



MASTERARBEIT | MASTER'S THESIS

Titel | Title

Evaluierung verschiedener Klassifikationsmethoden zur
fernerkundlichen Veränderungsdetektion der
Bodenversiegelung anhand einer Langzeitstudie von Graz

verfasst von | submitted by
Anton Wolf Kiesling BSc

angestrebter akademischer Grad | in partial fulfilment of the requirements for the degree of
Master of Science (MSc)

Wien | Vienna, 2025

Studienkennzahl lt. Studienblatt | Degree
programme code as it appears on the
student record sheet:

UA 066 856

Studienrichtung lt. Studienblatt | Degree
programme as it appears on the student
record sheet:

Masterstudium Kartographie und Geoinformation

Betreut von | Supervisor:

Ass.-Prof. Mag. Dr. Andreas Riedl

Danksagung

Für seine Anregungen und Unterstützung möchte ich mich bei meinem Betreuer Herrn Ass.-Prof. Mag. Dr. Andreas Riedl herzlich bedanken. Des Weiteren möchte ich mich bei der Abteilung 17 - Landes und Regionalentwicklung - des Landes Steiermark bedanken, die mir bei der Akquise der Geodaten und bei der Beantwortung sämtlicher Fragen zu meinem Projekt unterstützt haben. Zudem möchte ich mich bei meinen Ausbildnern und jenen Kollegen des Österreichischen Bundesheeres bedanken, die mein Interesse an der Geographie und vor allem an der Kartographie und der Geoinformation geweckt haben.

Abschließend möchte ich mich bei meinen Geschwistern, Eltern und Freunden für die Unterstützung und Rückhalt bedanken. Ein ganz besonderer Dank geht auch an meine Familie, die mich immer moralisch und emotional unterstützt haben und ohne die dieser Abschluss nicht möglich gewesen wäre.

Abstract

Für die fernerkundliche Veränderungsdetektion der Bodenversiegelung ist die Klassifikation der Erdoberfläche von zentraler Bedeutung. Für die Fernerkundung kommen überwiegend Satellitenbilder oder Orthophotos zum Einsatz. Zur Bestimmung der Bodenbedeckung stehen verschiedene Klassifikationsmethoden zur Verfügung. Sie lassen sich in pixelbasierte und objektbasierte Verfahren unterteilen. Darüber hinaus unterscheidet man zwischen überwachten und unüberwachten Methoden. Während bei überwachten Verfahren der Nutzer dem System zusätzliche Informationen wie Trainingsdaten bereitstellt, erfolgt die Klassifikation bei unüberwachten Verfahren ausschließlich durch Algorithmen.

In dieser Masterarbeit werden vier unterschiedliche Klassifikationsmethoden anhand von fünf hochauflösenden Orthophotos des politischen Bezirks Graz aus den Jahren 2009, 2012, 2015, 2018 und 2021 angewendet und evaluiert. Um eine fundierte Vergleichsbasis für die Klassifikationsergebnisse zu schaffen, wurde zunächst ein Grunddatensatz für den gesamten Bezirk erstellt. Hierfür kam ein Convolutional Neural Network zum Einsatz. Pro Orthophoto wurden Testdaten generiert anhand derer die Deep-Learning-Modelle trainiert wurden. Um möglichst präzise Ergebnisse zu erzielen wurden die Klassifikationsergebnisse der verschiedenen Methoden anschließend anhand einer Genauigkeitsanalyse miteinander verglichen. Für die Erstellung und das Training der Deep-Learning-Modelle sowie für die Klassifikation der Orthophotos mit den unterschiedlichen Methoden, wurde die Software ArcGIS Pro verwendet.

Die Analyse der erstellten Grunddaten zeigte, dass die Deep-Learning-Modelle insgesamt präzise Klassifikationen liefern, jedoch nicht frei von Fehlern sind. Die Evaluierung der Klassifikationsmethoden ergab, dass insbesondere überwachte, objektbasierte Verfahren deutlich genauere Ergebnisse lieferten, als unüberwachte Methoden. Auch die überwachte, pixelbasierte Klassifikation erzielte gute Resultate, war jedoch anfällig für den Salz- und Pfeffer-Effekt, der durch die Fehlklassifizierung einzelner Pixel verursacht wird.

Abstract

The classification of the earth's surface is of central importance for the remote sensing detection of changes in soil sealing. Satellite images or orthophotos are mainly used for remote sensing. Various classification methods are available for determining land cover. They can be divided into pixel-based and object-based methods. A distinction is also made between supervised and unsupervised methods. While in supervised methods the user provides the system with additional information such as training data, in unsupervised methods the classification is performed exclusively by algorithms.

In this master's thesis, four different classification methods are applied and evaluated using five high-resolution orthophotos of the political district of Graz from the years 2009, 2012, 2015, 2018 and 2021. In order to create a sound basis for comparison for the classification results, a ground truth data set was first created for the entire district. A convolutional neural network was used for this. Test data was generated for each orthophoto and used to train the deep learning models. In order to achieve the most precise results possible, the classification results of the different methods were then compared with each other using an accuracy assessment. ArcGIS Pro software was used to create and train the deep learning models and to classify the orthophotos using the different methods.

The analysis of the ground truth data showed that the deep learning models provide precise classifications overall, but are not free of errors. The evaluation of the classification methods showed that supervised, object-based methods in particular delivered significantly more accurate results than unsupervised methods. The supervised, pixel-based classification also achieved good results, but was susceptible to the salt and pepper effect, which is caused by the misclassification of individual pixels.

Inhaltsverzeichnis

1 Einleitung.....	1
1.1 Einführung in die Thematik.....	1
1.2 Stand der Forschung.....	1
1.3 Zielsetzung und Forschungsfragen	3
1.4 Aufbau der Arbeit	4
2. Theoretische Grundlagen	5
2.1 Methode zur Erfassung physikalischer Umweltinformationen	5
2.1.1 Physikalische Grundlagen der Fernerkundung	8
2.1.1.1 Sensoren.....	8
2.1.1.2 Elektromagnetische Strahlung	9
2.1.1.3 Einfluss der Atmosphäre	11
2.1.1.4 Reflexionseigenschaften des Geländes	14
2.1.2 Klassifikation der Erdoberfläche.....	15
2.1.3 Arten der Klassifikation	16
2.1.3.1 Überwachte und unüberwachte Klassifikation.....	16
2.1.3.2 Pixel- und objektbasierte Klassifikation.....	17
2.1.4 Deep Learning Klassifikation.....	18
2.2 Bodenversiegelung.....	19
2.2.1 Ursachen der Bodenversiegelung	21
2.2.1.1 Urbanisierung.....	22
2.2.1.2 Infrastrukturentwicklung	23
2.2.1.3 Raumplanung.....	24
2.2.2 Auswirkungen der Bodenversiegelung	25
2.2.2.1 Beeinflussung des Wasserhaushalts durch die Bodenversiegelung ..	26
2.2.2.2 Einfluss der Bodenversiegelung auf die Biodiversität	28
2.2.2.3 Einfluss der Bodenversiegelung auf das Stadtklima	29
2.2.2.4 Zusammenhang von Bodenversiegelung und CO ₂ -Emissionen	31
2.2.2.5 Einfluss der Bodenversiegelung auf die menschliche Gesundheit.....	33
2.2.3 Ansätze zur Reduzierung der Bodenversiegelung	34
2.3 Fernerkundliche Identifizierung der Bodenversiegelung.....	36
2.4 Anwendungsbeispiele zur Klassifikation der Bodenversiegelung	38
3. Methode und Datenmaterial	40

3.1 Beschreibung des Projektgebietes	40
3.2 Evaluierung der Orthophotos.....	41
3.3 Verwendete Software	44
3.4 Verwendete Algorithmen	47
3.4.1 Grunddaten (Deep Learning, U-Net)	47
3.4.1.1 Durchführung der Klassifikation	49
3.4.1.2 Genauigkeit der Modelle	52
3.4.2 Unüberwachte Klassifikation	53
3.4.2.1 ISO-Cluster (pixel- und objektbasiert, unüberwacht).....	53
3.4.3 Überwachte Klassifikation	56
3.4.3.1 Trainingsdaten	56
3.4.3.2 Random Trees (pixelbasiert, überwacht)	57
3.4.3.3 Supported Vector Machines (objektbasiert, überwacht).....	59
3.5 Genauigkeitsanalyse	61
3.5.1 Konfusionsmatrix.....	62
4 Ergebnisse.....	65
4.1 Ergebnisse der Deep Learning Grunddatensätze	65
4.2 Ergebnisse der pixel- und objektbasierten Klassifikationen.....	66
4.2.1 Pixelbasiert, unüberwacht (ISO-Cluster)	66
4.2.2 Objektbasiert, unüberwacht (ISO-Cluster)	67
4.2.3 Pixelbasiert, überwacht (Random Trees)	68
4.2.4 Objektbasiert, überwacht (Supported Vector Machines)	69
4.3 Ergebnisse der Genauigkeitsanalyse	71
4.3.1 Pixelbasiert, unüberwacht (ISO-Cluster)	71
4.3.2 Objektbasiert, unüberwacht (ISO-Cluster)	73
4.3.3 Pixelbasiert, überwacht (Random Trees)	75
4.3.4 Objektbasiert, überwacht (Supported Vector Machines)	78
4.3.5 Zusammenfassung der Ergebnisse.....	80
5 Diskussion und Interpretation der Ergebnisse	83
6 Zusammenfassung	88
7 Einsatz generativer KI-Tools.....	89
8 Quellen	90

Abbildungsverzeichnis

Abbildung 1: Verbildlichung eines Fernerkundungssystems	6
Abbildung 2: Skizze von aktiven und passiven Systemen bei der Datenaufnahme....	9
Abbildung 3: Das elektromagnetische Spektrum	10
Abbildung 4: Spektraler Transmissionsgrad der Atmosphäre	12
Abbildung 5: Schematische Strahlungsverhältnisse bei der Aufnahme	13
Abbildung 6: Die unterschiedlichen Arten der Reflexion an einer Oberfläche.....	15
Abbildung 7: Vergleich einer pixel- und einer objektbasierten Klassifikation	18
Abbildung 8: Auswirkungen der Urbanisierung auf den Wasserhaushalt	27
Abbildung 9: Zentrale Kohlenstoffflüsse und -umsetzungen im Boden.....	32
Abbildung 10: Vergleiche von unterschiedlichen spektralen Reflexionskurven	37
Abbildung 11: Bevölkerungswachstum der Gemeinde Graz von 2001 bis 2024	41
Abbildung 12: Orthophoto des politischen Bezirks Graz aus dem Jahr 2021	43
Abbildung 13: Beispiel einer Minimum-Maximum-Streckung	44
Abbildung 14: Beispiel einer U-Netz-Architektur	48
Abbildung 15: Beispiele für Eingangsdaten des Deep-Learning-Algorithmus.....	50
Abbildung 16: Workflow für das Erstellen eines Deep-Learning-Modells	51
Abbildung 17: Klassifikation des Orthophotos von 2012.....	53
Abbildung 18: Iterative Clusterbildung des ISO-Cluster-Algorithmus.....	54
Abbildung 19: Diagramm eines Random Tree Klassifikationsprozesses	57
Abbildung 20: Trennung von zwei Klassen mittels SVM-Algorithmus.....	60
Abbildung 21: Ergebnis der Deep-Learning-Klassifikation (Kraftwerk)	66
Abbildung 22: Ergebnis der Deep-Learning-Klassifikation (Friedhof)	66
Abbildung 23: Ergebnis der pixelbasierten, unüberwachten Klassifikation	67
Abbildung 24: Ergebnis der objektbasierten, unüberwachten Klassifikation	68
Abbildung 25: Ergebnis der pixelbasierten, überwachten Klassifikation	69
Abbildung 26: Ergebnis der objektbasierten, überwachten Klassifikation	70
Abbildung 27: Gesamtgenauigkeit für die pixelbasierten, unüberwachten Klassifikationen von 2009 bis 2021	71
Abbildung 28: Kappa-Koeffizient für die pixelbasierten, unüberwachten Klassifikationen von 2009 bis 2021	73
Abbildung 29: Gesamtgenauigkeit für die objektbasierten, unüberwachten Klassifikationen von 2009 bis 2021	73

Abbildung 30: Kappa-Koeffizient für die objektbasierten, unüberwachten Klassifikationen von 2009 bis 2021	75
Abbildung 31: Gesamtgenauigkeit für die pixelbasierten, überwachten Klassifikationen von 2009 bis 2021	76
Abbildung 32: Kappa-Koeffizient für die pixelbasierten, überwachten Klassifikationen von 2009 bis 2021	78
Abbildung 33: Gesamtgenauigkeit für die objektbasierten, überwachten Klassifikationen von 2009 bis 2021	78
Abbildung 34: Kappa-Koeffizient für die objektbasierten, überwachten Klassifikationen von 2009 bis 2021	80
Abbildung 35: Gesamtgenauigkeit für die pixel- und objektbasierten sowie unüberwachten und überwachten Klassifikationen von 2009 bis 2021.....	81
Abbildung 36: Kappa-Koeffizient für die pixel- und objektbasierten sowie unüberwachten und überwachten Klassifikationen von 2009 bis 2021.....	82

Tabellenverzeichnis

Tabelle 1: Dauersiedlungsraum der Bundesländer, Gebietsstand 2022.....	21
Tabelle 2: Beschreibung der Metadaten zu den fünf verwendeten Orthophotos.	43
Tabelle 3: Softwareevaluierung zur Durchführung der Masterarbeit.....	45
Tabelle 4: Klassifikationsgenauigkeiten der erstellten U-Net-Modelle	52
Tabelle 5: Parameter der unüberwachten Klassifikation.....	55
Tabelle 6: Auflistung der Anzahl der verwendeten Trainingsgebiete	56
Tabelle 7: Parameter der überwachten Klassifikation (Random-Trees)	58
Tabelle 8: Parameter der überwachten Klassifikation (Supported Vector Machine).	60
Tabelle 9: Beispiel einer Konfusionsmatrix.....	62
Tabelle 10: Konfusionsmatrizen für die pixelbasierten, unüberwachten Klassifikationen von 2009 bis 2021.	72
Tabelle 11: Konfusionsmatrizen für die objektbasierten, unüberwachten Klassifikationen von 2009 bis 2021	74
Tabelle 12: Konfusionsmatrizen für die pixelbasierten, überwachten Klassifikationen von 2009 bis 2021	76
Tabelle 13: Konfusionsmatrizen für die objektbasierten, überwachten Klassifikationen von 2009 bis 2021	79

Glossar

Convolutional Neural Network (CNN)

Neuronale Netzwerke, die ähnlich wie ein menschliches Hirn arbeiten

Deep-Learning (DL)

Eine Machine-Learning Methode die auf CNN basiert

Geographisches Informationssystem (GIS)

Software, mit der man Geodaten speichern, analysieren und visualisieren kann

Geometrische Auflösung

Die kleinste unterscheidbare Einheit eines Bildes (Pixelgröße)

ISO-Cluster

Eine Klassifikationsmethode

Klassifikation

Ein Prozess, bei dem Aufnahmen der Erdoberflächen in Bedeckungsklassen eingeteilt werden

Machine-Learning (ML)

Ein Algorithmus, der aus Testdaten lernt, Muster zu erkennen

Normalized Difference Vegetation Index (NDVI)

Ein Index, der mithilfe des nahen Infrarotbereichs die Vegetationsdichte misst

Orthophoto

Ist ein verzerrungsfreies, geometrisch korrigiertes Luftbild

Random Trees (RT)

Ein Machine-Learning-Algorithmus

Spektrale Auflösung

Fähigkeit eines Sensors, verschiedene Wellenlängen zu unterscheiden

Supported Vector Machines (SVM)

Ein Machine-Learning-Algorithmus

U-Net

Ein Deep-Learning-Algorithmus

1 Einleitung

1.1 Einführung in die Thematik

Diese Masterarbeit untersucht pixelbasierte und objektbasierte Klassifikationsmethoden fernerkundlicher Veränderungsdetektion in Bezug auf ihre Genauigkeit. Die praktisch untersuchten Klassifikationsmethoden fanden Anwendung bei der Identifizierung von Veränderungen in Rasterdaten über die Bodenversiegelung im urbanen Raum. Im Zusammenhang mit der Stadtentwicklung ist die Problematik der Bodenversiegelung von großer Bedeutung. Eine nachhaltige Stadtentwicklung erfordert eine sorgfältige Planung und Bewirtschaftung des städtischen Raums, um die negativen Auswirkungen der Bodenversiegelung zu minimieren. Dies kann durch die Implementierung von Maßnahmen wie der Förderung von Grünflächen, der Nutzung von durchlässigen Oberflächenmaterialien und der gezielten Steuerung von Bauvorhaben erreicht werden.

Die zunehmende Bodenversiegelung im urbanen Raum stellt eine drängende Herausforderung dar, da sie zu einer Reduzierung der natürlichen Durchlässigkeit des Bodens führt und somit die Versickerung von Regenwasser behindert. Dies kann zu Problemen wie Überflutungen, verminderter Grundwasserneubildung und einer erhöhten Belastung der Kanalisation führen. Darüber hinaus hat die Bodenversiegelung negative Auswirkungen auf die Biodiversität, das Mikroklima und die Lebensqualität der städtischen Bevölkerung (WWF.at, 2023).

Die Masterarbeit soll zur Bewältigung dieser Herausforderung beitragen, indem sie verschiedene Klassifikationsmethoden zur fernerkundlichen Veränderungsdetektion hinsichtlich ihrer Genauigkeit bei der Erfassung von Bodenversiegelung analysiert. Die Ergebnisse dieser Analyse können wichtige Erkenntnisse für die Stadtplanung und die Entwicklung von Maßnahmen zur Reduzierung der Bodenversiegelung liefern, was wiederum zu einer Optimierung der Stadtentwicklung beiträgt.

1.2 Stand der Forschung

Die zeitnahe und genaue Erfassung von Veränderungen an der Erdoberfläche ist besonders wichtig für das Verständnis von Beziehungen und Wechselwirkungen zwischen menschlichen und natürlichen Phänomenen. Die so gewonnenen Daten liefern Entscheidungsgrundlagen für die Raumplanung (Lu et al., 2004).

Die Klassifikation von Fernerkundungsdaten wird durch verschiedene Elemente beeinflusst, darunter räumliche, spektrale, thematische und zeitliche Beschränkungen, radiometrische Auflösung, atmosphärische Bedingungen und Bodenfeuchtigkeit (Jensen, 2005).

Die Erkennung von Veränderungen anhand von Fernerkundungsbildern mit sehr hoher räumlicher Auflösung (≤ 5 m) ist jedoch eine Herausforderung. Um diese Herausforderungen zu bewältigen, wurden zahlreiche Algorithmen zur Erkennung von Veränderungen entwickelt. In der aktuellen Fachliteratur fehlt aber ein direkter Vergleich der unterschiedlichen Algorithmen über die Erkennung von Veränderungen in hochauflösenden Bildern (Wen et al., 2021).

Parelius (2023) beschreibt, dass zur Beobachtung der Bodenversiegelung die hochauflösende Orthographie genutzt werden kann. Klassische und moderne sowie pixel- und objektbasierte Methoden zur Klassifizierung von Rasterdaten werden praktisch angewendet und die Ergebnisse verglichen und diskutiert. Die Dynamiken der Landnutzung zu erfassen und Veränderungen wie Versiegelung und deren Effekte auf die Umwelt zu analysieren sind ein wichtiges Ziel des Fachbereichs Geoinformatik und Umweltforschung.

Im Kontext dieser Masterarbeit wird die Bodenversiegelung als zentrales Thema im Bereich der Fernerkundung und der Veränderungsdetektion behandelt. Ziel der Arbeit ist es, verschiedene Klassifikationsmethoden zur Detektion von Veränderungen der Bodenversiegelung mithilfe von Orthophotos zu evaluieren. Bodenversiegelung, die durch die Ausbreitung urbaner Gebiete und Infrastrukturprojekte verursacht wird, hat erhebliche Auswirkungen auf den natürlichen Wasserkreislauf, das lokale Klima und die Biodiversität. Die präzise und zeitlich differenzierte Erfassung von Versiegelungsprozessen ist daher von großer Bedeutung, um die Auswirkungen dieser Veränderungen zu verstehen und zu überwachen. Anhand der Langzeitstudie eines Siedlungsgebietes können die Veränderungen der Bodenversiegelung über einen längeren Zeitraum hinweg gut nachverfolgt werden, was eine detaillierte Analyse der Raumplanung und der zugrunde liegenden Trends ermöglicht.

Unterschiedliche Fernerkundungstechniken und Klassifikationsansätze werden untersucht, um eine möglichst genaue und effiziente Detektion von Bodenversiegelungsänderungen zu ermöglichen. Dabei werden sowohl traditionelle

als auch moderne Verfahren berücksichtigt, um deren Eignung und Genauigkeit im Kontext der Bodenversiegelungsanalyse zu bewerten.

1.3 Zielsetzung und Forschungsfragen

Die vorliegende Masterarbeit beschäftigt sich mit der Analyse und dem Vergleich von Klassifikationsmethoden zur Veränderungsdetektion in hochauflösenden Fernerkundungsbildern, wobei ein besonderer Fokus auf die Identifikation von Bodenversiegelung im urbanen Raum gelegt wird. Angesichts der zunehmenden Versiegelung der urbanen Böden, als eines der drängendsten Probleme der Stadtentwicklung, ist es von entscheidender Bedeutung, präzise Methoden zur Erfassung und Analyse von Veränderungen der Erdoberfläche zu entwickeln, um nachhaltige und ressourcenschonende Stadtplanung zu ermöglichen. Ziel der Arbeit ist es, die Genauigkeit von pixelbasierten und objektbasierten Klassifikationsverfahren zu untersuchen und zu bewerten.

Die zentrale Forschungsfrage dieser Arbeit lautet:

Wie unterscheiden sich pixelbasierte und objektbasierte Klassifikationsmethoden in Bezug auf ihre Genauigkeit bei der Klassifikation?

Zur Beantwortung dieser Frage werden die folgenden Leitfragen behandelt:

Welche Rolle spielen verschiedene Parameter und Einstellungen bei der Genauigkeit der Klassifikationsmethode?

Welche Klassifikationsmethoden sind am effektivsten bei der Identifizierung von versiegelten Flächen anhand von Orthophotos?

