsdaten, sowohl in LBM1 als auch LBM2 Format, gut verarbeitet und das transferierte Wissen aus den Trainingsgebieten umsetzen kann.

Vergleicht man dazu die Klassifikation der *eCognition Deep Learning* Methode, ist zu beobachten, dass die Hauptklasse 3 überklassifiziert wird, wodurch Hauptklasse 1 — die markante LB der Szene — nur moderat klassifiziert wird. Die künstlichen neuronalen Netzwerke schaffen es zudem die bauliche Infrastruktur von natürlichen, felsigen Flächen zu unterscheiden, was ein großer Vorteil gegenüber den RF-Methoden bringt.

Quantitativ betrachtet werden die optischen Werte bestätigt. Die *Arcgis Pro Deep Learning Methode* erzielt auf die gesamte Klassifikation bezogen die besten Genauigkeitswerte. Die Tabellen 12 und 13 liefern dazu die Veranschaulichungen. Versiegelte und bebaute Flächen werden einerseits gut erkannt. Mischflächen andererseits werden sowohl mit DL- als auch RF-Methoden fehlklassifiziert. Klasse 5 und deren Subklassen werden so beispielsweise als versiegelte Flächen fehlklassifiziert.

Tabelle 12: Szene 1 - LBM2 – Producer- und User Accuracies pro Klasse und Methode. Quelle: eigene Darstellung.

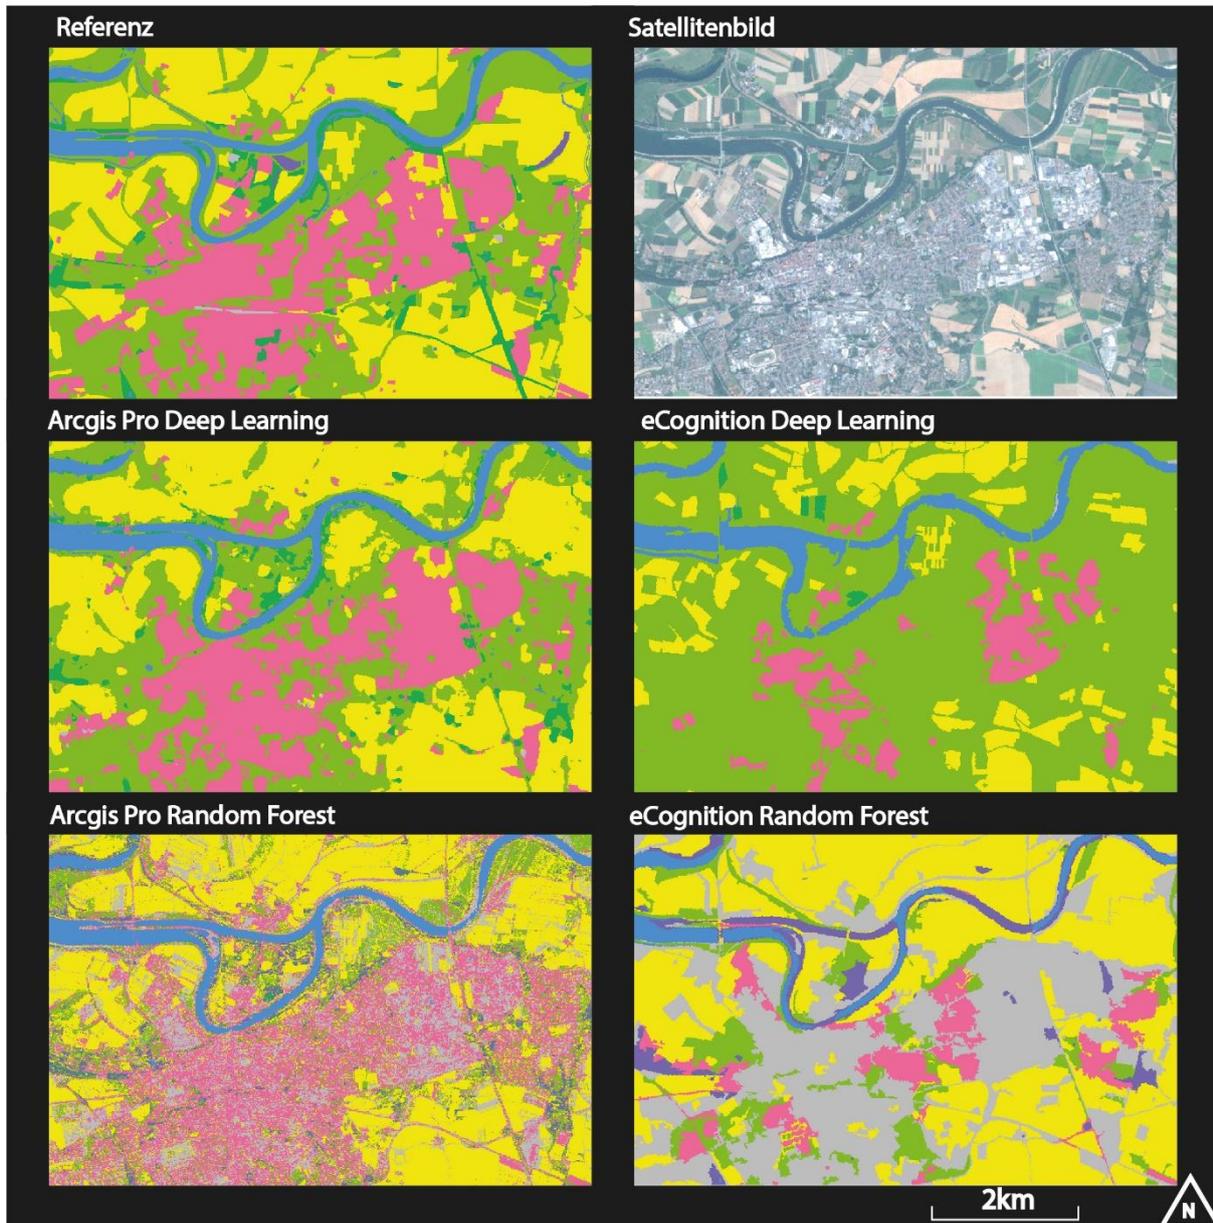
Arcgis Pro Deep Learning			eCognition Deep Learning		Arcgis Pro Random Forest		eCognition Random Forest	
Klasse	1	7	1	7	1	7	1	7
PA	42,1%	82,9%	18,9%	18,7%	52,3%	77,5%	15,9%	66,8%
UA	68,3%	92,1%	25,9%	72,0%	13,3%	73,6%	19,2%	24,8%

Tabelle 13: Szene 1 – LBM1 – Producer- und User Accuracies pro Klasse und Methode. Quelle: eigene Darstellung.

Arcgis Pro Deep Learning			eCognition Deep Learning		Arcgis Pro Random Forest		eCognition Random Forest	
Klasse	PA	UA	PA	UA	PA	UA	PA	UA
110	50,2%	61,9%	21,1%	25,6%	17,5%	15,6%	7,0%	11,0%
121	18,6%	86,4%	2,7%	2,4%	20,2%	2,7%	2,5%	3,2%
122	38,6%	47,3%	27,4%	9,5%	43,8%	2,9%	63,1%	2,6%
242	3,6%	41,9%	13,1%	1,3%	18,8%	0,3%	15,9%	0,8%

Ergebnisse Landbedeckungsklassifikation LBM2

Szene
1.



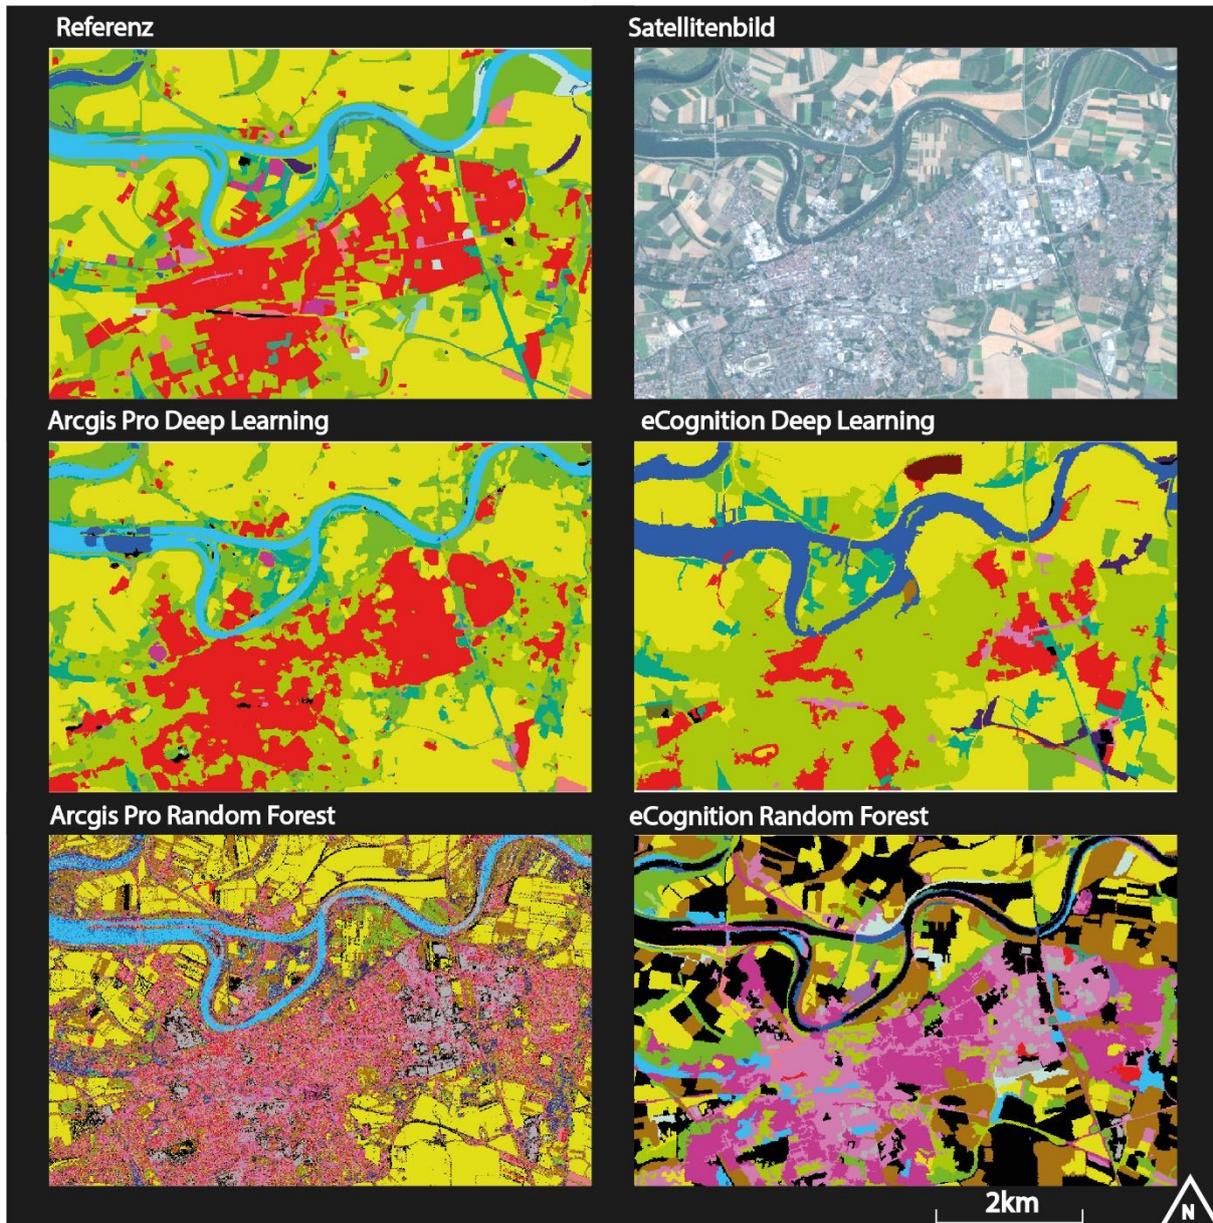
Legende

	1		5
	2		6
	3		7
	4		unklassifiziert

Abbildung 25: Ergebnisse der Landbedeckungsklassifikation in LBM2 Darstellung - Szene 1. Quelle: eigene Darstellung.

Ergebnisse Landbedeckungsklassifikation LBM1

Szene
1.



Legende

110	211	231	310	330	411	511
121	221	233	311	332	412	512
122	222	321	312	335	413	unklassifiziert
242	224		313		414	
			322			
			324			

Abbildung 26: Ergebnisse der Landbedeckungsklassifikation in LBM1 Darstellung - Szene 1. Quelle: eigene Darstellung.

Szene 2 (siehe Abbildung 27 und Abbildung 28) zeigt einen Ausschnitt des Testgebiets in der Region Niederbayern, welche vor allem durch Landwirtschaft geprägt ist. Ein Vergleich der Methoden und der Ergebnisse soll zeigen, inwiefern die Hauptklasse 2 und deren Subklassen klassifiziert wurden.

Bei einem qualitativen Vergleich der Szene stellt sich heraus, dass die *Arcgis Pro Deep Learning* Methode die vorkommende LB am genauesten gliedern kann. Sowohl die Landwirtschaft als auch vorkommende Siedlungsgebiete, Wald- und Grünflächen werden durch die KI erkannt, sodass die Strukturen dementsprechend wiedergegeben werden können.

Im Vergleich dazu ist die *eCognition Deep Learning* Methode weniger gut geeignet, wenn es darum geht, Siedlungsgebiete zu erkennen. Besonders auffällig ist jedoch die Überklassifikation der Grünflächen. Die RF-Methoden wiederum weichen in beiden Fällen von der Referenzdatei ab. Nichtsdestotrotz lassen sich die landwirtschaftlichen Muster, welche auf dem Satellitenbild zu sehen sind, gut wiedergeben. Ähnlich dem Ergebnis der Szene 1, gibt es mit RF-Methoden Komplikationen in der Unterscheidung von versiegelten, bewirtschafteten, und sandigen bzw. felsigen Flächen.

Der quantitative Vergleich, dargestellt in den Tabellen 14 und 15, zeigt, dass die *Arcgis Pro Deep Learning* Methode, sofern genug Trainingsdaten vorhanden sind, am zuverlässigsten ist. Obst- und Beerenobstbau sowie Hopfen sind Klassen, welche aufgrund des geringen Vorkommens in Bayern nahezu keine Trainingsgebiete liefern. Es ist somit vor allem zu sehen, dass SL-Methoden in solchen Fällen zu bevorzugen wären. Die niedrigen UA-Werte sind jedoch Indizien, dass auch SL-Methoden mit kleinflächigen Klassen Probleme haben, da auch diese Fehlklassifikationen aufweisen.

Tabelle 14: Szene 2 - LBM2 – Producer- und User Accuracies pro Klasse und Methode

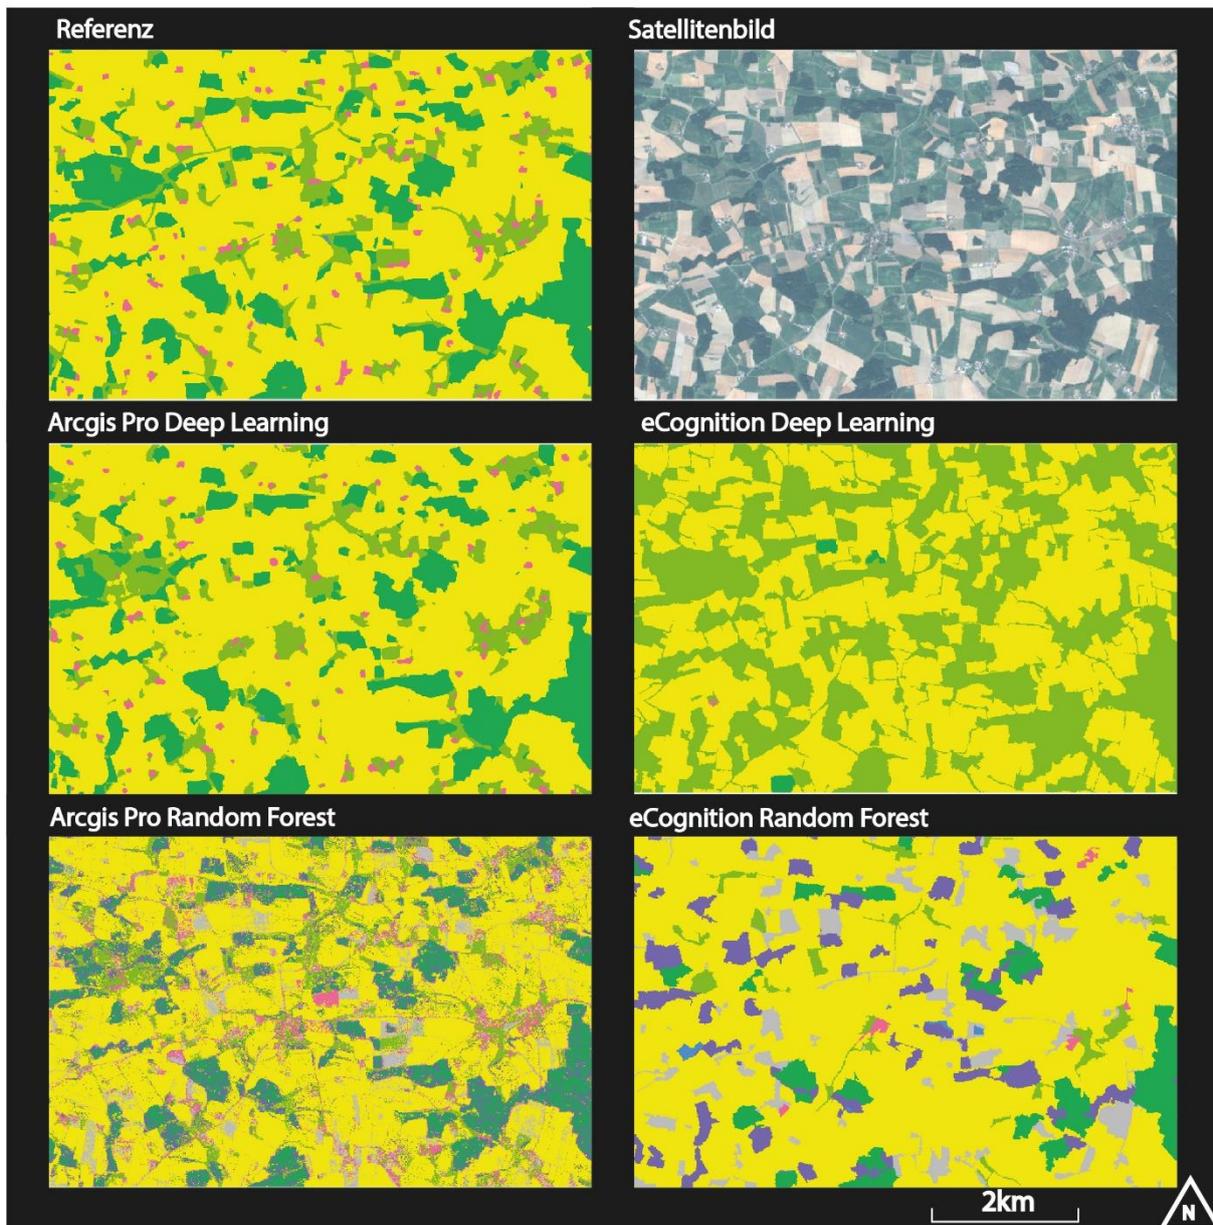
Arcgis Pro Deep Learning		eCognition Deep Learning		Arcgis Pro Random Forest		eCognition Random Forest	
Klasse	2	2	2	2	2	2	2
PA	80,1%	18,9%	52,3%	77,3%			
UA	68,3%	25,9%	13,3%	19,2%			

Tabelle 15: Szene 2 – LBM1 – Producer- und User Accuracies pro Klasse und Methode

Klasse	Arcgis Pro Deep Learning		eCognition Deep Learning		Arcgis Pro Random Forest		eCognition Random Forest	
	PA	UA	PA	UA	PA	UA	PA	UA
211	82,9%	88,8%	67,7%	64,8%	45,3%	88,9%	58,1%	72,8%
222	0,0%	0,0%	1,5%	0,2%	54,8%	0,4%	62,3%	0,5%
224	0,0%	0,0%	0,0%	0,0%	79,4%	0,0%	0,0%	0,0%

Ergebnisse Landbedeckungsklassifikation LBM2

Szene
2.



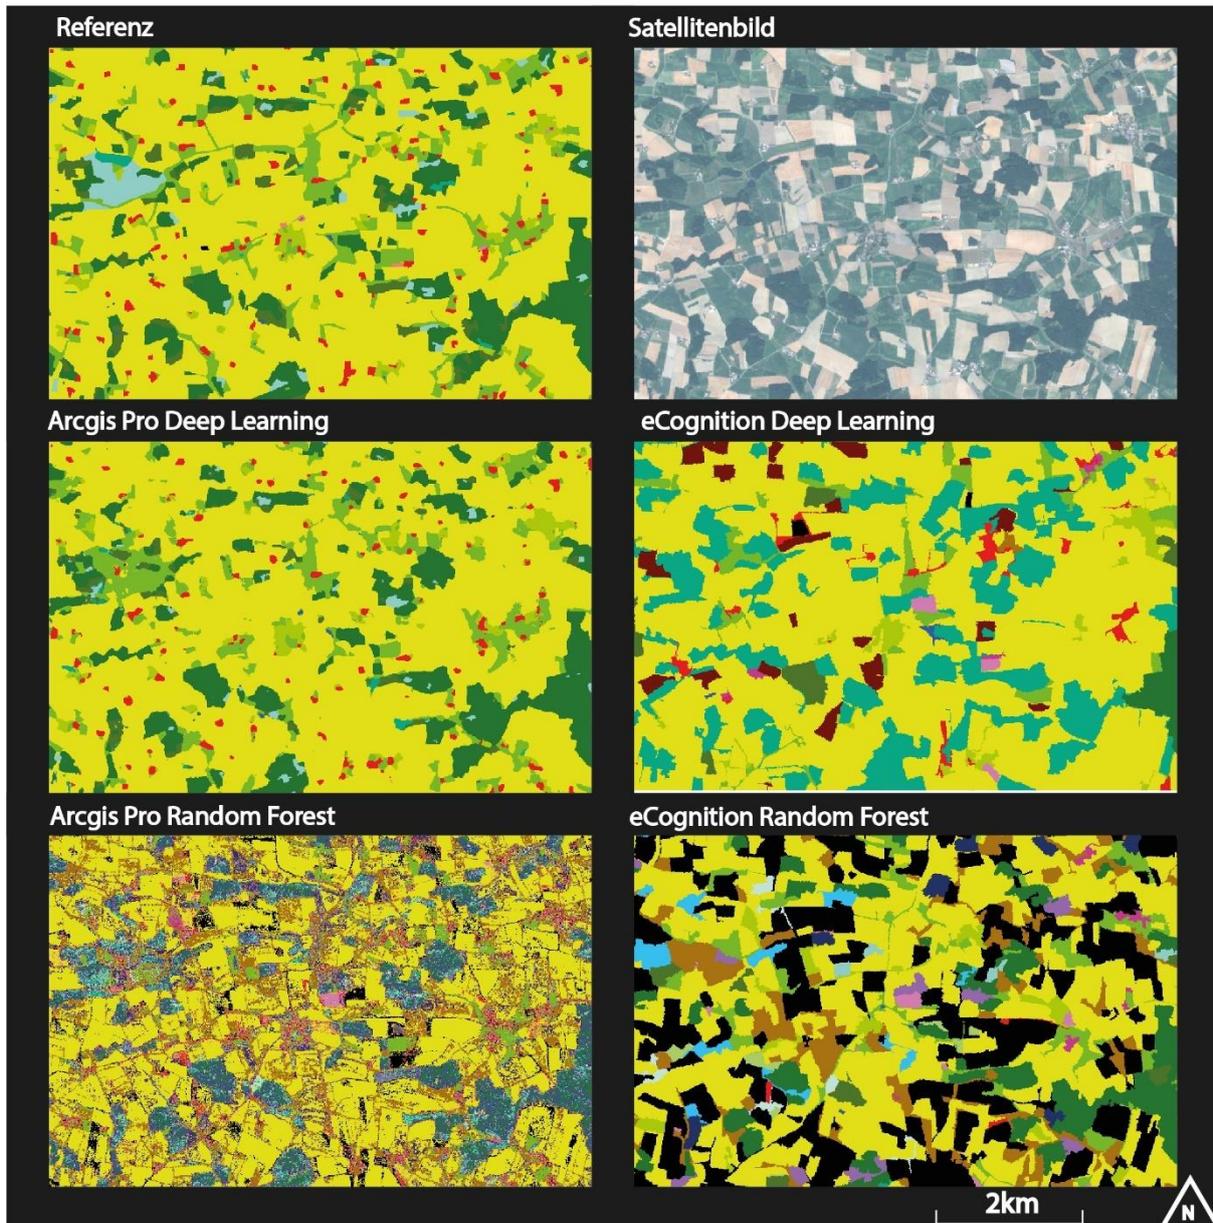
Legende

1	5
2	6
3	7
4	unklassifiziert

Abbildung 27: Ergebnisse der Landbedeckungsklassifikation in LBM2 Darstellung - Szene 2. Quelle: eigene Darstellung.

Ergebnisse Landbedeckungsklassifikation LBM1

Szene
2.



Legende

110	211	231	310	330	411	511
121	221	233	311	332	412	512
122	222	321	312	335	413	unklassifiziert
242	224		313		414	
			322			
			324			

Abbildung 28: Ergebnisse der Landbedeckungsklassifikation in LBM1 Darstellung - Szene 2. Quelle: eigene Darstellung.

Szene 3 (siehe Abbildung 29 und Abbildung 30) veranschaulicht die Klassifikationsergebnisse von Grünflächen im Bayerischen Wald. Das Charakteristische der Szene ist, dass der Wald die Kontinuität der Grünflächen unterbricht.