Zusätzlich wird ein Deep-Learning-Algorithmus als Kontrollmethode verwendet, um die Ergebnisse der traditionellen Klassifikationsmethoden mit denen eines modernen, leistungsstarken Ansatzes zu vergleichen. Der Deep-Learning-Algorithmus ermöglicht eine Analyse komplexer Muster und Unterschiede in den Bilddaten und stellt eine Referenz dar, um die Leistungsfähigkeit der klassischen Klassifikationsverfahren zu evaluieren.

Diese Forschungsfragen sind im Kontext der Stadtentwicklung und Ressourcennutzung von hoher Relevanz, insbesondere in Bezug auf die Reduzierung der negativen Auswirkungen der Bodenversiegelung. Eine präzise Veränderungsdetektion kann wesentliche Erkenntnisse liefern, um nachhaltige Maßnahmen zu entwickeln, die

die ökologischen Folgen der Zersiedelung und der Versiegelung von Flächen minimieren.

1.4 Aufbau der Arbeit

Die vorliegende Arbeit gliedert sich in einen theoretischen und einen praktischen Teil. Kapitel 2 bildet den theoretischen Teil der Arbeit und befasst sich zunächst mit den Grundlagen der Fernerkundung. Im Anschluss wird das Thema der Bodenversiegelung behandelt, wobei sowohl die Ursachen und Auswirkungen als auch die langfristigen ökologischen und sozialen Folgen dieser landwirtschaftlichen und urbanen Entwicklung thematisiert werden. Der theoretische Teil bietet damit die notwendigen Grundlagen, um die praktischen Analysen im späteren Verlauf der Arbeit besser zu verstehen.

Anschließend beginnt in Kapitel 3 der praktische Teil der Masterarbeit. Hier wird das spezifische Projektgebiet, in dem die Klassifikationen durchgeführt wurden, beschrieben. Es folgt eine Darstellung der verwendeten Software und der eingesetzten Klassifikationsmethoden, um die Forschungsfragen zu beantworten.

Im darauffolgenden Kapitel 4 werden die Ergebnisse der durchgeführten Evaluierung vorgestellt. Hier werden die wesentlichen Erkenntnisse systematisch und strukturiert dargelegt, um die Forschungsfragen zu beantworten und einen tieferen Einblick in das Thema zu geben. In Kapitel 5 erfolgt schließlich die Diskussion und Interpretation der Ergebnisse.

2. Theoretische Grundlagen

In diesem Kapitel werden die theoretischen Grundlagen der Fernerkundung und der Bodenversiegelung erläutert, die für das Verständnis und die Analyse der Landklassifizierung wesentlich sind.

2.1 Methode zur Erfassung physikalischer Umweltinformationen

Damit das Zusammenspiel von Mensch und Natur gelingt, ist die kontinuierliche Beobachtung von Veränderungen in der Umwelt erforderlich, denn die Umwelt unterliegt einem ständigen Wandel. Natürliche Prozesse wie der Fluss des Wassers, das Wettergeschehen, oder der jahreszeitliche Wechsel der Vegetation sind Beispiele dieser Veränderungen. Gleichzeitig wird die Umwelt maßgeblich durch menschliche Aktivitäten beeinflusst, die die Landoberfläche, Gewässer und die Atmosphäre verändern. Angesichts dieser Dynamik ist es heute wichtiger denn je, die natürlichen Abläufe besser zu verstehen, menschliche Eingriffe gezielt zu planen und ihre Auswirkungen sorgfältig zu überwachen. Dafür sind verlässliche Informationen über den Zustand der Umwelt und dessen Wandel unerlässlich. Diese Daten müssen daher laufend erfasst werden.

Physikalische Umweltinformationen lassen sich grundsätzlich auf drei Arten erfassen:

1. Direkte Messung: Das Messgerät befindet sich am Ort der Messung, beispielsweise ein Thermometer, das die Temperatur misst.
2. Fernmessung: Hier wird die Messung vor Ort durchgeführt, die Ergebnisse jedoch über eine Entfernung hinweg übertragen, etwa durch Funksignale. Ein Beispiel ist die Temperaturmessung in der Atmosphäre mittels Radiosonden.
3. Fernerkundung: Das Messgerät ist vom Messort entfernt, und die Messwerte werden durch Analyse der reflektierten oder ausgestrahlten elektromagnetischen Strahlung des Objekts ermittelt. So wird beispielsweise die Wassertemperatur mithilfe eines Thermal-Scanners von einem Flugzeug aus gemessen (Albertz, 2007).

Die Fernerkundung ist ein indirektes Verfahren zur Beobachtung, bei dem Informationen über Objekte gewonnen werden, ohne sie physisch zu berühren. Um den breiten Begriff der Fernerkundung zu präzisieren, versteht man darunter üblicherweise (de Lange, 2013):

1. Verfahren, die elektromagnetische Strahlung nutzen, die von einem beobachteten Objekt ausgesendet oder reflektiert wird,
2. Verfahren, die Empfangseinrichtungen für diese Strahlung an Bord von Luftfahrzeugen (wie Flugzeugen) oder Raumfahrzeugen (meist Satelliten) einsetzen und
3. Verfahren, die zur Beobachtung der Erdoberfläche mit allen darauf befindlichen Objekten, der Meeresoberfläche oder der Atmosphäre dienen.

Besonders bedeutsam und weit verbreitet sind Fernerkundungsverfahren, die bildhafte Darstellungen der Erdoberfläche erzeugen. Solche Systeme bestehen aus drei zentralen Komponenten: Datenaufnahme, Datenspeicherung und Datenauswertung (Abb. 1).




Abbildung 1: Verbildlichung eines Fernerkundungssystems (Albertz, 2007)

Bei der Datenaufnahme wird die von den Objekten der Erdoberfläche ausgesandte oder reflektierte elektromagnetische Strahlung von einem Sensor erfasst und in Bilddaten umgewandelt. Gleichzeitig erfolgt die Datenspeicherung, wodurch Luft- oder Satellitenbilder entstehen, die später ausgewertet werden können. Voraussetzung für dieses Verfahren ist, dass die elektromagnetische Strahlung durch die Objekte an der Erdoberfläche charakteristisch beeinflusst wird. Nur so können aus den aufgezeichneten Signalen spezifische Informationen über die beobachteten Objekte abgeleitet werden (Albertz, 2007).

Luftbilder sind in erster Linie fotografische Aufnahmen eines Teils der Erdoberfläche, die aus Luftfahrzeugen, meist Flugzeugen, gemacht werden. Jedoch wird der Begriff oft auch für andere Aufnahmeverfahren verwendet. Beispielsweise spricht man von

Thermalluftbildern, wenn die Darstellung der Erdoberfläche im thermischen Strahlungsbereich aus der Luft erfolgt. Satellitenbilder hingegen sind Abbildungen der Erdoberfläche, die von bemannten oder unbemannten Satelliten erstellt werden. Dabei spielt es keine Rolle, ob es sich um fotografische Aufnahmen oder andere Fernerkundungstechniken handelt, solange eine bildhafte Darstellung erzeugt wird.

Solche Bilder enthalten eine Fülle an Informationen über das abgebildete Gelände, die in zahlreichen wissenschaftlichen und technischen Bereichen von großem Wert sind. Die Verfahren, mit denen dieses Informationspotenzial erschlossen wird, werden unter dem Begriff Auswertung zusammengefasst. Dabei unterscheidet man zwischen:

- Photogrammetrie, die sich auf die geometrische Analyse der Bilder konzentriert, etwa für die Erstellung topographischer Karten, und
- Bildinterpretation, die sich auf die inhaltliche Analyse der Oberflächenmerkmale und der darauf befindlichen Objekte fokussiert. Diese ist besonders wichtig für Geowissenschaften, Umweltüberwachung, Planung und ähnliche Anwendungsfelder (Albertz, 2007).

Eine strikte Trennung zwischen diesen beiden Ansätzen ist jedoch kaum möglich. In der Photogrammetrie müssen oft Objekte erkannt und interpretiert werden, beispielsweise für die Kartierung topographisch relevanter Details. Ebenso sind in der Interpretation häufig Messungen erforderlich, etwa zur Bestimmung von Baumkronendurchmessern, Böschungshöhen oder Flusslängen. Zudem wird in der Bildinterpretation häufig versucht, aus sichtbaren Merkmalen auf nicht direkt erkennbare Eigenschaften zu schließen, etwa aus der Vegetation auf die Bodeneigenschaften (de Lange, 2013).

Für eine erfolgreiche Auswertung von Luft- und Satellitenbildern sind umfassende Fachkenntnisse nötig. Dies umfasst sowohl die jeweilige Anwendungsdisziplin (etwa forstwissenschaftliche Expertise für die forstliche Bildanalyse) als auch regionalspezifisches Wissen (beispielsweise über die Geografie eines Entwicklungslandes). Zusätzlich sind Kenntnisse über die Entstehung und die Eigenschaften der Bilder unerlässlich, um deren Informationsgehalt voll auszuschöpfen und Fehlinterpretationen möglichst zu vermeiden (Campell et al., 2023).

2.1.1 Physikalische Grundlagen der Fernerkundung

Jedes Bild entsteht durch einen Abbildungsprozess, der sowohl geometrische als auch physikalische (radiometrische) Prinzipien umfasst. Daher enthalten Bilder immer Informationen zu Raum und Strahlung. Der geometrische Aspekt bezieht sich darauf, dass die erfassten Daten aus einer spezifischen räumlichen Richtung stammen, während der physikalische Aspekt die Stärke und die spektrale Zusammensetzung der Strahlung beschreibt, die zur Bildentstehung beiträgt.

Die spektrale Zusammensetzung und die Intensität der erfassten Strahlung werden sowohl bei fotografischen Aufnahmen als auch bei der Erfassung mit digitalen Systemen maßgeblich von der Beleuchtung des Geländes und den Reflexionseigenschaften der dortigen Objekte bestimmt. Bei thermischen Aufnahmen hingegen spielen die Oberflächentemperatur und die spezifischen Emissionsmerkmale der Materialien eine zentrale Rolle für die entstehenden Bilder. Radaraufnahmen werden in erster Linie durch die Wechselwirkung der ausgesandten Strahlung mit den Oberflächenmaterialien beeinflusst, was deren charakteristische Abbildung im Bild entscheidend prägt.

Die folgenden Unterkapitel sollen einen Überblick über die wichtigsten physikalischen Zusammenhänge in der Fernerkundung geben (Albertz, 2007).

2.1.1.1 Sensoren

Systeme zur Aufnahme von Luft- und Satellitenbildern müssen so gestaltet sein, dass sie sowohl die Richtung der einfallenden Strahlung als auch deren Intensität präzise erfassen. Während der Aufnahme wird die elektromagnetische Strahlung, die von der Erdoberfläche ausgeht und auf einem Flugzeug oder Satelliten eintrifft, von einem Sensor registriert, in Messsignale umgewandelt und gespeichert. Solche Systeme, die als Fernerkundungssensoren bezeichnet werden, erzeugen entweder direkt ein Bild wie bei fotografischen Aufnahmen, oder sie speichern Messwerte, aus denen durch spezifische Verarbeitungstechniken ein Bild erstellt wird.

Nach der Quelle der empfangenen Strahlung unterscheidet man passive und aktive Systeme (Abb. 2). Passive Systeme nutzen die in der Natur vorhandene elektromagnetische Strahlung, die entweder als reflektierte Sonnenstrahlung oder als Eigenstrahlung von Objekten infolge ihrer Temperatur (Thermalstrahlung) registriert wird. Im Gegensatz dazu arbeiten aktive Systeme mit einer künstlichen Energiequelle,

die die Erdoberfläche bestrahlt. Dabei wird die reflektierte Strahlung erfasst und ausgewertet (Campell et al., 2023).




Abbildung 2: Skizze von aktiven und passiven Systemen bei der Datenaufnahme.

Die Systeme zur Datenerfassung werden außerdem nach den Wellenlängenbereichen der aufgenommenen Strahlung kategorisiert. Diese Bereiche, die als Kanäle oder Bänder bezeichnet werden, erfassen spezifische physikalische Merkmale. Werden Messwerte in mehreren Wellenlängenbereichen gleichzeitig erfasst, spricht man von einem Multispektralsystem. Schließlich unterscheiden sich die Systeme auch durch die Art der eingesetzten Strahlungsempfänger und die damit verbundenen technischen Konstruktionen, die wesentliche Aspekte der Datenaufnahme und -verarbeitung beeinflussen (de Lange, 2013).

2.1.1.2 Elektromagnetische Strahlung

Elektromagnetische Strahlung stellt eine Energieform dar, die sich in Form von Wellen ausbreitet. Dabei kann sie als ein sich regelmäßig veränderndes elektromagnetisches Feld beschrieben werden, das sich mit Lichtgeschwindigkeit ausbreitet (Campell et al., 2023).

Das elektromagnetische Spektrum zeigt die gesamte Bandbreite der Wellenlängen dieser Strahlung. Es wird entsprechend der Entstehung und Wirkung der Strahlung in verschiedene Bereiche unterteilt, die fließend ineinander übergehen und sich teils überschneiden. Am bekanntesten ist das sichtbare Licht, ein kleiner Abschnitt des Spektrums mit Wellenlängen zwischen etwa 400 und 700 Nanometern (0,4 bis 0,7 Mikrometer). Daran schließen sich auf der Seite der kürzeren Wellenlängen zunächst der nahe und dann der allgemeine ultraviolette Bereich an, gefolgt von Röntgen- und

Gammastrahlen bis hin zur extrem kurzwelligen kosmischen Strahlung. In Richtung längerer Wellenlängen folgt das Infrarot, das in drei Unterbereiche gegliedert wird: das nahe Infrarot (bis etwa 1 Mikrometer), das mittlere Infrarot (etwa 1 bis 7 Mikrometer) und das ferne Infrarot (ab etwa 7 Mikrometer), das auch als Thermalstrahlung bezeichnet wird. Daran schließen sich die Mikrowellen (mit Wellenlängen zwischen etwa 1 Millimeter und 1 Meter) sowie die Radiowellen an (Campell et al., 2023).

Für die Fernerkundung wird nur ein spezifischer Ausschnitt des Spektrums genutzt. Dabei kommen Wellenlängen zwischen dem nahen Ultraviolett und dem mittleren Infrarot sowie aus dem Mikrowellenbereich zum Einsatz. Die wichtigsten Wellenlängenbereiche, die für die Datenerfassung verwendet werden, sind in Abbildung 3 dargestellt (Walford, 2002).




Abbildung 3: Das elektromagnetische Spektrum und die unterschiedlichen Sensortechnologien und deren Bereiche. Aufgrund der Strahlungsenergie der Sonne und der Durchlässigkeit der Atmosphäre können nur einzelne Bereiche der elektromagnetischen Strahlung für die Fernerkundung genutzt werden, sie werden „Atmosphärische Fenster“ genannt (Albertz, 2007).

Jeder Körper steht durch elektromagnetische Strahlung in einem kontinuierlichen Austausch mit seiner Umgebung. Dabei nimmt er Strahlung aus seiner Umwelt auf und gibt gleichzeitig Strahlung wieder ab. Diese spezifische Wechselwirkung zwischen Strahlung und den materialbedingten Eigenschaften eines Objekts bildet die Grundlage der Fernerkundung.

Wenn elektromagnetische Strahlung auf einen Körper trifft, wird sie teilweise an der Oberfläche reflektiert, teilweise vom Körper absorbiert und ein weiterer Teil dringt durch das Material hindurch. Das Verhältnis dieser Anteile variiert erheblich und wird sowohl von den physikalischen Eigenschaften des Materials als auch von der Wellenlänge der Strahlung beeinflusst (Albertz, 2007).

2.1.1.3 Einfluss der Atmosphäre

Die elektromagnetische Strahlung, die in der Fernerkundung als Träger von Informationen dient, muss stets die Atmosphäre durchqueren, um vom Objekt bis zum Empfänger in einem Flugzeug oder Satelliten zu gelangen. Bei Verfahren, die auf reflektierter Strahlung basieren, erfolgt zuvor ein zusätzlicher Durchgang der Strahlung von der Quelle zum Objekt. Aus diesem Grund können Fernerkundungsdaten nur in solchen Wellenlängenbereichen erfasst werden, in denen die Atmosphäre für elektromagnetische Strahlung weitgehend transparent ist.

Die extraterrestrische Strahlung der Sonne trifft zunächst auf die oberen Schichten der Atmosphäre, wo ein Teil in den Weltraum zurückreflektiert wird. Der verbleibende Anteil wird auf seinem Weg zur Erdoberfläche durch verschiedene Prozesse wie Brechung, Absorption und Streuung beeinflusst.

Die Refraktion, auch atmosphärische Strahlenbrechung genannt, entsteht durch die Dichteunterschiede in der Luft und führt zu einer leichten Krümmung der Strahlen. Während dieser Effekt bei präzisen photogrammetrischen Analysen berücksichtigt werden muss, spielt er für die meisten Anwendungen der Fernerkundung eine eher untergeordnete Rolle (de Lange, 2013).

Absorption und Streuung spielen im Vergleich zur Refraktion eine wesentlich größere Rolle in der Fernerkundung. Bei der Absorption wird ein Teil der elektromagnetischen Strahlung in Wärme oder andere Energieformen umgewandelt, was die Menge der durch die Atmosphäre gelangenden Strahlung verringert. Streuung hingegen tritt auf, wenn die Strahlung durch kleine Partikel wie Aerosole, Staub, Dunst oder Wassertröpfchen in verschiedene Richtungen abgelenkt wird. Die Intensität und Art der Streuung hängen sowohl von der Wellenlänge der Strahlung als auch von der Beschaffenheit und Größe der Partikel ab. Obwohl Absorption und Streuung auf unterschiedlichen physikalischen Prozessen beruhen, haben sie gemeinsam, dass sie

die durch die Atmosphäre tretende Strahlung schwächen. Daher werden beide Effekte unter dem Begriff Extinktion zusammengefasst.

Die Fähigkeit der Atmosphäre, Strahlung durchzulassen, wird durch den sogenannten Transmissionsgrad beschrieben, der stark von der Wellenlänge abhängt. Diese Abhängigkeit ergibt sich aus den Absorptionseigenschaften bestimmter Gase wie Wasserdampf, Kohlendioxid und Ozon, die in der Atmosphäre vorkommen (Abb. 4). Stickstoff und Sauerstoff, die Hauptbestandteile der Luft, absorbieren nahezu die gesamte ultraviolette Strahlung unterhalb von 0,3 Mikrometern Wellenlänge. Wellenlängenbereiche, in denen die Atmosphäre weitgehend transparent ist, werden als atmosphärische Fenster bezeichnet und sind für die Fernerkundung besonders wichtig. Die bedeutendsten dieser Fenster liegen im Bereich des sichtbaren Lichts und des nahen Infrarots (etwa 0,3 bis 2,5 Mikrometer), des mittleren Infrarots (etwa 3 bis 5 Mikrometer) sowie des thermalen Infrarots (etwa 8 bis 13 Mikrometer). Darüber hinaus lässt die Atmosphäre Mikrowellen nahezu uneingeschränkt durch (Albertz, 2007).




Abbildung 4: Spektraler Transmissionsgrad der Atmosphäre (Albertz, 2007).

Die Streuung in der Atmosphäre beeinflusst maßgeblich die Lichtverhältnisse auf der Erdoberfläche und ist daher auch für die Fernerkundung von großer Bedeutung. Ohne diese Streuung wäre der Himmel schwarz, während die Sonne als extrem heller und scharf abgegrenzter Lichtpunkt erscheinen würde. Durch den Streuungseffekt wird der gesamte atmosphärische Raum jedoch mit diffuser Strahlung durchdrungen, wodurch die Atmosphäre selbst zu einer sekundären Lichtquelle wird, die in alle Richtungen Strahlung aussendet. Auf der Erdoberfläche äußert sich dies als diffuse Himmelsstrahlung oder Himmelslicht (de Lange, 2013).

Bei klarem, wolkenlosem Himmel dominiert im Himmelslicht der kurzwellige Anteil im ultravioletten und blauen Spektralbereich, was den Himmel blau erscheinen lässt. Mit

zunehmender Trübung der Atmosphäre nimmt die Intensität der Himmelsstrahlung zwar zu, jedoch sinkt der relative Anteil der kurzwelligen Strahlung, wodurch das Licht eine weißliche Färbung annimmt.

Auf jede Fläche des Geländes treffen stets zwei Arten von Strahlung: die direkte Sonnenstrahlung, die trotz Absorption und Streuung in der Atmosphäre die Erde erreicht, und die indirekte, diffuse Himmelsstrahlung (Abb. 5). Die Gesamtheit dieser Strahlungsenergie, die eine Geländefläche erreicht, wird als Globalstrahlung bezeichnet. Deren Intensität und spektrale Zusammensetzung können stark variieren und sind primär abhängig von der Sonnenhöhe, dem Trübungsgrad der Atmosphäre, der Geländeneigung und -ausrichtung sowie der Höhe über der betrachteten Fläche (Campell et al., 2023).




Abbildung 5: Schematische Strahlungsverhältnisse bei der Aufnahme. Die Aufnahme von Bilddaten durch einen Sensor sowie die Geländebeleuchtung (Himmelslicht) werden durch die Absorption und die Streuung in der Atmosphäre beeinflusst (Albertz, 2007).

Die Atmosphäre beeinflusst nicht nur die Beleuchtung der Erdoberfläche, sondern auch die auf dem Weg zum Sensor registrierte Strahlung. Die von Geländeobjekten reflektierte Strahlung muss vor dem Eintreffen am Sensor in Flugzeugen oder Satelliten erneut die Atmosphäre durchqueren und unterliegt dabei denselben physikalischen Prozessen wie die einfallende Sonnenstrahlung. Zusätzlich vermischt sich diese reflektierte Strahlung mit einem weiteren Anteil diffuser Himmelsstrahlung, der ebenfalls in Richtung des Sensors wirkt und als Luftlicht bezeichnet wird (Abb. 5).

Darüber hinaus hat die Atmosphäre durch Bewölkung einen erheblichen Einfluss auf die Fernerkundung. Aufnahmen im sichtbaren Licht, im nahen Infrarot und im Thermal-Infrarot erfordern klare Sichtverhältnisse zwischen Erdoberfläche und Sensor, was in

der Regel einen wolkenfreien Himmel voraussetzt. Nur in Ausnahmefällen, etwa bei einer gleichmäßig hohen Wolkendecke, können unter bestimmten Bedingungen dennoch brauchbare Luftbilder entstehen. Mikrowellen hingegen, die für Radarbilder genutzt werden, sind in der Lage, Wolken zu durchdringen, was Fernerkundungsmethoden auf dieser Grundlage unabhängig von Wetterbedingungen macht (de Lange, 2013).

2.1.1.4 Reflexionseigenschaften des Geländes

Für die Erfassung von Fernerkundungsdaten ist die unterschiedliche Reaktion der Geländeoberfläche und ihrer Objekte auf einfallende Strahlung von zentraler Bedeutung. Die Reflexionseigenschaften variieren je nach Material und physikalischem Zustand wie Feuchtigkeit, Oberflächenbeschaffenheit und geometrischen Faktoren, beispielsweise dem Einfallswinkel der Strahlung oder der Richtung der Beobachtung. Diese Vielfalt ermöglicht es, Objekte sowohl direkt als auch auf Bildern visuell zu unterscheiden (Campell et al., 2023).

Nur ein Teil der auf ein Objekt treffenden Strahlung wird reflektiert, wobei die Art der Reflexion maßgeblich von der Oberflächenrauigkeit abhängt. Bei glatten Flächen, deren Rauigkeit im Verhältnis zur Wellenlänge der Strahlung gering ist, tritt spiegelnde Reflexion auf, die dem Reflexionsgesetz folgt, wonach Einfalls- und Reflexionswinkel gleich sind. Solche Reflexionen werden in der Fernerkundung häufig bei Wasserflächen beobachtet, gelten jedoch als störend und werden durch geeignete Wahl der Aufnahmeparameter minimiert (Albertz, 2007).

Ist die Oberflächenrauigkeit hingegen vergleichbar mit der Wellenlänge der einfallenden Strahlung, entsteht diffuse Reflexion. Dabei wird die Strahlung in alle Richtungen zurückgeworfen. Eine ideale diffus reflektierende Fläche, bekannt als Lambertsche Fläche, reflektiert unabhängig von der Betrachtungsrichtung gleichmäßig und erscheint daher aus jedem Winkel gleich hell. Natürliche Oberflächen weisen jedoch meist keine reine spiegelnde oder diffuse Reflexion auf, sondern eine Mischung aus beiden. Diese gemischte Reflexion bewirkt, dass die Strahlung zwar in verschiedene Richtungen zurückgeworfen wird, jedoch mit unterschiedlicher Intensität. Aufgrund ihrer Komplexität lässt sich diese Art der Reflexion nicht mit einfachen mathematischen Modellen beschreiben (Abb. 6) (Heritage und Large, 2009).




Abbildung 6: Die unterschiedlichen Arten der Reflexion an einer Oberfläche. Links: Spiegelfnde Reflexion. Mitte: Diffuse Reflexion. Rechts: Gemischte Reflexion (Albertz, 2007).

2.1.2 Klassifikation der Erdoberfläche

Die Landnutzungsklassifikation ist ein Verfahren der Bildverarbeitung, das darauf abzielt, in Rasterbildern mithilfe von Algorithmen Flächen mit ähnlichen Eigenschaften wie etwa Waldgebiete oder Gewässer, zu identifizieren. Dabei werden Muster erkannt, die auf den spektralen Signaturen basieren, die von den Sensoren der Satelliten erfasst werden. Für die Klassifikation ist es – abhängig von der gewählten Methode – erforderlich, zuvor Trainingsgebiete festzulegen.

Das Hauptziel der Fernerkundung besteht darin, aus den erhobenen Daten Informationen zu gewinnen, die zur Lösung verschiedener Fragestellungen beitragen. Dies erfolgt in erster Linie durch Bildauswertung oder Bildanalyse, wozu sowohl klassische analoge Techniken wie die Photogrammetrie und Photointerpretation zählen. Bei der visuellen Bildinterpretation werden räumliche Objekte anhand von Eigenschaften wie Farbe, Helligkeit, Textur, Muster, Form, Größe, Lage oder Schatten identifiziert. Dabei spielen insbesondere die Erfahrung und das Fachwissen des Interpreten eine entscheidende Rolle (de Lange, 2020).

Zu den Anwendungsbereichen der Landnutzungsklassifikation gehören unter anderen:

- **Umweltüberwachung und Naturschutz**

Eine der größten Stärken der Klassifikationen liegt in der Fähigkeit, Veränderungen der Bodenbedeckung und Umweltveränderungen mit großer Präzision zu erkennen und zu verfolgen. Durch den Einsatz fortschrittlicher Algorithmen und hochauflösenden Orthophotos können Entwicklungen wie Entwaldung, Zersiedelung oder Veränderungen in Ökosystemen effektiv analysiert werden. Diese Technik ist besonders wertvoll für den Naturschutz, da sie die Überwachung von Schutzgebieten, die Erkennung von Habitatdegradationen und die Erstellung gezielter Schutzmaßnahmen ermöglicht.

- **Infrastrukturentwicklung und Stadtplanung**

Die Klassifikation von Bodenbedeckungsänderungen leistet einen wichtigen Beitrag zur Bewältigung der Herausforderungen, die durch die zunehmende Urbanisierung entstehen. Mithilfe der Analyse von Bodenbedeckungsänderungen können Stadtplaner Veränderungen in Flächennutzungsmustern und Stadterweiterungen erkennen und fundierte Entscheidungen zur Infrastrukturentwicklung, Flächennutzungsplanung und Ressourcenzuweisung treffen. Diese proaktive Herangehensweise trägt dazu bei, die negativen Umweltauswirkungen wachsender Metropolregionen zu minimieren und eine nachhaltige Stadtentwicklung zu fördern.

- **Landwirtschaft und Ressourcenmanagement**

Die Analyse von Bodenbedeckungsänderungen spielt eine zentrale Rolle bei der nachhaltigen Bewirtschaftung natürlicher Ressourcen und landwirtschaftlicher Flächen. Mithilfe von GIS-Technologien können Landwirte ihre Felder effektiv überwachen, die Erträge optimieren und potenzielle Herausforderungen wie Bodenerosion oder Bereiche mit stehendem Wasser frühzeitig identifizieren. Darüber hinaus unterstützt diese Technologie die Bewertung der Auswirkungen von Bodenbedeckungsänderungen auf die Wasserversorgung. Dies ermöglicht die Entwicklung nachhaltiger Wassermanagementpläne, die angesichts klimatischer Schwankungen immer wichtiger werden (Satpalda.com, 2024).

2.1.3 Arten der Klassifikation

Je nach Art der gewünschten Interaktion zwischen Systemnutzer und System bei der Klassifizierung gibt es zwei grundlegende Ansätze: die überwachte und die unüberwachte Klassifizierung (Kap. 3.4). Zusätzlich stehen für die Wahl der Klassifizierungsmethode zwei Ansätze zur Verfügung: die pixelbasierte und die objektbasierte Klassifizierung.

2.1.3.1 Überwachte und unüberwachte Klassifikation

Bei der überwachten Klassifizierung legt der Systemnutzer die Klassenkategorien, denen Pixel oder Bildsegmente zugeordnet werden sollen, eigenständig fest. Diese Kategorien werden in einem sogenannten Klassifizierungsschema definiert. Nach der Durchführung der Klassifizierung ist es notwendig, das resultierende Dataset zu

prüfen, um Fehler zu korrigieren. Dabei werden falsch zugewiesene Klassen oder Polygone identifiziert und entsprechend dem Schema neu zugeordnet.

Im Gegensatz dazu erfolgt die unüberwachte Klassifizierung automatisiert. Der Computer identifiziert Klassen basierend auf statistischen Unterschieden in den spektralen Eigenschaften der Pixel im Bild. Nach Abschluss dieses Prozesses besteht Ihre Aufgabe darin, die vom Computer ermittelten Klassen manuell den definierten Kategorien Ihres Schemas zuzuweisen, um ein sinnvolles Ergebnis zu erzielen (Pro.Arcgis.com, o.A. g).

Für die unüberwachte Klassifikation standen zwei Methoden zur Auswahl: ISO Cluster und K-Nearest Neighbors. Aufgrund der hohen Effizienz der ISO Cluster-Methode (Kap. 3.4.2.1) bei der Klassifikation großer Rasterdatensätze und ihrer Fähigkeit, Pixel schnell und präzise in Gruppen zu unterteilen (Lemenkova, 2021), wurde diese Methode für die unüberwachte, sowohl pixel- als auch objektbasierte Klassifikation gewählt.

Für die überwachte Klassifikation standen die Methoden Maximum Likelihood, Random Trees (Kap. 3.4.3.2) und Support Vector Machines (SVM) (Kap. 3.4.3.3) zur Auswahl. Aufgrund ihrer Robustheit und Präzision wurden Random Trees und SVM für die Durchführung der pixel- und objektbasierten Klassifikation gewählt. Random Trees zeichnet sich durch seine Effizienz bei der Verarbeitung großer Rasterdatensätze aus und ist in der Lage, Muster in den Testdaten effektiv zu berücksichtigen (Breiman, 2001). Die Methode der Supported Vector Machines wurde aufgrund ihrer Fähigkeit zur präzisen Definition von Klassengrenzen ausgewählt und bietet eine hohe Genauigkeit sowie Robustheit bei der Klassifikation komplexer, hochauflösender Rasterdaten (Foody und Mathur, 2004).

2.1.3.2 Pixel- und objektbasierte Klassifikation

Der pixelbasierte Typ folgt einem traditionellen Ansatz, bei dem jedes Pixel einzeln analysiert und einer Klasse zugeordnet wird, ohne dabei Informationen aus benachbarten Pixeln einzubeziehen. Dieser Ansatz kann jedoch zu einem "Salz-und-Pfeffer"-Effekt führen, bei dem die Klassifizierungsergebnisse fragmentiert und weniger homogen wirken.




Abbildung 7: Vergleich einer pixelbasierten Klassifikation (linkes Bild) und einer objektbasierten Klassifikation (rechtes Bild) (Uca Avci et al., 2011).

Im Gegensatz dazu gruppiert die objektbasierte Klassifizierung benachbarte Pixel, die sich durch ähnliche Eigenschaften auszeichnen, in einem Prozess namens Segmentierung. Dabei werden Merkmale wie Farbe und Form einbezogen, um die Größe und Struktur der Gruppen zu bestimmen. Durch die Kombination und Mittelung der Pixelwerte sowie die Einbeziehung geographischer Kontextinformationen erzeugt diese Methode Segmente, die realen Objekten in den Bilddaten näherkommen. Das Ergebnis sind sauberere und homogener wirkende Klassifizierungsergebnisse (Abb. 7) (Pro.Arcgis.com, o.A. g).

2.1.4 Deep Learning Klassifikation

Die modernen Klassifikationsmethoden im Bereich der Machine-Learning-Methoden haben sich mittlerweile weit verbreitet und sind zu gängigen Standardverfahren geworden. Diese neuen Klassifikatoren, die zu den überwachten Klassifikationsansätzen zählen, benötigen keine Annahmen über die Häufigkeitsverteilung der Trainingsdaten wie es beispielsweise bei der Maximum-Likelihood-Methode der Fall ist. Als nicht-parametrische Verfahren zeichnen sich diese Methoden dadurch aus, dass sie keine statistischen Informationen der Trainingsgebiete (wie Minimum, Maximum, Mittelwert oder Varianz-Kovarianz der Merkmale, also der Kanäle, in einem Cluster) voraussetzen. Aufgrund dieser

fehlenden Anforderungen sind sie für die Klassifikation zunehmend populär geworden (de Lange, 2020).

In den letzten Jahren hat sich Deep Learning als leistungsstarke Alternative etabliert. Diese Methode nutzt künstliche neuronale Netzwerke, insbesondere Convolutional Neural Networks (CNNs), um komplexe Muster und Merkmale in Bilddaten zu erkennen. Ein Hauptmerkmal von Deep Learning ist seine Fähigkeit, hierarchische Merkmalsrepräsentationen zu lernen, wodurch sowohl spektrale als auch räumliche Informationen erfasst werden. Dies führt zu einer höheren Klassifikationsgenauigkeit und ermöglicht die Erkennung subtiler Unterschiede in der Landschaft.

Zu den bekanntesten Segmentierungsmodellen gehören U-Net, Linknet, FPN und PSPNet. Die Modellarchitekturen der einzelnen Modelle unterscheidet sich voneinander stark, wodurch ein direkter Vergleich nicht möglich ist (Yakubovskiy, o.A.). Das meist genutzte Deep-Learning-Modell ist das U-Net, welches von Ronnenberger et al. (2015) vorgestellt wurde. Da das U-Net-Modell weit verbreitet und sehr gute Ergebnisse erzielt werden konnten, kommt es auch in dieser Masterarbeit zur Anwendung (Kap. 3.4.1).

Im Gegensatz zu traditionellen Methoden erfordert Deep Learning große Mengen an Trainingsdaten und erhebliche Rechenressourcen. Zudem sind die Modelle oft als "Black Boxes" schwer interpretierbar. Dennoch übertreffen sie häufig die Genauigkeit pixel- und objektbasierter Ansätze, insbesondere in komplexen Szenarien (Zhu et al., 2017).

2.2 Bodenversiegelung

Die Bodenversiegelung bezeichnet die Veränderung der Bodenoberfläche durch bauliche Nutzung, bei der der Boden stark verdichtet und mit undurchlässigen Materialien wie Asphalt, Beton oder Bauwerken überdeckt wird. Durch diese Versiegelung wird der Austausch zwischen Boden und Atmosphäre erheblich eingeschränkt. Prozesse wie das Eindringen und Verdunsten von Wasser aus dem Boden oder der Luftaustausch zwischen Boden und Umgebungsluft werden im abiotischen Bereich stark reduziert oder gänzlich verhindert. Auch der biotische Bereich wird beeinträchtigt, da die Lebensbedingungen für Bodenorganismen verschlechtert und natürliche Kreisläufe unterbrochen werden (Böcker, 1985).

In Städten führt die weit verbreitete Bodenversiegelung zu erheblichen Störungen des natürlichen Wasserhaushalts. Bei starkem Regen fließt das Wasser größtenteils oberflächlich ab, sodass weniger Sickerwasser in tiefere Bodenschichten gelangt und die Verdunstung verringert wird. Die zunehmende Bebauung und Versiegelung beeinflussen zudem indirekt auch angrenzende Böden, indem sie den Wasser- und Wärmehaushalt der umliegenden Gebiete verändern und so deren natürliche Balance stören (Fiedler, 1996).

Die Bodenversiegelung verdeutlicht, wie menschliche Aktivitäten zunehmend natürliche Flächen beanspruchen. Im größeren Maßstab zeigt sich dieser Trend im globalen Verbrauch von Landfläche, der immer mehr Raum für Städte und Landwirtschaft schafft und dabei natürliche Ökosysteme verdrängt.

Die menschliche Landnutzung hat zunehmend globale Auswirkungen. Aktuell werden schätzungsweise 3 % der weltweiten Landfläche für städtische Gebiete und 38 % für die Landwirtschaft genutzt, darunter der Anbau von Pflanzen und Viehzucht. Rund 30 % der Erdoberfläche bestehen aus Gebieten wie Felsen, Eis, Tundra und Wüste, die für eine langfristige Nutzung ungeeignet sind. Somit verbleiben etwa 29 % als natürliche Ökosysteme, darunter Wälder, die theoretisch für menschliche Zwecke erschlossen werden könnten, jedoch wertvolle ökologische Funktionen erfüllen (Raven et al., 2013).

Natürliche Ökosysteme erbringen zahlreiche wertvolle Leistungen, die für das Überleben der Menschheit von zentraler Bedeutung sind. Dennoch haben sich städtische Gebiete sowie Acker- und Weideflächen in den letzten Jahrzehnten weltweit ausgeweitet, um die Versorgung einer wachsenden Bevölkerung von fast 7 Milliarden Menschen sicherzustellen (Raven et al., 2013).

In Österreich wird der Bodenverbrauch intensiv betrieben. Seit der Jahrtausendwende lag der durchschnittliche Flächenverbrauch bei etwa 120 Quadratmetern pro Minute. Zum Vergleich: Das entspricht mehr als dem Dreifachen der Fläche der Bundeshauptstadt Wien. Alle fünf Jahre gehen etwa 310 Quadratkilometer Boden verloren – eine Fläche vergleichbar mit dem Neusiedlersee. Zuletzt wurden jährlich über 40 Quadratkilometer versiegelt und damit für natürliche Nutzung unzugänglich gemacht (Wegscheider-Pichler et al., 2021).

Österreich hat im internationalen Vergleich einen auffallend hohen Bodenverbrauch, was angesichts seiner Topographie besondere Herausforderungen mit sich bringt. Im Jahr 2022 wies Österreich eine Landesfläche von 83.883 km² auf, von denen 32.584 km² als Dauersiedlungsraum klassifiziert wurden (Tab. 1). Dies entspricht 39 % der gesamten Bundesfläche. Der Siedlungsraum, der die gegenwärtig bewohnten Flächen umfasst, beträgt 11.502 km² und entspricht damit 14 % der Gesamtfläche des Bundesgebiets (Schutzwald.at, 2023).

Tabelle 1: Dauersiedlungsraum der Bundesländer, Gebietsstand 2022 (Statistik.at, 2024 b).

	Fläche	Dauersiedlungsraum		Siedlungsraum	
Bundesland	in km ²	in km ²	in %	in km ²	in %
Burgenland	3.965	2.485	63	483	12
Kärnten	9.537	2.455	26	1.079	11
Niederösterreich	19.180	11.616	61	2.616	14
Oberösterreich	11.983	6.842	57	2.678	22
Salzburg	7.155	1.496	21	731	10
Steiermark	16.399	5.230	32	2.452	15
Tirol	12.648	1.573	12	868	7
Vorarlberg	2.602	567	22	344	13
Wien	415	321	77	248	60
Österreich	83.883	32.584	39	11.502	14

Die hohen Zahlen des Bodenverbrauchs in Österreich verdeutlichen die Herausforderungen, die sich aus der spezifischen Topographie und den zunehmenden menschlichen Aktivitäten ergeben. Diese Situation erfordert ein vertieftes Verständnis der komplexen Wechselwirkungen zwischen Siedlungsraum und Umwelt, um die Auswirkungen der Bodenversiegelung angemessen zu bewerten und künftig nachhaltigere Ansätze zu fördern.

2.2.1 Ursachen der Bodenversiegelung

Die Hauptursachen der Bodenversiegelung liegen in der Urbanisierung, der Infrastrukturentwicklung und der Raumplanung. Urbanisierung führt zur Ausdehnung von Siedlungsgebieten und der Bebauung von ehemals natürlichen Flächen. Die Infrastrukturentwicklung wie der Bau von Straßen, Parkplätzen und Verkehrsanlagen, verstärkt diese Versiegelung. Zudem tragen unzureichende raumplanerische Maßnahmen und unkoordiniert wachsende Siedlungen dazu bei, dass wertvolle Flächen für Natur und Landwirtschaft verloren gehen. Diese Faktoren

zusammengenommen tragen erheblich zur zunehmenden Bodenversiegelung bei, die negative Auswirkungen auf Klima, Umwelt und Biodiversität hat.

2.2.1.1 Urbanisierung

Laut der aktuellen ÖROK-Regionalprognose für den Zeitraum von 2021 bis 2050 wird in Österreich mit einer weiteren Bevölkerungssteigerung von 7,8 % gerechnet. Die bestehenden Trends werden voraussichtlich fortbestehen, wobei die Bevölkerungszunahme vor allem in städtischen Ballungsgebieten stattfindet, während viele inneralpine und randständige Bezirke einen Rückgang verzeichnen. Die Nachfrage nach Wohnraum, einschließlich Zweitwohnungen, wird somit ein entscheidender Faktor für den Flächenverbrauch in Österreich bleiben. Hierbei sind nicht nur die dynamischen Entwicklungen in der Bevölkerung relevant, sondern auch der Trend hin zu kleineren Haushalten und einer steigenden Wohnfläche pro Person (Oerok.gv.at, 2022).

Wenn Siedlungsflächen ineffizient genutzt werden und dadurch ein hoher Landverbrauch entsteht, bringt das oft erhebliche Probleme mit sich. Wichtige ökologische und wirtschaftliche Funktionen des Bodens gehen verloren, ohne dass die Fläche einen entsprechenden Nutzen für die Bevölkerung bietet. In vielen Fällen trägt der hohe Flächenverbrauch lokal zur Zersiedelung bei, was zu einer ineffizienten Nutzung von Ressourcen und Infrastruktur führt. Die Zersiedelung spiegelt sich in verschiedenen Siedlungsmustern wider:

- In ländlichen Gebieten entstehen vereinzelt Wohnhäuser oder kleine Gruppen von Gebäuden abseits der bestehenden Ortschaften. Diese Bauten bilden sogenannte „Siedlungssplitter“ und unterbrechen die freie Landschaft. Durch diese verstreuten Strukturen entstehen zusätzliche Kosten für Infrastrukturanbindung und Erschließung, und die Naturflächen werden zerschnitten.
- Die Bebauung dehnt sich oft an den Rändern der Städte und Gemeinden aus, während zentrale, bereits erschlossene Flächen innerhalb der Ortsgrenzen häufig ungenutzt bleiben. Dies führt dazu, dass Ressourcen wie Strom- und Wasserversorgung oder Straßennetze über weite Strecken bereitgestellt werden müssen, obwohl es innerhalb der Kerngebiete noch Platz gibt. Dieser Prozess fördert nicht nur den Flächenverbrauch, sondern belastet auch die Umwelt und Infrastruktur unnötig.

- Einige Wohngebiete sind sehr weitläufig gestaltet und bestehen hauptsächlich aus freistehenden Einfamilienhäusern mit großen Grundstücken. Oft bleibt ein Drittel dieser Flächen unbebaut, was eine niedrige Siedlungsdichte zur Folge hat. Solche Gebiete nehmen überdurchschnittlich viel Fläche in Anspruch, ohne dass eine entsprechend hohe Anzahl an Menschen dort lebt. Dies erfordert ein aufwändiges Versorgungs- und Verkehrsnetz und trägt zur Zersiedelung und zum Verlust an zusammenhängenden Grünflächen bei (Emrich, 2013).