Im qualitativen Vergleich der Szenen und der Methoden zeigt sich, dass die *Arcgis Pro Deep Learning* Klassifikation am ehesten mit der Referenzdatei übereinstimmt. Die Hauptklassen 1, 2, 3 und 4 und deren Subklassen werden von den künstlichen neuronalen Netzwerken für den Interpreten gut dargestellt.

Die *eCognition Deep Learning* Methode wiederum ist von Fehlklassifikationen geprägt. Während die LBM2 Darstellung, die Strukturen der Referenz moderat errahnen lässt, ist die LBM1 Darstellung nahezu vollständig fehlklassifiziert. Homogenes Grünland wird fälschlicherweise als Laubwald klassifiziert. Zudem werden Klassen der Bebauung, der Feuchtgebiete und des Ackerlandes überklassifiziert.

Die RF-Methoden andererseits haben gegenüber den DL-Methoden den Nachteil, dass die unterschiedliche Strukturierung der Szene in LBM1 Darstellung zu Fehlklassifikationen führt. Die eigentlichen Grünflächen werden in diesem Fall zunehmend als Busch- und Strauchvegetation klassifiziert.

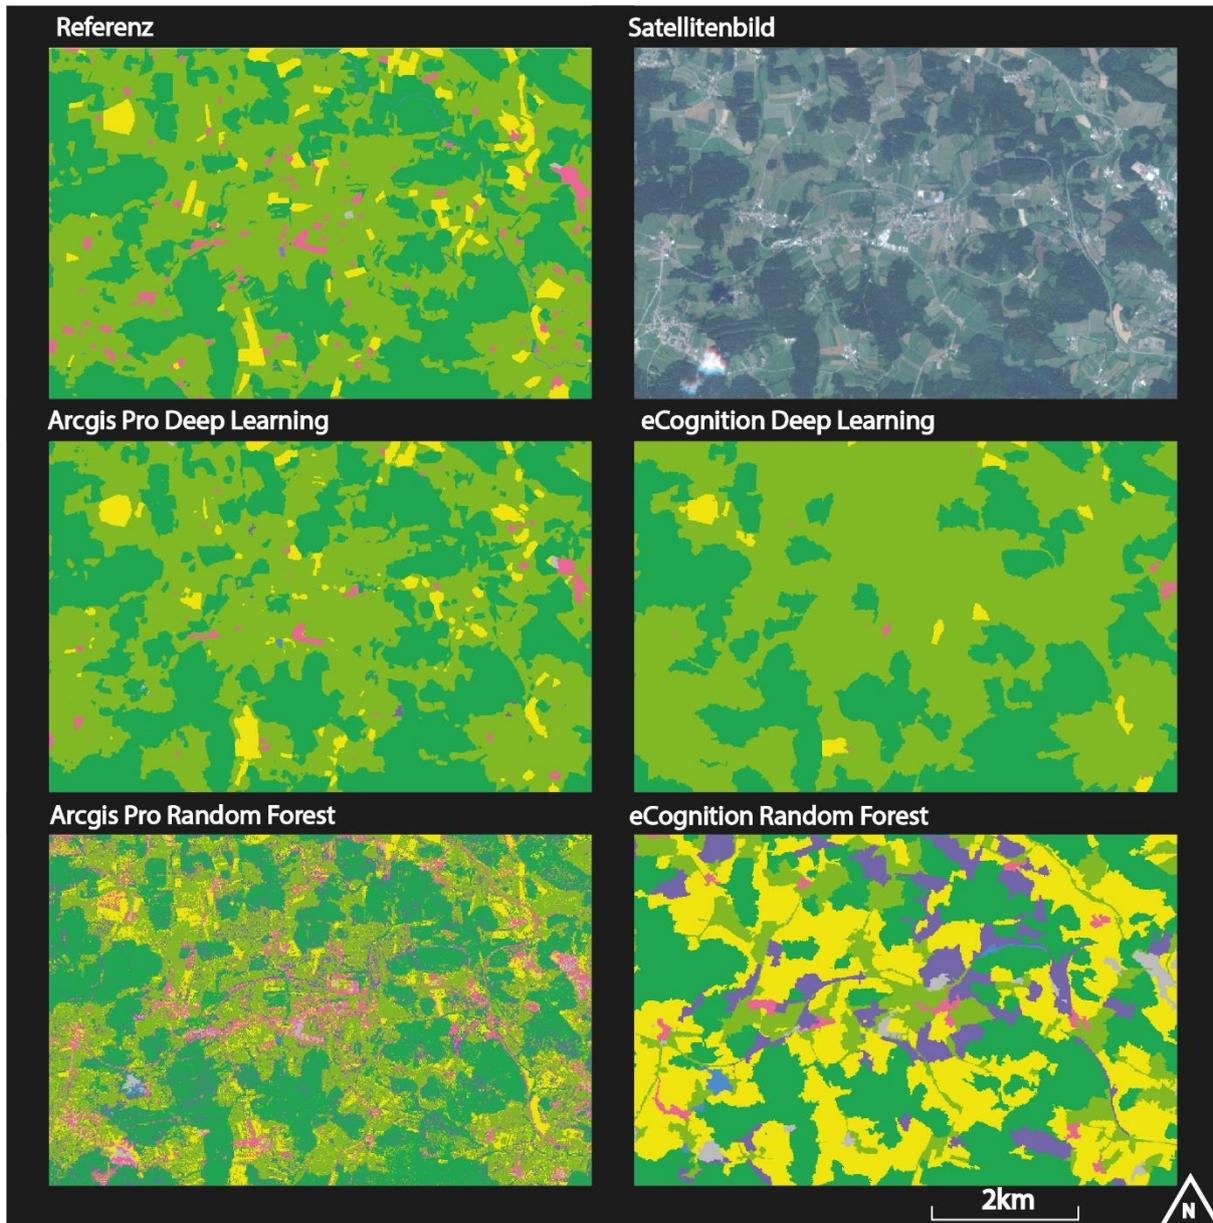
Der quantitative Vergleich (siehe Tabelle 16 und 17) zeigt, dass dies auch auf die gesamte Klassifikation zutrifft. Sowohl die LBM1- als auch die LBM2 Darstellung, basierend auf der *Arcgis Pro Deep Learning* Methode, erzielen konstante Werte.

Tabelle 16: Szene 3 - LBM2 – Producer- und User Accuracies pro Klasse und Methode. Quelle: eigene Darstellung.

	Arcgis Pro Deep Learning	eCognition Deep Learning	Arcgis Pro Random Forest	eCognition Random Forest
Klasse	3	3	3	3
PA	80,4%	66,0%	36,6%	20,7%
UA	71,7%	41,7%	59,4%	55,0%

Tabelle 17: Szene 3 – LBM1 – Producer- und User Accuracies pro Klasse und Methode. Quelle: eigene Darstellung.

	Arcgis Pro Deep Learning		eCognition Deep Learning		Arcgis Pro Random Forest		eCognition Random Forest	
Klasse	PA	UA	PA	UA	PA	UA	PA	UA
231	79,1%	71,2%	17,9%	60,2%	18,8%	56,2%	26,3%	56,2%
321	49,5%	53,3%	5,9%	28,0%	40,7%	7,7%	45,6%	7,8%
233	64,2%	61,4%	44,2%	36,8%	12,4%	13,2%	17,6%	31,1%



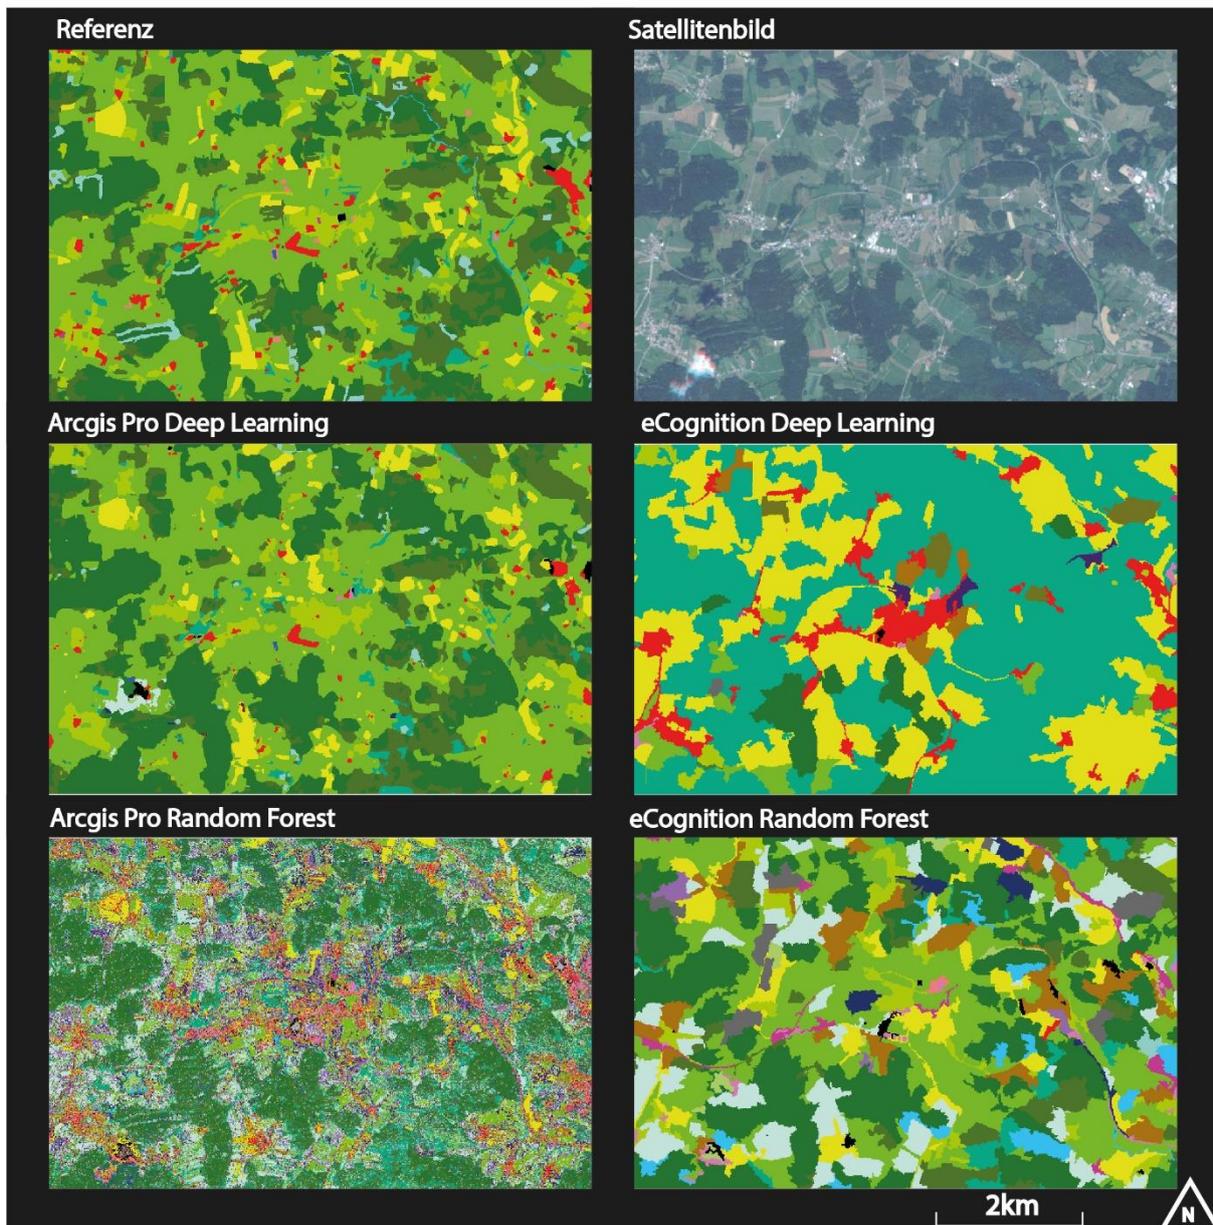
Legende

 1	 5
 2	 6
 3	 7
 4	 unklassifiziert

Abbildung 29: Ergebnisse der Landbedeckungsklassifikation in LBM2 Darstellung - Szene 3. Quelle: eigene Darstellung.

Ergebnisse Landbedeckungsklassifikation LBM1

Szene
3.



Legende

110	211	231	310	330	411	511
121	221	233	311	332	412	512
122	222	321	312	335	413	unklassifiziert
242	224		313		414	
			322			
			324			

Abbildung 30: Ergebnisse der Landbedeckungsklassifikation in LBM1 Darstellung - Szene 3. Quelle: eigene Darstellung.

Szene 4 (siehe Abbildung 31 und Abbildung 32) stellt einen Vergleich der Klassifikationsergebnisse im Bayerischen Wald dar und eignet sich vor allem, um Aussagen zur Genauigkeit von Forst- und Waldklassen zu treffen, da diese von Laub-, Nadel- und Mischwäldern geprägt wird.

Werden die Szenen erneut verglichen, ist feststellbar, dass die *Arcgis Pro Deep Learning* Methode optisch die besten Ergebnisse erzielt. Laub- und Nadelbäume werden überwiegend richtig wiedergegeben und auch die Mischverhältnisse derer werden von der KI erkannt.

Eine Erkenntnis, die aus dieser Betrachtung hervorgeht und durchaus Erwähnung in dieser Arbeit finden sollte, ist, dass die unterschiedlichen Lichtverhältnisse bzw. die hohen Kontrastunterschiede der zu einem Mosaik zusammengesetzten Satellitenszenen die Klassifikation mitbeeinflussen. Sowohl die RF-Methoden als auch die *eCognition Deep Learning* Methoden sind davon betroffen. Dies zeigt sich in abrupten Übergängen zwischen den klassifizierten Klassen, oder der Klassifikation von Flächen als, in dieser Szene nicht vorkommender, Sumpf- und Moorgebiete. Zudem werden überwiegend in eCognition die Grünflächen als Waldflächen fehlklassifiziert.

In den Tabellen 18 und 19 werden erneut die Genauigkeitswerte je Klasse und Methode miteinander verglichen. Die *Arcgis Pro Deep Learning Methode* erweist sich als bevorzugte Methode, wobei Unstetigkeiten zwischen den Klassen der LBM1 zu sehen sind. Vor allem die Klassifikation von Busch- und Strauchvegetation führt zu keinen verlässlichen Genauigkeitswerten.

Tabelle 18: Szene 4 - LBM2 – Producer- und User Accuracies pro Klasse und Methode. Quelle: eigene Darstellung.

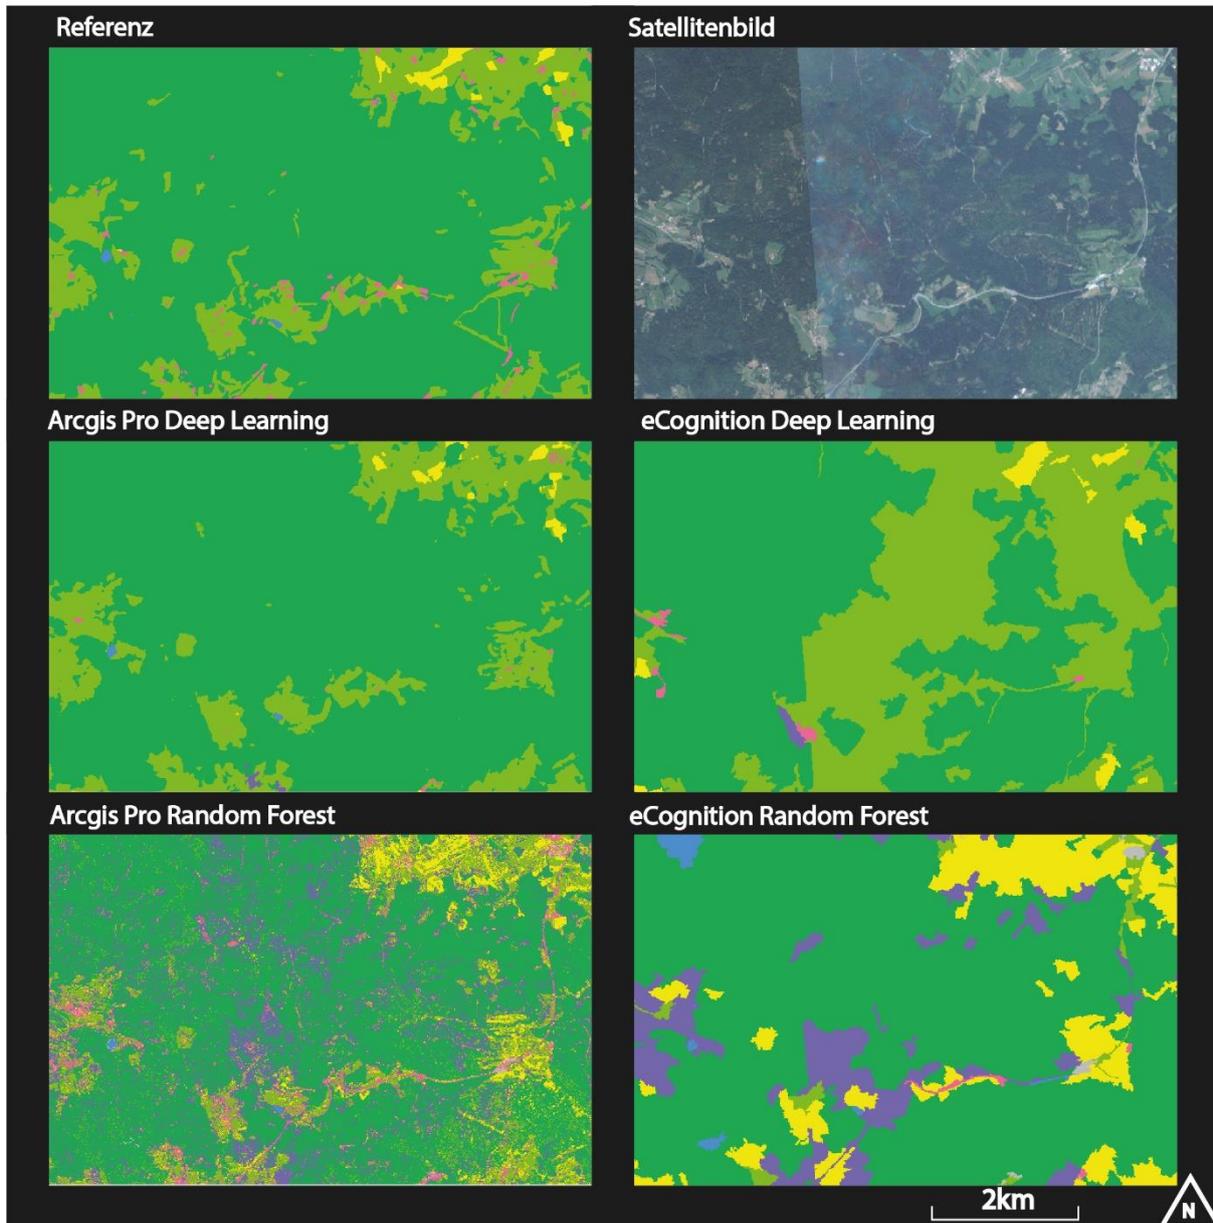
Arcgis Pro Deep Learning		eCognition Deep Learning	Arcgis Pro Random Forest	eCognition Random Forest
Klasse	4	4	4	4
PA	95,3%	66,3%	71,8%	71,9%
UA	92,5%	83,4%	88,9%	89,8%

Tabelle 19: Szene 4 – LBM1 – Producer- und User Accuracies pro Klasse und Methode. Quelle: eigene Darstellung.

Klasse	Arcgis Pro Deep Learning		eCognition Deep Learning		Arcgis Pro Random Forest		eCognition Random Forest	
	PA	UA	PA	UA	PA	UA	PA	UA
322	42,7%	56,5%	0,8%	12,6%	27,7%	4,5%	52,8%	7,0%
324	0,1%	23,7%	0,0%	0,0%	8,2%	1,5%	0,9%	2,7%
310	27,9%	47,0%	0,3%	6,9%	14,0%	4,6%	3,1%	6,7%
311	46,7%	56,0%	47,0%	9,0%	28,7%	18,4%	22,3%	28,3%
312	88,4%	77,4%	48,3%	55,6%	45,9%	75,7%	75,8%	69,3%
313	59,3%	64,5%	11,4%	23,6%	25,6%	42,0%	19,4%	49,9%

Ergebnisse Landbedeckungsklassifikation LBM2

Szene
4.



Legende

1	5
2	6
3	7
4	unklassifiziert

Abbildung 31: Ergebnisse der Landbedeckungsklassifikation in LBM2 Darstellung - Szene 4. Quelle: eigene Darstellung.

Ergebnisse Landbedeckungsklassifikation LBM1

Szene
4.

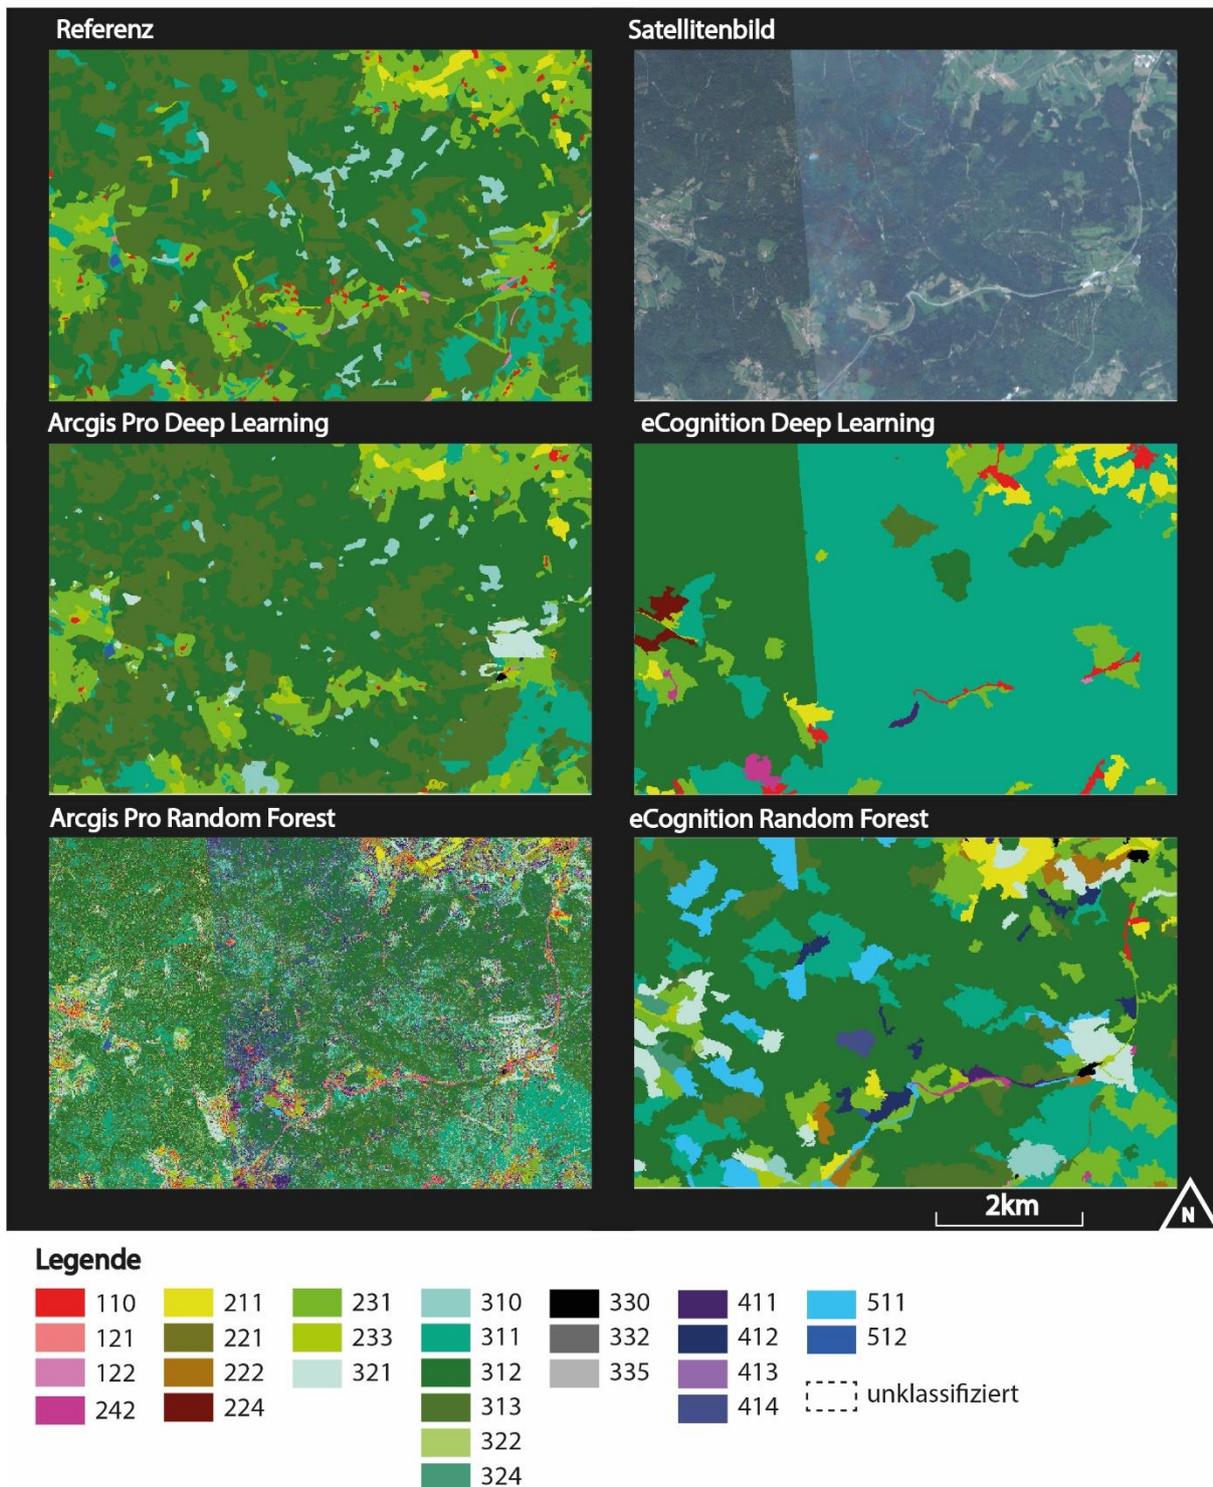


Abbildung 32: Ergebnisse der Landbedeckungsklassifikation in LBM1 Darstellung - Szene 4. Quelle: eigene Darstellung.