Die niedrige Bebauungsdichte erschwert den wirtschaftlichen Betrieb öffentlicher Verkehrsmittel mit einem angemessenen Angebot. Da die Entfernungen zwischen Wohn-, Arbeits-, Schul-, Einkaufs- und Freizeitorten oft groß sind, bleibt das Auto oft die einzige praktikable Option, um die täglichen Wege zu bewältigen. Siedlungen, die abgelegen und schlecht an den öffentlichen Nahverkehr angebunden sind, beanspruchen daher erheblich mehr Fläche als zentrale Wohngebiete. In zentralen Lagen kann durch die gute öffentliche Anbindung der Bedarf an Stellflächen um fast 50 % verringert werden (Dallhammer et al., 2011). Insgesamt führen Verkehrsinfrastrukturen zu einem erheblichen Flächenverbrauch. In dicht bebauten städtischen Gebieten ist der Anteil der Verkehrsflächen an der gesamten Flächennutzung vergleichsweise gering, während er in ländlichen Gegenden deutlich höher liegt (Oerok.gv.at, 2022).

Die zunehmende Zersiedelung und der steigende Flächenverbrauch haben weitreichende ökologische, wirtschaftliche und soziale Auswirkungen auf die Gemeinden. In Österreich wird die Nutzung von Flächen in den kommenden Jahren voraussichtlich stark ansteigen. Schätzungen zufolge könnten Siedlungs- und Verkehrsflächen bis 2060 um bis zu 55 Prozent wachsen. Dies entspricht einer täglichen Ausweitung von etwa 25 Fußballfeldern (Oerok.gv.at, 2015).

2.2.1.2 Infrastrukturentwicklung

Die Entwicklung stellt einen komplexen Teufelskreis dar. Die Zersiedelung, die durch die Verlagerung von Einzelhandelsgeschäften, Produktionsstätten und Wohngebieten an die Ortsränder geprägt ist, führt zu längeren zurückzulegenden Wegen und einer steigenden Verkehrsbelastung. Diese Situation verstärkt die Abhängigkeit vom Auto. In Österreich wird seit Jahrzehnten versucht, dieses Problem mit dem Bau neuer Straßen, Umgehungsstraßen und Autobahnen zu bekämpfen, was zur Entstehung eines der dichtesten Straßennetze in Europa geführt hat.

Allerdings führt der Ausbau der Straßeninfrastruktur auch zu einem Anstieg des Verkehrsaufkommens. Das übermäßige Angebot an Straßen macht die Randgebiete für Unternehmensansiedlungen attraktiver, wodurch der Kreislauf von Neuem in Gang gesetzt wird. Straßen und Parkplätze nehmen dabei fast die Hälfte der versiegelten Flächen in Österreich ein.

Am Beispiel Wiener Neustadt wird deutlich, dass die Stadt durch die bereits bestehende Autobahn A2 und die Schnellstraße S4 über ein stark ausgebautes Straßennetz verfügt. Die Straßenausbauprojekte der vergangenen Jahrzehnte haben zu einer massiven Expansion der Betriebsgebiete am Stadtrand geführt, wodurch Wiener Neustadt zu den Städten mit dem höchsten Bodenverbrauch pro Kopf in Österreich zählt. Gleichzeitig weist die Innenstadt den höchsten Anteil an leerstehenden Geschäftslokalen auf (WWF.at, 2022).

Industrie-, Gewerbe- und Handelsbetriebe sowie zunehmend auch Logistikzentren sind ebenfalls entscheidende Faktoren für den Flächenverbrauch in Österreich. Das Wachstum in der Produktion und im Dienstleistungssektor erhöht die Nachfrage nach verfügbaren Flächen erheblich. Gleichzeitig nimmt auch der Bedarf an Flächen für Freizeit- und Tourismuseinrichtungen sowie für die Energieerzeugung zu. Diese Entwicklungen tragen maßgeblich zur weiteren Inanspruchnahme von Bodenressourcen bei und verstärken den Druck auf die bereits begrenzten Flächen in Österreich (Oerok.gv.at, 2022).

Zusammenfassend hat die Bodenversiegelung durch Verkehrsinfrastruktur und Industrie weitreichende negative Auswirkungen auf Umwelt und Lebensqualität. Der kontinuierliche Ausbau von Straßen und Parkflächen führt nicht nur zur Zersiedelung, sondern verringert auch die Fläche unversiegelter Böden. Dies verstärkt die Abhängigkeit vom Auto und perpetuiert den Kreislauf der Versiegelung. Um die Folgen zu mindern, ist ein Umdenken in der Stadt- und Verkehrsplanung notwendig, mit einem stärkeren Fokus auf nachhaltige Mobilitätskonzepte und die Förderung öffentlicher Verkehrsmittel.

2.2.1.3 Raumplanung

Auf Bundesebene regulieren Gesetze wie das Umweltverträglichkeitsprüfungsgesetz, das Forstgesetz und das Wasserrecht sowie die Infrastrukturplanung mehrere zentrale Bereiche der Bautätigkeit. Die Raumplanung und Bauordnung unterliegt jedoch der

Kompetenz der Länder, während die Gemeinden im Rahmen dieser Landesgesetze für die Aufstellung von Flächenwidmungs- und Bebauungsplänen zuständig sind. Die Länder fungieren hierbei als Prüf- und Aufsichtsbehörden, doch in der Praxis fehlen oft klare ökologische Instrumente und verbindliche Zielvorgaben für eine nachhaltige Raumplanung. Dadurch entstehen große Spielräume für Nutzungsänderungen, die einer strategischen Raumordnung im Wege stehen (Gruber et al., 2018).

Die Bundesländer nutzen ihre rechtlichen Möglichkeiten zur regionalen Steuerung der Raumentwicklung bislang kaum. In Oberösterreich beispielsweise gibt es nur in vier von 18 politischen Bezirken regionale Raumordnungsprogramme, die wichtige Aspekte wie die Festlegung von Grünzonen beinhalten (Land-Oberoesterreich.gv.at, o.A.). Selbst in diesen wenigen Programmen bestehen jedoch große Lücken, wodurch wichtige Entwicklungsziele unzureichend umgesetzt werden.

Der hohe Bodenverbrauch der letzten Jahrzehnte sowie aufgedeckte Umwidmungsskandale verdeutlichen die strukturellen Schwächen des aktuellen Raumplanungssystems. Um diese Defizite zu beheben, wäre eine stärkere zentrale Steuerung auf regionaler und gesamtstaatlicher Ebene notwendig. Nur so können verbindliche Standards für eine nachhaltige Flächennutzung festgelegt und eine effiziente Raumplanung langfristig gewährleistet werden (WWF.at, 2024).

2.2.2 Auswirkungen der Bodenversiegelung

Die Versiegelung städtischer Flächen durch Bebauung, Infrastruktur und Verkehrsanlagen ist ein fester Bestandteil des Urbanisierungsprozesses. Durch die zunehmende Flächennutzung für Gebäude, Straßen und Parkplätze wird der natürliche Bodenanteil in Städten immer weiter verdrängt. Dies beeinflusst nicht nur die Funktion des Bodens, etwa seine Fähigkeit zur Wasseraufnahme oder zur Klimaregulation, sondern auch die Lebensqualität in dicht besiedelten Gebieten. Angesichts dieser Entwicklungen ist es entscheidend, die vielfältigen Auswirkungen der Versiegelung auf Umwelt, Gesundheit und Lebensraum zu betrachten. Diese Wirkungen machen deutlich, dass Bodenversiegelung in urbanen Räumen mit komplexen, oft auch langfristigen Folgen verbunden ist, die besonders im Kontext von Klimawandel und Bevölkerungswachstum relevant werden.

2.2.2.1 Beeinflussung des Wasserhaushalts durch die Bodenversiegelung

Intakte Böden sind ein zentraler Bestandteil des Wasserhaushalts. Sie nehmen Regenwasser effizient auf, speichern es in großen Mengen, geben es später an Pflanzen ab und tragen zur Grundwasserneubildung bei. Menschliche Eingriffe beeinträchtigen diese essenziellen Funktionen erheblich. In städtischen Gebieten mit hoher Flächenversiegelung durch Siedlungen und Verkehr gehen die Versickerungs- und Speicherfähigkeiten der Böden nahezu vollständig verloren. Auf landwirtschaftlich genutzten Flächen erfolgt die Beeinträchtigung der Bodenfunktionen oft schleichend, mit teils gravierenden Folgen. Da landwirtschaftliche Böden etwa die Hälfte der für Versickerung und Wasserspeicherung nutzbaren Landfläche ausmachen, sind sie von entscheidender Bedeutung für einen stabilen Wasserhaushalt (Statistikportal.de, o.A.).

Die fortschreitende Urbanisierung und die unkontrollierte Ausdehnung bebauter Flächen führen zur Versiegelung von Böden und dem Verlust ihrer wichtigen Ökosystemleistungen (Wiggering et al., 2009). Böden erfüllen wichtige Funktionen für das Ökosystem, insbesondere die Versickerung und Speicherung von Wasser. Diese Prozesse tragen zur Reduzierung von Erosion bei, sichern die Wasserversorgung für das Pflanzenwachstum und fördern die Grundwasserneubildung. Faktoren wie Topographie, Bodentextur, Struktur, Landnutzung und Bewirtschaftungssysteme beeinflussen dabei maßgeblich die Effizienz von Versickerung und Wasserspeicherung. Die Fähigkeit von Böden, Wasser zu speichern, variiert stark, je nach Landnutzung und Bewirtschaftungsform. Sie nimmt von natürlichen und extensiven Systemen wie Wäldern und Dauergrünland hin zu intensiven, konventionellen Anbaumethoden deutlich ab. Während Wälder bis zu 100 Prozent des Wasserspeicherpotenzials erreichen, liegt dieser Wert bei Dauergrünland bei 78 Prozent und fällt über ökologischen Ackerbau (35 Prozent) und konservierende Bodenbearbeitung (27 Prozent) bis hin zum konventionellen Ackerbau auf lediglich 16 Prozent ab (Abu-Hashim, 2011).




Abbildung 8: Auswirkungen der Urbanisierung auf den Wasserhaushalt, insbesondere durch die Versiegelung von Flächen und die Veränderung des natürlichen Wasserkreislaufs. Dies führt zu einem verstärkten Oberflächenabfluss und zu einer reduzierten Bodenversickerung und Evapotranspiration (Sieker.de, o.A.).

Die Versickerungsraten und die Fähigkeit zur Wasserspeicherung können selbst innerhalb eines pflanzenbaulichen Produktionssystems variieren. Negative Veränderungen der Bodenstruktur wie sie beispielsweise durch Verschlämmung und Verdichtung auftreten, entstehen oft schrittweise. Hauptursachen hierfür sind der Einsatz immer größerer und schwererer Fahrzeuge, die den Boden zunehmend belasten (Lilienthal und Schnug, 2008). Gebiete mit einem lockeren, von Wurzeln und Regenwürmern geprägten Bodenaufbau zeichnen sich durch stabile Makroporen aus. Diese ermöglichen es, Niederschlagswasser schnell in tiefere Bodenschichten zu leiten und dadurch die Wasserspeicherkapazität des Unterbodens effektiv zu nutzen (Han et al., 2015). Abbildung 8 ermöglicht einen Vergleich der Versickerungsraten in verschiedenen verbauten Gebieten.

Die Ergebnisse dieses Kapitels verdeutlichen, dass die fortschreitende Flächenversiegelung erhebliche negative Auswirkungen auf den Wasserhaushalt hat. Sie reduziert nicht nur die natürliche Versickerung und Grundwasserneubildung,

sondern fördert auch Oberflächenabfluss und das Risiko von Überschwemmungen. Langfristig beeinträchtigt dies die Wasserverfügbarkeit, die Wasserqualität und die ökologischen Funktionen von Boden und Gewässern.

2.2.2.2 Einfluss der Bodenversiegelung auf die Biodiversität

Der Begriff Biodiversität beschreibt die gesamte Bandbreite des Lebens auf der Erde. Dazu gehören die Vielfalt der Ökosysteme, die unterschiedlichen Arten sowie die genetischen Unterschiede innerhalb einzelner Arten (National Forum on BioDiversity, 2011). Die zentrale Bedeutung der Biodiversität wird durch das 1992 unterzeichnete Übereinkommen über die biologische Vielfalt (CBD) hervorgehoben. Dennoch schreitet der Verlust an biologischer Vielfalt sowohl oberhalb als auch unterhalb der Erdoberfläche unaufhaltsam voran, was nicht nur die Lebensgrundlage unseres Planeten gefährdet, sondern auch die essenziellen Dienstleistungen, die sie für die Menschheit erbringt.

Der Boden, als Fundament aller terrestrischen Ökosysteme, wird dabei in Umweltbewertungen oft vernachlässigt, obwohl seine biologische Vielfalt eine entscheidende Rolle spielt. In diesem Kontext wird der Zustand des Bodens als Kernbestandteil der Landressourcen besonders hervorgehoben. Die Bedeutung eines gesunden Bodenökosystems, häufig überschattet von der Aufmerksamkeit für auffällige und farbenprächtige Arten, verdient dabei verstärkte Beachtung (Dudley et al., 2017).

Intakte Böden sind essenziell für die Sicherstellung der Nahrungsversorgung, die Regulierung des Klimas, die Reinheit von Wasser und Luft sowie für den Erhalt einer vielfältigen Lebenswelt sowohl ober- als auch unterhalb der Erdoberfläche (Smith et al., 2015). Veränderungen in der Landnutzung beeinflussen den Zustand des Bodens und führen meist zu einer Verschlechterung seiner Qualität.

Verschiedene Faktoren, einzeln oder in Kombination, beeinflussen die Oberflächenökosysteme direkt. Der Rückgang der biologischen Vielfalt im Boden ist dabei nicht nur eine Herausforderung für den Naturschutz, sondern hat weitreichende Auswirkungen auf zahlreiche ökologische Funktionen. Dazu gehören die Geschwindigkeit der Zersetzung organischer Stoffe, die Speicherung von Nährstoffen, die Bildung stabiler Bodenstrukturen und die Aufrechterhaltung des Nährstoffkreislaufs (Wagg et al., 2014). Diese Funktionen sind unverzichtbar für die Versorgung mit

sauberem Wasser, die Kontrolle von Schädlingen und Krankheitserregern, die Förderung der Bodenfruchtbarkeit, den erfolgreichen Pflanzenbau sowie die Minderung des Klimawandels. Daher ist die Wiederherstellung der biologischen Vielfalt im Boden ein entscheidender Schritt, um die Grundlage für gesunde und leistungsfähige Böden zu schaffen.

Die Lebensgemeinschaften im Boden sind außergewöhnlich vielfältig und bestehen aus Millionen von Arten sowie Milliarden von Individuen, die in einem einzigen Ökosystem zusammenwirken (Bardgett und Van der Putten, 2014). Diese Vielfalt umfasst zudem einen bemerkenswert hohen Anteil an endemischen Arten, die ausschließlich in bestimmten Regionen vorkommen (Orgiazzi et al., 2016). Ein erheblicher Anteil der weltweiten biologischen Vielfalt findet seinen Lebensraum im Boden (FAO and ITPS, 2015). Bakterien und Pilze zählen zu den häufigsten und artenreichsten Gruppen von Bodenorganismen. Sie erfüllen zentrale Aufgaben wie den Abbau organischer Substanzen, das Stabilisieren von Bodenaggregaten zur Verhinderung von Erosion sowie das Fördern von Drainage, Wasserspeicherung und Belüftung des Bodens. Ergänzt wird die Bodenfauna durch eine Vielzahl anderer Organismen, darunter Protozoen (wie Amöben, Flagellaten und Wimpertierchen), Nematoden (die sich von Wurzeln, Mikroben oder anderen Nematoden ernähren), Milben, Springschwänze, Enchyträen und Regenwürmer. Gemeinsam bilden diese Organismen komplexe Nahrungsnetze, die essenziell für ökologische Prozesse im Boden sind wie den Nährstoffkreislauf und die Bindung von Kohlenstoff. Sie tragen maßgeblich zu globalen Stoff-, Energie- und Nährstoffkreisläufen bei (Wolters et al., 2000). Bodenbasierte Nahrungsnetze sind entscheidend für die Bereitstellung von Ökosystemleistungen (Brussaard et al., 2007), die sowohl die Pflanzenproduktion fördern als auch zur Bewahrung der biologischen Vielfalt beitragen (Hooper et al., 2000).

Insbesondere wird die natürliche Fruchtbarkeit des Bodens stark beeinträchtigt, wenn er versiegelt wird. Wird der Boden dauerhaft von Luft und Wasser abgeschnitten, stirbt die darin lebende Fauna ab, die für die Aufrechterhaltung und Erneuerung fruchtbarer Böden von entscheidender Bedeutung ist (Umweltbundesamt.de, 2024).

2.2.2.3 Einfluss der Bodenversiegelung auf das Stadtklima

Städtische Gebiete unterscheiden sich deutlich von ländlichen Regionen, insbesondere in klimatischen Faktoren wie Niederschlag, Windverhältnissen und

Temperatur. Diese Unterschiede führen zum Phänomen der „städtischen Wärmeinseln“ (Urban Heat Islands), bei dem städtische Bereiche durch gespeicherte Sonnenwärme und fehlende Vegetation spürbar wärmer bleiben als ihr Umland – ein Effekt, der bereits seit dem 19. Jahrhundert bekannt ist (Howard, 1820). Der Temperaturunterschied zwischen urbanen Gebieten und dem ländlichen Umland kann bis zu 12 °C erreichen (Eliasson, 2000).

Auch innerhalb von Städten gibt es deutliche Temperaturunterschiede zwischen Stadtteilen, die je nach Begrünung, Wasserflächen und Versiegelungsgrad variieren. Stark versiegelte Viertel ohne ausreichende grüne und blaue Infrastruktur heizen sich stärker auf, während begrünte und entsiegelte Bereiche durch Verdunstung kühlere Temperaturen bieten (Böttner et al., 2012).

Die Hauptursache für die Entstehung städtischer Wärmeinseln liegt in der Versiegelung und Bebauung natürlicher, wasserdurchlässiger Flächen (Kuttler, 2011). Natürliche Böden mit Vegetationsbedeckung speichern Feuchtigkeit und lenken einen erheblichen Teil der Sonnenenergie in Verdunstungsprozesse wie Transpiration und Evaporation, die die Umgebung kühlen und wie eine natürliche Klimaanlage wirken. In versiegelten, bebauten Flächen fehlt dieser kühlende Effekt, wodurch die Temperaturen stark steigen. Zudem heizen sich natürliche Böden und Pflanzen dank Schatten und Verdunstung weit weniger auf als Beton und Asphalt, was den Temperaturunterschied zwischen Stadt und Umland weiter verstärkt.

Bebaute Oberflächen bestehen meist aus wärmespeichernden, oft wasserundurchlässigen Materialien, die sich tagsüber stark aufheizen. Regenwasser kann nicht versickern und fließt schnell ab, was die Verdunstungskühlung erheblich verringert. Zudem vergrößert die Architektur der Städte die wärmeabsorbierenden Flächen: Vertikale Gebäudewände fangen nicht nur direkte Sonnenstrahlen ein, sondern auch reflektierte Hitze benachbarter Fassaden. Dadurch verstärkt sich die Hitzeaufnahme im städtischen Raum erheblich, was die Wärmeinseln weiter aufheizt (Brandenburg et al., 2015).

Die dichte Anordnung und Form der Gebäude in Städten, kombiniert mit dem oft niedrigen Himmelssichtfaktor (Sky View Factor, ein Maß für die Offenheit eines städtischen Raumes), behindern zusätzlich die Luftzirkulation und reduzieren die Möglichkeit zur Abstrahlung gespeicherter Wärme. Diese eingeschränkte

Luftbewegung und blockierte Wärmeabgabe verstärken das Aufheizen der urbanen Räume und tragen erheblich zur Entstehung städtischer Hitzeinseln bei (Kuttler, 2011). Exponierte Flächen, insbesondere solche mit dunklen Bodenbelägen oder Dächern, die wenig oder keine Wärme reflektieren, können sich um bis zu 50 °C stärker erwärmen als die umgebende Lufttemperatur (U.S. Environmental Protection Agency, 2008).

Weitere Faktoren, die den städtischen Wärmeinseleffekt verstärken, sind der Verlust und die Zerstückelung von städtischen Grünflächen sowie die Abwärme, die durch Industrieprozesse, Klimaanlage und Fahrzeuge entsteht. Zudem führt die Bebauung zu einer erhöhten Oberflächenrauigkeit, wodurch die Windgeschwindigkeit verringert wird. Häufig hindert die dichte Bebauung auch den Eintritt von Kaltluft aus umliegenden, unbebauten Gebieten in die Städte.

Der stärkste Wärmeinseleffekt tritt in windstillen, klaren Sommernächten auf. Baumaterialien besitzen eine hohe thermische Trägheit, wodurch sie tagsüber aufgenommene Wärme speichern und diese nach Sonnenuntergang, teilweise bis in den Morgen, wieder an die Umgebung abgeben. In unbebauten Gebieten hingegen kühlen die Erdoberflächen während dieser Zeit ab, da der wolkenlose Himmel die Wärmeabstrahlung fördert und die Ausgangstemperatur hier im Vergleich zu städtischen Flächen niedriger ist (Brandenburg et al., 2015).

Urban Heat Islands erhöhen die Temperaturen in Städten, was zu mehr Energieverbrauch und gesundheitlichen Problemen führt. Dies resultiert aus der Bebauung, dem Verlust grüner Flächen und der Wärmeabsorption versiegelter Oberflächen. Maßnahmen wie verstärkte Begrünung und Entsiegelung sind notwendig, um diese Effekte abzumildern und das Stadtklima zu verbessern.

2.2.2.4 Zusammenhang von Bodenversiegelung und CO₂-Emissionen

Böden sind ein essenzieller Bestandteil des globalen Kohlenstoffkreislaufs und tragen wesentlich zur Regulierung des CO₂-Gehalts in der Atmosphäre bei. Sie speichern mehr Kohlenstoff als alle Wälder der Erde zusammen und beherbergen etwa fünfmal so viel wie in der Vegetation vorhanden ist. Damit sind Böden der größte terrestrische Kohlenstoffspeicher und spielen eine Schlüsselrolle im Klimaschutz. Ihr Schutz und eine nachhaltige Bewirtschaftung sind entscheidend, um den Kohlenstoffspeicher langfristig zu erhalten (Umweltbundesamt.de, 2024).

In den letzten zehn Jahren hat die Natur über die Hälfte der vom Menschen verursachten Treibhausgasemissionen (54 Prozent) aufgenommen. Dabei wurde ein bedeutender Anteil, über 30 Prozent, in landbasierten Ökosystemen wie Wäldern, Böden und anderen Vegetationsflächen gespeichert (Groc, 2023).




Abbildung 9: Zentrale Kohlenstoffflüsse und -umsetzungen im Boden. Die Aktivität der Bodenorganismen und ihre Abbauprozesse hängen nicht nur von verfügbaren Kohlenstoffquellen, sondern auch stark von Temperatur und Bodenfeuchtigkeit ab (Schrumpf und Trumbore, 2011).

Pflanzen sind die Hauptquelle für den Kohlenstoff im Boden. Abgestorbene Pflanzenreste gelangen sowohl an der Oberfläche als auch unterirdisch in den Boden, wo sie von Bodenorganismen über komplexe Nahrungsnetzwerke verarbeitet und in Bodenkohlenstoff umgewandelt werden (Abb. 9). Mikroorganismen spielen dabei eine zentrale Rolle, da sie den Kohlenstoff durch Mineralisation zu CO₂ abbauen (Schmidt et al., 2011).

Der Mensch beeinflusst den Kohlenstoffkreislauf im Boden auf vielfältige Weise, etwa durch die Auswahl der angebauten Pflanzen, den Einsatz von Düngemitteln und unterschiedliche Methoden der Bodenbearbeitung. Diese Eingriffe steuern nicht nur den Kohlenstoffeintrag in den Boden, sondern auch die Lebensbedingungen für Mikroorganismen, die für den Abbau und die Mineralisation von Kohlenstoff verantwortlich sind. Besonders stark wirken sich Landnutzungsänderungen aus wie

die Umwandlung von Wäldern oder Wiesen in Acker- oder versiegelte Flächen. Solche Veränderungen reduzieren den Kohlenstoffgehalt des Bodens und führen zu einer deutlichen Erhöhung von CO₂-Emissionen, wodurch der globale Kohlenstoffkreislauf und das Klima erheblich beeinflusst werden (Schrumpf und Trumbore, 2011).

Die Versiegelung von Böden trägt wesentlich zur Zunahme von CO₂-Emissionen bei, da sie natürliche Prozesse des Kohlenstoffkreislaufs unterbricht. Durch die Abdeckung mit Asphalt, Beton oder anderen Materialien wird der Kohlenstoffeintrag aus Pflanzenresten in den Boden gestoppt, während gleichzeitig die Aktivität von Bodenorganismen und die Speicherung von Kohlenstoff in Form von Humus drastisch reduziert werden. Darüber hinaus wird der zuvor gespeicherte Kohlenstoff durch veränderte mikroklimatische Bedingungen und Störungen freigesetzt, was zu einem Nettoverlust von Bodenkohlenstoff und erhöhten Emissionen führt. Die Folgen sind nicht nur lokale Umweltprobleme, sondern auch ein globaler Beitrag zur Verschärfung des Klimawandels.

2.2.2.5 Einfluss der Bodenversiegelung auf die menschliche Gesundheit

Zusätzlich zu den bereits beschriebenen physisch-geografischen Auswirkungen der Flächenversiegelung bringt die Urbanisierung auch ein erhöhtes Risiko für Stress und psychische Erkrankungen mit sich. Besonders das Gefühl der Hilflosigkeit gegenüber städtischen Stressfaktoren belastet die mentale Gesundheit und könnte das vermehrte Auftreten psychischer Erkrankungen in urbanen Gebieten erklären (Adli und Schöndorf, 2020). Angenehme Wohnbedingungen und leicht zugängliche Grünflächen sind im städtischen Raum wesentliche Pfeiler für die Förderung von Lebensqualität und Gesundheit (Hachmann, 2020). Zu den ohnehin gesundheitsschädlichen klimatischen Bedingungen (Kap. 2.2.2.3) kommen weitere Belastungen wie Feinstaub, Luftverschmutzung und Lärm hinzu (Menke, 2020). Zunehmende wissenschaftliche Erkenntnisse zeigen, dass städtische Naturräume das Wohlbefinden der Bewohner erheblich fördern können (Salomon et al., 2018).

Urbane Grünflächen tragen maßgeblich zur körperlichen und psychischen Gesundheit bei (Adli und Schöndorf, 2020), indem sie den Bewohnern wertvolle Erholungs- und Bewegungsräume bieten. Sie schaffen Orte der Ruhe und Entspannung, die in der dichten Bebauung oft fehlen, und wirken so stressreduzierend und stimmungsaufhellend. Zusätzlich steigern sie die Lebensqualität und spielen eine wichtige Rolle im Umgang mit den Folgen des Klimawandels, etwa durch

Kühlungseffekte und die Verbesserung der Luftqualität in städtischen Gebieten (Salomon et al., 2018).

Schaffung von ausreichend Wohnraum sowie von Grün- und Freiflächen stellt Städte vor große Herausforderungen, da die Verstärkung der Bebauung oft die Verfügbarkeit von Grünflächen verringert und den Zugang zu Erholungsorten für die Bewohner einschränkt (Köckler und Sieber, 2020). Die weite Verbreitung von Autos und der damit verbundene Ausbau der Straßeninfrastruktur in Städten führt zu einer Zerstückelung der vorhandenen Grünflächen. In dicht besiedelten urbanen Gebieten fehlen daher oft öffentliche Räume, die für soziale Interaktionen, Bewegung und Erholung genutzt werden könnten (Salomon et al., 2018). Diese Flächen sind von wesentlicher Bedeutung für das Wohlbefinden der Bewohner, da sie Erholung bieten, die Luftqualität verbessern und zur Kühlung der Umgebung beitragen (Köckler und Sieber, 2020). Bestimmte Gesundheitsprobleme wie Atemwegs-erkrankungen, können in direktem Zusammenhang mit der Wohnumgebung stehen. Faktoren wie schlechte Luftqualität, Lärm und begrenzter Zugang zu Grünflächen tragen wesentlich zur Entstehung solcher Krankheiten bei (Salomon et al., 2018). Um auch künftig eine gesunde Lebensqualität in urbanen Räumen zu gewährleisten, ist es notwendig, verschiedene Einflussfaktoren zu berücksichtigen und deren negative Auswirkungen zu minimieren oder auszugleichen (Saß et al., 2020).

Aktuelle Luftbilder verdeutlichen, dass städtische Zentren durch eine hohe Dichte an Gebäuden und Verkehrsflächen geprägt sind. Grün- und Freiflächen sind dagegen vor allem an den Rändern der Städte zu finden. Innerhalb der Stadt sind Begrünungen meist nur vereinzelt, etwa in Form von Dach- und Balkonpflanzungen oder kleinen Grünflächen auf Plätzen. Dennoch leisten auch diese eine wichtige Rolle für das städtische Klima und tragen zur Verbesserung des Wohlbefindens der Menschen bei, die diese Bereiche nutzen (Menke, 2020).

2.2.3 Ansätze zur Reduzierung der Bodenversiegelung

Die Versiegelung von Böden durch städtische Entwicklung und den Ausbau von Infrastrukturen ist eine der gravierendsten Formen der Bodendegradation, da sie sämtliche Ökosystemleistungen stark beeinträchtigt. Wissenschaftler und Politiker betonen die Notwendigkeit, diese Entwicklung einzudämmen und neue Versiegelungen durch gezielte Entsiegelungsmaßnahmen auszugleichen. Dabei gewinnen die Sanierung von Böden nach Bergbau- und Bauaktivitäten sowie die

Wiederherstellung und Renaturierung von Industriebrachen zunehmend an Bedeutung (Tobias et al., 2018). Wissenschaftler schlagen vor, städtische Böden, brachliegende Industrieflächen und Deponien so aufzubereiten, dass sie nach einer fachgerechten Schadstoffsanierung neuen Nutzungen zugeführt werden können. Beispiele hierfür sind die Umgestaltung zu städtischen Parks, die Anlage von Gründächern oder die Nutzung für urbanes Gärtnern (Morel et al., 2015).

Das europäische Forschungsprojekt CircUse setzte sich für ein nachhaltiges Flächennutzungsmanagement ein, das insbesondere Planer und kommunale Behörden adressierte. Ziel war es, die Versiegelung unberührter Grünflächen zu verhindern, brachliegende Areale durch Sanierung oder Renaturierung wieder nutzbar zu machen und neue Eingriffe in die Natur durch Entsiegelungs- oder Renaturierungsmaßnahmen zu kompensieren (Ec.Europa.eu, 2015). Ein weiteres Projekt entwickelte einen Handlungsrahmen für die Wiederherstellung von Brachflächen, der speziell auf die Bedürfnisse lokaler Behörden, Grundstückseigentümer und Investoren zugeschnitten ist. Ziel dieses Ansatzes ist es, die Anzahl ungenutzter Flächen durch gezielte Sanierungsmaßnahmen vollständig zu eliminieren (Zerobrownfields.eu, o.A.).

Wissenschaftler haben die Bevölkerungsdichte und die wirtschaftliche Wettbewerbsfähigkeit als entscheidende Faktoren für das Brachflächenmanagement in europäischen Ländern identifiziert. In hochentwickelten, dicht besiedelten Staaten wie Deutschland, dem Vereinigten Königreich, Belgien und den Niederlanden spielt die Wiederherstellung und Nutzung von Brachflächen eine zentrale Rolle. Aufgrund des begrenzten Zugangs zu unberührten Grünflächen wird hier verstärkt auf die Sanierung und Integration solcher Flächen in die Stadt- und Regionalentwicklung gesetzt. Weniger dicht besiedelte, aber wirtschaftlich wettbewerbsfähige Länder wie die skandinavischen Staaten und Irland, legen ihren Fokus vor allem auf die Sanierung kontaminierter Standorte, um spezifische Umweltprobleme zu adressieren. Im Gegensatz dazu zeigen Länder mit mittlerer Bevölkerungsdichte und geringerer wirtschaftlicher Leistungsfähigkeit, darunter viele Mittelmeerländer und Staaten des ehemaligen Ostblocks, nur ein geringes Engagement im Brachflächenmanagement. Häufig fehlt es hier an Ressourcen und politischem Willen, um entsprechende Strategien systematisch umzusetzen (Oliver et al., 2005).

In mehreren Ländern, darunter die USA, Kanada (De Sousa, 2004), das Vereinigte Königreich (Doick et al., 2006) und Deutschland (Bundesministerium für Verkehr, Bau und Stadtentwicklung und Bundesamt für Bauwesen und Raumordnung, 2008), wurden zahlreiche ehemalige Industriebrachen erfolgreich in städtische Parks umgewandelt. Diese Umgestaltungen haben die Lebens- und Erholungsqualität in den umliegenden Stadtvierteln erheblich gesteigert (De Sousa, 2006). Beispiele für solche Projekte sind der Millennium Park in Chicago (Lewis, 2006), der Emscher Landschaftspark im Ruhrgebiet und der Thames Barrier Park in London, die als Vorzeigemodelle für die nachhaltige Nutzung brachliegender Flächen gelten (Villella et al., 2006).

Erfahrungen aus der Bodensanierung nach temporären Bauprojekten oder Rohstoffabbau zeigen deutlich, welche Bedingungen für die erfolgreiche Wiederherstellung von land- und forstwirtschaftlich genutzten Böden erforderlich sind. Insbesondere das Abtragen und Wiederaufbringen von Bodenmaterial, oft unter Einsatz schwerer Maschinen, hat in der Vergangenheit häufig zu erheblichen Verdichtungen des Bodens geführt (Harris et al., 1998).

Um die Bodenversiegelung zu reduzieren, sind gezielte Maßnahmen und Strategien erforderlich, die sowohl auf Prävention als auch auf nachhaltige Flächennutzung abzielen. Dazu gehört die Förderung von Nachverdichtung in bereits urbanisierten Gebieten anstatt der Weiterentwicklung unversiegelter Flächen. Zusätzlich sollten durch Entsiegelungsmaßnahmen wie das Aufbrechen versiegelter Flächen und deren Renaturierung, bestehende Flächen wieder nutzbar gemacht werden. Ein weiterer wichtiger Ansatz ist die Förderung von umweltfreundlicher Stadtplanung, die eine Reduktion der Versiegelung von Böden in neuen Entwicklungsgebieten berücksichtigt. Nur durch eine Kombination dieser Maßnahmen kann der Verlust wertvoller Böden eingedämmt und die negativen Auswirkungen auf das Klima und die Biodiversität gemildert werden.

2.3 Fernerkundliche Identifizierung der Bodenversiegelung

Das sichtbare Spektrum umfasst Wellenlängen im Bereich von 0,4 bis 0,7 μm wie in Abbildung 3 in Kapitel 2.1.1.2 dargestellt. Die echtfarbenen Orthophotos liegen vollständig innerhalb dieses sichtbaren Bereichs.




Abbildung 10: Vergleiche von unterschiedlichen spektralen Reflexionskurven von Oberflächenbedeckungen (Lillesand et al., 2015).

Die Erfassung der Erdoberfläche mit passiven Sensoren basiert grundsätzlich auf der Reflexionskurve. Dabei wird je nach Aufnahmekanal und dem genutzten Bereich des elektromagnetischen Spektrums die reflektierte und emittierte Strahlungsleistung gemessen. Fernerkundungsdaten sind daher eng mit den physikalischen Eigenschaften des Materials bzw. der Erdoberfläche verknüpft (Üreyen und Thiel, 2017). Die spektrale Reflexionskurve verdeutlicht das Verhalten versiegelter Flächen im sichtbaren Spektrum. Wie in Abbildung 10 zu erkennen ist, reflektiert Asphalt in diesem Bereich weniger als 20 Prozent der einfallenden Strahlung. Im Gegensatz dazu zeigen natürliche Objekte wie Boden, Vegetation oder Schnee eine deutlich höhere

Reflexion. Bei der Klassifizierung zeichnen sich versiegelte Flächen durch spezifische Eigenschaften aus wie Texturmerkmale und ihre Farb- und Helligkeitswerte, die ihre Unterscheidung ermöglichen.

2.4 Anwendungsbeispiele zur Klassifikation der Bodenversiegelung

In der wissenschaftlichen Literatur existiert eine Vielzahl an Veröffentlichungen zur Ableitung versiegelter Flächen mithilfe von Fernerkundungsdaten. Besonders hochauflösende Fernerkundungsdaten in Kombination mit Klassifizierungsverfahren spielen dabei eine zentrale Rolle. Unterschiedliche Methoden und Ansätze werden genutzt, um Bodenversiegelung präzise zu erfassen.

García et al. (2014) untersuchten die Erkennung versiegelter Flächen unter Einsatz überwachter und unüberwachter Bildklassifizierungsverfahren. Die Analyse basiert auf Satellitenbildern von Madrid, aufgenommen zwischen 1989 und 2010. Die überwachte Klassifikation erfolgte durch eine Einteilung in versiegelte und unversiegelte Flächen. Die Ergebnisse wurden mit einer manuellen Kartierung abgeglichen, wobei in einigen Bereichen Fehlklassifikationen aufgetreten sind. Diese wurden vor allem auf ähnliche spektrale Eigenschaften unterschiedlicher Flächentypen zurückgeführt. Die Autoren bewerteten die überwachte Klassifizierung als effektiver.

Mohamed et al. (2015) analysierten Veränderungen der Bodenversiegelung anhand verschiedener Machine-Learning-Algorithmen. Als Datengrundlage dienten Aufnahmen der Satelliten Landsat 7 und Landsat 8. Die Ergebnisse zeigten, dass Support Vector Machines (SVMs) und neuronale Netzwerke besonders hohe Klassifikationsgenauigkeiten erzielten, beide mit einer Gesamtgenauigkeit von über 90 %.

Hendawy et al. (2019) nutzten SVMs zur Analyse der Landschaftsnutzung. Diese Methode, die auf statistischen Prinzipien basiert, erwies sich als effektiv für die Klassifikation unterschiedlicher Landschaftsstrukturen innerhalb eines Datensatzes.

Weitere Forschungsarbeiten kombinieren den Normalized Difference Vegetation Index (NDVI) mit Methoden des maschinellen Lernens. Zhao et al. (2022) setzten eine Deep-Learning-Architektur zur Klassifizierung der Landbedeckung ein, wobei der NDVI als zusätzliche Informationsquelle diente. Deep Learning ermöglicht nicht nur die Extraktion spektraler Merkmale, sondern erfasst auch kontextbezogene und

semantische Informationen. Dies verbessert die Genauigkeit bei der Analyse hochauflösender Fernerkundungsdaten erheblich.

Die wissenschaftlichen Artikel und Beiträge zeigen, dass die Erfassung versiegelter Flächen im urbanen und ländlichen Raum durch Fernerkundungsdaten mithilfe verschiedener Klassifikationsmethoden erfolgen kann.

Die in der wissenschaftlichen Literatur untersuchten Ansätze zur Klassifikation versiegelter Flächen mittels Fernerkundungsdaten verdeutlichen die Vielseitigkeit und Effektivität der verwendeten Klassifikationsmethoden. Sowohl überwachte als auch unüberwachte Verfahren haben sich als nützlich erwiesen, wobei kein direkter Vergleich der unterschiedlichen Klassifikationsmethoden und Algorithmen durchgeführt wurde.

3. Methode und Datenmaterial

3.1 Beschreibung des Projektgebietes

Um die Klassifikationsalgorithmen anzuwenden und zu evaluieren wurde ein Projektgebiet gesucht, dass möglichst viele Variablen abdeckt, die auf den Klassifikationsprozess Einfluss nehmen können. Das Testgebiet sollte eine breite topographische Vielfalt aufweisen wie Höhenlagen und Hangneigungen, da topographische Variationen Einfluss auf die radiometrische Auflösung der Aufnahme haben. Weiters sollte das Gebiet hügelige bis bergige, aber auch flache Regionen beinhalten, um zu prüfen wie die Algorithmen mit Schatteneffekten umgeht. Zusätzlich sollen eine Vielzahl von Bodenbedeckungen vorkommen wie landwirtschaftliche Flächen, Waldgebiete, Gewässer und urbane Infrastrukturen. Die beschriebenen Kriterien erlauben es, die Algorithmen unter möglichst realitätsnahen Bedingungen zu testen (Richards und Jia, 2006).

Als Untersuchungsgebiet für die Masterarbeit wurde Graz, die Landeshauptstadt des Bundeslandes Steiermark, gewählt. Das Zentrum von Graz befindet sich 47°05' nördlicher Breite und 15°26' östlicher Länge, 353 Meter über dem Meeresspiegel. Das Stadtgebiet erstreckt sich über 127,58 km², wovon 68% Grünfläche sind (Graz.at, 2024).

Der politische Bezirk von Graz hat eine Nord-Süd-Ausdehnung von knapp 13.600 Metern sowie eine Ost-West-Ausdehnung von 14.000 Metern und wird in 17 Bezirke unterteilt. Die Bezirke sind in zwei Ringen um den ersten Bezirk, Innere Stadt, angeordnet.

Graz befindet sich am Ostrand der Alpen, im Grazer Becken. Die Stadt wird im Westen durch den Plabutsch (754m), im Norden durch die Hohe Rannach (1018m) sowie Platte (651m) und im Osten durch die Laßnitzhöhe und die anschließende Riedellandschaft begrenzt. Gegen Süden öffnet sich das Grazer Feld bis Wildon und führt dort als Leibnitzer Feld fort.

In Österreich zählt die Stadt Graz zu den Gemeinden mit dem höchsten Bevölkerungswachstum. Seit 2001 verzeichnet die Stadt ein starkes und kontinuierliches Wachstum der Einwohnerzahl (Abb. 11). Um auf diese Entwicklung zu reagieren, hat Graz in den vergangenen Jahren zahlreiche Infrastrukturprojekte initiiert. Diese umfassen Maßnahmen zur Schaffung von Wohnraum, die Erweiterung

der Mobilitätsinfrastruktur sowie die Förderung von Freizeitangeboten (Steiermark.at, 2024).




Abbildung 11: Bevölkerungswachstum der Gemeinde Graz von 2001 bis 2024. Hervorzuheben ist der signifikante Zuwachs der Einwohnerzahl, die von 226.244 im Jahr 2001 auf 302.749 im Jahr 2024 gestiegen ist (Statistik.at, 2023) (Statistik.at, 2024 a).

Graz ist aufgrund seiner dynamischen urbanen Entwicklung und seines hohen Bevölkerungswachstums ein ideales Projektgebiet. Die städtische Erweiterung sowie die zahlreichen Bau- und Infrastrukturprojekte der letzten Jahre haben zu einer signifikanten Zunahme versiegelter Flächen geführt. Dies bietet eine hervorragende Grundlage für eine Langzeitstudie zur Bodenversiegelung im städtischen Raum. Darüber hinaus eignet sich Graz aufgrund seiner geographischen Lage und der vielfältigen Landnutzungsformen – von dichten urbanen Bezirken bis hin zu ausgedehnten Grünflächen – besonders gut für eine differenzierte Analyse mittels Fernerkundungsdaten. Die verschiedenen topografischen und infrastrukturellen Veränderungen machen Graz zu einem besonders interessanten Fallbeispiel für die Evaluierung von Veränderungsdetektionsmethoden in urbanen Gebieten.

3.2 Evaluierung der Orthophotos

Als Grundlage für die Durchführung meines Forschungsvorhabens dienen fünf Orthophotos des politischen Bezirkes Graz. Sie wurden von der Abteilung 17 - Landes und Regionalentwicklung - des Landes Steiermark zur Verfügung gestellt. Es handelt sich hierbei um verzerrungsfreie und maßstabsgetreue Darstellungen der Erdoberfläche, die flächendeckend für das gesamte österreichische Bundesgebiet verfügbar sind.

Im Gegensatz zu herkömmlichen Luftbildern weisen Orthophotos theoretisch keine Verzerrungen oder Verschiebungen auf. Solche Fehler entstehen üblicherweise durch die fotografische Zentralprojektion sowie durch Höhenunterschiede im Gelände. Mithilfe eines digitalen Geländemodells können diese Unregelmäßigkeiten korrigiert werden, sodass ein flächen- und winkeltreues Orthophoto entsteht. Dennoch kann es bei hohen Gebäuden oder in Bereichen, die durch die Perspektive nicht vollständig erfasst werden, zu unscharfen Bildabschnitten oder sogenannten Kippeffekten kommen. Die erreichbare Genauigkeit hängt von der Dichte der Daten im digitalen Geländehöhenmodell ab. Im flachen Gelände kann eine Präzision von 0,5 bis 1 Meter erreicht werden, während in hügeligem Gelände eine Genauigkeit von 1 bis 2 Metern möglich ist. In gebirgigen Regionen liegt die Genauigkeit hingegen bei 2 bis 5 Metern. (Bev.gv.at, o.A.).