Szene 5 (siehe Abbildung 33 und Abbildung 34) zeigt einen Ausschnitt der Alpen bei Ramsau bei Berchtesgaden. Als Teil der Nördlichen Kalkalpen ist dieser Ausschnitt von schroffen und steilen Geländen geprägt.

Während die bereits vorgestellten Szenen durch die *Arcgis Pro Deep Learning* Methode begünstigt wurden, lässt sich grundsätzlich festhalten, dass in Bezug zu Szene 5 die RF-Methoden optisch gute Ergebnisse erzielen. Die DL-Methoden sind teilweise lückenhaft und unklassifiziert. Eine Erklärung hierfür liegt in der kaum vorhandenen Anzahl an Trainingsdaten der Hauptklasse 5. Gebirgsflächen sind in Bayern prozentuell betrachtet kaum vorhanden, was sich auf die Verfügbarkeit der Trainingsdaten und wiederum auf den Lernprozess auswirkt. Die DL-Methoden sind so von unklassifizierten Flächen durchzogen, welche den Mangel an spezifischen Trainingsgebieten bezeugen. Nichtsdestotrotz sind die RF-Methoden nicht fehlerlos. Sand, Stein und Erde werden im hohen Ausmaß als versiegelte Flächen — u.a. Asphalt, Beton etc. — klassifiziert.

Wie aus dem quantitativen Vergleich (siehe Tabelle 20 und 21) hervorgeht, ist die *Arcgis Pro Deep Learning* Methode in der Klassifikation von Sand, Stein, Erde und Fels jedoch besser als die RF-Methoden. Einzig Schnee und Eis lassen sich mit den DL-Methoden kaum feststellen.

Tabelle 20: Szene 5 - LBM2 – Producer- und User Accuracies pro Klasse und Methode. Quelle: eigene Darstellung.

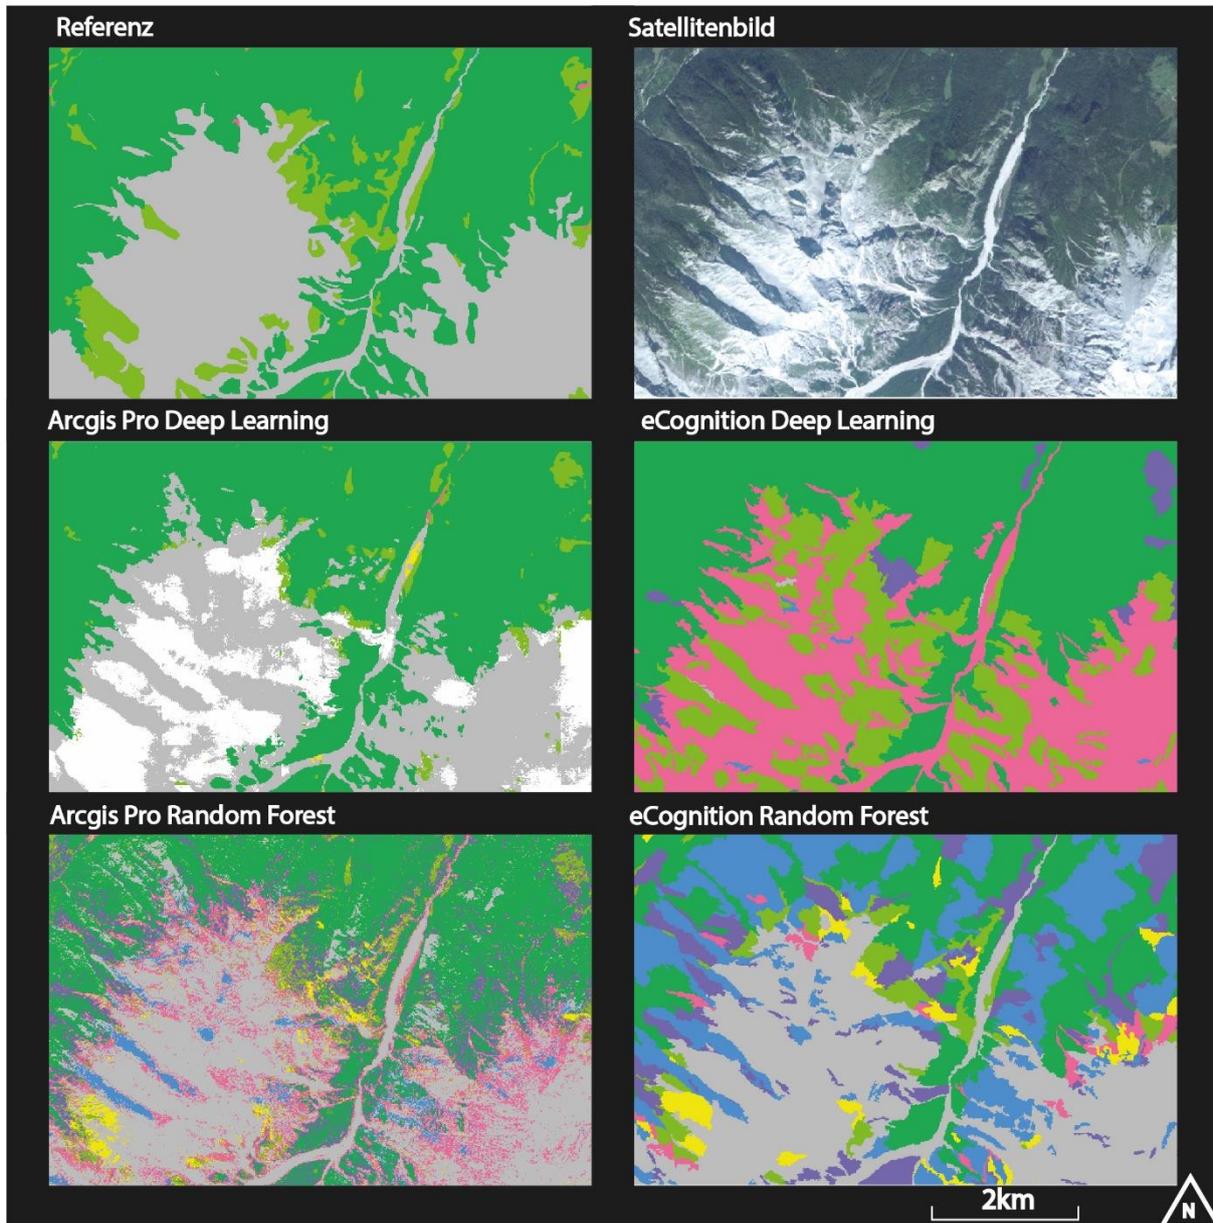
Arcgis Pro Deep Learning		eCognition Deep Learning	Arcgis Pro Random Forest	eCognition Random Forest
Klasse	5	5	5	5
PA	51,3%	7,1%	55,1%	57,8%
UA	69,8%	35,4%	12,4%	14,7%

Tabelle 21: Szene 5 – LBM1 – Producer- und User Accuracies pro Klasse und Methode. Quelle: eigene Darstellung.

Klasse	Arcgis Pro Deep Learning		eCognition Deep Learning		Arcgis Pro Random Forest		eCognition Random Forest	
	PA	UA	PA	UA	PA	UA	PA	UA
330	37,9%	49,9%	24,2%	39,2%	23,0%	8,7%	36,2%	3,6%
332	44,9%	62,1%	19,8%	21,0%	38,9%	21,2%	2,5%	2,1%
335	0,0%	0,0%	42,4%	0,0%	85,4%	0,6%	98,3%	1,2%

Ergebnisse Landbedeckungsklassifikation LBM2

Szene
5.



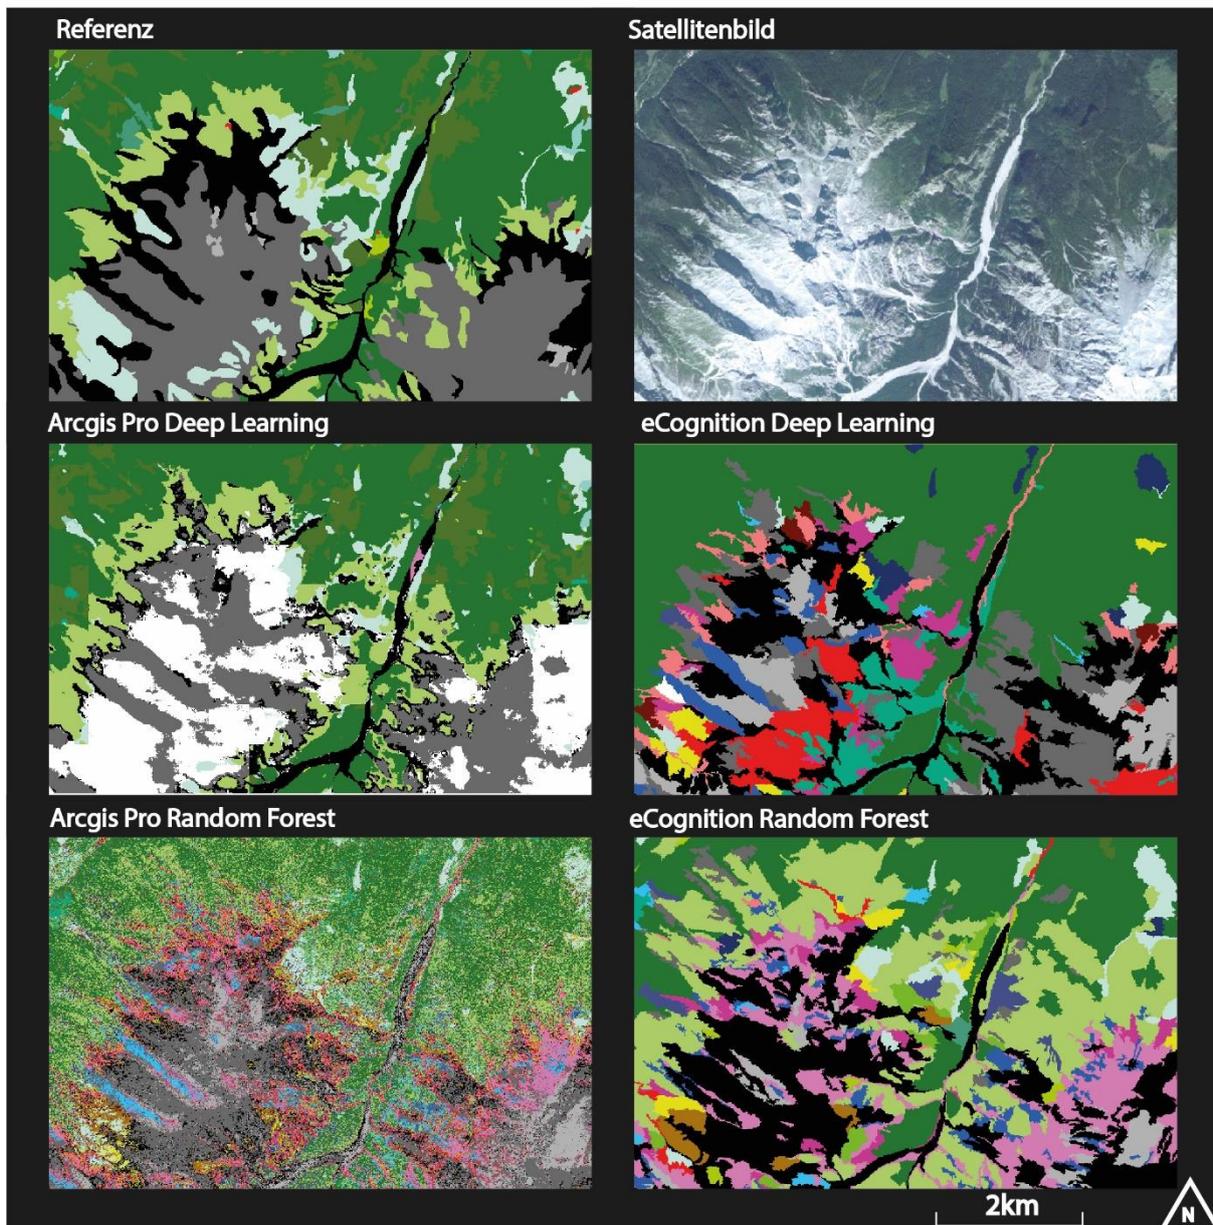
Legende

1	5
2	6
3	7
4	unklassifiziert

Abbildung 33: Ergebnisse der Landbedeckungsklassifikation in LBM2 Darstellung - Szene 5. Quelle: eigene Darstellung.

Ergebnisse Landbedeckungsklassifikation LBM1

Szene
5.



Legende

110	211	231	310	330	411	511
121	221	233	311	332	412	512
122	222	321	312	335	413	unklassifiziert
242	224		313		414	
			322			
			324			

Abbildung 34: Ergebnisse der Landbedeckungsklassifikation in LBM1 Darstellung - Szene 5. Quelle: eigene Darstellung.

Szene 6 (siehe Abbildung 35 und Abbildung 36) zeigt ein Sumpf- und Moorgebiet südlich des Chiemsees. Hier sind vor allem Feuchtwiesen, Hoch- und Niedermoore charakteristisch.

Wie in Szene 4 ist auch hier ein Kontrastunterschied aufgrund des Mosaiks zu sehen, welche die Ergebnisse zum Teil mitbeeinflusst. Von dieser Fehlerquelle sind alle verwendeten Methoden betroffen, wobei die pixelbasierte Klassifikation in der LBM2 Darstellung diesen Fehler optisch am ehesten minimieren kann. Die *Arcgis Pro Deep Learning*- als auch *die Arcgis Pro Random Forest* Methoden liefern optisch gute Ergebnisse, welche sich vor allem quantitativ unterscheiden lassen. Wird zum einen die RF-Methode mit der Satellitenszene verglichen, zeigt sich, dass die RF-Methode die Realität im Detail sogar genau wiedergibt.

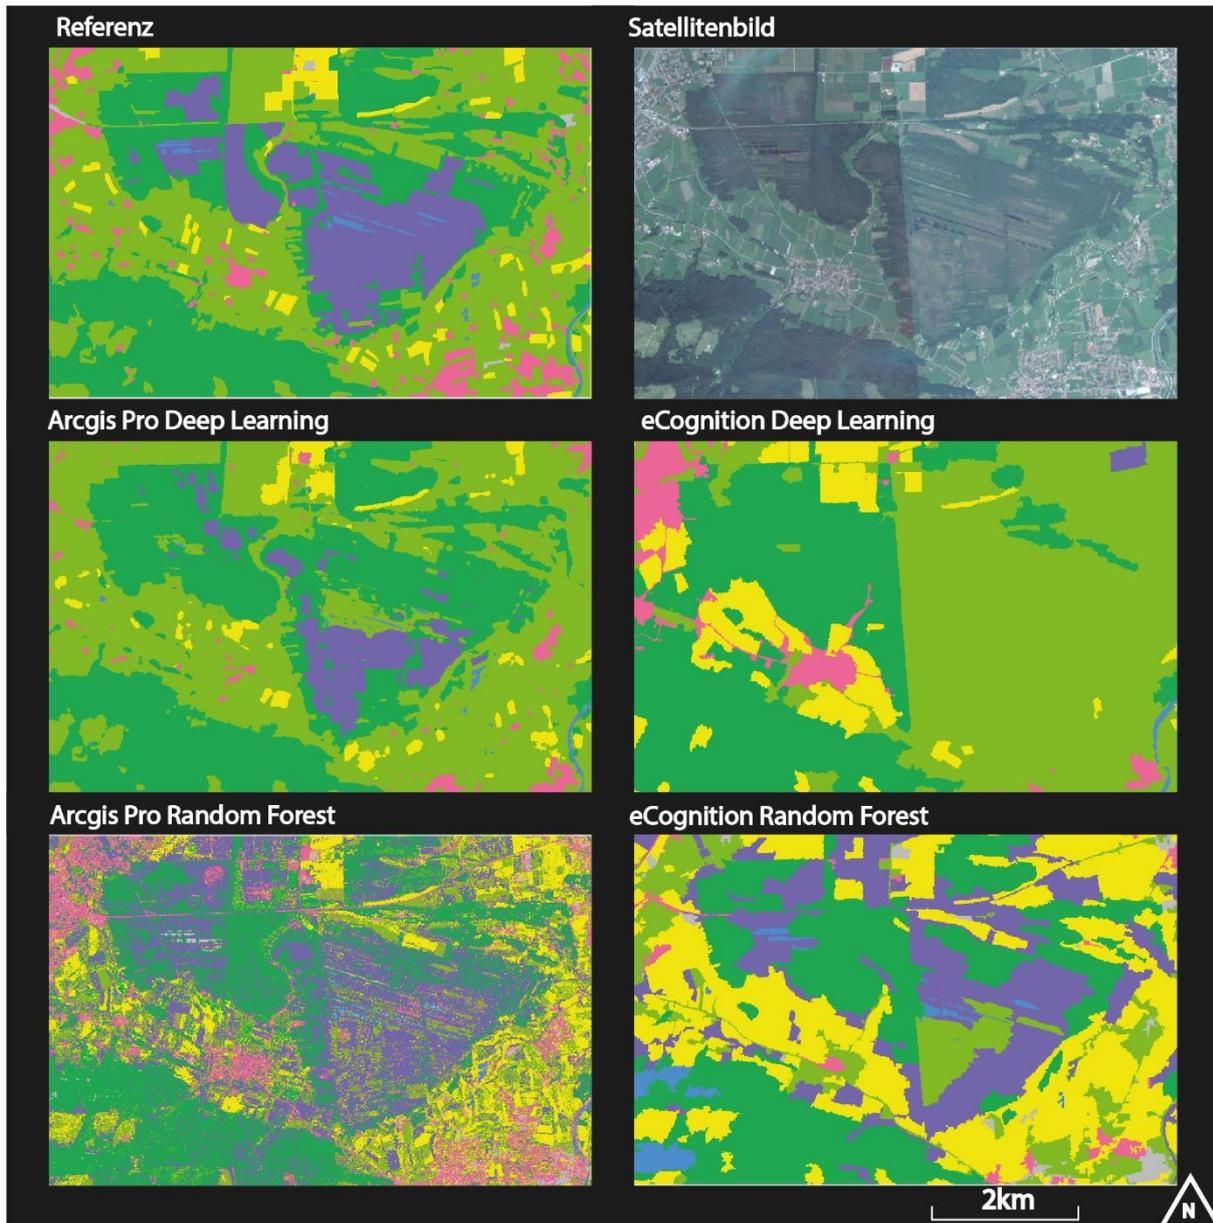
Wie ein quantitativer Vergleich (siehe Tabelle 22 und 23) der für diese Szene charakteristischen Klassen zeigt, eignet sich kaum eine Methode für zuverlässige Klassifikationen von Sumpf- und Moorgebieten. Die Klasse 412, Moore, ist als einzige Biotopsform qualitativ als auch quantitativ zu differenzieren.

Tabelle 22: Szene 6 - LBM2 – Producer- und User Accuracies pro Klasse und Methode. Quelle: eigene Darstellung.

Arcgis Pro Deep Learning		eCognition Deep Learning		Arcgis Pro Random Forest		eCognition Random Forest	
Klasse	6	6	6	6	6	6	6
PA	19,0%	1,6%	57,4%	57,5%			
UA	29,8%	0,2%	0,9%	1,1%			

Tabelle 23: Szene 6 – LBM1 – Producer- und User Accuracies pro Klasse und Methode. Quelle: eigene Darstellung.

Klasse	Arcgis Pro Deep Learning		eCognition Deep Learning		Arcgis Pro Random Forest		eCognition Random Forest	
	PA	UA	PA	UA	PA	UA	PA	UA
411	0,0%	0,0%	2,0%	0,4%	25,4%	0,2%	7,0%	1,0%
412	35,2%	27,4%	0,2%	0,0%	27,9%	1,3%	25,2%	2,6%
413	0,0%	0,0%	0,0%	0,0%	14,4%	0,1%	48,5%	1,0%
414	0,0%	5,7%	0,0%	0,0%	25,3%	0,2%	25,7%	2,2%



Legende

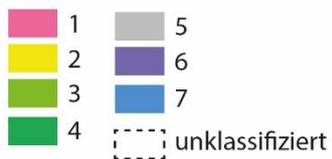
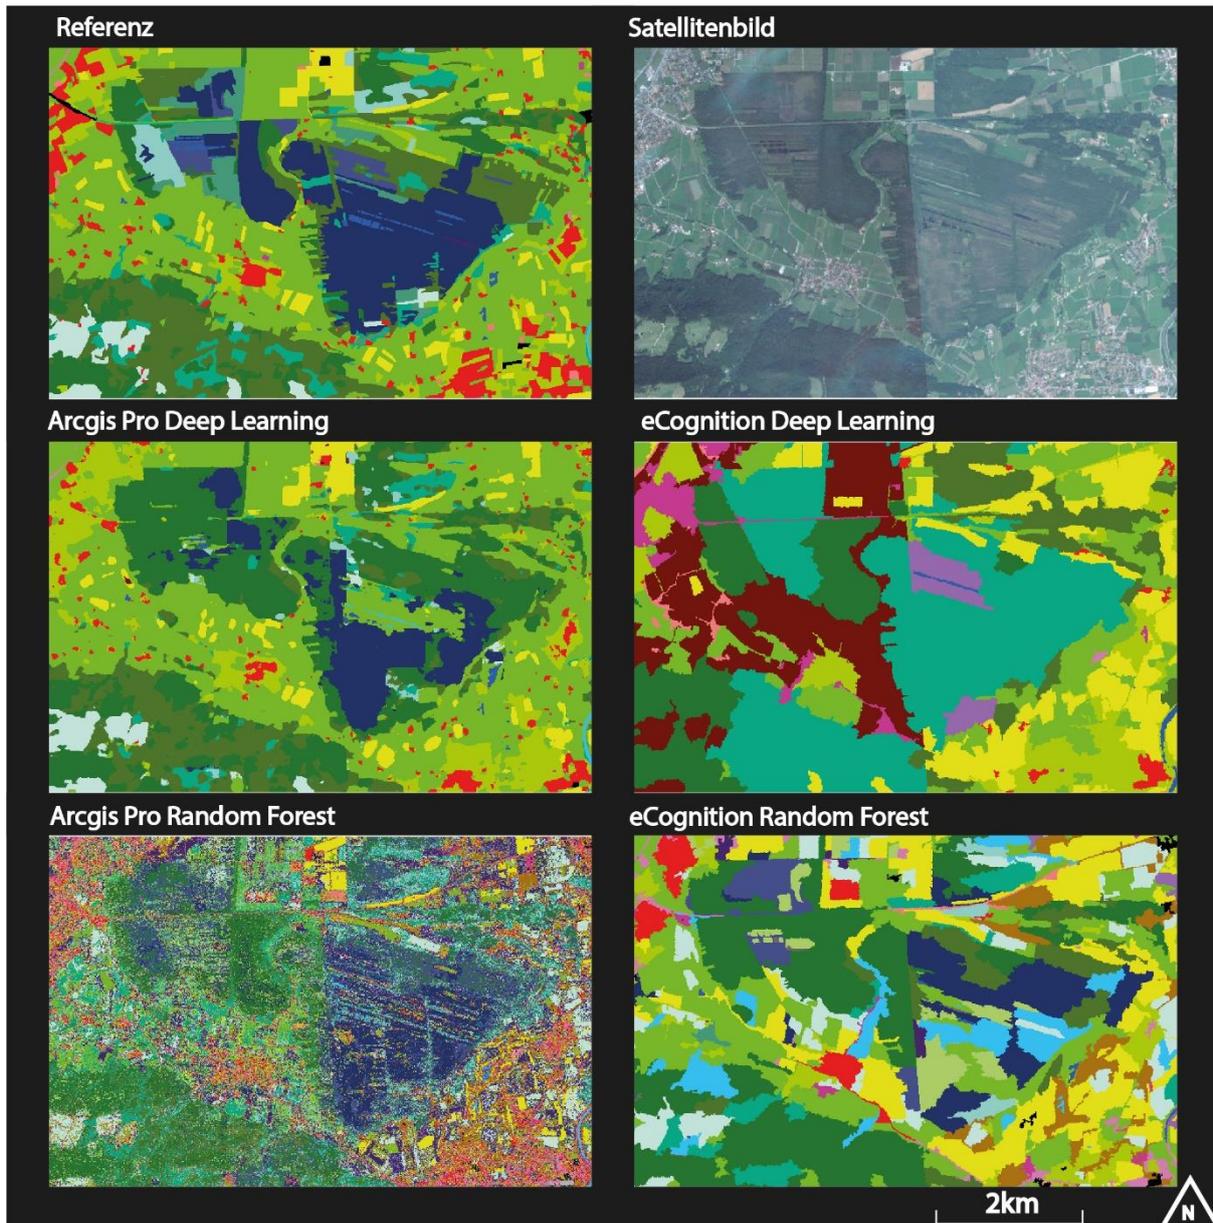


Abbildung 35: Ergebnisse der Landbedeckungsklassifikation in LBM2 Darstellung - Szene 6. Quelle: eigene Darstellung.

Ergebnisse Landbedeckungsklassifikation LBM1

Szene
6.



Legende

110	211	231	310	330	411	511
121	221	233	311	332	412	512
122	222	321	312	335	413	unklassifiziert
242	224		313		414	
			322			
			324			

Abbildung 36: Ergebnisse der Landbedeckungsklassifikation in LBM1 Darstellung - Szene 6. Quelle: eigene Darstellung.

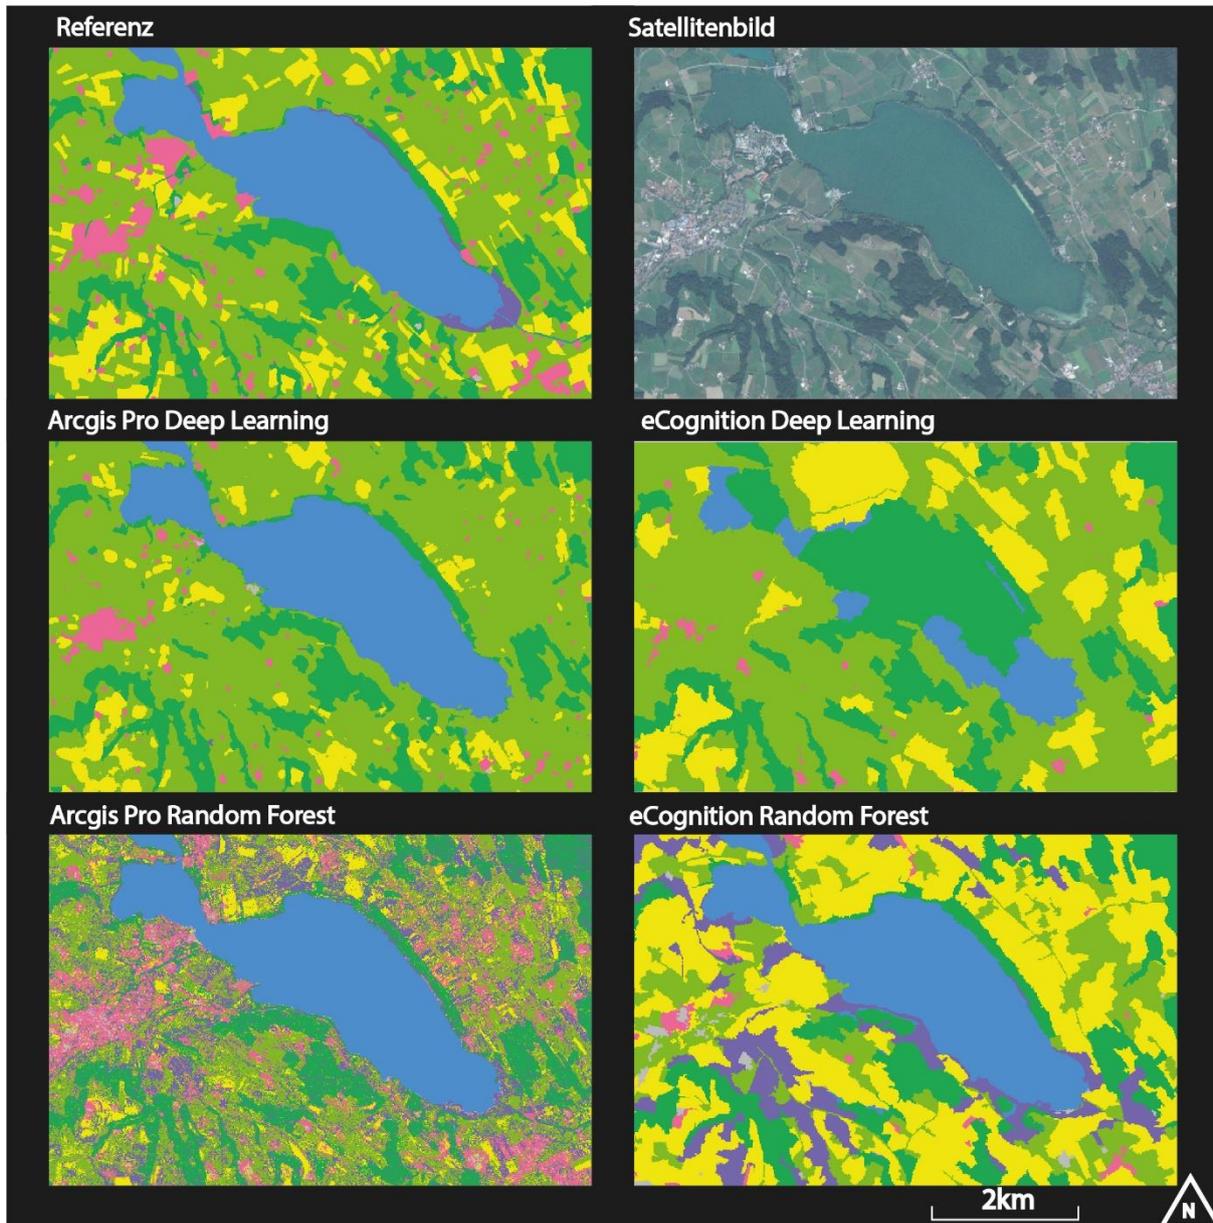
Szene 7 (siehe Abbildung 37 und Abbildung 38) zeigt einen Ausschnitt, in dem der Waginger See zu sehen ist. Anhand dessen soll dargestellt werden, inwiefern die Klassifikation stehender Gewässer glückte bzw. missglückte. Grundsätzlich fällt bei einer qualitativen Betrachtung auf, dass die objektbasierte Klassifikation in *eCognition* von Fehlklassifikationen durchsetzt ist. Dies ist besonders bei der LBM2 Darstellung der DL-Methode als auch bei der LBM1 Darstellung der RF-Methode zu sehen. Im Falle der LBM1 Darstellung wird die Klasse 512, die stehenden Gewässer zusammenfasst, als Klasse 330, Sand-Steine-Erde, fehlklassifiziert. Im Falle der LBM2 Darstellung wird Hauptklasse 7 mit Klasse 4 fehlklassifiziert, was den Eindruck erweckt, als wäre der See verlandet. Beides kann darauf zurückzuführen sein, dass die Wasserstände in diesen Bereichen niedrig ist und die Reflexionseigenschaften beeinflusst. Wie in den Tabellen 24 und 25 quantitativ gegenübergestellt ist, lässt sich zeigen, dass die *Arcgis Pro Deep Learning Methode*, sich am besten zur Klassifikation von fließenden als auch stehenden Gewässern eignet.

Tabelle 24: Szene 7 - LBM2 - Producer und User Accuracies pro Klasse und Methode. Quelle: eigene Darstellung.

Arcgis Pro Deep Learning		eCognition Deep Learning	Arcgis Pro Random Forest	eCognition Random Forest
Klasse	7	7	7	7
PA	82,9%	18,7%	77,5%	66,8%
UA	92,1%	72,0%	73,6%	24,8%

Tabelle 25: Szene 7 – LBM1 - Producer und User Accuracies pro Klasse und Methode. Quelle: eigene Darstellung.

Arcgis Pro Deep Learning			eCognition Deep Learning		Arcgis Pro Random Forest		eCognition Random Forest	
Klasse	PA	UA	PA	UA	PA	UA	PA	UA
511	67,3%	83,5%	0,3%	2,4%	56,8%	30,9%	0,2%	1,3%
512	89,9%	88,6%	78,0%	46,7%	70,4%	89,5%	9,6%	28,9%



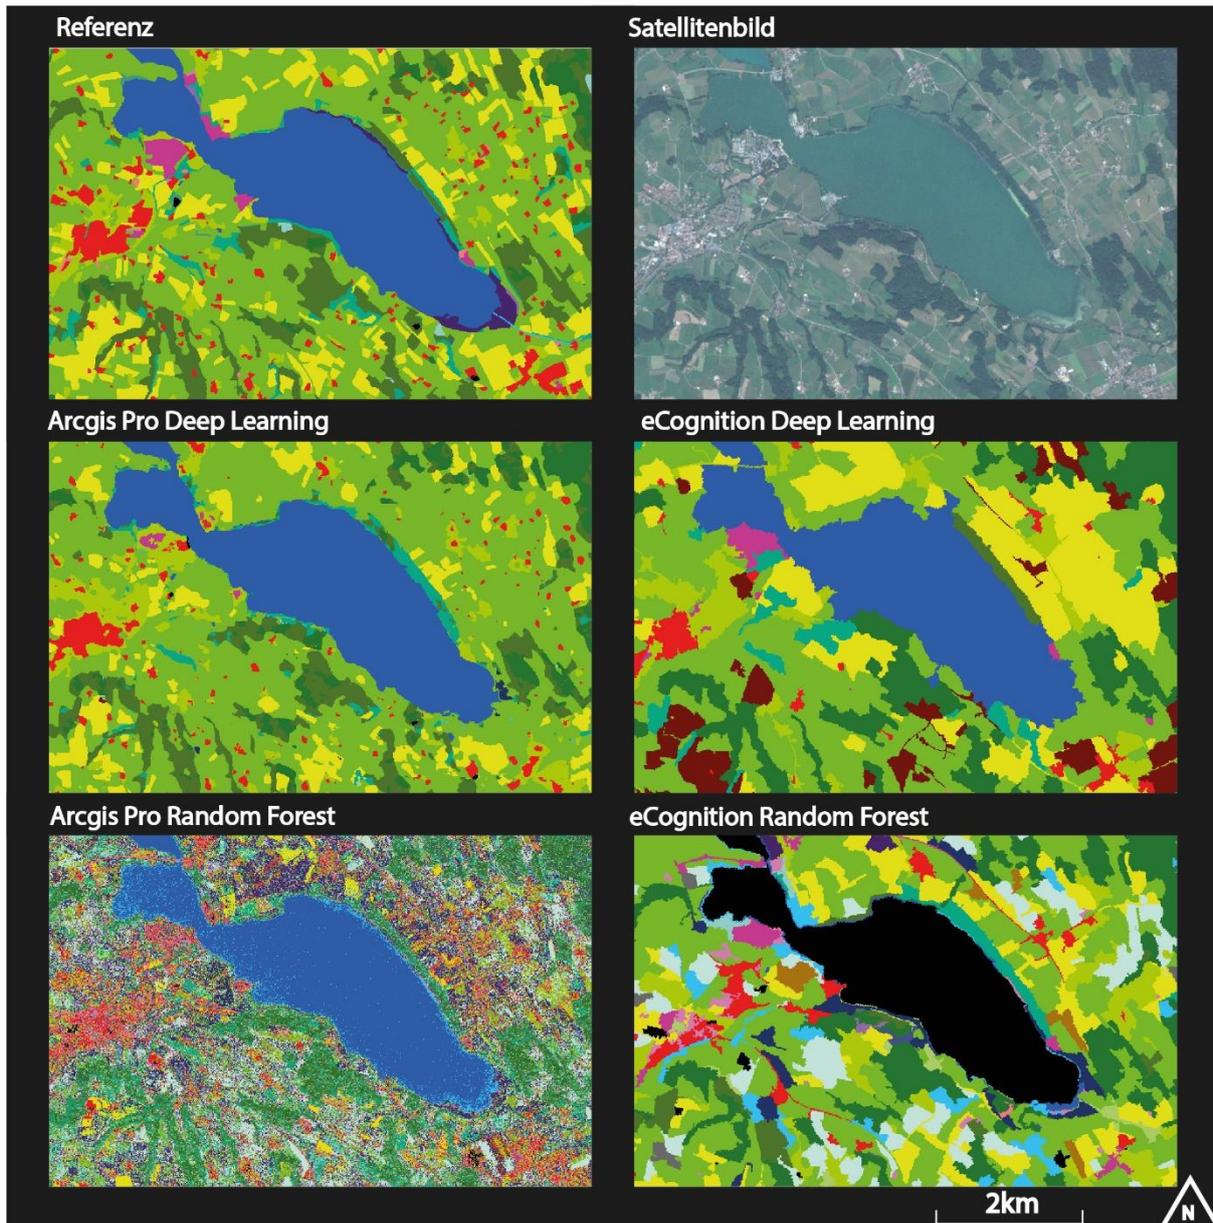
Legende

1	5
2	6
3	7
4	unklassifiziert

Abbildung 37: Ergebnisse der Landbedeckungsklassifikation in LBM2 Darstellung - Szene 7. Quelle: eigene Darstellung.

Ergebnisse Landbedeckungsklassifikation LBM1

Szene
7.



Legende

110	211	231	310	330	411	511
121	221	233	311	332	412	512
122	222	321	312	335	413	unklassifiziert
242	224		313		414	
			322			
			324			

Abbildung 38: Ergebnisse der Landbedeckungsklassifikation in LBM1 Darstellung - Szene 7. Quelle: eigene Darstellung.

Zu den Ergebnissen lässt sich zusammenfassend festhalten, dass die *Arcgis Pro Deep Learning* Methode, wie bereits am Anfang des Kapitels erwähnt, gute Ergebnisse liefert. Die KI hat die nötigen kognitiven Kapazitäten, um die Landbedeckungen ähnlich den bereitgestellten Trainingsgebieten zu klassifizieren, sodass qualitativ und quantitativ hochübereinstimmende Klassifikationen erzielt werden können.

Die *Deep Learning* Anwendung ist nichtsdestotrotz auch fehlerbehaftet und die Ergebnisse weisen Fehlklassifikationen auf. Vor allem der deutliche Unterschied zwischen den in *Arcgis Pro* und *eCognition* erreichten Genauigkeitsbewertungen mit der *Deep Learning* Methode ist sehr auffällig. Besonders die Anwendung in *eCognition* weist Schwierigkeiten auf, die unterschiedlichen Lichtverhältnisse der Satellitenszenen zu berücksichtigen, was sich auch am hohen Anteil an Fehlklassifikationen bemerkbar macht. Ähnlich verhält es sich bei den Subklassen wie z.B.: Hopfen, Obst- und Beerenobstbau, Schnee und Eis. Klassen, die im Untersuchungsgebiet kaum auftreten und nicht ausreichend Trainingsdaten liefern, werden in der Klassifikation unterklassifiziert.

5 Conclusio

In diesem abschließenden Kapitel erfolgt nun die Beantwortung der Forschungsfragen dieser Arbeit zum Thema ‚**Ein Vergleich von Verfahren zu Landbedeckungsklassifikationen mittels Künstlicher Intelligenz**‘. Die Beantwortung erfolgt auf Basis der angewandten Recherche und Methodik und wird folgend zusammengefasst.

Nach Betrachtung der Relevanz der KI für die Fernerkundung in Kapitel 1 wurden in Kapitel 2 die Grundlagen zu *Deep Learning* und Klassifikationen in der Fernerkundung vermittelt. Daraus geht hervor, dass Klassifikationsverfahren der Fernerkundung fest in der Informatik verankert sind. Insbesondere die Funktionsweise von *Deep Learning* und künstlicher neuronaler Netzwerke zeigt dabei die Stärken der KI, die im selbständigen und rationalen Denken intelligenter Agenten liegt. Gemeinsam mit der Datengrundlage – DLM-DE und *Rapid Eye* Satellitendaten – wurden die Möglichkeiten dargestellt, wie diese Stärken für Landbedeckungsklassifikationen genutzt werden können. In Kapitel 3 wurden die Teilschritte der Methodik – Trainingsgebiete, Modelltraining und Klassifikation – erläutert. Gemäß dieser Herangehensweise wurden auf Basis von *Rapid Eye*- und DLM-DE Daten für das Bundesland Bayern mit unterschiedlichen Klassifikationsverfahren acht Landbedeckungsklassifikationen geschaffen, die in Kapitel 4 quantitativ und qualitativ verglichen wurden. Dieser Vergleich von *Deep Learning*- und *Shallow Learning* Klassifikationsverfahren in den Softwarepaketen *Arcgis Pro* und *eCognition* wird zur Beantwortung der Forschungsfragen herangezogen.

5.1 Beantwortung der Forschungsfragen

Welche Genauigkeiten für Landbedeckungsklassifikationsergebnisse lassen sich mit den zwei ausgewählten kommerziellen Softwareprogrammen und *Deep Learning* erreichen?

Sowohl in *Arcgis Pro* als auch in *eCognition* ist es möglich *Deep Learning* in Form von CNN zu nutzen und Landbedeckungsklassifikationen auf Basis der *Rapid Eye* Satellitendaten und des DLM-DE — jeweils aus dem Jahr 2015 — zu generieren. Nach dem heuristischen Verfahren ist es gelungen die bestmöglichen Einstellungen zu ermitteln, welche schließlich auf das Testgebiet angewendet wurden. Gemessen an der *Overall Accuracy*, wurden mit der *Deep*

Learning Methode in *Arcgis Pro* 75% (LBM1) bzw. 84% (LBM2) und im *eCognition* Softwarepaket 40% (LBM1) bzw. 62% (LBM2) erreicht. Grundsätzlich ist feststellbar, dass die zusammengefassten Hauptklassen einen ausbalancierteren Datensatz ergeben und bessere Klassifikationen ermöglichen. Betrachtet man die einzelnen Subklassen, ist zu sehen, dass einzelne Klassen, deren Vorkommen gering sind, stark unterklassifiziert werden. Zusammenfassend kann gesagt werden, dass mit der DL-Methode in dieser Arbeit moderate bis gute Ergebnisse — nach Altman (1991) — erzielt wurden.

Welche Kombination aus Methode und Softwareprogramm eignet sich besser für Landbedeckungsklassifikationen und inwiefern trifft das auf die Klassifikationsgüte einzelner Klassen nicht zu?

Diese zweite Frage dient zur Vertiefung der ersteren und greift den ursprünglichen Vergleich auf. Die angewendeten DL- und SL- Methoden erzielten unterschiedliche Ergebnisse, was sich auch in der Genauigkeit der einzelnen Klassen widerspiegelt. Die *Arcgis Pro Deep Learning* Methode ist nicht nur im Vergleich zur Anwendung in *eCognition* besser, sondern übertrifft auch die Ergebnisse der jeweiligen *Shallow Learning* Methoden. Nichtsdestotrotz gibt es Klassen auf welche dies nicht zutrifft. Folgende Subklassen werden mit künstlichen neuronalen Netzwerken unter- bzw. fehlklassifiziert:

- **222** Obst- und Beerenobstbau
- **224** Hopfen
- **242** Mischflächen (regelmäßige Strukturen)
- **335** Schnee und Eis
- **411** Sumpf
- **413** Sumpf mit Büschen/Bäumen <50%
- **414** Moor mit Büschen/Bäumen <50%

Besonders die Subklassen der Hauptklassen 2, 5 und 7 bezeugen, dass maschinelles Lernen markante Spektraleigenschaften von Schnee und Fels gut erkennen und mit weniger Trainingsgebieten Entscheidungen treffen können. Je nach Thema und Forschungsziel können

so unterschiedliche Methoden bevorzugt werden. Gleichzeitig weist diese Thematik auf Herausforderungen der Trainingsdaten- bzw. Stichprobenauswahl hin. Künstliche neuronale Netzwerke funktionieren am besten mit ausbalancierten Datensätzen, in denen Klassen nicht über- bzw. unterrepräsentiert werden.

Welche Hyperparameter im *Deep Learning* eignen sich, um die Klassifikationsgenauigkeiten zu erhöhen?

Performanz steht in diesem Kontext für die Relation zwischen brauchbaren Ergebnissen und der aufgewendeten Zeit. Zeitmanagement ist ein wichtiger Faktor, der besonders aufgrund der genutzten Hardware und der subjektiven Erfahrung relativiert wird. Es sind Unterschiede in der Performanz zwischen *Arcgis Pro* und *eCognition* zu beobachten. Dies lässt sich in Betracht auf die Anzahl der benötigten Zwischenschritte, die mit der *eCognition* Anwendung verbunden sind, auch objektiv behaupten. Die Anwendung in *eCognition* war stets mit höherem Zeitaufwand verbunden. Mit den richtigen Einstellungen lassen sich, sowohl in *Arcgis Pro* als auch in *eCognition*, in limitierter Zeit die bestmöglichen Ergebnisse erzielen. Aufgrund der heuristischen Herangehensweise wurden viele Parameter und Einstellungen getestet, weshalb besonders die Adaption folgender Hyperparameter hervorgehoben wird:

- **der Hidden Layer**
- **der Epochen**
- **und der Lernrate**

Es sei jedoch erwähnt, dass ein gutes Modell erst durch ausreichende Trainingsdaten vervollständigt wird und grundsätzlich nur so gut wie die Trainingsdaten selbst sein kann. Darum auch ein Fazit zur Manipulation des Inputs durch Augmentation und Bänderkombinationen. Die Augmentation eignet sich zwar für die Erhöhung der Sampleanzahl, jedoch nicht direkt für die Ausbalancierung des Datensatzes. Ebenso geht hervor, dass die Anzahl, der genutzten Layer, vernachlässigbar ist. Die Limitierung auf drei Bänder in *Arcgis Pro*, zieht keinen Nachteil nach sich, was durch die erreichten Ergebnisse bezeugt wird. Die in *Arcgis Pro* verwendete *U-Net* Architektur, die adaptive *Lernrate*, die Einbringung von *Transfer Learning* bzw. *Backbone Modellen* und die daraus resultierenden

Ergebnisse zeigen, dass sich mit diesem Setting und diesen Auswahlmöglichkeiten bessere Ergebnisse erzielen lassen, als mit jenen Optionen die der CNN Architektur innerhalb des *eCognition* Softwarepaketes zur Verfügung stehen. Der Input wird je nach verwendetem Softwarepaket unterschiedlich verarbeitet und so können sich Fehlerquellen auch unterschiedlich auf die Ergebnisse auswirken.

Die Performanz der genutzten Geoinformationssysteme unterscheidet sich somit. Objektiv betrachtet an den Ergebnissen der OA und der jeweiligen Berechnungszeiten, in denen Modelle trainiert wurden, ist die *Deep Learning* Implementierung in *Arcgis Pro* zu bevorzugen. Generell ist das Interface auf automatisiertes Arbeiten festgelegt, während *eCognition* in zahlreichen Einstellungen eingeschränkt ist und für die volle Kontrolle externes Programmieren voraussetzt.

5.2 Schlussbetrachtung

Das Fazit zu den Erkenntnissen dieser Arbeit ist, dass sich *Deep Learning* gut eignet, um große Mengen an Satellitendaten zu verarbeiten und komplexe Muster zu erkennen, welche für den Menschen ohne technische Unterstützung nicht möglich wären. Allerdings ist es wichtig zu beachten, dass die Klassifikationsergebnisse direkt von der Qualität und der Menge der verfügbaren Trainingsdaten abhängt. Die Stärken, die mit künstlichen neuronalen Netzwerken einhergehen, sprich die Objektivität und Präzision der Klassifikation, sind immer durch menschlichen Einfluss und damit auftretenden Fehlern voreingenommen. Während die *Arcgis Pro Deep Learning* Methode Klassifikationen hervorbringt, welche mit der Referenzdatei nahezu gänzlich übereinstimmen, ist gleichzeitig zu beobachten, dass sich Referenz und Satellitenszenen im Detail unterscheiden. Das Ziel war es stets, die vorhandenen Trainingsgebiete bzw. die Referenz basierend auf dem DLM-DE mit den Klassifikationsergebnissen zu vergleichen. Wie jedoch der qualitative Vergleich der Ergebnisse mit der Satellitenszene anstatt der Referenz zeigt, wird die Erdoberfläche durch *Random Forest* Methoden im Detail sogar genauer wiedergegeben als mit den *Deep Learning* Methoden. Dies unterstreicht die Tatsache, dass der Mensch und von ihm durchgeführte visuelle Klassifikationen aufgrund mangelnder Präzision und Genauigkeit stets mit Fehlern verbunden sind und dass die Trainingsgebiete von Anfang an einen gewissen Mangel bei der Wiedergabe der Realität aufweisen. Da solche visuellen Klassifikationen nur in den seltensten

Fällen von einer einzigen Person durchgeführt werden, ist es somit auch eine Frage der Standardisierung und der Definition, wie genau Trainingsgebiete der Realität entsprechen. Außerdem geht aus der Untersuchung hervor, dass mit zusammengefassten bzw. homogeneren Landbedeckungen bessere Übereinstimmungen erzielt werden als mit kleinstrukturierten, heterogenen Landbedeckungen. Die Generalisierung der Darstellung ist eine altbekannte Herausforderung der Geographie und Kartographie, die sich auch im Arbeiten mit *Deep Learning* zeigt und in der Entscheidungsmacht der Anwender:innen liegt.

Zudem ist *Deep Learning* keine Anwendung, die von heute auf morgen eine Fehlerquote von 0% aufweist. Im Laufe dieser Masterarbeit hat es immer Adaptierungen und Verbesserungen der Methoden gegeben und so verhält es sich auch in vergleichbaren Forschungsgebieten, die zeitlich nicht so eingeschränkt sind. Ein *Deep Learning* Modell bezeugt einen Lernprozess, der dem des Menschen ähnlich ist und reifen muss, um ein Optimum zu erreichen. Rückblickend hätten durch ein radiometrisches Angleichen vor der Klassifikation, der für das Mosaik genutzten Satellitenszenen, in beiden Softwarepaketen bessere Ergebnisse erzielt werden können, da eine Konstanz in den Reflexionsverhältnissen vor allem dem Testdatensatz zugutekommt. Kontrast- und Helligkeitsunterschiede der Satellitenszenen haben einen mitwirkenden Anteil an Fehlklassifikationen durch die KI. Dies bezeugt, dass die KI-Schwierigkeiten hat, solche Unterschiede zu berücksichtigen und dass zum Ausgleich dieser Varianz mehr Trainingsdaten benötigt werden. Fehler dieser Art sind überwiegend auf die Stichprobenauswahl und auf die Trainingsgebiete, aber auch auf die Art und Weise der Vorprozessierung der Satellitendaten zurückzuführen. Eine radiometrische Angleichung, im Zuge der Mosaikbildung, gilt es in diesem Sinne mehr zu beachten, um die radiometrische Varianz der Trainingsdaten zu minimieren und den Lernprozess zu stabilisieren. Mit einem ausgeglichenen Datensatz, in welchem die Lichtverhältnisse berücksichtigt werden, ist eine Verbesserung in Bezug zu den unterschiedlichen Satellitenszenen und deren Reflexionseigenschaften zu erwarten. Zudem hätten Höheninformationen bzw. digitale Geländemodelle als zusätzliche Layer rückblickend vor allem in *eCognition* einen zusätzlichen Versuch dargestellt, die Klassifikationen zu verbessern und an die erreichten Ergebnisse in *Argis Pro* anzuknüpfen.