Die Orthophotos wurden in Blattschnitten mit einer Ausdehnung von 1 km mal 1,25 km im GeoTIFF-Format geliefert und haben eine durchschnittliche Auflösung von 20 cm pro Pixel. Neben den Farbkanälen Rot, Grün und Blau (RGB) enthält das Bildmaterial auch einen Infrarotkanal. Dieser ermöglicht Anwendungen wie die Berechnung des Normalized Difference Vegetation Index (NDVI) oder die Erstellung von Falschfarbenbildern. Obwohl solche abgeleiteten Orthophotodaten theoretisch klassifiziert und zum Training für einen Deep-Learning-Algorithmus genutzt werden könnte, wurde in dieser Masterarbeit darauf verzichtet.

Die nachfolgende Tabelle (Tab. 2) enthält die detaillierten Metadaten der in dieser Masterarbeit verwendeten Orthophotos. Sie umfasst Informationen zur Flugperiode, dem verantwortlichen Unternehmen, dem Aufnahmedatum, der eingesetzten Kamera, der geometrischen Auflösung, der Flughöhe (AMSL) sowie die Längs- und Querüberlappungen.

Das gesamte Gebiet des politischen Bezirks Graz erstreckt sich über 132 der oben beschriebenen Blattschnitte. Nach Erhalt der Daten wurden die einzelnen Blattschnitte mithilfe eines geographischen Informationssystems zusammengefügt. Aus dem Gesamtdatensatz aller steirischen Bezirksgrenzen der Abteilung 17 des Landes Steiermark musste in einem ersten Schritt die Grenze des politischen Bezirks Graz extrahiert werden (Data.gv.at, 2025). Anhand dieser extrahierten Grenze wurden die fünf Raster-Datensätze mithilfe der extrahierten Bezirksgrenze zugeschnitten, die in der Analyse Verwendung fanden (Abb. 12).

Tabelle 2: Beschreibung der Metadaten zu den fünf verwendeten Orthophotos. Eigener Entwurf (Kiesling 21.10.20024) (Kiesling 13.12.2024) (Steiermark.at, o.A.).

Flugperiode	Erzeuger	Datum	Kamera (SN)	Auflösung	Flughöhe	Längs- /Querüberlappung
2019-2021	ARGE Angst. Primis	09.05.2021 bis 11.05.2021	Vexcel UltraCam Eagle Mark 3	20,0 cm	5.300 m AMSL	80/75 %
2016-2018	ARGE Angst. Primis	05.08.2018 bis 13.08.2018	Vexcel UltraCam Xp	20,0 cm	3.600 m AMSL	80/45 %
2013-2015	FMM GmbH	12.05.2015	Vexcel UltraCam Eagle 1	20,0 cm	5.000 m AMSL	80/40 %
2011-2013	Astec GmbH/ OPEGIEKA	16.06.2012	DCM II 230	20,0 cm	3.600 m AMSL	80/40 %
2008-2011	FMM GmbH	18.06.2009 bis 14.07.2009	Vexcel UltraCam X	20,0 cm	3.000 m AMSL	80/40 %



Abbildung 12: Orthophoto des politischen Bezirks Graz aus dem Jahr 2021 nachdem die einzelnen Blattschnitte zusammengefügt und der Zuschnitt auf die Bezirksgrenzen durchgeführt wurde. Es wurde jedoch noch kein Minimum-Maximum-Streckung durchgeführt. Eigener Entwurf.

Um ein möglichst genaues Ergebnis der Klassifikationen zu gewährleisten, wurde in einem letzten Schritt der Vorbereitung der Daten eine Minimum-Maximum-Streckung durchgeführt. Dieser Streckungstyp führt eine lineare Anpassung der Pixelwerte durch, basierend auf den minimalen und maximalen Helligkeitswerten des Ausgabe-Histogramms. Dabei dienen die kleinsten und größten Werte der Daten als Grenzen für die Verteilung. In einem 8-Bit-Datensatz könnten diese Grenzen beispielsweise bei 37 und 224 liegen. Die lineare Streckung passt die Werte so an, dass sie den gesamten Bereich von 0 bis 255 ausschöpfen. Dadurch werden die Details im Bild deutlicher sichtbar, da die Helligkeitswerte gleichmäßig über den gesamten Wertebereich verteilt werden. Das Ergebnis ist ein Bild mit höherem Kontrast und mehr Helligkeit, wodurch Bildmerkmale besser hervortreten (Abb. 13) (Al-amri ,2011).




Abbildung 13: Beispiel einer Minimum-Maximum-Streckung. Links das ursprüngliche Orthophoto und auf der rechten Seite das Bild mit der Streckung. Der Helligkeitsunterschied ist deutlich zu erkennen und die einzelnen Details des Bildes wesentlich besser zu deuten (Pro.arcgis.com, o.A.f).

3.3 Verwendete Software

Für die Klassifizierung des politischen Bezirks Graz sind mehrere spezialisierte Softwarelösungen erforderlich. Einerseits wird eine GIS-Software (Geographisches Informationssystem) benötigt, um die Klassifikationsergebnisse visuell darzustellen und grundlegende Werkzeuge zum Einsatz bringen zu können, um die Rasterdaten auf die Grenzen des Testgebietes zu beschneiden. Auf dem Markt existieren verschiedene GIS-Anwendungen mit unterschiedlichen Lizenzmodellen.

Ein führender Anbieter in diesem Bereich ist Esri mit seiner proprietären Software ArcGIS Pro. Dieses Programm setzt auf ein kostenpflichtiges Lizenzmodell (Esri.com, o.A.). Im Gegensatz dazu steht Quantum GIS (QGIS), eine verbreitete Open-Source-Alternative. Während QGIS kostenfrei erhältlich ist, bietet es keinen offiziellen

Kundensupport und verfügt über einen geringeren Umfang an Basisfunktionen als ArcGIS Pro (Qgis.org, o.A.).

Zusätzlich wurde für die Masterarbeit eine Software benötigt, die Rasterdaten mittels überwachter, unüberwachter und Deep-Learning-Klassifikationen analysieren kann. Auch hier kommen GIS-Lösungen wie ArcGIS Pro und QGIS infrage, die jeweils besondere Vorteile bieten: ArcGIS Pro bietet integrierte Klassifikationswerkzeuge. Eine entsprechende Funktion in der Grundversion von QGIS, jedoch kann QGIS mit entsprechenden Add-ons genutzt werden, um Rasterdaten zu klassifizieren (Qgis.org, o.A.).

Darüber hinaus ist es für die Erstellung der Ground-Truth-Daten erforderlich, eine Möglichkeit, Deep-Learning-Modelle zu entwickeln, bzw. solche zu trainieren. Dies erfordert eine geeignete Umgebung zur Modellierung neuronaler Netze.

Eine Option zur Erstellung und Anwendung von Deep-Learning-Modellen ist ERDAS IMAGINE, eine spezialisierte Fernerkundungssoftware. Sie bietet nicht nur Werkzeuge zur Entwicklung und zum Training von Deep-Learning-Modellen, sondern ermöglicht auch die Durchführung von überwachten und unüberwachten Klassifikationen. Ähnlich wie ArcGIS Pro von Esri basiert ERDAS IMAGINE auf einem kostenpflichtigen Lizenzmodell (Hexagon.com, o.A.).

Für ArcGIS Pro besteht die Möglichkeit, kostenlose Deep-Learning-Bibliotheken herunterzuladen und zu installieren. Diese Bibliotheken ermöglichen es, die in ArcGIS Pro integrierten Deep-Learning-Tools zu nutzen. Dadurch können Anwender direkt innerhalb der Software eigene Modelle erstellen, trainieren und für die Bildklassifikation einsetzen (Github.com, o.A.).

Tabelle 3: Softwareevaluierung zur Durchführung der Masterarbeit (Esri.com, o.A.; Qgis.org, o.A.; Hexagon.com, o.A.; Github.com, o.A.)

Software Wahlkriterien	QGIS	ArcGIS Pro	ERDAS IMAGINE
	✓	✓	✗
	✓	✓	✓
	✓	✓	✓
	✗	✓	✓
	✗	✓	✓

Da ArcGIS Pro über die Universität Wien zu geringen Kosten bezogen werden kann, bot sich eine All-in-One-Lösung an. Nicht nur umfasst die Software zahlreiche GIS-Werkzeuge zur Darstellung und spezialisierte Fernerkundungstools zur Klassifikation, sondern auch die Möglichkeit, Deep-Learning-Tools zu nutzen, ohne dass dies mit Zusatzkosten verbunden wäre (Tab. 3).

ArcGIS Pro bietet die Grundstruktur zur Bearbeitung von raster- und vektorbasierten Geodaten. Käuflich können lizenzierte Erweiterungen genutzt werden, die getrennt vom Hauptprodukt zusätzliche Analysemöglichkeiten erlauben (Pro.Arcgis.com, o.A. e).

Für die Bearbeitung und Durchführung der Klassifikation der Orthophotos von Graz waren zwei Zusatzlizenzen von besonderer Bedeutung:

- Image Analyst

Mit der Erweiterung "ArcGIS Image Analyst" werden Werkzeuge zur Verfügung gestellt, um Bilddaten zu visualisieren, zu vermessen und zu analysieren. Nutzer erhalten 3D-Feature-Daten mit speziellen Funktionen zur Stereodarstellung und Kartenerstellung, zur Bearbeitung von Schrägluftbildern direkt im Bildraum und die es ermöglichen Bildklassifizierungen durchzuführen. Außerdem lassen sich Bilddaten mit vielfältigen Bildbearbeitungswerkzeugen und -funktionen analysieren (Pro.Arcgis.com, o.A. b).

- Spatial Analyst

Mit der Erweiterung "ArcGIS Spatial Analyst" stehen Werkzeuge zur Verfügung, um Raster-Daten zu erstellen und zu analysieren sowie kombinierte Analysen von Raster- und Vektordaten durchzuführen. So lassen sich Oberflächenparameter wie Hangneigung und Ausrichtung aus digitalen Höhenmodellen ableiten, Standorteignungsmodelle mittels gewichteter Überlagerungsanalysen erstellen und komplexe Landschaftsanalysen durchführen. Dazu zählen beispielsweise das Ermitteln der kostengünstigsten Route oder das Modellieren von Flussverläufen, Materialkonzentrationen und Materialverteilungen auf einer Oberfläche (Pro.Arcgis.com, o.A. b).

Zusammenfassend lässt sich sagen, dass ArcGIS Pro sich hervorragend für die Bewältigung der Aufgabenstellung eignet. Die Software bietet in einem einzigen Programm eine umfassende Palette von Werkzeugen, die für die Bearbeitung

erforderlich sind. Darüber hinaus steht ein zuverlässiger Kundensupport zur Verfügung, der bei Fragen und Herausforderungen hilfreich zur Seite steht. Diese Kombination aus Funktionalität und Unterstützung macht ArcGIS Pro zu einer idealen Wahl für die Durchführung und Bearbeitung der Fragestellung dieser Masterarbeit.

3.4 Verwendete Algorithmen

In diesem Kapitel werden die Algorithmen vorgestellt, die zur Klassifizierung der vorliegenden Orthophotos eingesetzt wurden. Klassifikationsalgorithmen spielen eine zentrale Rolle bei der Auswertung und Interpretation von Fernerkundungsdaten. Sie ermöglichen es unter anderem, Muster und Strukturen innerhalb der Daten zu erkennen und diese in spezifische Klassen einzuteilen. Im Folgenden werden die in dieser Masterarbeit genutzten Methoden beschrieben und ihre Funktionsweise erläutert.

3.4.1 Grunddaten (Deep Learning, U-Net)

Um die Hauptfragestellung dieser Masterarbeit bearbeiten zu können, ist es nötig einen möglichst genauen Ground-Truth-Layer zu erstellen an dem die Klassifikationsergebnisse der pixel- und objektbasierten Klassifikationen verglichen werden können.

Der Ausdruck Ground-Truth ist in der Geomatik weit verbreitet und beschreibt eine idealerweise fehlerfreie und absolut präzise Darstellung eines bestimmten Aspekts der realen Welt wie etwa der Bodenbedeckung. In der Praxis sind Datensätze jedoch selten perfekt, sodass ein gewisser Fehleranteil unvermeidlich ist. Daher ziehen es viele Forschende vor, anstelle von „Ground Truth“ Begriffe wie „Grunddaten“ oder „Referenzdaten“ zu verwenden (Foody, 2024).

Für die Erstellung möglichst genauer Grunddaten wurde der U-Net Algorithmus gewählt, der zu den Deep-Learning-Algorithmen (Kap. 2.1.4) zählt. U-Net gehört zu den semantischen Segmentierungen, bei der jedes einzelne Pixel des Datensatzes bestimmt und einer Klasse zugeordnet wird.

Der U-Net-Algorithmus wurde ursprünglich für die biomedizinische Bildsegmentierung erfunden und eingesetzt. Seine Architektur lässt sich im Großen und Ganzen als ein Encoder-Netzwerk, gefolgt von einem Decoder-Netzwerk beschreiben. Dieser semantische Segmentierungsansatz unterscheidet Merkmale auf Pixelebene. Zu dem besitzt er einen Mechanismus, der die in den verschiedenen Phasen des Encoders

erlernten Unterscheidungsmerkmale auf den Pixelraum überträgt (Ronneberger et al., 2015).

Der Encoder ist die erste Hälfte des Verlaufdiagramms. Dabei handelt es sich in der Regel um einen vortrainierten Klassifizierungsalgorithmus, bei dem Faltungsblöcke, gefolgt von einem Maxpool-Downsampling angewendet werden, um das Eingangsbild in Merkmalsdarstellungen auf mehreren verschiedenen Ebenen zu kodieren. Der Decoder ist die zweite Hälfte dieses Modells. Ziel ist die semantische Projektion der vom Encoder gelernten Unterscheidungsmerkmale (niedrigere Auflösung) auf den Pixelraum (höhere Auflösung), um eine dichte Klassifizierung zu erhalten. Der Decoder besteht aus Upsampling und Verkettung, gefolgt von regulären Faltungsoperationen (Abb. 14) (Developers.arcgis.com, o.A.).




Abbildung 14: Beispiel einer U-Netz-Architektur. Jeder blaue Kasten entspricht einer mehrkanaligen Merkmalskarte. Weiße Kästchen stellen kopierte Merkmalskarten dar. Die Pfeile kennzeichnen die verschiedenen Operationen (Ronneberger et al., 2015).

Upsampling ist ein wichtiger Bestandteil vieler CNN-Architekturen für Bildsegmentierung, unterscheidet sich jedoch von den Techniken, die typischerweise in der Bildklassifikation verwendet werden. Das grundlegende Ziel besteht darin, die komprimierten Merkmalskarten wieder auf die ursprüngliche Größe des Eingabedatensatzes zu bringen. Dies geschieht durch eine Erweiterung der Merkmalsdimensionen. Upsampling wird auch als Transposed Convolution, Upconvolution oder Deconvolution bezeichnet (Developers.arcgis.com, o.A.).

Ein zentrales Konzept in der U-Net-Architektur ist, dass die hochaufgelösten Merkmalskarten aus dem Encoder-Pfad mit den hochgesampelten Merkmalskarten im Decoder kombiniert werden. Diese Verknüpfung, die in U-Net durch sogenannte Skip Connections realisiert wird, hilft dem Modell, präzisere Repräsentationen für die nachfolgenden Faltungen zu lernen. In der Visualisierung lassen sich diese Verbindungen an den grauen und grünen Pfeilen erkennen. Da Upsampling eine lückenhafte Operation ist, benötigt das Modell zusätzliche Informationen aus früheren Netzwerkstufen, um die Position und Struktur der Objekte im Bild besser rekonstruieren zu können (Developers.arcgis.com, o.A.).

3.4.1.1 Durchführung der Klassifikation

Die Deep Learning Libraries für ArcGIS Pro bilden die Grundlage für die durchgeführte U-Net-Klassifikation. Sie ermöglichen die nahtlose Integration neuronaler Netzwerke in die bestehenden ArcGIS-Workflows und stellen Werkzeuge für das Training und die Verarbeitung von Rasterdaten bereit. Durch die Nutzung dieser Bibliotheken können Deep-Learning-Modelle trainiert und auf räumliche Daten angewendet werden, um genaue Segmentierungsergebnisse zu erzielen (Github.com, o.A.).

Für die Klassifikation wurden drei Klassen definiert: „Wasser“, „Vegetation“ und „Versiegelt“. Diese Klasseneinteilung wurde gewählt, um eine möglichst präzise und vergleichbare Bewertung der angewendeten Methoden zu ermöglichen. Durch die Reduzierung auf drei übergeordnete Klassen lassen sich Unterschiede in den Klassifikationsergebnissen klarer herausarbeiten, ohne dass seltene oder schwer unterscheidbare Klassen die Ergebnisse verfälschen.





Abbildung 15: Beispiele für Eingangsdaten zum Trainieren des Deep-Learning-Algorithmus. In der 1. Reihe Beispiele für die Klasse „Wasser“ und in der 2. Reihe Beispiele für die Klasse „Vegetation“. Die 3. Reihe zeigt Beispiel für die Klasse „Versiegelt“. Eigener Entwurf.

Um das U-Net trainieren zu können, müssen die Eingangsdaten zunächst vorbereitet werden. Da das Netzwerk auf einer überwachten Klassifizierung basiert, werden die Trainingsgebiete (Abb. 15) und Orthophotos mithilfe des Tools „Export Training Data for Deep Learning“ in kleine Kacheln unterteilt. Dabei werden sowohl das originale Orthophoto als auch die manuell erstellten Trainingsgebiete in Segmente mit dem Format „Classified Tiles“ von 256 x 256 Pixeln zugeschnitten. Die so erzeugten Bildausschnitte (Images) und dazugehörigen Objektmasken (Labels) dienen als Trainingsdaten für das Deep-Learning-Modell. Insgesamt stehen mehr als 3.000 Bilder und 5.000 Objekte als Eingangsdaten zur Verfügung.

Um versiegelte Flächen mit dem U-Net zu klassifizieren, muss das Modell trainiert und mehrfach durchlaufen werden. Dazu wurde das Tool „Train Deep Learning Model“

verwendet. Für das Training spielen zentrale Parameter wie die Anzahl der Epochen (epochs) und die Lernrate (learning rate) eine entscheidende Rolle.

Die Epochenanzahl bestimmt, wie oft das Netzwerk mit dem vollständigen Trainingsdatensatz trainiert wird. Eine Epoche ist abgeschlossen, sobald alle Trainingsdaten einmal durch das Netzwerk gelaufen sind. Mit steigender Anzahl an Epochen verbessert sich in der Regel die Genauigkeit der Klassifikation. Für das Training des Modells werden insgesamt 100 Epochen eingeplant, wobei der Prozess frühzeitig gestoppt wird, falls keine wesentlichen Verbesserungen mehr erzielt werden. Im Durchschnitt wurden 35 - 40 Epochen benötigt, um die einzelnen Modelle zu trainieren. Da der Trainingsprozess der Modelle mehrere Stunden in Anspruch nimmt, ist eine hohe Rechenleistung des Computers von entscheidender Bedeutung.




Abbildung 16: Vereinfachter Workflow für das Erstellen und Trainings eines Deep-Learning-Modells. Eigener Entwurf.

Nachdem das Modell trainiert wurde, wurde es für eine Klassifizierung eines Orthophotos angewendet. Das Ergebnis und die Genauigkeit der Klassifikation wurden dabei beurteilt und mögliche Fehler festgestellt. Bei Fehlklassifikationen und Ungenauigkeiten kann das bestehende Modell auch mit dem Tool „Train Deep Learning Model“ verbessert werden. Dabei müssen erneut Trainingsdaten für die Klassen erstellt werden, bei denen man Verbesserungen erreichen will. Anschließend wird im selben Erstellungsprozess ein neues Modell berechnet, wobei das

Vorgängermodell in die Berechnung miteinbezogen und mit den neuen Trainingsdaten verbessert wird (Abb. 16).

3.4.1.2 Genauigkeit der Modelle

Die durchschnittliche Genauigkeit der erstellten Deep-Learning-Modelle ist ein zentraler Indikator für die Leistungsfähigkeit der U-Net-Modelle. Sie gibt Aufschluss darüber, wie präzise die Modelle zwischen verschiedenen Klassen unterscheiden können und wie gut sie die einzelnen Pixel und Muster erkennen. Eine hohe Genauigkeit weist darauf hin, dass das Modell das zugrunde liegende Orthophoto zuverlässig analysieren konnte. Die Genauigkeiten der trainierten Modelle kann im Trainingsprotokoll der einzelnen Modelle eingesehen werden.

Die auf beschriebene Weise generierten Deep-Learning-Modelle weisen folgende durchschnittliche Genauigkeiten auf:

Tabelle 4: Klassifikationsgenauigkeiten der erstellten U-Net-Modelle. Eigener Entwurf.

Deep-Learning-Model für:	Genauigkeit (%)
Orthophoto 2021	82,6
Orthophoto 2018	81,9
Orthophoto 2015	80,8
Orthophoto 2012	86,4
Orthophoto 2009	83,6

Grundsätzlich sind Grunddatenmodelle niemals fehlerfrei und weisen Ungenauigkeiten auf (Foody, 2024). Bei durchgeführten Klassifikationsstudien wurde bei den Grunddaten eine durchschnittliche Genauigkeit von 82,4% als zufriedenstellende Referenz angesehen (Robinson et al., 2021). Diese Werte verdeutlichen, dass die in dieser Arbeit erstellten Deep-Learning-Klassifikationen (Abb. 17) mit durchschnittlichen Genauigkeiten zwischen 80,8 % und 86,4 % als ausreichend zuverlässig angesehen werden können. Anhand der erstellten Grundklassifikationen können die folgenden Klassifikationsarten miteinander verglichen werden.



Abbildung 17: Klassifikation des Orthophotos von 2012 mittels Deep-Learning-Modell. Eigener Entwurf.

3.4.2 Unüberwachte Klassifikation

3.4.2.1 ISO-Cluster (pixel- und objektbasiert, unüberwacht)

Für die unüberwachten pixel- als auch objektbasierten Klassifikationen wurde der ISO-Cluster Algorithmus gewählt, bei dem die Software selbstständig Klassen erstellt und diese anschließend durch den User zugeordnet werden.