Demzufolge lassen mich zum einen die kognitiven Eigenschaften der KI und zum anderen die menschlichen Erkenntnisse auf diesem Gebiet behaupten, dass zukünftige

Landbedeckungsklassifikationen zunehmend auf künstliche neuronale Netzwerke setzen werden und traditionelle Klassifikationsverfahren nach und nach abgelöst werden. Insbesondere geht durch diese Forschungsarbeit hervor, dass *Rapid Eye* Satellitendaten und das DLM-DE vergangener Jahre als Grundlage dienen können, aktuelle Landbedeckungsmodelle durch *Deep Learning* zu automatisieren. Auf Basis des bereits vorhandenen Wissens zum Untersuchungsgebiet Bayern ist es der KI möglich die Landbedeckung nach den Klassen des DLM-DE selbständig und flächendeckend zu klassifizieren. Von dieser Erkenntnis können in diesem Fall das *Bundesamt für Kartographie und Geodäsie*, das *Deutsche Zentrum für Luft- und Raumfahrt* als auch die gesamten Bundesländer profitieren, welche gemeinsam für die Pflege der digitalen Landschaftsmodelle verantwortlich sind. Bis dato werden die digitalen Landschaftsmodelle alle drei Jahre aktualisiert. Die Klassifikation erfolgt dabei größtenteils manuell und ist vom menschlichen Einschätzungsvermögen geprägt. Durch den *Deep Learning* Ansatz — vor allem in der *Arcgis Pro* Anwendung — ergibt sich eine präzise Möglichkeit, die nötige Zeit zwischen den Veröffentlichungen der aktualisierten digitalen Landbedeckungsmodelle zu minimieren. Der beobachtete und erforschte Raum steht somit auch in Relation mit der Zeit. Aus der geographischen Perspektive kann auch von einer Raum-Zeit Komprimierung gesprochen werden, welche mit dem Einsatz von KI einhergeht.

Jedoch ist zu beachten, dass die mit *Deep Learning* erreichten Klassifikationsergebnisse nur so gut wie die vorliegenden Trainingsgebiete selbst sein können. Auf Basis dieser Erkenntnis sind Kontrollen durch den Menschen — trotz der selbständigen Funktionsweise von künstlichen neuronalen Netzwerken — nicht ausgeschlossen, bis Trainingsdaten und Methoden vollständig ausgereift sind.

Die Integration der *Deep Learning* Funktionen in den betrachteten Geoinformationssystemen ist ein Werkzeug, welches in der Fernerkundung den Status quo mitbestimmen und Vorteile für Forschung und Behörden mit sich bringen wird. Neben den Möglichkeiten sind jedoch auch die Risiken abzuwägen, denn nichtsdestotrotz bleibt der Einsatz der KI ein kontroverses Thema und muss sich in der Gesellschaft etablieren. Schließlich ist der Lernprozess sowohl für die KI als auch für die Gesellschaft entscheidend.

Quellenverzeichnis

- Aery, M. K.; Ram, C. (2017):** A review on machine learning: trends and future prospects. In: An International Journal of Engineering Sciences, 25, S. 89-96.
- Albertz, J. (2007):** Einführung in die Fernerkundung – Grundlagen der Interpretation von Luft- und Satellitenbildern. Darmstadt: Wissenschaftliche Buchgesellschaft, 3 Auflage.
- Altman, D. G. (1991):** Practical statistics for medical research. London: Chapman & Hall.
- Alyafeai, Z.; Ghouti, L. (2019):** A Fully-Automated Deep Learning Pipeline for Cervical Cancer Classification. In: Expert Systems with Applications, 141, S. 1-40.
- Angermann, D.; Pail, R.; Seitz, F.; Hugentobler, U. (2021):** Mission Erde - Geodynamik und Klimawandel im Visier der Satellitengeodäsie. Berlin: Springer Verlag.
- Arnold, S. (2012):** Differenzierte Freirauminformationen durch Fernerkundung. In: Meinel, G.; Schumacher, U.; Behnisch, M (Hg.): Flächennutzungsmonitoring IV - Genauere Daten - informierte Akteure - praktisches Handeln. Berlin: Rhombos Verlag, 60, S. 55-62.
- Apaydin, H.; Feizi, H.; Sattari, M. T.; Çolak, M. S.; Band, S. S.; Chau, K. W. (2020):** Comparative Analysis of Recurrent Neural Network Architectures for Reservoir Inflow Forecasting. In: Water, 12, 1500, S. 1-18.
- Bannari, A.; Morin, D.; Bonn, F. (1995):** A Review of Vegetation Indices. In: Remote Sensing Reviews, 13, S. 95-120.
- Blaschke, T. (2010):** Object based image analysis for remote sensing. In: ISPRS Journal of Photogrammetry and Remote Sensing, 65, S. 2-16.
- Breiman, L. (2001):** Random Forests. In: Machine Learning, 45, S. 5-32.
- Bundesamt für Kartographie und Geodäsie (Hg.) (2018):** Digitales Landbedeckungsmodell für Deutschland LBM-2015. Frankfurt am Main: Bundesamt für Kartographie und Geodäsie.
- Büttner, G.; Kosztra, B.; Kleeschulte, S.; Hazeu, G.; Vittek, M.; Schröder, C.; Littkopf, A. (2021):** CORINE Land Cover Product User Manual. Kopenhagen: European Environment Agency.
- Campeato, O. (2020):** Artificial Intelligence, Machine Learning, and Deep Learning. Dulles: Mercury Learning and Information.

Camps-Valls, G.; Tuia, D.; Zhu, X. X.; Reichenstein, M. (2021): Deep Learning for the Earth Sciences - A Comprehensive Approach to Remote Sensing, Climate Science, and Geosciences. Hoboken: John Wiley & Sons Ltd.

Cheng, G.; Xie, X.; Han, J.; Guo, L.; Xia, G.-S. (2020): Remote Sensing Image Scene Classification Meets Deep Learning: Challenges, Methods, Benchmarks, and Opportunities. In: IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 13, S. 3735-3756.

Chollet, F. (2021): Deep Learning with Python. Shelter Island: Manning Publications Co., 2 Auflage.

Chuvieco, E. (2016): Fundamentals of Satellite Remote Sensing: An Environmental Approach. Boca Raton, London, New York: CRC Press, Taylor & Francis Group, 2 Auflage.

Colditz, R. R. (2015): An Evaluation of Different Training Sample Allocation Schemes for Discrete and Continuous Land Cover Classification Using Decision Tree-Based Algorithms. In: Remote Sensing, 7, S. 9655-9681.

Comber, A.; Fisher, P.; Wadsworth, R. (2005): What is Land Cover? In: Environment and Planning B, 32, 2, S. 199-209.

Cresson, R. (2020): Deep Learning for Remote Sensing Images with Open Source Software. Boca Raton, London, New York: CRC Press.

Cunningham, P.; Delany, S. J. (2007): K-Nearest Neighbour Classifiers. In: ACM Computing Surveys, 54, 6, 128, S. 1-17.

Dastres, R.; Soori, M. (2021): Artificial Neural Network Systems. In: International Journal of Imaging and Robotics, 21, 2, S. 13-25.

Deutsches Zentrum für Luft- und Raumfahrt (Hg.) (2013): Erdbeobachtung – Unseren Planeten erkunden, vermessen und verstehen. Bonn: Köllen Druck und Verlag GmbH.

Estornell, J.; Martí-Gavilá, J. M.; Sebastiá, M. T.; Mengual, J. (2013): Principal component analysis applied to remote sensing. In: Modelling in Science Education and Learning, 6, 2, 7, S. 83-89.

Fischer-Kowalski, M.; Haberl, H. (1997): Stoffwechsel und Kolonisierung – Konzepte zur Beschreibung des Verhältnisses von Gesellschaft und Natur. In: Fischer-Kowalski, M. (Hg.): Gesellschaftlicher Stoffwechsel und Kolonisierung von Natur – Ein Versuch in Sozialer Ökologie. Amsterdam: G+B Verlag Fakultas, S. 3-12.

Fischer, P.; Hofer, P. (2011): Lexikon der Informatik. Berlin, Heidelberg: Springer Verlag, 15 Auflage.

Gong, P. (2012): Remote sensing of environmental change over China - A review. In: Chinese Science Bulletin, 57, 22, S. 2793-2801.

Goodfellow, I.; Bengio, Y.; Courville, A. (2016): Deep Learning. Cambridge, London: The MIT Press.

Gore, A. (1999): The Digital Earth - Understanding Our Planet in the 21st Century. In: Photogrammetric Engineering and Remote Sensing, 65, 5, S. 528-530.

Grosjean, G. (2013): Geschichte der Kartographie. Bern: Verlag des Geographischen Institutes der Universität Bern, 3 Auflage.

Hamwood, J.; Alonso-Caneiro, D.; Read, S. A.; Vincent, S. J.; Collins, M. J. (2018): Effect of patch size and network architecture on a convolutional neural network approach for automatic segmentation of OCT retinal layers. In: Biomedical Optic Express, 9, 7, S. 3049-3066.

Hovenbitzer, M.; Emig, F.; Happe, K.; Wende, C. (2015): Das neue Landbedeckungsmodell Deutschlands LBM-DE. In: Meinel, G.; Schumacher, U.; Behnisch, M.; Krüger, T. (Hg.): Flächennutzungsmonitoring VII Boden – Flächenmanagement – Analysen und Szenarien. Berlin: Rhombos Verlag, 67, S. 145-154.

Janiesch, C.; Zschech, P.; Heinrich, K. (2021): Machine learning and deep learning. In: Electronic Markets, 31, S. 685-695.

Janssen, L. L. F.; van der Wel, F. J. M. (1994): Accuracy Assessment of Satellite Derived Land-Cover Data: A Review. In: Photogrammetric Engineering & Remote Sensing, 60, 4, S. 419-426.

Jia, S.; Jiang, S.; Lin, Z.; Li, N.; Meng, X.; Yu, S. (2021): A survey: Deep learning for hyperspectral image classification with few labeled samples. In: Neurocomputing, 448, S. 179-204.

Jipp, M. (2021): Einleitende Worte zur Gestaltung des Zusammenwirkens. In: Haux, R.; Gahl, K.; Jipp, M.; Kruse, R.; Richter, O. (Hg.): Zusammenwirken von natürlicher und künstlicher Intelligenz. Wiesbaden: Springer VS, S. 13-15.

Johnson, J. M.; Khoshgoftaar, T. M.; (2019): Survey on deep learning with class imbalance. In: Journal of Big Data, 6, 27, S. 1-54.

Khan, S. D.; Alarabi, L.; Basalamah, S. (2021): Deep Hybrid Network for Land Cover Semantic Segmentation in High-Spatial Resolution Satellite Images. In: Information, 12, 6, 230, S. 1-16.

Koch, B.; Jochum, M.; Ivits, E.; Dees, M. (2003): Pixelbasierte Klassifizierung im Vergleich und zur Ergänzung zum objektbasierten Verfahren. In: Photogrammetrie Fernerkundung Geoinformation, 3, S. 195-204.

LeCun, Y.; Bengio, Y.; Hinton, G. (2015): Deep Learning. In: Nature, 521, S. 436- 445.

Li, S.; Lin, J.; Li, G.; Bai, T.; Wang, H.; Pang, Y. (2018): Vehicle type detection based on deep learning in traffic scene. In: Procedia Computer Science, 131, S. 564-572.

Liang, J.; Xu, J.; Shen, H.; Fang, L. (2020): Land-use classification via constrained extreme learning classifier based on cascaded deep convolutional neural networks. In: European Journal of Remote Sensing, 53, 1, S. 219-232.

Lima, B.; Ferreira, L.; Moura, J. M. (2021): Helping to detect legal swimming pools with deep learning and data visualization. In: Procedia Computer Science, 181, S. 1058-1065.

Lu, D.; Li, G.; Moran, E.; Dutra, L.; Batistella, M. (2014): The roles of textural images in improving land-cover classification in the Brazilian Amazon. In: International Journal of Remote Sensing, 35, 24, S. 8188–8207.

Ma, L.; Liu, Y.; Zhang, X.; Ye, Y.; Yin, G.; Johnson, B. A. (2019): Deep learning in remote sensing applications: A meta-analysis and review. In: ISPRS Journal of Photogrammetry and Remote Sensing, 152, S. 166-177.

Mahmoud, A. S.; Mohamed, S. A.; El-Khoribi, R. A.; Abdel Salam, H. M. (2019): Object Detection Using Adaptive Mask RCNN in Optical Remote Sensing Images. In: International Journal of Intelligent Engineering and Systems, 13, 1, S. 65-76.

Maxwell, A. E.; Warner, T. E.; Guillén, L. A. (2021): Accuracy Assessment in Convolutional Neural Network-Based Deep Learning Remote Sensing Studies—Part 1: Literature Review. In: Remote Sensing, 13, 2450, S. 1-27.

Patel, K.; Bhatt, C.; Mazzeo, P. L. (2022): Deep Learning-Based Automatic Detection of Ships: An Experimental Study Using Satellite Images. In: Journal of Imaging, 8, 7, 182, S. 1-17.

Planet Labs (Hg.) (2016): Satellite Imagery Product Specifications. San Francisco, Berlin, Washington D.C., Haarlem: Planet Labs PBC.

Ronneberger, O.; Fischer, P.; Brox, T. (2015): U-Net: Convolutional Networks for Biomedical Image Segmentation. Freiburg: University of Freiburg - Computer Science Department and BIOS Centre for Biological Signalling Studies.

Russel, S. J.; Norvig, P. (2003): Artificial Intelligence - A Modern Approach. Upper Saddle River: Prentice Hall Series in Artificial Intelligence.

Said, Y.; Barr, M.; Saidani, T.; Atri, M. (2022): Desertification Detection in Makkah Region based on Aerial Images Classification. In: *Computer Systems Science & Engineering*, 40, 2, S. 607-618.

Salehi, B.; Zhang, Y.; Zhong, M.; Dey, V. (2012): Object-Based Classification of Urban Areas Using VHR Imagery and Height Points Ancillary Data. In: *Remote Sensing*, 4, S. 2256-2276.

Senecal, J. J.; Sheppard, J. W.; Shaw, J. A. (2019): Efficient Convolutional Neural Networks for Multi-Spectral Image Classification. In: *International Joint Conference on Neural Networks*, S. 1-8.

Sewak, M.; Karim, R.; Pujari, P. (2018): Practical Convolutional Neural Networks – Implement Advanced Deep Learning Models Using Python. In: Birmingham, Mumbai: Packt Publishing.

Shorten, C.; Khoshgoftaar, T. M.; (2019): A survey on Image Data Augmentation for Deep Learning. In: *Journal of Big Data*, 6, 60, S. 1-48.

Stengel, O. (2017): Die Ökologische Frage im Digitalzeitalter: Zukunft der Natur. In: Stengel, O.; van Looy, A.; Wallaschkowski, S. (Hg.): *Digitalzeitalter – Digitalgesellschaft. Das Ende des Industriezeitalters und der Beginn einer neuen Epoche*. Wiesbaden: Springer Fachmedien, S. 193-222.

Stoll, A. (2020): Supervised Machine Learning mit Nutzergenerierten Inhalten - Oversampling für nicht balancierte Trainingsdaten. In: *Publizistik*, 65, S. 233-255.

Tong, Q.; Xue, Y.; Zhang, L. (2014): Progress in Hyperspectral Remote Sensing Science and Technology in China Over the Past Three Decades. In: *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 7, 1, S. 70-91.

Tong, X.-Y.; Xia, G.-S.; Lu, Q.; Shen, H.; Li, S.; You, S.; Zhang, L. (2020): Land-cover classification with high-resolution remote sensing images using transferable deep models. In: *Remote Sensing of Environment*, 237, 111322, S. 1-20.

Trogemann, G. (2010): Algorithmen im Alltag. In: Trogemann, G. (Hg.): *Code und Material – Exkursionen ins Undingliche*. Wien, New York: Springer Verlag, S. 158-185.

Tuia, D.; Marcos, D.; Schindler, K.; Le Saux, B. (2021): Deep Learning-based Semantic Segmentation in Remote Sensing. In: Camps-Valls, G.; Tuia, D.; Zhu, X. X.; Reichstein, M. (Hg.): *Deep Learning for the Earth Sciences - A Comprehensive Approach to Remote Sensing, Climate Science, and Geosciences*. Hoboken: John Wiley and Sons Ltd, S. 46-66.

Turner, D.; Wilhelm, R.; Lemberg, W. (2021): User Guide - Trimble eCognition Developer. München: Trimble Germany GmbH for Windows operating system.

Wagner, H. (2013): Digitales Mapping in der Medienkunst. In: Picker, M.; Maleval, V.; Gabaude, F. (Hg.): Die Zukunft der Kartographie – Neue und nicht so neue epistemologische Krisen. Bielefeld: Transcript Verlag, S. 23-39.

Wu, H.; Liu, Q.; Liu, X. (2019): A Review on Deep Learning Approaches to Image Classification and Object Segmentation. In: Computers, Materials & Continua, 60, 2, S. 575-597.

Wurm, M.; Stark, T.; Zhu, X. X.; Weigand, M.; Taubenböck, H.; (2019): Semantic segmentation of slums in satellite images using transfer learning on fully convolutional neural networks. In: ISPRS Journal of Photogrammetry and Remote Sensing, 150, S. 59-69.

Wurm, M.; Droin, A.; Stark, T.; Geiß, C.; Sulzer, W.; Taubenböck, H. (2021): Deep Learning-Based Generation of Building Stock Data from Remote Sensing for Urban Heat Demand Modeling. In: ISPRS International Journal of Geo-Information, 10, 1, 23, S. 1-20.

Yuan, Q.; Shen, H.; Li, T.; Li, Z.; Li, S.; Jiang, Y.; Xu, H.; Tan, W.; Yang, Q.; Wang, J.; Gao, J.; Zhang, L. (2020): Deep learning in environmental remote sensing: Achievements and challenges. In: Remote Sensing of Environment, 241, 111716, S. 1-24.

Onlinequellen

Alouta, R.; Hess, K. (2021): Deep Learning with ArcGis Pro Tips & Tricks: Part 2. <https://www.esri.com/arcgis-blog/products/arcgis-pro/imagery/deep-learning-with-arcgis-pro-tips-tricks-part-2/>, zuletzt geprüft am 13.07.2022.

Bundesamt für Kartographie und Geodäsie (Hg.) (2022): Digitales Landbedeckungsmodell für Deutschland, Stand 2015 (LBM-DE2015). <https://gdz.bkg.bund.de/index.php/default/digitales-landbedeckungsmodell-fur-deutschland-stand-2015-lbm-de2015.html>, zuletzt geprüft am 03.05.2022.

Clarivate (Hg.) (2022): Web of Science: <https://www.webofscience.com/wos/woscc/summary/a789c501-2642-47f7-9fe9-6da69f83fdd5-5cb12db2/relevance/1>, zuletzt geprüft am 09.11.2022.

Copernicus (Hg.) (2022): Corine Land Cover Classes. https://land.copernicus.eu/Corinelandcoverclasses.eps.75dpi.png/image_view_fullscreen, zuletzt geprüft am 02.08.2022.

DLR (Hg.) (2022): Rapid Eye. https://www.dlr.de/rd/desktopdefault.aspx/tabid-2440/3586_read-5336/, zuletzt geprüft am 19.05.2022.

ESA (Hg.) (2022): Rapid Eye Instruments. <https://earth.esa.int/eogateway/missions/rapideye>, zuletzt geprüft am 19.05.2022.

Esri (Hg.) (2022a): About ArcGIS Pro. <https://pro.arcgis.com/en/pro-app/2.8/get-started/get-started.htm>, zuletzt geprüft am 31.05.2022.

Esri (Hg.) (2022b): Deep learning using the ArcGIS Image Analyst extension. <https://pro.arcgis.com/en/pro-app/2.8/get-started/get-started.htm>, zuletzt geprüft am 31.05.2022.

Esri (Hg.) (2022c): Pixel Classification. <https://pro.arcgis.com/en/pro-app/latest/tool-reference/image-analyst/pixel-classification.htm>, zuletzt geprüft am 13.06.2022.

Esri (Hg.) (2022d): Indices gallery. <https://pro.arcgis.com/en/pro-app/latest/help/data/imagery/indices-gallery.htm>, zuletzt geprüft am 21.09.2022.

Esri (Hg.) (2022e): Deep-Learning-Modell trainieren (Image Analyst). <https://pro.arcgis.com/de/pro-app/latest/tool-reference/image-analyst/train-deep-learning-model.htm>, zuletzt geprüft am 05.10.2022.

Esri (Hg.) (2022f): Classify Pixels Using Deep Learning (Image Analyst). <https://pro.arcgis.com/en/pro-app/latest/tool-reference/image-analyst/classify-pixels-using-deep-learning.htm>, zuletzt geprüft am 21.09.2022.

GISGeography (Hg.) (2022a): 30 Best GIS Software Applications [Rankings]. <https://gisgeography.com/best-gis-software/#:~:text=ArcGIS%20Desktop%20is%20cutting%20edge,powerhouse%20for%20all%20things%20GIS>, zuletzt geprüft am 01.06.2022.

GISGeography (Hg.) (2022b): OBIA – Object-Based Image Analysis (GEOBIA). <https://gisgeography.com/obia-object-based-image-analysis-geobia/>, zuletzt geprüft am 01.06.2022.

Kavlakoglu, E. (2020): AI vs. Machine Learning vs. Deep Learning vs. Neural Networks: What's the Difference? <https://www.ibm.com/cloud/blog/ai-vs-machine-learning-vs-deep-learning-vs-neural-networks>, zuletzt geprüft am 16.07.2022.

Long, J.; Shelhammer, E.; Darrell, T. (2015): Fully Convolutional Networks for Semantic Segmentation. <https://arxiv.org/abs/1411.4038v2>, zuletzt geprüft am 04.10.2022.

Microsoft (Hg.) (2022): Deep learning vs. machine learning in Azure Machine Learning. <https://docs.microsoft.com/en-us/azure/machine-learning/concept-deep-learning-vs-machine-learning>, zuletzt geprüft am 01.08.2022.

OTB-Cookbook (Hg.) (2018): HaralickTextureExtraction - Haralick Texture Extraction. https://www.orfeo-toolbox.org/CookBook-6.6.1/Applications/app_HaralickTextureExtraction.html, zuletzt geprüft am 21.09.2022.

Pollatos, V.; Kouvaras, L.; Charou, E. (2020): Land Cover Semantic Segmentation Using ResUNet. <https://arxiv.org/abs/2010.06285#:~:text=In%20this%20paper%20we%20present,same%20resolution%20as%20the%20input>, zuletzt geprüft am 12.01.2023.

Singh, R. (2019): Deep Learning + GIS = Opportunity. <https://www.esri.com/about/newsroom/arcuser/deep-learning/#:~:text=The%20field%20of%20artificial%20intelligence,reading%20comprehension%2C%20and%20translating%20text.>, zuletzt geprüft am 12.07.2022.

TensorFlow (Hg.) (2022): Image Segmentation. <https://www.tensorflow.org/tutorials/images/segmentation>, zuletzt geprüft am 15.06.2022.

Trimble (Hg.) (2022): What is eCognition? <https://geospatial.trimble.com/what-is-ecognition>, zuletzt geprüft am 31.05.2022.

United Nations Office for Outer Space Affairs (Hg.) (2022): Online Index of Objects Launched into Outer Space. https://www.unoosa.org/oosa/osoindex/searching.jsp?lf_id=#?c=%7B%22filters%22:%5B%7B%22fieldName%22:%22en%23object.status.objectStatus_s1%22,%22value%22:%22in%20orbit%22%7D,%7B%22fieldName%22:%22en%23object.launch.stateOrganization_s%22,%22value%22:%22Germany%22%7D%5D,%22sortings%22:%5B%7B%22fieldName%22:%22object.launch.dateOfLaunch_s1%22,%22dir%22:%22desc%22%7D%5D%7D, zuletzt geprüft am 02.05.2022.

Wang, J.; Zheng, Z.; Ma, A.; Lu, X.; Zhong, Y. (2021): LoveDA: A Remote Sensing Land-Cover Dataset for Domain Adaptive Semantic Segmentation. <https://arxiv.org/abs/2110.08733>, zuletzt geprüft am 12.01.2023.

Anhang

Anhang 1: Corine Land Cover Classes.....	xvi
Anhang 2: Zuordnung von Landnutzung und Landbedeckung im Digitalen Landbedeckungsmodell Deutschland.....	xvii
Anhang 3: Kreuztabelle zur Zuordnung des DLM-DE ins CLC-Schema	xxi
Anhang 4: Arcgis Pro Export Training.....	xxii
Anhang 5: eCognition Export Training.....	xxiii
Anhang 6: Supervised Classification – Genutzte Shallow Learning Methode in Arcgis Pro und eCognition.....	xxiv
Anhang 7: Arcgis Pro – Training Deep Learning Modell.....	xxv
Anhang 8: eCognition – Training Deep Learning Modell.....	xxvi
Anhang 9: Arcgis Pro – Experimente mit Ergebnissen zur Methodenauswahl	xxvii
Anhang 10: eCognition – Experimente mit Ergebnissen zur Methodenauswahl.....	xxviii
Anhang 11: eCognition und Arcgis Pro – Experimente mit Ergebnissen zur Methodenauswahl	xxix
Anhang 12: Fehlermatrizen Deep Learning LBM2.....	xxx
Anhang 13: Fehlermatrizen Random Forest LBM2	xxxi
Anhang 14: Fehlermatrizen Deep Learning LBM1.....	xxxii
Anhang 15: Fehlermatrizen Random Forest LBM1	xxxiii
Anhang 16: Klassifikation – Arcgis Pro – Deep Learning – LBM1	xxxiv
Anhang 17: Klassifikation – Arcgis Pro – Random Forest – LBM1.....	xxxv
Anhang 18: Klassifikation – eCognition – Deep Learning – LBM1.....	xxxvi
Anhang 19: Klassifikation – eCognition – Random Forest – LBM1.....	xxxvii
Anhang 20: Klassifikation – Arcgis Pro – Deep Learning – LBM2	xxxviii
Anhang 21: Klassifikation – Arcgis Pro – Random Forest – LBM2.....	xxxix
Anhang 22: Klassifikation – eCognition – Deep Learning – LBM2.....	xl
Anhang 23: Klassifikation – eCognition – Random Forest – LBM2.....	xli
Anhang 24: Genauigkeitsbewertungen der Arcgis Pro Random Forest Methode.....	xlii
Anhang 25: Genauigkeitsbewertungen der Arcgis Pro Deep Learning Methode	xliii
Anhang 26: Genauigkeitsbewertungen der eCognition Random Forest Methode.....	xliv
Anhang 27: Genauigkeitsbewertungen der eCognition Deep Learning Methode.....	xlv

Anhang 1: Corine Land Cover Classes



Quelle: Copernicus (Hg.) (2022): Corine Land Cover Classes. https://land.copernicus.eu/Corinelandcoverclasses.eps.75dpi.png/image_view_fullscreen, zuletzt geprüft am 02.08.2022.

Anhang 2: Zuordnung von Landnutzung und Landbedeckung im Digitalen Landbedeckungsmodell Deutschland

LN	Bemerkung	LB
N112	Wohnbebauung, Kirchen	B110
N120	Produktionsgelände (Gebäude o. Hallen)	
N121	öffentliche Einrichtungen	
N123	zu einem Hafen gehörige Gebäude o. Hallen	
N131	zu einem Abbaubetrieb gehörige Gebäude o. Hallen	
N132	zu einer Deponie gehörige Gebäude o. Hallen	
N122	Raststätten, Bahnhofsgebäude	
N124	zu einem Flughafen gehörige Gebäud o. Hallen	
N142	Klöster, Sporthallen, Hallenbäder	
N120	Kraftwerk, Kläranlage, Raffinerie, Solarparks	
N142	Freizeitpark, Schwimmbad	
N211	Gewächshäuser	
N112	Fußgängerzonen	B122
N120	versiegelte Flächen bei Produktionsstätten	
N121	versiegelte Flächen bei Industrie-oder Verwaltungsobjekten	
N123	versiegelte Flächen bei Häfen	
N131	versiegelte Flächen bei Abbauflächen	
N132	versiegelte Flächen bei Deponien	
N122	Parkplätze, Autobahnen	
N124	Vorfeld, Rollbahnen	
N142	Rennstrecke, Autokino	
N112	Wohnbebauung	B242
N142	Klein-und Schrebergartenanlagen, außerstädt. Friedhöfe, Camping	
N141	Innerstädtische Friedhöfe	
N211	Ackerland	B211
N211	Weinberge	B221
N214	Aufgegebener Weinberg	
N211	Obstplantagen	B222
N211	Hopfnfelder	B224
N120	Auf Industriegelände gelegene Rasenflächen	B231
N121	Auf Gelände v. Verwaltung o. sonstiger öffentlicher Einrichtung gelegene Rasenflächen	
N123	Auf Hafengelände gelegene Rasenflächen	
N132	Begrünte Deponien	
N122	Grünstreifen neben Straßen	
N124	Auf Flughafengelände gelegene Rasenflächen	
N142	Sportgelände, Fußballplätze, Zeltplatz	
N141	Wiesen in Parkanlagen, Hundewiesen, Hausgärten (Rasenflächen)	
N211	Weiden und Wiesen zur Futtergewinnung	
N999	Keine Nutzung	
N131	Nebenflächen zu Abbaugeländen (ehem. Abbauflächen)	

LN	Bemerkung	LB
N132	Begrünte Deponie	B321
N122	Grünstreifen neben Straßen	
N124	Auf Flughafengelände gelegene inhomogene Grünfläche	
N214	Extensiv genutzte Wiesen	
N311	begrünte Kahlschlag-/Windwurfflächen noch ohne Bäume oder Büsche	
N510	Salzwiesen	
N999	Keine Nutzung	
N112	Grasland mit Bäumen zu Wohnnutzung gehörig	B233
N120	Grasland mit Bäumen zu Produktionsstätte gehörig	
N121	Grasland mit Bäumen zu Industrie oder Verwaltung gehörig	
N123	Grasland mit Bäumen zu Hafen gehörig	
N131	Grasland mit Bäumen zu Abbaufäche gehörig	
N132	Grasland mit Bäumen zu Deponie gehörig	
N122	Grünstreifen mit Bäumen neben Straßen	
N124	Grasland mit Bäumen zu Flughafen gehörig	
N142	Zeltplätze, Wildpark	
N141	Stadtparks, (Hausgarten)	
N211	Grasland mit Bäumen, intensiv bewirtschaftet	
N214	Streuobstwiesen	
N311	Naturverjüngungsflächen, Waldlichtungen	
N999	Keine Nutzung	
N121	Truppenübungsplatz	B322
N122	Heide neben Straßen	
N124	Heide auf Flughafengelände	
N999	Keine Nutzung	
N112	Bebauung am Dorfrand	B324
N120	ungenutzte / verwildernde (Rand)Bereiche von Industrieflächen	
N121	ungenutzte / verwildernde (Rand)Bereiche von Industrie-u. Verwaltungsflächen	
N123	ungenutzte / verwildernde (Rand)Bereiche von Hafentflächen	
N131	ungenutzte / verwildernde Bereiche von Abbauflächen (keine Abbauaktivität)	
N132	ungenutzte / verwildernde Bereiche von Deponien (keine Aktivität)	
N122	Grünstreifen mit Büschen und Sträuchern neben Straßen	
N124	ungenutzte / verwildernde (Rand)Bereiche von Flughafenflächen	
N142	Wildpark	
N141	Stadtwald	
N999	Keine Nutzung, Gebüsch	
N211	Baumschule	B310
N311	Wiederaufforstungs-oder Naturverjüngungsflächen mit Bäumen im Wachstum (bis 5m Höhe)	
N112	Bebauung unter Bäumen am Dorfrand	B311
N120	bewaldete (Rand)Bereiche von Industrieflächen	
N121	bewaldete (Rand)Bereiche von Industrie-u. Verwaltungsflächen	
N123	bewaldete (Rand)Bereiche von Hafentflächen	
N131	bewaldete Bereiche von Abbauflächen (keine Abbauaktivität)	
N132	bewaldete Bereiche von Deponien (keine Aktivität)	
N122	Baumreihen neben Straßen	

LN	Bemerkung	LB
N124	bewaldete (Rand)Bereiche von Flughafenflächen	B311
N142	Kletterwälder, Wildpark, Waldfriedhof	
N141	Stadtwald	
N211	Baumschule	
N311	Laubwald	
N999	Wald ohne spezifische Nutzung (u.a. Nationalpark)	
N112	Bebauung unter Bäumen am Dorfrand	B312
N120	bewaldete (Rand)Bereiche von Industrieflächen	
N121	bewaldete (Rand)Bereiche von Industrie-u. Verwaltungsflächen	
N123	bewaldete (Rand)Bereiche von Hafentflächen	
N131	bewaldete Bereiche von Abbaufächen (keine Abbauaktivität)	
N132	bewaldete Bereiche von Deponien (keine Aktivität)	
N122	Baumreihen neben Straßen	
N124	bewaldete (Rand)Bereiche von Flughafenflächen	
N142	Kletterwald, Wildpark, Waldfriedhof	
N141	Stadtwald	
N211	Baumschule	
N311	Mischwald	
N999	Wald ohne spezifische Nutzung (u.a. Nationalpark)	B312
N122	Eisenbahn	B313
N131	Sandgrube, Kiesgrube	
N133	Baustelle	
N142	(künstlicher) Badestrand	
N311	Windwurfflächen	
N999	Erosionsflächen im Hochgebirge, Dünen und sonstige Sandflächen	
N131	Steinbruch	B330
N999	Natürlicher Fels ohn Nutzung	
/	Nutzung, die vor dem Brand vorlag, bleibt erhalten	B332
N999	Gletscher o. Dauerschneefelder	B334
N999	Sumpf	B335
N131	Aktiver Torfstich	B412
N999	Natürliches oder renaturiertes Moor	

LN	Bemerkung	LB
N999	Sumpf mit Büschen/Bäumen	B413
N999	Moor mit Büschen/Bäumen	B414
N510	Watt	B423
N123	Hafen am Fließgewässer	B511
N510	Fließgewässer für Schifffahrt	
N999	Fließgewässer ohne Nutzung	
N120	Fischzucht	B512
N123	Hafen am See	
N131	Baggersee	
N132	Flüssiger Abfall, Schlackensee	
N142	Badensee	
N510	Wasserfläche, die Teil von Wasserstraße (Schifffahrt) ist	
N999	Wasserfläche ohne Nutzung	
N999	Lagune oder Bodden	
N123	Hafen im Mündungsgebiet	B522
N510	Mündungsgebiet (Schifffahrt)	
N999	Mündungsgebiet	
N123	Meereshafen	B523
N999	Offenes Meer	

Quelle: verändert nach Bundesamt für Kartographie und Geodäsie (Hg.) (2018): Digitales Landbedeckungsmodell für Deutschland LBM-2015. Frankfurt am Main: Bundesamt für Kartographie und Geodäsie, S. 10-43.

Anhang 3: Kreuztabelle zur Zuordnung des DLM-DE ins CLC-Schema

LB / LN	SIE	VEG	Wohnen		Produktion	Öffentlichkeit	Hafen	Abbauflächen	Deponien	Straßen- und Bahnverkehr	Flugverkehr	Sport und Freizeit	städt. Grünfläche	Wasser	Landwirtschaft (intensiv)	extensive Nutzung	Forst	Im Bau	nicht relevant			
			N112	N120																N121	N123	N131
A	Bebauung	>= 70	B110	111	121	111	123	131	132	122	124	142			211				111			
				112	121	121	123	131	132	122	124	142			211				112			
				111	121	121	123	131	132	122	124	142			211					121		
				142	121	121	123	131	132	122	124	142	141			211	231			133	122	
B	Verlegte gebäudefreie Flächen	>= 0 & < 15	B242	112	121	121	123	131	132	122	124	142	141							142		
				112	121	121	123	131	132	122	124	142								142		
				112	121	121	123	131	132	122	124	142									142	
				112	121	121	123	131	132	122	124	142									142	
C	Mischflächen (regelmäßige Struktur)	>= 15 & <= 50	B211	211	121	121	123	131	132	122	124	142	141							142		
				211	121	121	123	131	132	122	124	142									142	
				211	121	121	123	131	132	122	124	142										142
				211	121	121	123	131	132	122	124	142										142
D	Ackerland	>= 15 & <= 50	B221							122												
E	Weinbau	>= 0 & < 15	B221							122												
F	Obst- und Beerensobst	>= 0 & < 15	B222							122												
G	Hopfen	>= 0 & < 15	B224							122												
H	homogenes Grünland	>= 15 & <= 50	B231	112	121	121	123	131	132	122	124	142	141						133	231		
				142	121	121	123	131	132	122	124	142	141						133	231		
				112	121	121	123	131	132	122	124	142	141							133	231	
				142	121	121	123	131	132	122	124	142	141							133	231	
I	inhomogenes Grünland	>= 15 & <= 50	B231	112	121	121	123	131	132	122	124	142	141						133	231		
				142	121	121	123	131	132	122	124	142	141						133	231		
				112	121	121	123	131	132	122	124	142	141							133	231	
				142	121	121	123	131	132	122	124	142	141							133	231	
J	Grasland mit Bäumen (<50%)	>= 0 & < 15	B233	142	121	121	123	131	132	122	124	142	141						133	231		
				142	121	121	123	131	132	122	124	142	141						133	231		
				142	121	121	123	131	132	122	124	142	141						133	231		
				142	121	121	123	131	132	122	124	142	141						133	231		
K	Zwergsträucher (Heide)	>= 0 & < 15	B322			121				122	124											
						121					122	124										
						121						122	124									
						121						122	124									
L	Büche und Sträucher	>= 15 & <= 50	B324	112	121	121	123	131	132	122	124	142	141						133	324		
				142	121	121	123	131	132	122	124	142	141						133	324		
				112	121	121	123	131	132	122	124	142	141							133	324	
				142	121	121	123	131	132	122	124	142	141							133	324	
M	Aufrostung	>= 0 & < 15	B310			121				122	124											
						121					122	124										
						121						122	124									
						121						122	124									
N	Laubbäume	>= 15 & <= 50	B311	112	121	121	123	131	132	122	124	142	141						133	311		
				142	121	121	123	131	132	122	124	142	141						133	311		
				112	121	121	123	131	132	122	124	142	141							133	311	
				142	121	121	123	131	132	122	124	142	141							133	311	
O	Nadelbäume	>= 15 & <= 50	B312	112	121	121	123	131	132	122	124	142	141						133	312		
				142	121	121	123	131	132	122	124	142	141						133	312		
				112	121	121	123	131	132	122	124	142	141							133	312	
				142	121	121	123	131	132	122	124	142	141							133	312	
P	Laub- und Nadelbäume	>= 15 & <= 50	B313	142	121	121	123	131	132	122	124	142	141						133	313		
				142	121	121	123	131	132	122	124	142	141						133	313		
				142	121	121	123	131	132	122	124	142	141						133	313		
				142	121	121	123	131	132	122	124	142	141						133	313		
Q	Sand, Steine, Erde	>= 10	B330		121	121	123	131	132	122	124	142							133	330		
					121	121	123	131	132	122	124	142							133	330		
					121	121	123	131	132	122	124	142							133	330		
					121	121	123	131	132	122	124	142							133	330		
R	Fels	< 10	B332		121	121	123	131	132	122	124	142							133	332		
					121	121	123	131	132	122	124	142							133	332		
					121	121	123	131	132	122	124	142							133	332		
					121	121	123	131	132	122	124	142							133	332		
S	Brandfläche	>= 10	B334		121	121	123	131	132	122	124	142							133	334		
					121	121	123	131	132	122	124	142							133	334		
					121	121	123	131	132	122	124	142							133	334		
					121	121	123	131	132	122	124	142							133	334		
T	Schnee (permanente) und Eis	>= 10	B335	112	121	121	123	131	132	122	124	142							133	335		
				112	121	121	123	131	132	122	124	142							133	335		
				112	121	121	123	131	132	122	124	142							133	335		
				112	121	121	123	131	132	122	124	142							133	335		
U	Brandfläche	>= 10	B334		121	121	123	131	132	122	124	142							133	334		
					121	121	123	131	132	122	124	142							133	334		

ARCGIS PRO
„EXPORT TRAINING DATA FOR DEEP LEARNING“ TOOL

INPUT DATA

(supported: 8bit, 3 layers)
- R G B; NIR GB; NDVI GB -

ADDITIONAL INPUT RASTER

--

OUTPUT FOLDER

- INDIVIDUAL-

INPUT FEATURE CLASS OR CLASSIFIED RASTER OR TABLE

- DLBMD 2015 -

CLASS VALUE FIELD

- LBM1 (=26 CLASSES), LBM2 (=7CLASSES) -

BUFFER RADIUS

- 0 (INPUT FEATURES ARE POLYGONS) -

INPUT MASK POLYGONS

--

IMAGE FORMAT

- TIFF -

TILE SIZE X/Y

- 320/320; 290/290 -

STRIDE X/Y

-320/320; 230/230 -

ROTATION ANGLE

-0; 90-

REFERENCE SYSTEM

- MAP SPACE-

METADATAFORMAT

- CLASSIFIED TILES -

eCOGNITION
„GENERATE LABELED SAMPLE PATCHES“
ALGORITHM PARAMETERS

DOMAIN
- IMAGE OBJECT LEVEL-

CLASS FILTER
- 1-7; 1-26-

CONDITION
- NO -

MAP/REGION
- FROM PARENT -

MAX. NUMBER OF OBJECTS
- ALL -

SAMPLES ONLY
- NO -

TYPE
- TIFF -

SAMPLE COUNT
-5.000; 80.000 PER CLASS -

SAMPLE PATCH SIZE
- 320; 64; 32 -

USE IMAGE LAYER ARRAY
- NO -

IMAGE LAYER
(supported: 8bit & 32bit, no layer limitation)
- R G B;; NIR GB; R G B redEdge NIR -

SAMPLE FOLDER
- INDIVIDUAL -

DELETE EXISTING FOLDER
- NO -

NORMALIZATION
- DISABLED-

ARCGIS PRO „TRAIN DEEP LEARNING MODEL“ TOOL

INPUT TRAINING DATA

(supported: 8bit, 3 layers)

- INDIVIDUAL FOLDER WITH METADATA -

OUTPUT MODEL

- INDIVIDUAL -

EPOCHS

- 20; 40 -

MODEL TYPE

- U-NET; PYRAMID SCENE PARSING NETWORK; DEEPLAB V3 -

LEARNING RATE

- DEFAULT: OPTIMAL LEARNING RATE WILL BE EXTRACTED-

BACKBONE MODEL

- RESNET 18; RESNET 34; RESNET 50; DENSE NET 121 -

PRE-TRAINED MODEL

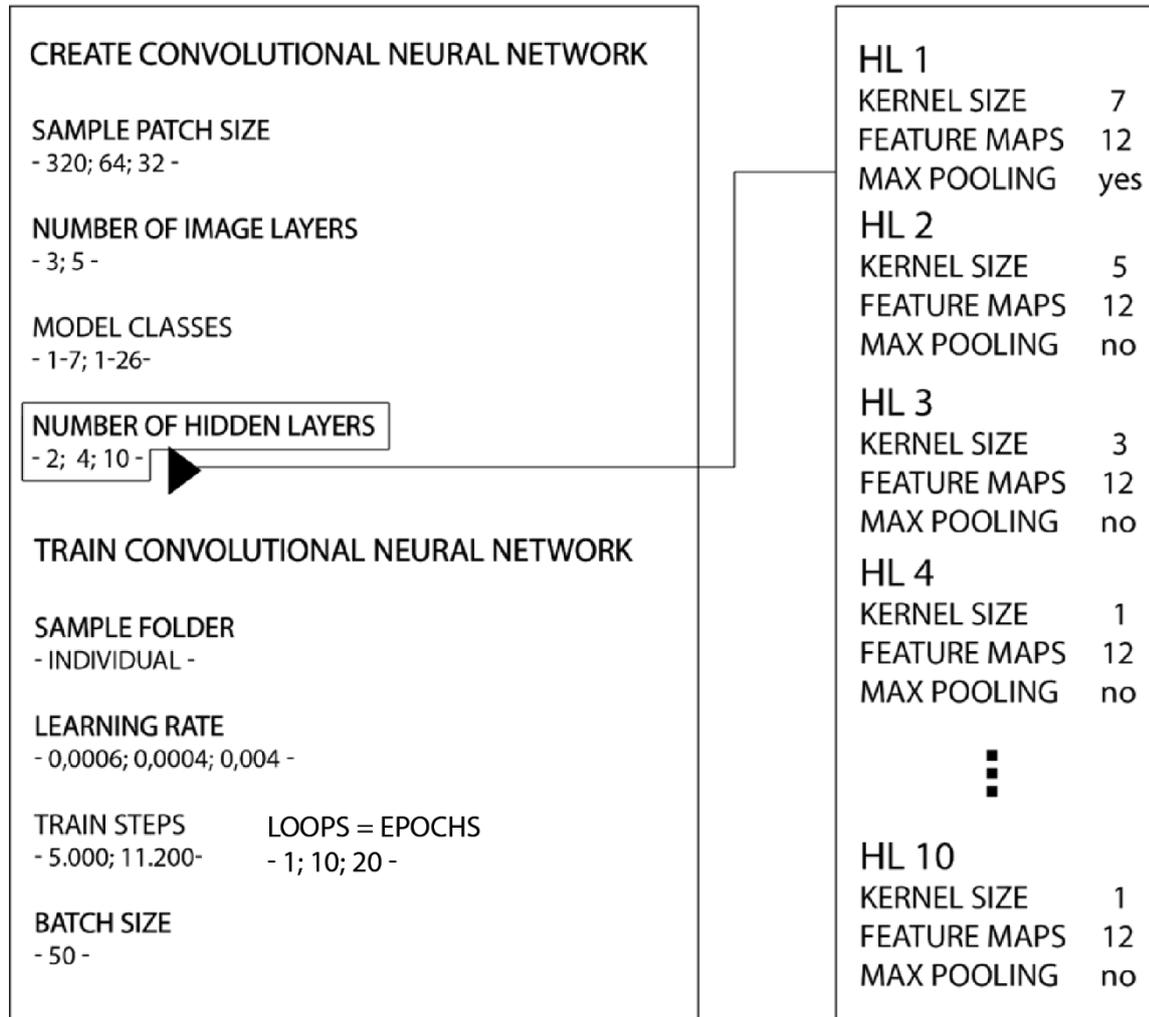
- -

VALIDATION

-16% -

(BATCH SIZE: 16; PROCESSOR TYPE: GPU)

eCOGNITION
„CREATE CONVOLUTIONAL NEURAL NETWORK“ +
„TRAIN CONVOLUTIONAL NEURAL NETWORK“
ALGORITHM PARAMETERS



Anhang 9: Arcgis Pro – Experimente mit Ergebnissen zur Methodenauswahl

Experimente zur Methodenauswahl Arcgis Pro - Deep Learning

	OA [%]
* R-G-B_LBM1_18_20_UN	72
R-G-B_LBM2_18_20_UN	82
R-G-B_LBM2_18_40_UN	84
R-G-B_LBM2_34_40_UN	84
NDVI-G-B_LBM1_18_20_UN	72
NDVI-G-B_LBM2_18_20_UN	82
NDVI-G-B_LBM2_18_40_UN	82
NDVI-G-B_LBM2_34_40_UN	83

	OA [%]
R-G-B_LBM2_RN34_40_PSPN	3
R-G-B_LBM2_D121_40_PSPN	79
NDVI-G-B_LBM2_RN34_40_DL	81
NDVI-G-B_LBM2_DN121_40_DL	79

	OA [%]
NDVI-G-B_LBM1_34_40	73
NIR-G-B_LBM2_34_40	85
PCA_LBM2_34_40	49
NIR-G-B_LBM1_34_40	77
PCA_LBM1_34_40	43
R-G-B_LBM1_34_40	72

	OA [%]
NIR-G-B_LBM1_34_40+A	76
R-G-B_LBM1_34_40+A	70

- es sind nur 3 Bänder als Input möglich: erste Versuche mit R-G-B und NDVI-G-B Bänderkombination
- U-Net Architektur
- 18 bzw. 34 Schichten tiefes Resnet (RN) Backbone-Modell
- 20 bzw. 40 Epochen

- ▼
- Versuch mit DeepLab (DL) und Pyramid Scene Parsing Network (PSPN) als Architekturen

- Versuch mit Densenet (DN) Backbonemodell - 121 Schichten tief

- ▼
- Versuch mit NIR-G-B und Hauptkomponenten (PCA) Bänderkombination

- ▼
- Versuch Ergebnisse mit Augmentation (A) der Samples zu verbessern (Rotation 90°; Überlappung (Stride 290x/290y statt 320x/320y) und Kachelgrößen (230x230 statt 320x320 Pixel)
- Bei der Klassifikation sind [tile_size] und [padding] vernachlässigbar

Durchführung der Klassifikation anhand der erhobenen Methode:

	OA [%]
NIR-G-B_LBM1	75
NIR-G-B_LBM2	84

- NIR-G-B Bandkombination
- Resnet-34 Backbone-Modell
- Augmentation
- 40 Epochen

* Bänderkombination_Klassen_Backbone-Modell_Epochen + Augmentation
 OA... Overall Accuracy
 LBM1/LBM2...Landbedeckungsmodell mit 26Klassen bzw. 7 Klassen

Anhang 10: eCognition – Experimente mit Ergebnissen zur Methodenauswahl

Experimente zur Methodenauswahl eCognition - Deep Learning

	OA
R-G-B_LBM1_s	25,2%
R-G-B_LBM2_s	13,7%
NIR-G-B_LBM1_s	13,0%
R-G-B_LBM2_s	39,0%
R-G-B-rE-NIR_LBM1_s	11,0%
R-G-B-rE-NIR_LBM2_s	53,8%
	OA
R-G-B_LBM1_s_mr	24,8%
R-G-B_LBM2_s_mr	13,9%
NIR-G-B_LBM1_s_mr	13,4%
R-G-B_LBM2_s_mr	38,1%
R-G-B-rE-NIR_LBM1_s_mr	11,2%
R-G-B-rE-NIR_LBM2_s_mr	53,5%
	OA
R-G-B_LBM1_s_ps320	[/]
R-G-B_LBM2_s_ps320	[/]
R-G-B-rE-NIR_LBM1_s_ps320	[/]
R-G-B-rE-NIR_LBM2_s_ps320	[/]
	OA
R-G-B_LBM1_s_A	3,6%
R-G-B_LBM2_s_A	43,5%
R-G-B-rE-NIR_LBM1_s_A	7,5%
R-G-B-rE-NIR_LBM2_s_A	40,3%
	OA
R-G-B_LBM1_tst2_A	9,1%
R-G-B_LBM2_tst2_A	50,0%
R-G-B-rE-NIR_LBM1_tst2_A	23,5%
R-G-B-rE-NIR_LBM2_tst2_A	61,0%
	OA
R-G-B-rE-NIR_LBM1_tst3_A	43,4%
R-G-B-rE-NIR_LBM2_tst3_A	68,6%
	OA
R-G-B-rE-NIR_LBM1_tst4_A	27,5%
R-G-B-rE-NIR_LBM2_tst4_A	57,0%
	OA
R-G-B-rE-NIR_LBM1_tst5_A	40,5%
R-G-B-rE-NIR_LBM2_tst5_A	42,3%

	s...simple (=Voreinstellungen)
■	Patch Size 64
■	Scale Parameter 42
■	Modell: 1 Loop, 2 Hidden Layer, Batch Size 50, Steps 5000, Lernrate 0,0006
▼	s_mr...Änderung Segmentierung Scale Parameter 20
▼	s_ps320...Änderung Sample Patch Size
■	Patch Size 320
▼	A...Augmentation
■	Patch Size 32
■	Rotation 90°
▼	tst2...Änderungen Modell
■	Modell: 10 Loops, 2 Hidden Layer, Batch Size 50, Steps 5000, Lernrate 0,0004
▼	tst3...Änderungen Modell
■	Modell: 10 Loops, 10 Hidden Layer, Batch Size 50, Steps 5000, Lernrate 0,0004
▼	tst4...Änderungen Modell
■	Modell: 20Loops, 10 Hidden Layer, Batch Size 50, Steps 5000, Lernrate 0,0004
▼	tst5...Änderungen Modell
■	Modell: 20Loops, 10 Hidden Layer, Batch Size 50, Steps 5000, Lernrate 0,004
▼	Durchführung der Klassifikation anhand der erhobenen Methode:
	OA
	R-G-B-rE-NIR_LBM1_tst4_A 40,16%
	R-G-B-rE-NIR_LBM2_tst4_A 62,3%

* Bänderkombination_Klassen_Einstellungen_Augmentation
OA... Overall Accuracy
LBM1/LBM2...Landbedeckungsmodell mit 26Klassen bzw. 7 Klassen

Quelle: eigene Darstellung.