Der ISO-Cluster-Algorithmus basiert auf einem iterativen Verfahren zur Minimierung der euklidischen Distanz bei der Zuweisung jedes Pixels zu einem Cluster. Zu Beginn werden Startmittelwerte für die Cluster von der Software festgelegt, wobei die Anzahl der Cluster jener der gewünschten Klassenzahl entspricht. Jede Zelle wird dann im mehrdimensionalen Attributraum dem nächstgelegenen Mittelwert zugeordnet

(Abb. 18). Anschließend werden die Mittelwerte basierend auf den Attributwerten der zugehörigen Zellen neu berechnet. Dieser Prozess wiederholt sich iterativ: Jede Zelle wird erneut dem nächstgelegenen Mittelwert zugewiesen, woraufhin die Clusterzentren unter Berücksichtigung der aktuellen Clusterzugehörigkeit aktualisiert werden (Pro.arcgis.com, o.A. c).




Abbildung 18: Veranschaulichung der iterativen Clusterbildung des ISO-Cluster-Algorithmus mit drei Klassen (Geol260.academic.wlu.edu, o.A.).

Die Anzahl der Iterationen wird im Klassifikationstool über „Maximal Number of Iterations“ festgelegt. Dieser Wert sollte ausreichend hoch sein, um sicherzustellen, dass die Zellmigration zwischen Clustern nach Abschluss der Iterationen minimal ist und alle Cluster stabil bleiben (Pro.arcgis.com, o.A. e).

„Maximal Number of Classes“ gibt die maximale Anzahl an Clustern an, die durch den Clustering-Prozess entstehen können. Die tatsächliche Anzahl der Cluster in der Ausgabesignaturdatei kann jedoch von diesem Wert abweichen, da bei einer zu großen Anzahl gewünschter Cluster die Software entscheidet, ob dies noch sinnvoll ist (Pro.arcgis.com, o.A. e).

Durchführung der Klassifikation

Für die Durchführung der unüberwachten Klassifikationen wurde vom vordefinierten Klassifikationsschema, das im Kapitel 3.4.1.1 beschrieben wurde, abgewichen. Aufgrund der Ungenauigkeit der unüberwachten Klassifikation wurden die Klassen auf zwei reduziert („Vegetation“ und „Versiegelt“). Um eine möglichst genaue Klassifikation

durchführen zu können wurde die Klasse „Wasser“ mit der Klasse „Vegetation“ zusammengefasst (Jensen, 2005).

Für die Clusterbildung wurden spezifische Parameter festgelegt, um eine effiziente Klassifikation zu gewährleisten. Die einzelnen Parameter wurden sowohl für die pixel- als auch für die objektbasierte Klassifizierung wie folgt festgelegt:

Tabelle 5: Parameter der unüberwachten Klassifikation unter Nutzung der ISO-Cluster-Methode.

Parametername	Beschreibung
Maximum Number of Classes	Die maximale Anzahl an Klassen für die Gruppierung von Pixeln oder Segmenten. Dieser Wert sollte entsprechend der Klassenzahl in der Legende festgelegt werden. Für die durchgeführte Klassifikation wurden zwei Klassen definiert.
Maximum Number of Iterations	Die Höchstzahl an Iterationen für den Clustering-Prozess. Beim Klassifikationsprozess wurden 20 Iterationen durchgeführt.
Maximum Number of Cluster Merges per Iteration	Die Obergrenze für die Anzahl der zulässigen Cluster-Merges. Pro Iteration wurde eine maximal fünf Cluster miteinander gemerged.
Maximum Merge Distance	Eine größere Entfernung ermöglicht die Zusammenführung weiterer Cluster und reduziert somit die Anzahl der Klassen, während ein niedrigerer Wert zu mehr Klassen führt. Die Distanz wird spektral bestimmt und basiert auf der RGB-Farbe. Für die Klassifikationen wurde ein Wert von 0,5 gewählt.
Minimum Samples Per Cluster	Die geringste Anzahl an Pixeln oder Segmenten, die erforderlich ist, damit ein Cluster oder eine Klasse Gültigkeit erhält.

	Ein Wert von 20 hat sich bei den Klassifikationen als ein guter Wert herausgestellt, um einen „Salz- und Pfeffereffekt“ zu vermeiden.
Skip Factor	Gibt an wie viele Pixel bei der Klassifizierung übersprungen werden. Je höher der Skipfaktor definiert wird, desto geringer ist die Laufzeit der Klassifizierung. Bei der Klassifizierung der verwendeten, hochauflösenden Orthophotos wurde dieser Faktor mit zehn definiert.

3.4.3 Überwachte Klassifikation

3.4.3.1 Trainingsdaten

Die Trainingsgebiete bilden die Basis für die überwachte Klassifizierung. Alle in dieser Arbeit verwendeten überwachten Klassifikationen basieren auf diesen Trainingsdaten, wodurch der Ersteller die Klassifizierung direkt beeinflussen kann. Dabei sollten die Trainingsgebiete möglichst gleichmäßig über das gesamte Untersuchungsgebiet verteilt sein. Der Anwender muss sicherstellen, dass innerhalb eines definierten Trainingsgebiets möglichst homogene Pixel für dieselbe Klasse ausgewählt werden.

Die Qualität der überwachten Klassifizierung wird maßgeblich von der Anzahl und der Verteilung der definierten Trainingsgebiete beeinflusst. Eine sorgfältige und repräsentative Auswahl dieser Gebiete verbessert die Erkennungsgenauigkeit der jeweiligen Klassen (Wang und Li, 2019). Die Genauigkeit der Klassifizierung hängt somit sowohl von der Qualität, als auch von der Anzahl der Trainingsstichproben ab (Lu et al., 2011).

Tabelle 6: Auflistung der Anzahl der verwendeten Trainingsgebiete der einzelnen Klassen sowie deren prozentualer Anteil an der Gesamtfläche der Orthophotos.

Klassen	Anzahl der Testgebiete	Prozent der Gesamtfläche
Wasser	70 - 90	1,7% - 1,9%
Vegetation	350 - 500	8,6% - 10,4%
Versiegelt	360 - 480	3,2% - 3,8%

Als Richtwert für die Trainingsdaten gilt, dass sie mindestens 0,25 % der Gesamtfläche abdecken sollten. Dieser Wert wird in den vordefinierten Testgebietsdatensets für die einzelnen Orthophotos eingehalten (Tab. 6).

Es wurden insgesamt fünf Testgebietsdatensets erstellt. Ein Datenset pro klassifiziertem Orthophoto. Die gleichen Testgebiete wurden jeweils für die pixel- und objektbasierte Klassifikation herangezogen.

3.4.3.2 Random Trees (pixelbasiert, überwacht)

Die Random-Trees-Klassifizierungsmethode basiert auf einer Sammlung einzelner Entscheidungsbäume, die jeweils aus unterschiedlichen Stichproben und Teilmengen der Trainingsdaten erstellt werden. Der Grundgedanke hinter Entscheidungsbäumen ist, dass für jedes zu klassifizierende Pixel eine Reihe von Entscheidungen getroffen und nach ihrer Wichtigkeit geordnet werden.




Abbildung 19: Diagramm eines Random Tree Klassifikationsprozesses (Abdulla et al., 2023).

Grafisch dargestellt, ähnelt dies einem Zweig, und die Gesamtstruktur für den gesamten Datensatz bildet einen Baum. Die Methode wird als „Zufallsbaum“ bezeichnet, weil die Daten durch zufällige Unterstichproben der Trainingspixel mehrfach klassifiziert werden, was zur Entstehung vieler Entscheidungsbäume führt. Jeder Baum gibt eine „Stimme“ ab, und die endgültige Entscheidung wird durch die Mehrheitswahl der Bäume getroffen. Dies hilft, Überanpassung zu vermeiden. Random Trees ist ein überwachtes Machine-Learning-Verfahren, das eine Vielzahl von Entscheidungsbäumen erstellt, bei denen für jeden Baum zufällige Teilmengen

von Variablen ausgewählt werden. Die Gesamtklassifikation basiert auf der häufigsten Ausgabe dieser Bäume (Abb. 19) (Pro.arcgis.com, o.A. d).

Diese Methode reduziert die Neigung von Entscheidungsbäumen, sich zu stark an die Trainingsdaten anzupassen. Eine Gruppe von Bäumen wird erzeugt, wobei die Variation zwischen den Bäumen durch die zufällige Projektion der Trainingsdaten in Unterräume entsteht, bevor jeder Baum angepasst wird. Die Entscheidungen an jedem Knoten werden durch ein randomisiertes Verfahren optimiert (Liaw und Wiener, 2002).

Durchführung der Klassifikation

Für die überwachte, pixelbasierte Klassifikation wurde der Algorithmus der Random-Trees genutzt. Für die Durchführung dieser überwachten Klassifikation war es nötig Testgebiete vorzubereiten, mit denen der Algorithmus lernen konnte, welche Pixel wie klassifiziert werden sollten. Die Erstellung und Beschreibung der verwendeten Testgebiete werden im Kapitel 3.4.3.1 behandelt.

Um eine möglichst genaue Klassifizierung durchzuführen wurden die speziellen Parameter des Random-Trees-Algorithmus angepasst und werden im Folgenden beschrieben.

Tabelle 7: Parameter der überwachten Klassifikation unter Nutzung der Random-Trees-Methode.

Parametername	Beschreibung
Training Samples	Einfügen der vordefinierten Trainingsgebietdatei. Die Trainingsgebiete können entweder als Shapefile oder als Feature-Class abgespeichert sein. An dieser Stelle wurden die vorbereiteten Testgebiete eingefügt (Kap. 3.4.2.1).
Maximum Number of Trees	Die maximale Anzahl an Bäumen im Modell. Eine Erhöhung der Baumanzahl kann die Genauigkeit steigern, jedoch nimmt der Zugewinn mit zunehmender Anzahl allmählich ab. Die Anzahl der zu erstellenden Bäume pro Klassifikation wurde auf 50 gesetzt.

Maximum Tree Depth	Die maximale Tiefe jedes Baums im Modell. Die Tiefe gibt an wie viele Regeln ein Baum erstellen darf, um eine Entscheidung zu treffen. Pro Baum wurden maximal 30 Regeln erstellt, um eine Klassifikation durchzuführen.
Maximum Number of Samples per Class	Die maximale Anzahl an Stichproben, die zur Definition jeder Klasse verwendet werden. Um alle erstellten Testgebiete in die Klassifikation miteinzubeziehen, wurde die Nummer der maximal einbezogenen Testgebiete auf 500 gesetzt.

3.4.3.3 Supported Vector Machines (objektbasiert, überwacht)

Supported Vector Machines, kurz SVM, ist ein mathematisch komplexes und rechenintensives Verfahren aus dem Teilbereich des maschinellen Lernens (Suthaharan, 2016).

In der Fernerkundung wird dieser Algorithmus zur Analyse der Landbedeckung und Landnutzung eingesetzt. SVM hat sich in der Vergangenheit als effiziente Methode bewährt, sowohl für komplexe Landschaftsstrukturen als auch für unterschiedliche räumliche Auflösungen. Dieses statistische Verfahren ermöglicht eine präzise Klassifizierung selbst bei anspruchsvollen Datensätzen (Mohamed et al., 2015).

SVM-Algorithmen sind in der Lage, sowohl lineare als auch nichtlineare Zusammenhänge in einem separaten Lernprozess zu erfassen. Durch wiederholtes Training und die Anwendung des erworbenen Wissens zählt man diesen Algorithmus zu den überwachten Klassifikationen (Üreyen und Thiel, 2017).

Bachofer et al. (2009) bezeichnen diesen Algorithmus als äußerst robust. Selbst bei begrenzter Verfügbarkeit von Trainingsdaten lassen sich hohe Genauigkeiten erzielen. Die Trennfläche zwischen den Klassen wird dabei mithilfe von Kernel-Funktionen definiert (Abb. 20).




Abbildung 20: Trennung von zwei Klassen mittels SVM-Algorithmus. Der Algorithmus setzt die Trennlinie (Hyperplane) nach dem Training so, dass sie die zwei Klassen maximal voneinander trennt (Lang, o.A).

Durchführung der Klassifikation

Für die überwachte, objektbasierte Klassifikation wurde der Algorithmus Support Vector Machines eingesetzt. Dazu war es erforderlich, Testgebiete vorzubereiten, die als Trainingsgrundlage für den Algorithmus dienten. Um die überwachten Klassifikationen bestmöglich vergleichen zu können, wurden für die überwachten Klassifikationen der einzelnen Orthophotos die gleichen Trainingsdaten genutzt.

Um die Supported Vector Machine Klassifizierung durchzuführen wurden folgende Parameter bestimmt:

Tabelle 8: Parameter der überwachten Klassifikation unter Nutzung der Supported Vector Machine Methode.

Parametername	Beschreibung
Training Samples	Einfügen der vordefinierten Trainingsgebietdatei. Die Trainingsgebiete können entweder als Shapefile oder als Feature-Class abgespeichert sein. An dieser Stelle wurden die vorbereiteten Testgebiete eingefügt (Kap. 3.4.2.1).

Maximum Number of Samples per Class	Die maximale Anzahl an Trainingsdaten, die pro Klasse verwendet wird. Um alle erstellten Trainingsdaten in die Klassifizierung miteinzubeziehen, wurde dieser Wert auf 500 gesetzt.
-------------------------------------	--

3.5 Genauigkeitsanalyse

Die Genauigkeitsbewertung (Accuracy Assessment) ist ein zentraler Bestandteil zur Validierung eines Klassifikationsmodells. Sie ermöglicht, zu beurteilen wie zuverlässig einzelne oder alle Klassen des Klassifikationsmodells bestimmte Objekte korrekt zuordnen. Das klassische Kontrollverfahren in der Fernerkundung ist hierfür die Konfusionsmatrix. In dieser werden in den Spalten die tatsächlich vorhandenen Klassen erfasst, während in den Zeilen die vom Modell vorhergesagten Klassenzuweisungen enthalten. So lassen sich richtige und falsche Klassifikationen gegenüberstellen (Congalton, 1991).

Zur Bewertung der Klassifikationsgenauigkeit wurde eine Genauigkeitsanalyse durchgeführt. Diese erfolgte mithilfe der ArcGIS Pro-Tools „Create Accuracy Assessment Points“, „Update Accuracy Assessment Points“ und „Compute Confusion Matrix“.

Um die Genauigkeit der Klassifikationen zu bewerten, müssen zwei Parameter festgelegt werden. Die „Number of Random Points“ und die „Sampling Strategy“. Der Parameter „Number of Random Points“ gibt die Gesamtzahl der zu generierenden Zufallspunkte an. Die tatsächliche Zahl kann diese Anzahl überschreiten, aber nicht unterschreiten, abhängig von der Sampling Strategy und der Anzahl der Klassen. Aufgrund der Größe des Projektgebietes wurde die Anzahl der Punkte auf 5000 gesetzt. Die Anzahl der Punkte stellt sicher, dass die Klassifikationsgenauigkeit präzise bestimmt wird (Pro.arcgis.com, o.A. a).

Als Sampling Strategy wurde „Stratified Random“ genutzt. Diese Strategie erstellt Punkte, die zufällig innerhalb jeder Klasse verteilt sind, wobei jede Klasse eine Anzahl an Punkten entsprechend ihrer relativen Fläche erhält. Diese Methode verteilt die Punkte so über das Klassifikationsergebnis, dass die Anzahl der Stichprobenpunkte pro Klasse im Verhältnis zur Fläche der jeweiligen Klasse der Klassifikation steht (Pro.arcgis.com, o.A. a).

Die Punkte werden anhand der Ergebnisse der Grunddaten, die durch den Deep-Learning-Algorithmus generiert wurden, erstellt. Da fünf Grunddatensätze generiert wurden – je einer pro Orthophoto, wurde dieser Schritt insgesamt fünf Mal durchgeführt.

Jedem erstellten Punkt wird bei der Erstellung ein Attribut zugeteilt, das die Klasse widerspiegelt, auf der er platziert wurde. Durch das Tool „Update Accuracy Assessment“ wird zusätzlich die zu vergleichende Klassifikation ausgewählt. Anschließend wird ein neues Attribut zugeteilt, entsprechend den Klassen der Klassifikation, mit der die Grunddaten verglichen werden.

Folgend wird das Tool „Compute Confusion Matrix“ angewendet. Dieses Werkzeug erstellt eine Konfusionsmatrix basierend auf den vergebenen Attributen der vorherigen Schritte.

3.5.1 Konfusionsmatrix

Durch das Ausführen des Tools „Compute Confusion Matrix“ wird eine grafische Darstellung der Konfusionsmatrix erstellt. Diese zeigt die Anzahl der Kontrollpunkte, die „User's accuracy“ und die „Producer's accuracy“ der Klassifikation an.

Aus der Konfusionsmatrix lassen sich weiters verschiedene Kennzahlen zur Bewertung der Klassifikationsgenauigkeit ableiten (Tab. 9). Die wichtigste ist die Gesamtgenauigkeit, die das Verhältnis korrekt klassifizierter Kontrollpunkte zur Gesamtanzahl der Kontrollpunkte angibt. Sie wird berechnet, indem die Summe der Werte entlang der Hauptdiagonale, welche die korrekt klassifizierten Kontrollpunkte repräsentiert, durch die Gesamtzahl aller Kontrollpunkte geteilt wird (Congalton, 1991).

Tabelle 9: Beispiel einer Konfusionsmatrix. Gesamtgenauigkeit in Gelb, Präzision der Klassen in Blau und der Kappa-Koeffizient in Grün. Eigener Entwurf.

	Klasse 1	Klasse 2	Klasse 3	Total	U_Accuracy	Kappa
Klasse 1	98	8	8	114	0,8594	0
Klasse 2	4	80	4	88	0,9091	0
Klasse 3	6	6	118	130	0,9077	0
Total	108	94	110	332	0	0
P_Accuracy	0,9074	0,8511	0,9077	0	0,8916	0
Kappa	0	0	0	0	0	0,8357

Der Kappa-Koeffizient ist ein zusätzlicher statistischer Kennwert zur Bewertung der Qualität eines Klassifikationsergebnisses (Tab. 9). Er misst, inwieweit die Klassifikation über den Zufall hinausgeht und ob die Übereinstimmung mit den Referenzdaten

statistisch signifikant ist (Congalton, 1991). Der Wert des Kappa-Koeffizienten liegt zwischen 0 und 1 (Pro.arcgis.com, o.A. a), wobei ein Wert nahe 0 darauf hindeutet, dass die Klassifikation mit den Referenzdaten nicht, bis wenig korreliert, während ein Wert nahe 1 darauf hinweist, dass eine starke Korrelation besteht (Congalton, 1991).

Die Präzision ist eine weitere klassenbezogene Kennzahl (Tab. 9). Sie gibt an, welcher Anteil der vom Modell vorhergesagten Klassifikationen tatsächlich der wahren Klasse entspricht. Zur Berechnung wird die Anzahl der korrekt klassifizierten Fälle durch die Gesamtzahl der vom Modell für diese Klasse vorhergesagten Kontrollpunkte geteilt (Powers, 2008). Man unterscheidet dabei zwischen der Benutzergenauigkeit und der Produzentengenauigkeit.

In der Spalte zur Benutzergenauigkeit (U-Accuracy) werden falsch-positive Ergebnisse, auch als Commission-Fehler bekannt, dargestellt. Diese treten auf, wenn Pixel fälschlicherweise einer bestimmten Klasse zugeordnet werden, obwohl sie eigentlich einer anderen Klasse hätten zugewiesen werden sollen. Die Benutzergenauigkeit wird auch als Fehler vom Typ 1 bezeichnet. Zur Berechnung dieser Fehlerrate werden die Daten aus den Zeilen der Tabelle entnommen. Sie ergibt sich aus dem Verhältnis der korrekt klassifizierten Punkte zu der Gesamtanzahl der klassifizierten Punkte dieser Klasse. Die Zeile "Total" gibt an wie viele Punkte gemäß der Referenzdaten tatsächlich dieser Klasse hätten zugeordnet werden müssen. Ein Beispiel hierfür wäre, wenn ein klassifiziertes Bild ein Pixel als „Versiegelt“ identifiziert, während die Referenzdaten es als „Vegetation“ ausweist. In diesem Fall enthält die Versiegelt-Klasse zusätzliche Pixel, die laut Referenzdaten dort nicht vorkommen sollten (Pro.arcgis.com, o.A. a).

Die Spalte zur Produzentengenauigkeit (P-Accuracy) zeigt hingegen falsch-negative Ergebnisse, auch als Auslassungsfehler bezeichnet. Sie gibt an wie genau die Klassifikation mit den Referenzdaten übereinstimmt und wird als Fehler vom Typ 2 bezeichnet. Zur Berechnung dieser Fehlerrate werden die Daten aus den Spalten der Tabelle genutzt. Die Produzentengenauigkeit berechnet sich aus dem Verhältnis der korrekt klassifizierten Punkte zur Gesamtanzahl der Referenzpunkte einer Klasse. Falsch-negative Werte treten auf, wenn die Klassifikation eine bestimmte Klasse nicht ausreichend erfasst. Die Zeile "Total" gibt an wie viele Punkte entsprechend der klassifizierten Karte einer bestimmten Klasse zugeordnet wurden. Ein Beispiel hierfür wäre, wenn die Referenzdaten ein Pixel als „Versiegelt“ angibt, das klassifizierte Bild

es jedoch als „Vegetation“ identifiziert. In diesem Fall fehlen der Versiegelt-Klasse Pixel, die laut Referenzdaten dort vorhanden sein sollten (Pro.arcgis.com, o.A. a).

4 Ergebnisse

In diesem Kapitel werden die Ergebnisse der durchgeführten Klassifikationen basierend auf den erstellten Grunddatensätzen für den politischen Bezirk Graz beschrieben. Dabei werden die Ergebnisse für die fünf analysierten Orthophotos aus den Jahren 2009, 2012, 2015, 2018 und 2021 betrachtet.

Im Folgenden werden zunächst die erstellten Deep-Learning-Grunddatensätze beschrieben, bevor die Ergebnisse der Klassifikationen vorgestellt und verglichen werden. Abschließend erfolgt eine Interpretation der Genauigkeitsanalyse sowie eine Zusammenfassung der zentralen Erkenntnisse.