Anhang 11: eCognition und Arcgis Pro – Experimente mit Ergebnissen zur Methodenauswahl

**Experimente zur Methodenauswahl
Arcgis Pro & eCognition- Shallow Learning**

OA		
Layer	ArcGis Pro	eCognition
R-G-B	pixel-basiert	objekt-basiert
KNN_LBM1	5,3%	22,6%
RT_LBM1	18,5%	37,8%
KNN_LBM2	17,7%	39,9%
RT_LBM2	33,4%	44,3%

OA		
Layer	ArcGis Pro	eCognition
R-G-B-rE-NIR	pixel-basiert	objekt-basiert
KNN_LBM1	19,3%	27,1%
RT_LBM1	24,2%	46,0%
KNN_LBM2	38,9%	41,3%
RT_LBM2	33,7%	41,6%

OA		
Layer	ArcGis Pro	eCognition
R-G-B-rE-NIR-NDVI-NDWI	pixel-basiert	objekt-basiert
KNN_LBM1	18,0%	27,0%
RT_LBM1	24,3%	46,3%
KNN_LBM2	35,9%	41,9%
RT_LBM2	40,2%	42,3%

**Durchführung der Klassifikation
anhand der erhobenen Methode:**

Arcgis Pro	
pixel-basiert	
RT_25_Bayern *	
RT_LBM1	34,0%
RT_LBM2	56,0%

eCognition	
objekt-basiert	
RT_25_Bayern *	
RT_LBM1	43,3%
RT_LBM2	57,6%

RT...Random Trees
 KNN... K-Nearest Neighbor * Indizes+Hauptkomponenten+Textur
 LBM1/LBM2...Landbedeckungsmodell mit 26Klassen bzw. 7 Klassen

Quelle: eigene Darstellung.

Anhang 12: Fehlermatrizen Deep Learning LBM2

Ergebnis Endklassifikation - Deep Learning Arcgis Pro									
Klassifikation/Referenz	1	2	3	4	5	6	7	Total	U A
0	444	14247	401472	133731	949044	0	497	1499435	
1	8101720	410669	2918625	127434	218741	553	78881	11856623	68,3%
2	942728	132954205	14243895	1066530	111047	16570	74151	149409126	89,0%
3	9491196	29655336	122272694	7630140	301544	400744	816441	170568095	71,7%
4	566698	2816727	11263855	202029039	497863	602401	612571	218389154	92,5%
5	115170	54990	239929	488442	2221735	478	61329	3182073	69,8%
6	281	12845	391251	171453	975	245492	534	822831	29,8%
7	36577	74278	281518	238521	26945	26158	7973313	8657310	92,1%
Total	19254814	165993297	152013239	211885290	4327894	1292396	9617717	564384647	
P A	42,1%	80,1%	80,4%	95,3%	51,3%	19,0%	82,9%		84,30%

Ergebnis Endklassifikation - Deep Learning eCognition									
Klassifikation/Referenz	1	2	3	4	5	6	7	Total	U A
1	3634056	1224463	5864185	1075586	2102269	1864	115310	14017733	25,9%
2	1449437	105218336	20685848	1896546	53582	39913	110207	129453869	81,3%
3	13222502	54914771	100272018	66949882	1485447	921490	2979314	240745424	41,7%
4	744084	3468809	18924725	140507809	335973	285258	4188234	168454892	83,4%
5	44513	43528	27888	35801	307053	340	408155	867278	35,4%
6	137191	971074	5992128	1197341	18128	20827	18622	8355311	0,2%
7	23073	152367	248471	226007	27567	22705	1801639	2501829	72,0%
Total	19254856	165993348	152015263	211888972	4330019	1292397	9621481	564396336	
P A	18,9%	63,4%	66,0%	66,3%	7,1%	1,6%	18,7%		62,30%

Quelle: eigene Darstellung.

Anhang 13: Fehlermatrizen Random Forest LBM2

Ergebnis Endklassifikation - Random Forest Arcgis Pro									
Klassifikation/Refer	1	2	3	4	5	6	7	Total	U A
1	10063047	31782587	28185842	4276166	997420	64855	404383	75774300	13,3%
2	1678809	87523239	21612762	3130337	274594	46665	74032	114340438	76,5%
3	2129021	22981318	55683669	12400288	185459	181418	143555	93704728	59,4%
4	611458	3880936	13497903	152089995	125320	228505	557258	170991375	88,9%
5	3122026	7113580	3943717	2128385	2387617	12373	498586	19206284	12,4%
6	1467272	12365322	28356446	36691835	140975	742304	484251	80248405	0,9%
7	183218	346319	734464	1171299	218546	16277	7458577	10128700	73,6%
Total	19254851	165993301	152014803	211888305	4329931	1292397	9620642	564394230	
P A	52,3%	52,7%	36,6%	71,8%	55,1%	57,4%	77,5%		56,0%
Ergebnis Endklassifikation - Random Forest eCognition									
Klassifikation/Refer	1	2	3	4	5	6	7	Total	U A
1	3058763	5674534	6546579	387399	173670	4035	67402	15912382	19,2%
2	4516868	128301608	66828716	8212216	473732	130719	548803	209012662	61,4%
3	4408355	14877235	31532274	5784868	339448	73292	303584	57319056	55,0%
4	557253	2367717	13524972	152289119	114002	301440	342885	169497388	89,8%
5	4999135	4254163	4108429	830269	2504798	2814	315049	17014657	14,7%
6	1523016	9934324	27746687	27943887	211137	742815	1613714	69715580	1,1%
7	191466	583767	1727606	16441216	513235	37282	6430045	25924617	24,8%
Total	19254856	165993348	152015263	211888974	4330022	1292397	9621482	564396342	
P A	15,9%	77,3%	20,7%	71,9%	57,8%	57,5%	66,8%		57,60%

Quelle: eigene Darstellung.

Klassifikation

Arcgis Pro
Deep Learning
LBM1

Legende

- 110
- 121
- 122
- 242

- 211
- 221
- 222
- 224

- 231
- 233
- 321

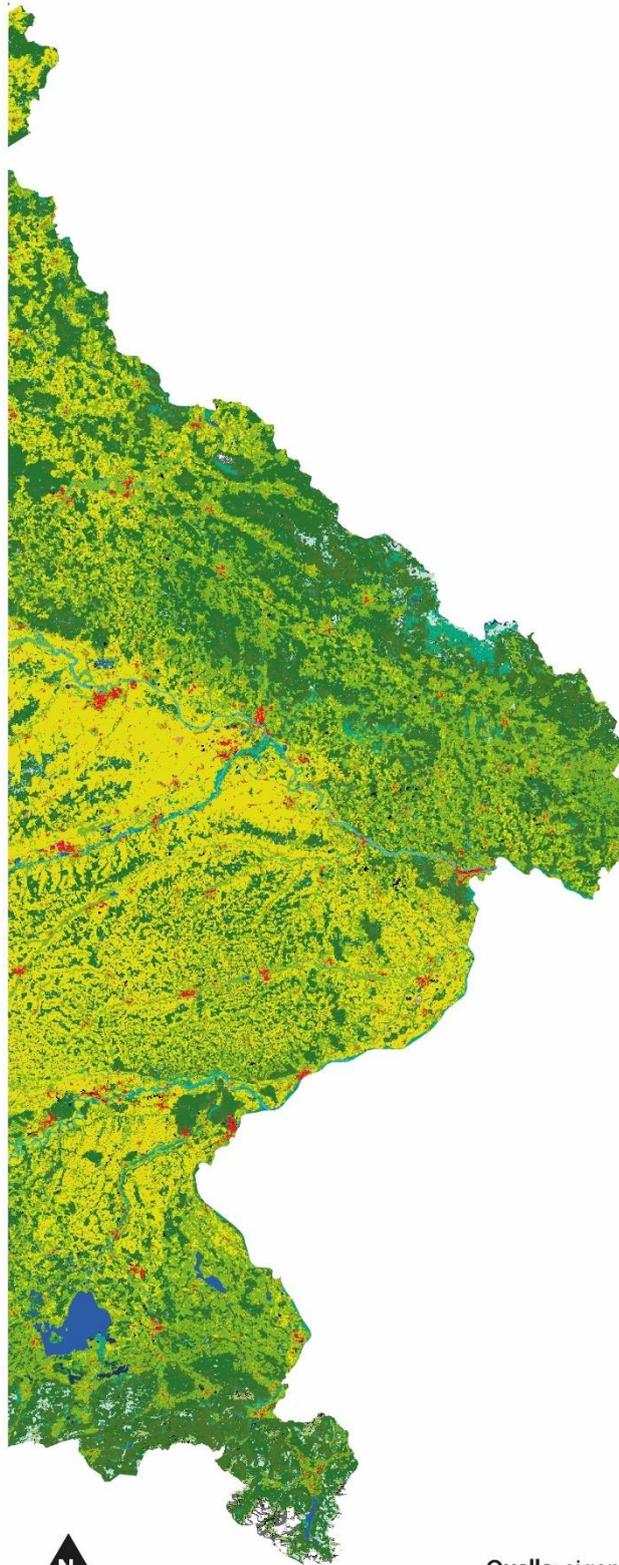
- 310
- 311
- 312
- 313
- 322
- 324

- 330
- 332
- 335

- 411
- 412
- 413
- 414

- 511
- 512

- unklassifiziert



Quelle: eigene Darstellung.

Klassifikation

Arcgis Pro
Random Forest
LBM1

Legende

- 110
- 121
- 122
- 242

- 211
- 221
- 222
- 224

- 231
- 233
- 321

- 310
- 311
- 312
- 313
- 322
- 324

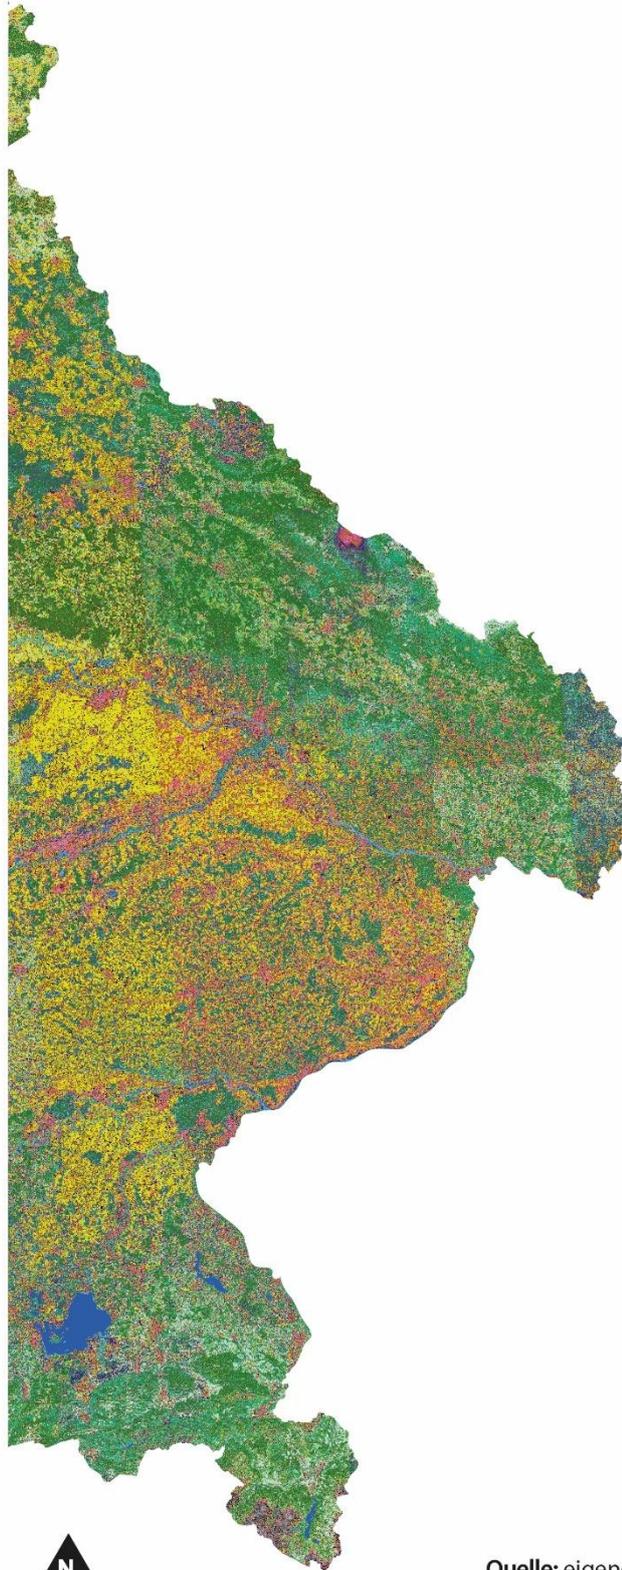
- 330
- 332
- 335

- 411
- 412
- 413
- 414

- 511
- 512

unklassifiziert

0 10 20 40 km



Quelle: eigene Darstellung.

Klassifikation
eCognition
Deep Learning
LBM1

Legende

- 110
- 121
- 122
- 242

- 211
- 221
- 222
- 224

- 231
- 233
- 321

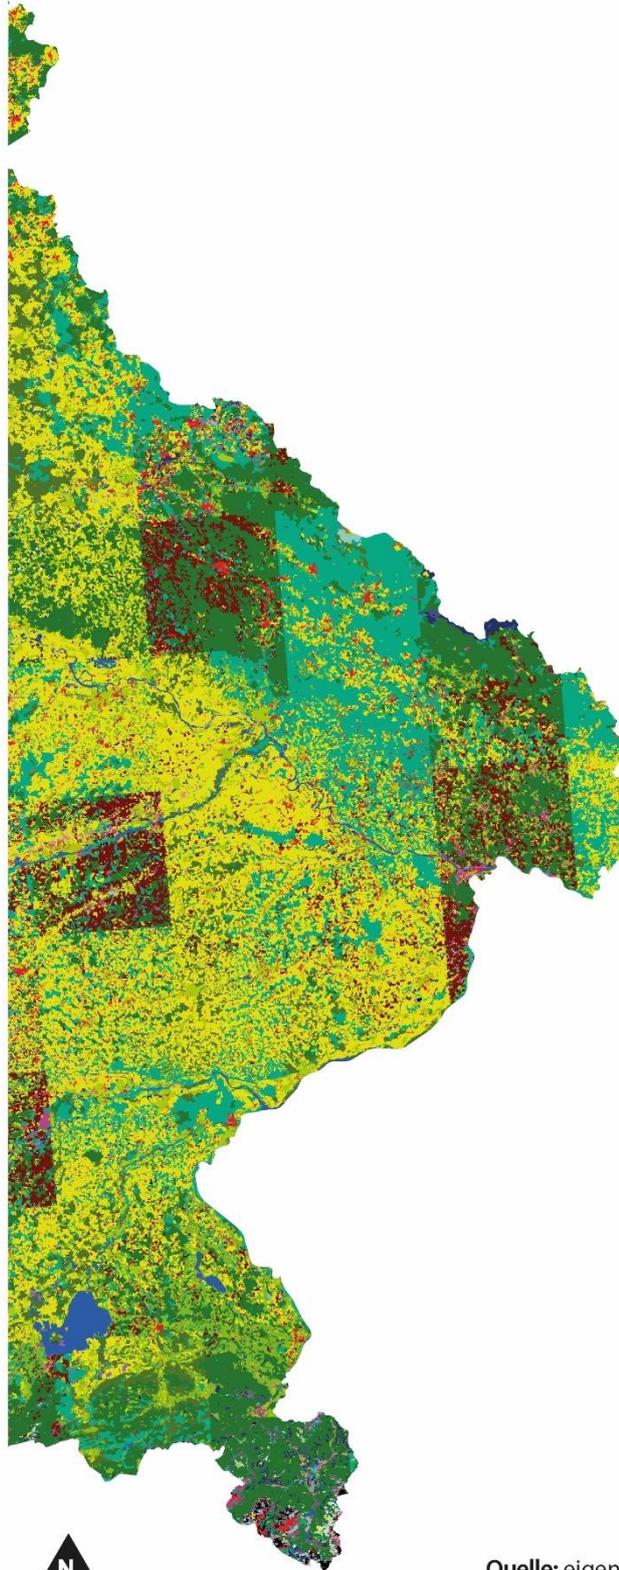
- 310
- 311
- 312
- 313
- 322
- 324

- 330
- 332
- 335

- 411
- 412
- 413
- 414

- 511
- 512

- unklassifiziert



Quelle: eigene Darstellung.

Klassifikation
eCognition
Random Forest
LBM1

Legende

- 110
- 121
- 122
- 242

- 211
- 221
- 222
- 224

- 231
- 233
- 321

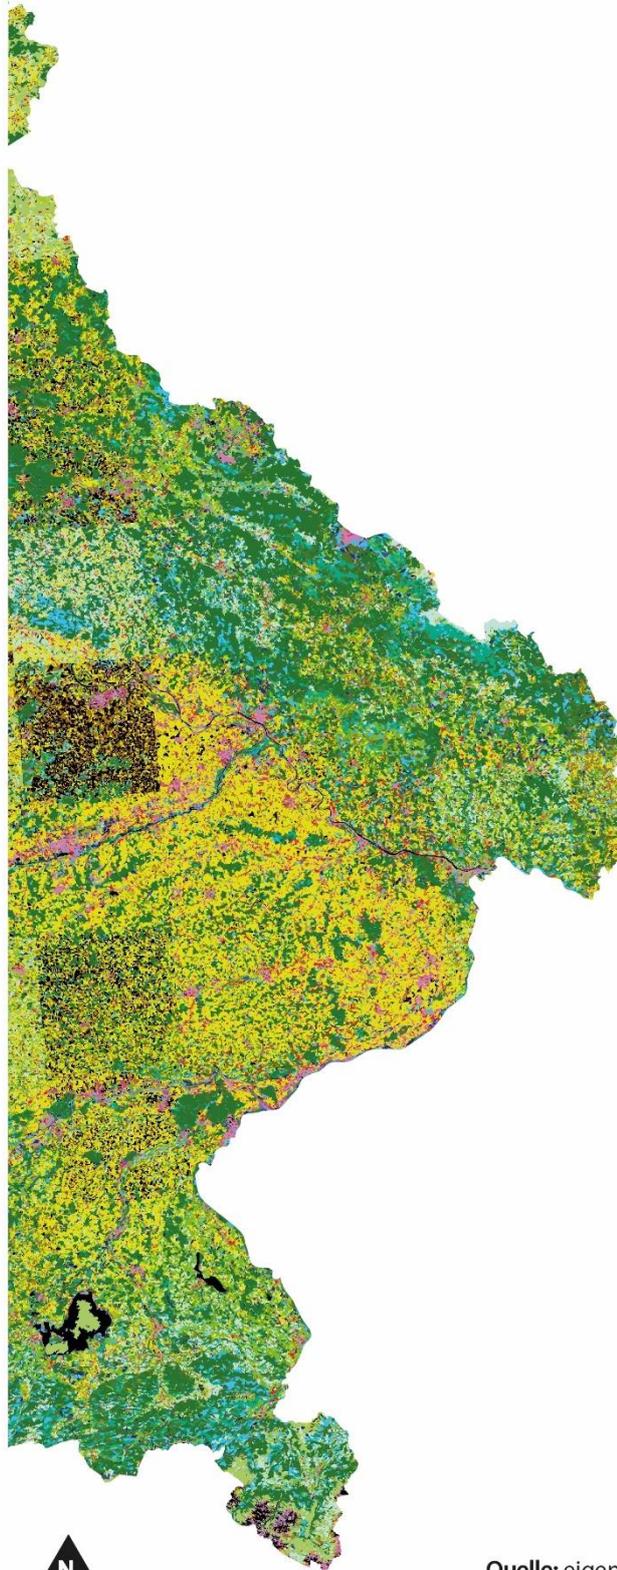
- 310
- 311
- 312
- 313
- 322
- 324

- 330
- 332
- 335

- 411
- 412
- 413
- 414

- 511
- 512

- unklassifiziert



0 10 20 40 km



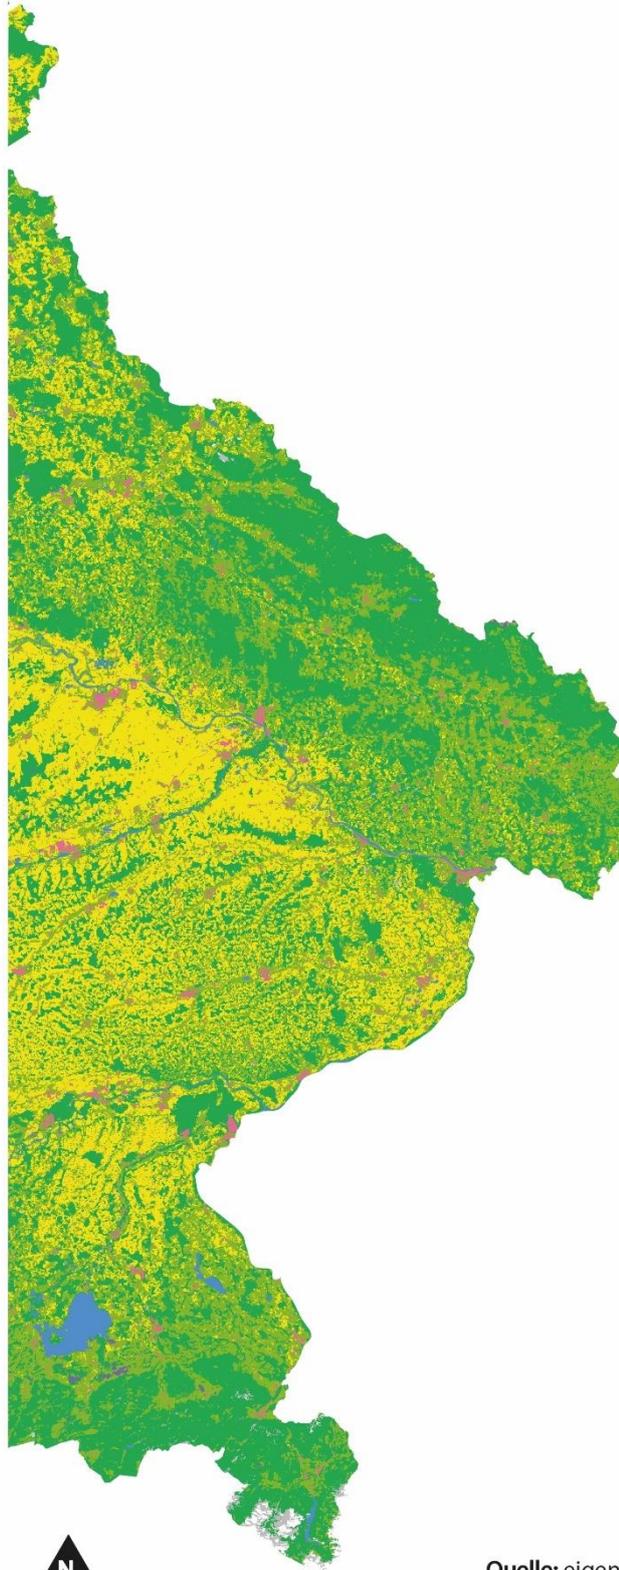
Quelle: eigene Darstellung.

Klassifikation

Arcgis Pro
Deep Learning
LBM2

Legende

- 1
- 2
- 3
- 4
- 5
- 6
- 7
- unklassifiziert



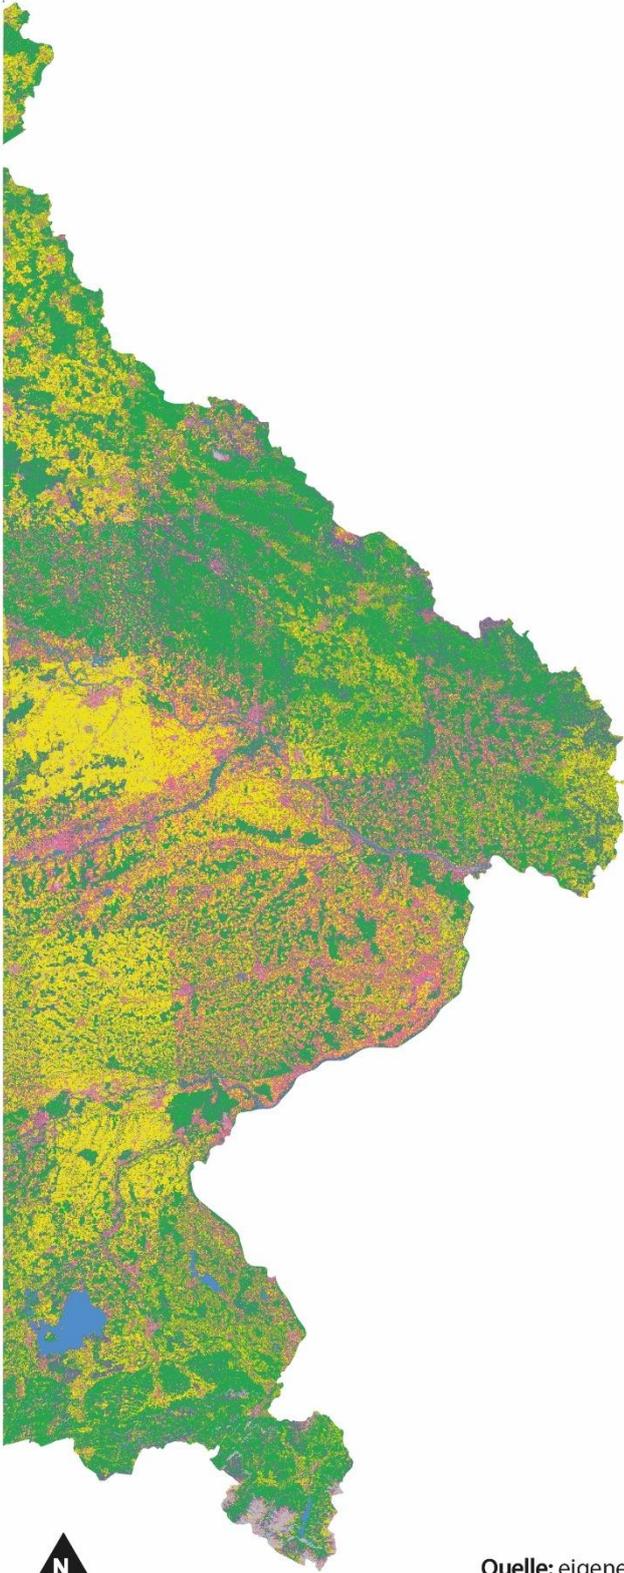
0 10 20 40 km



Quelle: eigene Darstellung.

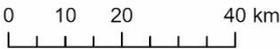
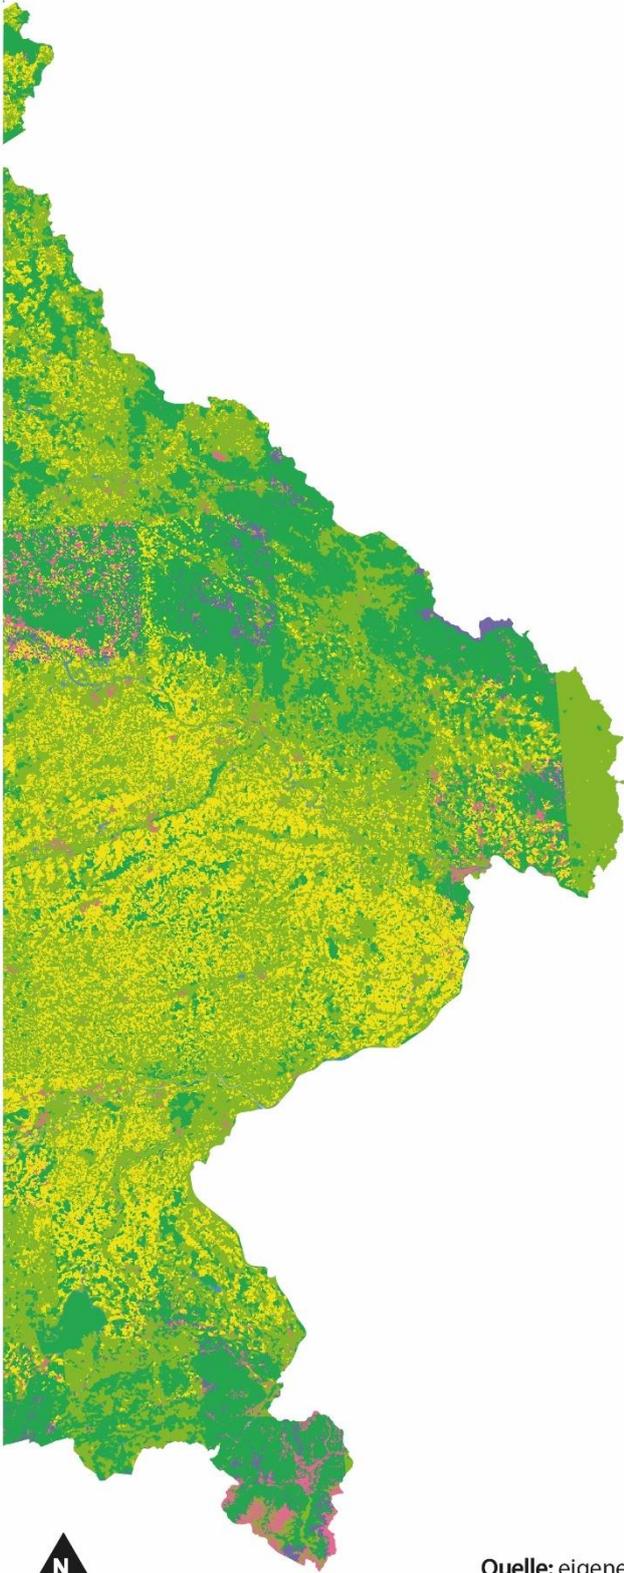
Klassifikation
Arcgis Pro
Random Forest
LBM2

- Legende**
- 1
 - 2
 - 3
 - 4
 - 5
 - 6
 - 7
 - unklassifiziert



Quelle: eigene Darstellung.

Klassifikation
eCognition
Deep Learning
LBM2

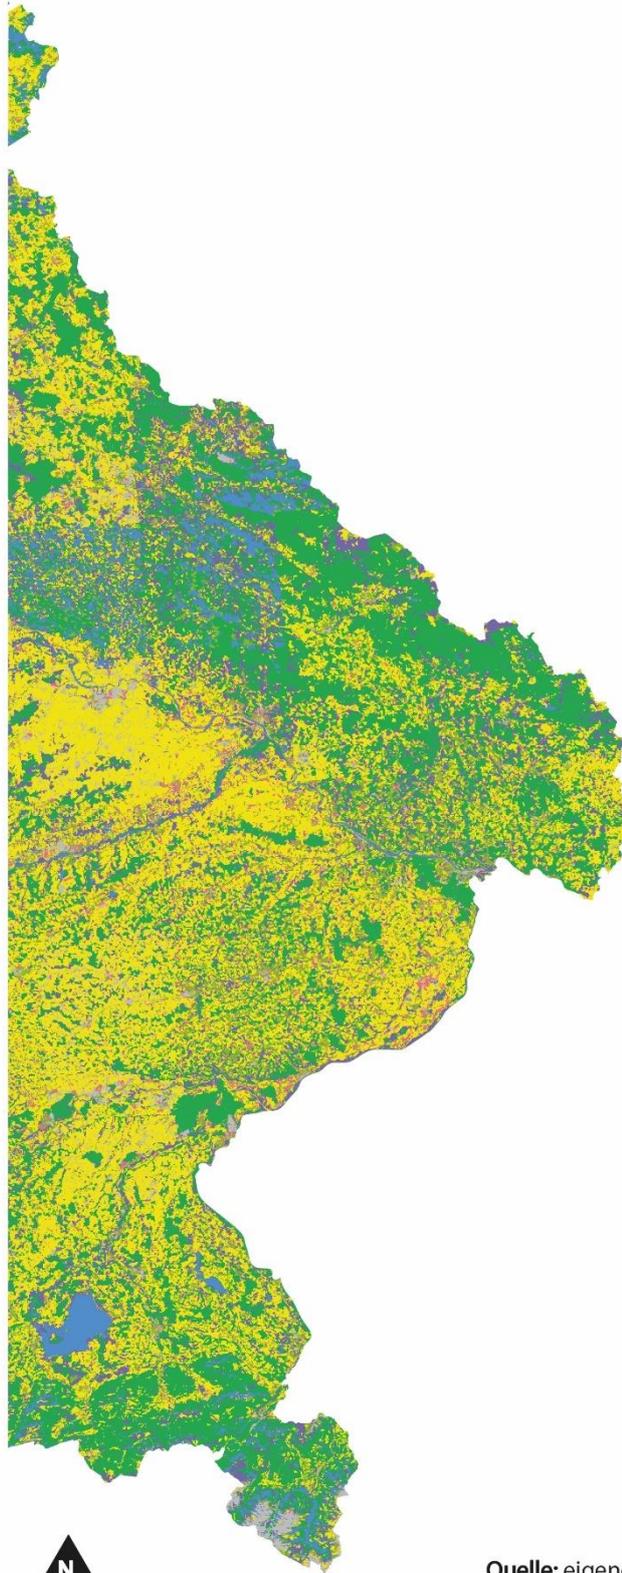


Quelle: eigene Darstellung.

Klassifikation
eCognition
Random Forest
LBM2

- Legende**
- 1
 - 2
 - 3
 - 4
 - 5
 - 6
 - 7
 - unklassifiziert

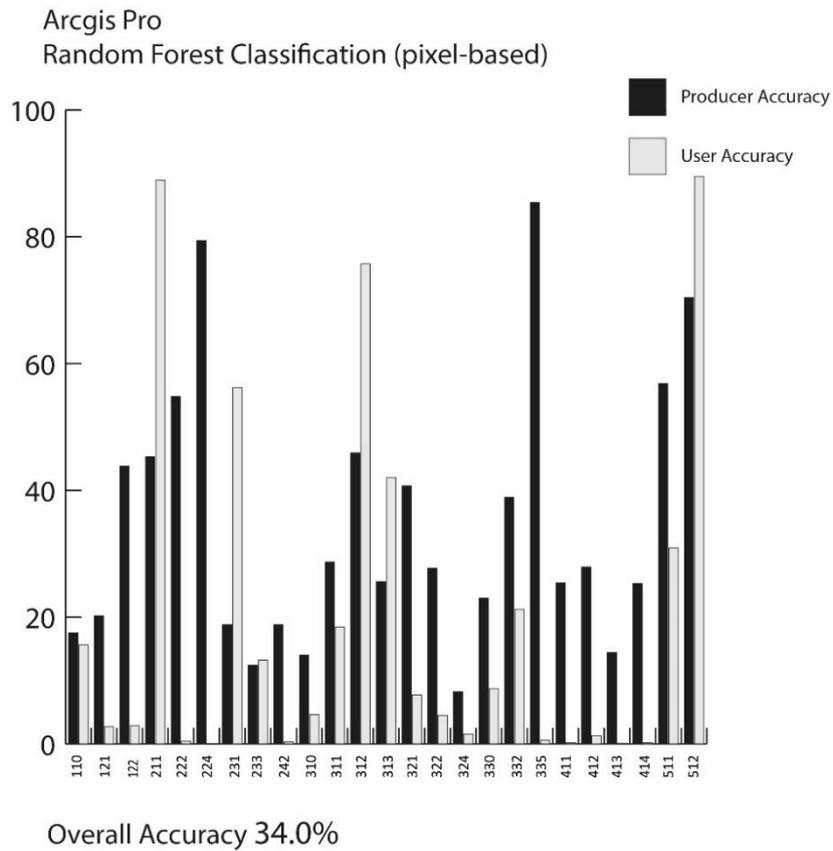
0 10 20 40 km



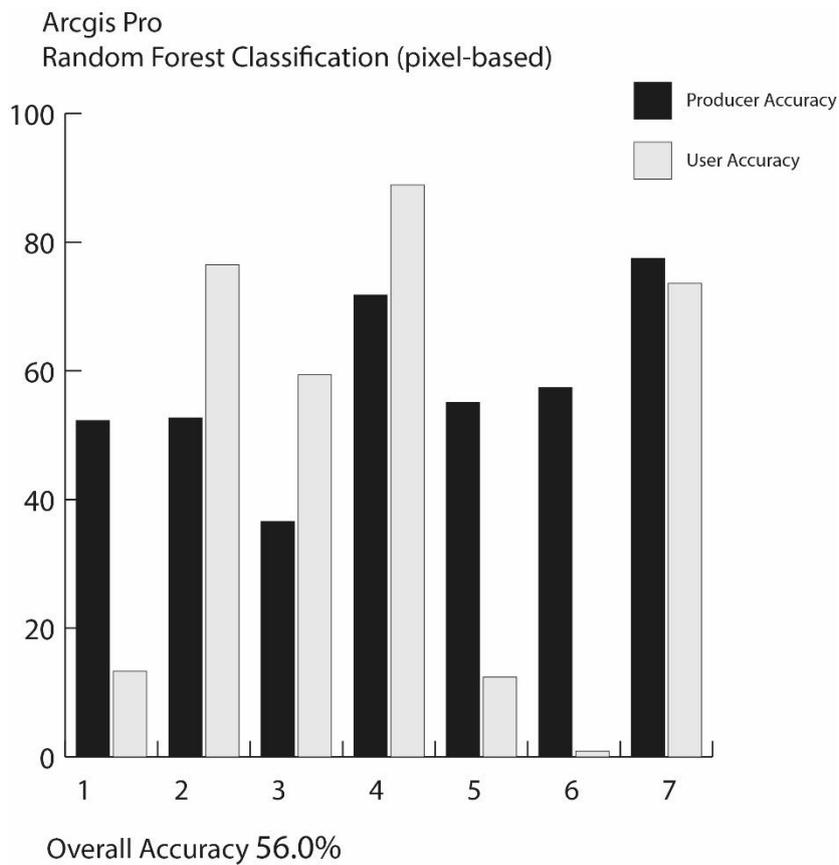
Quelle: eigene Darstellung.

Anhang 24: Genauigkeitsbewertungen der Arcgis Pro Random Forest Methode

LBM1



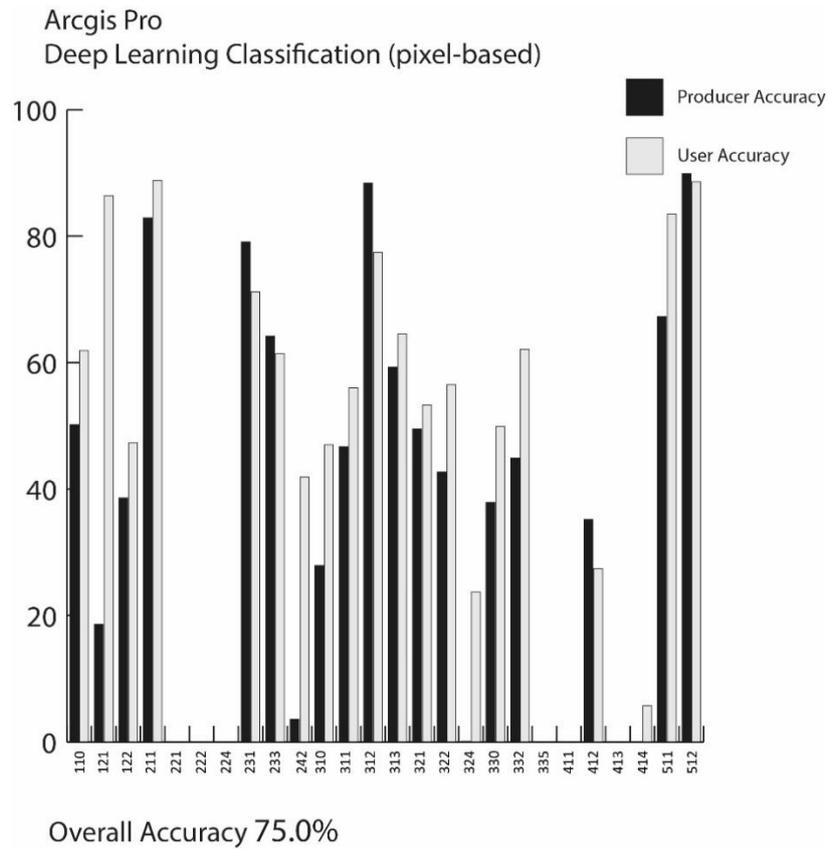
LBM2



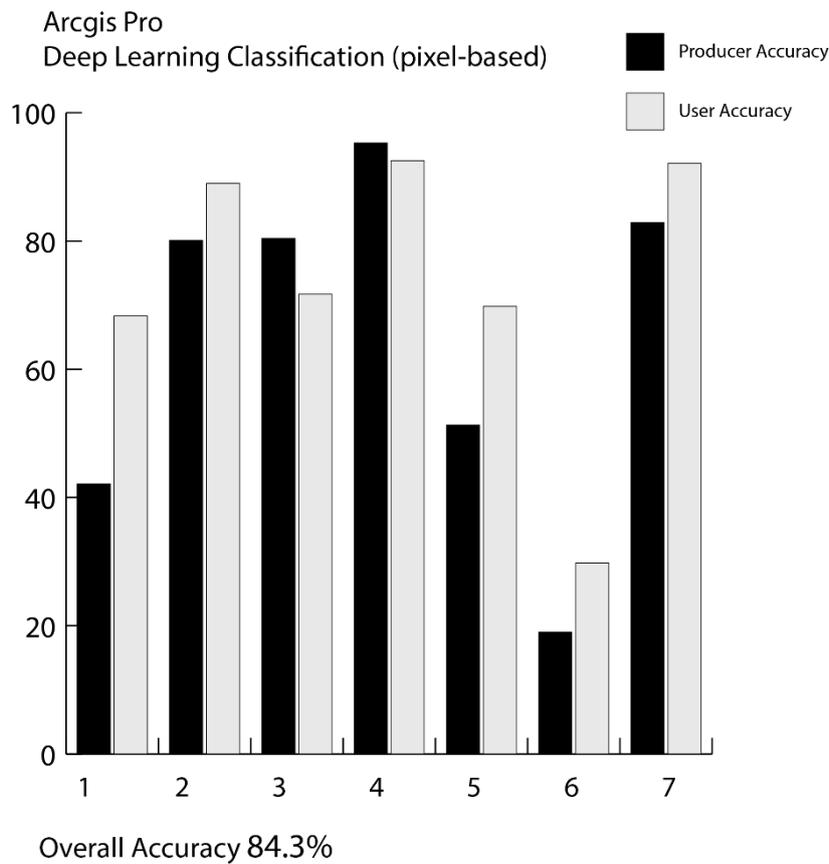
Quelle: eigene Darstellung.

Anhang 25: Genauigkeitsbewertungen der Arcgis Pro Deep Learning Methode

LBM1



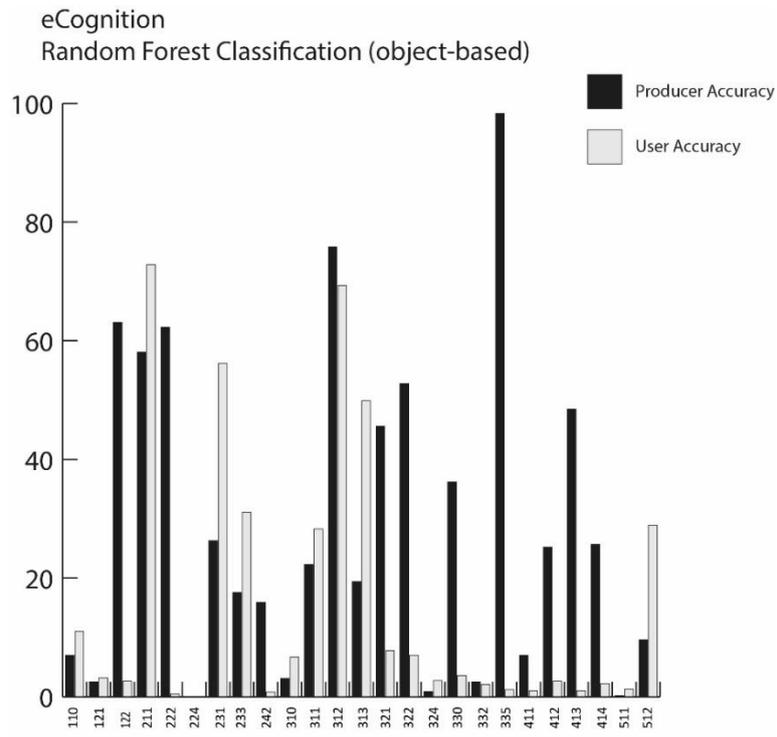
LBM2



Quelle: eigene Darstellung.

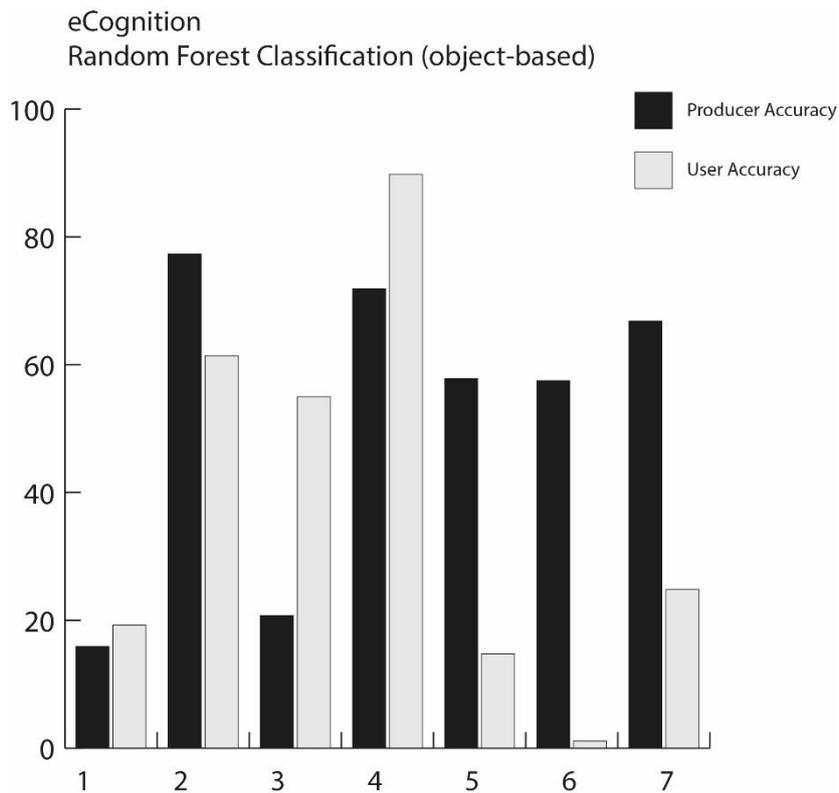
Anhang 26: Genauigkeitsbewertungen der eCognition Random Forest Methode

LBM1



Overall Accuracy 43.3%

LBM2

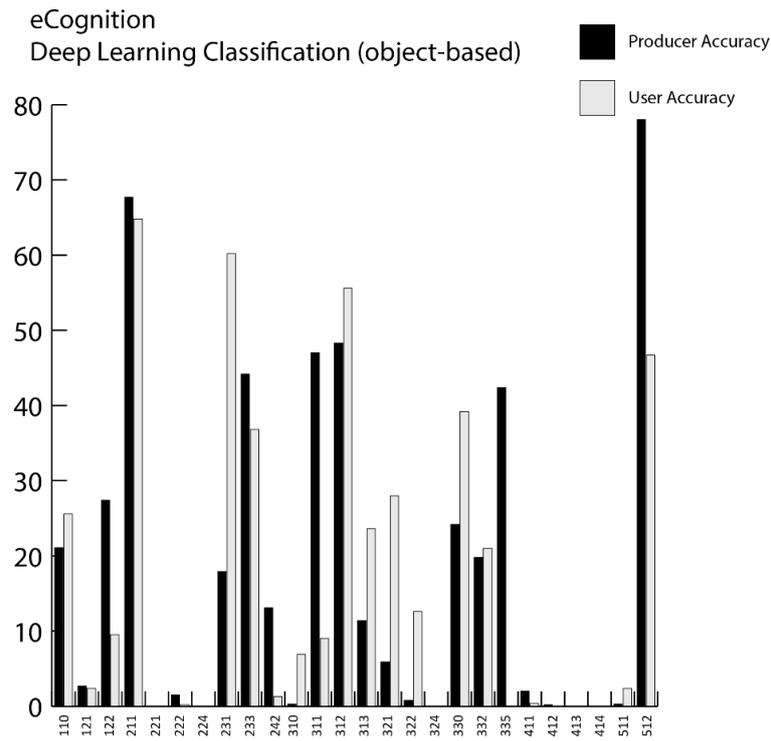


Overall Accuracy 57.6%

Quelle: eigene Darstellung.

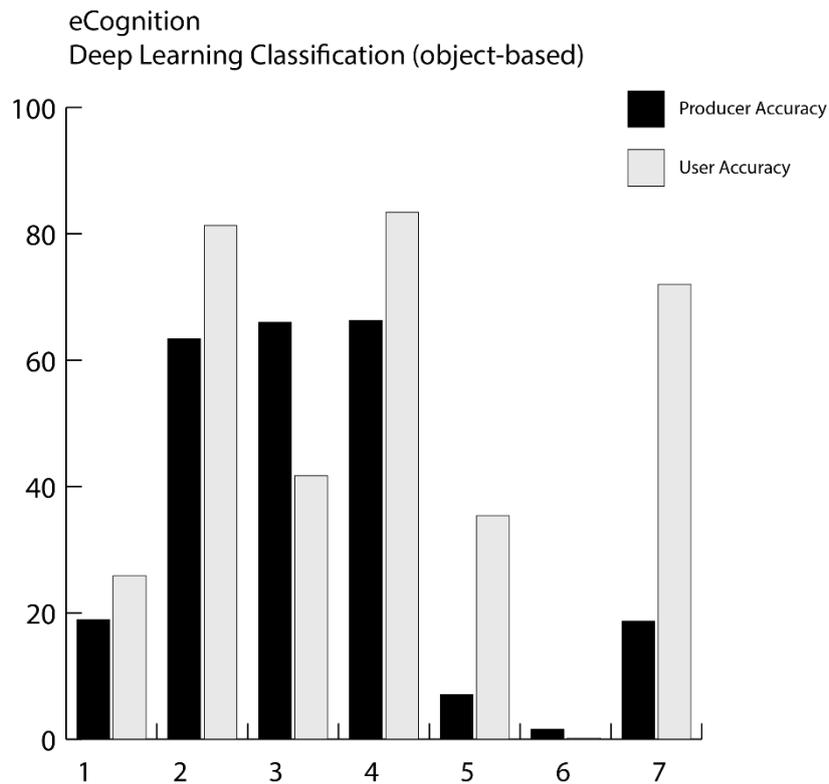
Anhang 27: Genauigkeitsbewertungen der eCognition Deep Learning Methode

LBM1



Overall Accuracy 40.2%

LBM2



Overall Accuracy 62.3%

Quelle: eigene Darstellung.