4.1 Ergebnisse der Deep Learning Grunddatensätze

Die Bewertungsgenauigkeiten der Deep-Learning-Methode basierend auf der U-Net-Architektur wurden bereits in Kapitel 3.4.1.2 beschrieben. Dort wurden die einzelnen Verarbeitungsschritte, die Modellparameter sowie die durchschnittliche Modellgenauigkeit (Tab. 4) detailliert erläutert. Im Folgenden wird nun auf die Analyse und Bewertung dieser Ergebnisse im Kontext der durchgeführten Klassifikationen eingegangen.

Die Ergebnisse der U-Net-Klassifikation können insgesamt als größtenteils genau betrachtet werden, da das Modell die wesentlichen Strukturen und Muster der analysierten Klassen zuverlässig erkennt. Allerdings führt der pixelbasierte Ansatz dazu, dass benachbarte Objekte nicht immer präzise voneinander getrennt werden und es zu „Überlappungen“ kommt (Abb. 21). Zudem zeigt sich ein gewisser Salz-und-Pfeffer-Effekt, bei dem vereinzelte Fehlklassifikationen als isolierte Pixel auftreten (Abb. 22).

Die Ungenauigkeiten der U-Net-Klassifikation wirken sich auf den weiteren Vergleich der Klassifikationen aus, da fehlerhafte Objektbegrenzungen und der Salz-und-Pfeffer-Effekt die Genauigkeitsanalyse beeinflussen können. Dennoch müssen diese Ungenauigkeiten in Kauf genommen werden, da die erstellten Grunddaten eine essentielle Grundlage für den Vergleich der überwachten und unüberwachten Klassifikationsmethoden bilden. Trotz der Einschränkungen ermöglichen sie eine konsistente und objektive Vergleichsbasis der Klassifikationsergebnisse.




Abbildung 21: Ergebnis der Deep-Learning-Klassifikation am Beispiel des Murkraftwerks Weinzödl aus dem Jahr 2018. Feinstrukturierte Objekte wie der Staudamm und deren Stützwände werden erkannt, aber nur grob klassifiziert. Eigener Entwurf.



Abbildung 22: Ergebnis der Deep-Learning-Klassifikation am Beispiel des Zentralfriedhofs Graz aus dem Jahr 2012. Die feinstrukturierte Oberflächenbedeckung der Gräber, wird einheitlich als Vegetation klassifiziert. Eigener Entwurf.

4.2 Ergebnisse der pixel- und objektbasierten Klassifikationen

Im folgenden Kapitel werden die Klassifikationsergebnisse der pixel- und objektbasierten sowie unüberwachten und überwachten Klassifikationen vorgestellt. Um die Vergleiche der Klassifikationsergebnisse gut vergleichen zu können, werden diese anhand des aktuellen Orthophotos aus dem Jahr 2021 dargestellt und beschrieben.

4.2.1 Pixelbasiert, unüberwacht (ISO-Cluster)

Die pixelbasierte, unüberwachte Klassifikation erbrachte die besten Ergebnisse, wenn anstelle von drei, nur zwei Klassen klassifiziert wurden (Kap. 3.4.2.1). Sobald jedoch eine Klassifikation mit drei oder mehr Klassen durchgeführt wurde, nahm die Genauigkeit merklich ab. Die Ergebnisse wurden unübersichtlicher, und eine visuelle

Kontrolle zeigte, dass die Klassifizierung in vielen Bereichen ungenauer war. Dies deutet darauf hin, dass die ISO-Cluster-Methode Schwierigkeiten hatte, zusätzliche Klassen präzise zu trennen, was zu einer erhöhten Variabilität und Fehlklassifikationen führte.

In diesem Fall konnten die Flächen größtenteils korrekt identifiziert werden, wobei die Klassifizierung versiegelter Flächen für Probleme sorgte. Besonders auffällig ist dies an den Dächern der Gebäude zu erkennen. Die durch die Sonne beschienene Dachseite wird der versiegelten Klasse und die beschattete Seite der Vegetationsklasse zugeordnet (Abb. 23).



Abbildung 23: Ergebnis der pixelbasierten, unüberwachten Klassifikation der Grazer Innenstadt mit entsprechendem Orthophoto. Von Westen nach Osten: Mariahilferplatz, Murinsel, Schlossbergplatz, Schlossberg mit Uhrturm und Karmeliterplatz. Eigener Entwurf.

4.2.2 Objektbasiert, unüberwacht (ISO-Cluster)

Ähnlich wie die pixelbasierte, unüberwachte Klassifikation, konnten auch mit der objektbasierten, unüberwachten Klassifikation die besten Ergebnisse erbracht werden, indem das Orthophoto nur mit zwei Klassen klassifiziert wurde. Wie bereits für die

pixelbasierte, unüberwachte Klassifikation nahmen die Genauigkeiten mit zunehmender Klassenanzahl drastisch ab.

Die objektbasierte, unüberwachte Methode hat ähnliche Schwierigkeiten wie die pixelbasierte, unüberwachte Klassifikation. Aufgrund der Segmentierung, die noch vor der Klassifikation durchgeführt wird (Kap. 2.1.3.2) werden Cluster von Pixel gebildet, die eine ähnliche spektrale Signatur besitzen. Durch diesen Prozess werden versiegelte Flächen ausgeprägter klassifiziert als bei der pixelbasierten, unüberwachten Klassifikationen (Abb. 24).




Abbildung 24: Ergebnis der objektbasierten, unüberwachten Klassifikation der Grazer Innenstadt mit entsprechendem Orthophoto. Eigener Entwurf.

4.2.3 Pixelbasiert, überwacht (Random Trees)

Die pixelbasierte, überwachte Klassifikation mithilfe des Random Tree Algorithmus erbrachte durch das Training der Testgebiete gute Ergebnisse. Aufgrund des Trainings konnten die drei Klassen Wasser, Vegetation und versiegelte Flächen weitgehendst voneinander unterschieden werden.

Bei der Klassifikation des Wassers kommt es jedoch zu Fehlklassifikationen. Reflektierende Flächen wie beispielsweise Glas (Murinsel), aber auch Schattenflächen (Schlagschatten der Gebäude) werden aufgrund ihrer spektralen Signatur fälschlicherweise als Wasser klassifiziert. Diese Fehlklassifikationen entstehen, weil die Klassifikation ausschließlich auf den spektralen Eigenschaften einzelner Pixel basiert, ohne dabei den räumlichen Kontext zu berücksichtigen

Ein weiteres Problem ist der Salz-und-Pfeffer-Effekt, der durch diese Fehlklassifikationen verstärkt wird. Dabei entstehen viele Fehlklassifikationen einzelner Pixel, die zu einer unruhigen, verrauschten Bildklassifikation führen (Abb. 25).




Abbildung 25: Ergebnis der pixelbasierten, überwachten Klassifikation der Grazer Innenstadt mit entsprechendem Orthophoto. Eigener Entwurf.

4.2.4 Objektbasiert, überwacht (Supported Vector Machines)

Durch das Training mit den vorerstellten Testgebieten klassifizierte die objektbasierte, überwachte Klassifikation mithilfe der Supported Vector Machines beim visuellen Vergleich gute und flächenhafte Ergebnisse. Durch das Training der Testdaten wurden

die drei Klassen Wasser, Vegetation und versiegelte Flächen klar voneinander unterschieden.

Auffallend ist im Vergleich mit der pixelbasierten, überwachten Klassifikation das Ausbleiben des Salz-und-Pfeffer-Effektes, der bereits bei den visuellen Ergebnissen der objektbasierten, unüberwachten Klassifikation beschrieben wurde.

Trotz der guten Ergebnisse kommt es auch bei dieser Klassifikation zu Fehlklassifikationen. Auch hier werden reflektierende Oberflächen falsch klassifiziert wie an der Murinsel, aber auch am Kirchturmdach der Mariahilfer Kirche zu sehen ist, die anstelle von versiegelter Fläche als Wasser erkannt werden. Weiters können auch Fehlklassifikationen im Bereich der Murofer erkannt werden. Hier wurden durch die Segmentierung der Pixel, Flächen der Klasse Wasser zugeordnet, die eigentlich der Klasse Vegetation zugeordnet werden müssten (Abb. 26).




Abbildung 26: Ergebnis der objektbasierten, überwachten Klassifikation der Grazer Innenstadt mit entsprechendem Orthophoto. Eigener Entwurf.

4.3 Ergebnisse der Genauigkeitsanalyse

Im folgenden Kapitel werden die Ergebnisse der Genauigkeitsanalyse für die vier durchgeführten Klassifikationen erläutert. Pro Klassifikationsart werden dabei die fünf entstandenen Konfusionsmatrizen beschrieben.

4.3.1 Pixelbasiert, unüberwacht (ISO-Cluster)

Aufgrund der visuellen Beurteilung für die höchste Genauigkeit wurde bei der Klassifizierung der pixelbasierten, unüberwachten Methode mittels ISO-Cluster, nur zwei Klassen spezifiziert (Kap. 3.4.2.1).

Durch die Genauigkeitsanalyse konnte für die Klassifizierungen der Orthophotos von 2009 bis 2021 Werte für die Gesamtgenauigkeit zwischen 0,7572 (2021) und 0,8598 (2018) erzielt werden (Abb. 27 und Tab. 10).




Abbildung 27: Gesamtgenauigkeit für die pixelbasierten, unüberwachten Klassifikationen von 2009 bis 2021. Eigener Entwurf.

Für die Klasse „Vegetation“ wurde bei den fünf Klassifikationen Benutzergenauigkeiten (U_Accuracy) von 0,716476 (2021) und 0,918838 (2012) sowie Produzentengenauigkeiten (P_Accuracy) von 0,848217 (2012) und 0,945488 (2018) erreicht (Tab. 10).

Bei der Klasse „Versiegelt“ konnten für die Benutzergenauigkeit Werte zwischen 0,669476 (2012) und 0,867354 (2018) sowie 0,544559 (2021) und 0,804049 (2012) für die Produzentengenauigkeit gemessen werden (Tab. 10).

Tabelle 10: Konfusionsmatrizen für die pixelbasierten, unüberwachten Klassifikationen von 2009 bis 2021. Eigener Entwurf.

Pixelbasiert, Unüberwacht - 2009					
	Vegetation	Versiegelt	Total	U_Accuracy	Kappa
Vegetation	3093	534	3627	0,852771	0
Versiegelt	288	1085	1373	0,79024	0
Total	3381	1619	5000	0	0
P_Accuracy	0,914818	0,670167	0	0,8356	0
Kappa	0	0	0	0	0,609101

Pixelbasiert, Unüberwacht - 2012					
	Vegetation	Versiegelt	Total	U_Accuracy	Kappa
Vegetation	3068	271	3339	0,918838	0
Versiegelt	549	1112	1661	0,669476	0
Total	3617	1383	5000	0	0
P_Accuracy	0,848217	0,804049	0	0,836	0
Kappa	0	0	0	0	0,614142

Pixelbasiert, Unüberwacht - 2015					
	Vegetation	Versiegelt	Total	U_Accuracy	Kappa
Vegetation	2642	813	3455	0,764689	0
Versiegelt	304	1241	1545	0,803236	0
Total	2946	2054	5000	0	0
P_Accuracy	0,896809	0,604187	0	0,7766	0
Kappa	0	0	0	0	0,520524

Pixelbasiert, Unüberwacht - 2018					
	Vegetation	Versiegelt	Total	U_Accuracy	Kappa
Vegetation	3122	521	3643	0,856986	0
Versiegelt	180	1177	1357	0,867354	0
Total	3302	1698	5000	0	0
P_Accuracy	0,945488	0,693168	0	0,8598	0
Kappa	0	0	0	0	0,671405

Pixelbasiert, Unüberwacht - 2021					
	Vegetation	Versiegelt	Total	U_Accuracy	Kappa
Vegetation	2570	1017	3587	0,716476	0
Versiegelt	197	1216	1413	0,86058	0
Total	2767	2233	5000	0	0
P_Accuracy	0,928804	0,544559	0	0,7572	0
Kappa	0	0	0	0	0,490752

Für den Kappa-Koeffizienten, der Auskunft gibt, ob eine Übereinstimmung mit den Referenzdaten statistisch gesehen gegeben ist wurden Werte zwischen 0,490752 (2021) und 0,671405 (2018) berechnet (Abb. 28 und Tab. 10).




Abbildung 28: Kappa-Koeffizient für die pixelbasierten, unüberwachten Klassifikationen von 2009 bis 2021. Eigener Entwurf.

4.3.2 Objektbasiert, unüberwacht (ISO-Cluster)

Wie bei der pixelbasierten, unüberwachten Klassifikation beschrieben, wurden bei der Klassifikation mit der objektbasierten, unüberwachten Methode mittels ISO-Cluster nur zwei Klassen spezifiziert (Kap. 3.4.2.1).

Die Genauigkeitsanalyse der Klassifikationen der Orthophotos von 2009 bis 2021 ergab Gesamtgenauigkeitswerte zwischen 0,7342 (2021) und 0,8436 (2009) (Abb. 28 und Tab. 11).




Abbildung 29: Gesamtgenauigkeit für die objektbasierten, unüberwachten Klassifikationen von 2009 bis 2021. Eigener Entwurf.

Für die Klasse „Vegetation“ wurden in den fünf Klassifikationen Benutzergenauigkeiten (U_Accuracy) zwischen 0,692349 (2021) und 0,844105 (2012) ermittelt. Die Produzentengenauigkeiten (P_Accuracy) erreichten Werte von 0,880855 (2012) bis 0,974864 (2018) (Tab. 11).

Für die Klasse „Versiegelt“ lagen die Benutzergenauigkeiten zwischen 0,776291 (2015) und 0,92155 (2018). Die Produzentengenauigkeiten variierten zwischen 0,484998 (2021) und 0,592989 (2015) (Tab. 11).

Tabelle 11: Konfusionsmatrizen für die objektbasierten, unüberwachten Klassifikationen von 2009 bis 2021. Eigener Entwurf.

Objektbasiert, Unüberwacht - 2009					
	Vegetation	Versiegelt	Total	U_Accuracy	Kappa
Vegetation	3258	659	3917	0,831759	0
Versiegelt	123	960	1083	0,886427	0
Total	3381	1619	5000	0	0
P_Accuracy	0,96362	0,592959	0	0,8436	0
Kappa	0	0	0	0	0,609127

Objektbasiert, Unüberwacht - 2012					
	Vegetation	Versiegelt	Total	U_Accuracy	Kappa
Vegetation	3422	632	4054	0,844105	0
Versiegelt	195	751	946	0,793869	0
Total	3617	1383	5000	0	0
P_Accuracy	0,946088	0,543022	0	0,8346	0
Kappa	0	0	0	0	0,541999

Objektbasiert, Unüberwacht - 2015					
	Vegetation	Versiegelt	Total	U_Accuracy	Kappa
Vegetation	2595	836	3431	0,756339	0
Versiegelt	351	1218	1569	0,776291	0
Total	2946	2054	5000	0	0
P_Accuracy	0,880855	0,592989	0	0,7626	0
Kappa	0	0	0	0	0,491411

Objektbasiert, Unüberwacht - 2018					
	Vegetation	Versiegelt	Total	U_Accuracy	Kappa
Vegetation	3219	723	3942	0,816591	0
Versiegelt	83	975	1058	0,92155	0
Total	3302	1698	5000	0	0
P_Accuracy	0,974864	0,574205	0	0,8388	0
Kappa	0	0	0	0	0,604399

Objektbasiert, Unüberwacht - 2021					
	Vegetation	Versiegelt	Total	U_Accuracy	Kappa
Vegetation	2588	1150	3738	0,692349	0
Versiegelt	179	1083	1262	0,858162	0
Total	2767	2233	5000	0	0
P_Accuracy	0,935309	0,484998	0	0,7342	0
Kappa	0	0	0	0	0,438715

Der Kappa-Koeffizient, der die statistische Übereinstimmung mit den Referenzdaten bewertet, zeigte Werte zwischen 0,438715 (2021) und 0,609127 (2009) (Abb. 30 und Tab. 11).




Abbildung 30: Kappa-Koeffizient für die objektbasierten, unüberwachten Klassifikationen von 2009 bis 2021. Eigener Entwurf.

4.3.3 Pixelbasiert, überwacht (Random Trees)

Die Genauigkeitsanalyse der pixelbasierten, überwachten Klassifikationen der Orthophotos von 2009 bis 2021, durchgeführt mit dem Random-Tree-Algorithmus, ergab Gesamtgenauigkeitswerte zwischen 0,7764 (2021) und 0,8512 (2012) (Abb. 31 und Tab. 12).




Abbildung 31: Gesamtgenauigkeit für die pixelbasierten, überwachten Klassifikationen von 2009 bis 2021. Eigener Entwurf.

Für die Klasse „Wasser“ zeigten die fünf Klassifikationen Benutzergenauigkeiten (U_Accuracy) zwischen 0,018303 (2009) und 0,06213 (2012), während die Produzentengenauigkeiten (P_Accuracy) Werte von 0,552623 (2012) bis 0,916667 (2009) erreichten (Tab. 12).

Die Klasse „Vegetation“ wies in den fünf Klassifikationen Benutzergenauigkeiten zwischen 0,793903 (2021) und 0,943936 (2012) auf. Die Produzentengenauigkeiten lagen hier zwischen 0,861977 (2009) und 0,911411 (2021) (Tab. 12).

Für die Klasse „Versiegelt“ variierten die Benutzergenauigkeiten zwischen 0,813826 (2012) und 0,927161 (2021), während die Produzentengenauigkeiten Werte zwischen 0,609942 (2021) und 0,749096 (2012) aufwiesen (Tab. 12).

Tabelle 12: Konfusionsmatrizen für die pixelbasierten, überwachten Klassifikationen von 2009 bis 2021. Eigener Entwurf.

	Pixelbasiert, Überwacht - 2009					
	Wasser	Vegetation	Versiegelt	Total	U_Accuracy	Kappa
Wasser	11	364	226	601	0,018303	0
Vegetation	0	2904	334	3238	0,89685	0
Versiegelt	1	101	1059	1161	0,912145	0
Total	12	3369	1619	5000	0	0
P_Accuracy	0,916667	0,861977	0,654107	0	0,7948	0
Kappa	0	0	0	0	0	0,579657

Pixelbasiert, Überwacht - 2012						
	Wasser	Vegetation	Versiegelt	Total	U_Accuracy	Kappa
Wasser	21	152	165	338	0,06213	0
Vegetation	8	3199	182	3389	0,943936	0
Versiegelt	9	228	1036	1273	0,813826	0
Total	38	3579	1383	5000	0	0
P_Accuracy	0,552632	0,893825	0,749096	0	0,8512	0
Kappa	0	0	0	0	0	0,664785

Pixelbasiert, Überwacht - 2015						
	Wasser	Vegetation	Versiegelt	Total	U_Accuracy	Kappa
Wasser	24	216	153	393	0,061069	0
Vegetation	7	2544	568	3119	0,815646	0
Versiegelt	3	152	1333	1488	0,895833	0
Total	34	2912	2054	5000	0	0
P_Accuracy	0,705882	0,873626	0,648978	0	0,7802	0
Kappa	0	0	0	0	0	0,572299

Pixelbasiert, Überwacht - 2018						
	Wasser	Vegetation	Versiegelt	Total	U_Accuracy	Kappa
Wasser	15	345	195	555	0,027027	0
Vegetation	2	2844	255	3101	0,917124	0
Versiegelt	0	96	1248	1344	0,928571	0
Total	17	3285	1698	5000	0	0
P_Accuracy	0,882353	0,865753	0,734982	0	0,8214	0
Kappa	0	0	0	0	0	0,643418

Pixelbasiert, Überwacht - 2021						
	Wasser	Vegetation	Versiegelt	Total	U_Accuracy	Kappa
Wasser	20	137	225	382	0,052356	0
Vegetation	3	2500	646	3149	0,793903	0
Versiegelt	1	106	1362	1469	0,927161	0
Total	24	2743	2233	5000	0	0
P_Accuracy	0,833333	0,911411	0,609942	0	0,7764	0
Kappa	0	0	0	0	0	0,572396

Der Kappa-Koeffizient, der die Übereinstimmung mit den Referenzdaten statistisch bewertet, lag zwischen 0,572299 (2015) und 0,664785 (2012) (Abb. 32 und Tab. 12).




Abbildung 32: Kappa-Koeffizient für die pixelbasierten, überwachten Klassifikationen von 2009 bis 2021. Eigener Entwurf.

4.3.4 Objektbasiert, überwacht (Supported Vector Machines)

Als letztes wird die Genauigkeitsanalyse der objektbasierten, überwachten Klassifikationen der Orthophotos von 2009 bis 2021 betrachtet. Diese wurde mithilfe des Supported Vector Machine Algorithmus durchgeführt und ergab Gesamtgenauigkeitswerte im Bereich von 0,8182 (2021) bis 0,91144 (2012) (Abb. 33 und Tab. 13).




Abbildung 33: Gesamtgenauigkeit für die objektbasierten, überwachten Klassifikationen von 2009 bis 2021. Eigener Entwurf.

In den fünf Klassifikationen der Klasse „Wasser“ lagen die Benutzergenauigkeiten (U_Accuracy) zwischen 0,045455 (2009) und 0,35 (2015), während die

Produzentengenauigkeiten (P_Accuracy) Werte von 0,166667 (2009) bis 0,583333 (2021) erreichten (Tab. 13).

Die Klasse „Vegetation“ zeigte Benutzergenauigkeiten im Bereich von 0,777876 (2021) bis 0,939277 (2012), während die Produzentengenauigkeiten zwischen 0,947945 (2018) und 0,975275 (2015) lagen (Tab. 13).

Für die Klasse „Versiegelt“ variierten die Benutzergenauigkeiten zwischen 0,873764 (2012) und 0,957204 (2015), während die Produzentengenauigkeiten Werte von 0,638603 (2021) bis 0,830803 (2012) erreichten (Tab. 13).

Tabelle 13: Konfusionsmatrizen für die objektbasierten, überwachten Klassifikationen von 2009 bis 2021. Eigener Entwurf.

Objektbasiert, Überwacht - 2009						
	Wasser	Vegetation	Versiegelt	Total	U_Accuracy	Kappa
Wasser	2	18	24	44	0,045455	0
Vegetation	8	3265	418	3691	0,884584	0
Versiegelt	2	86	1177	1265	0,930435	0
Total	12	3369	1619	5000	0	0
P_Accuracy	0,166667	0,96913	0,726992	0	0,8888	0
Kappa	0	0	0	0	0	0,735652

Objektbasiert, Überwacht - 2012						
	Wasser	Vegetation	Versiegelt	Total	U_Accuracy	Kappa
Wasser	20	15	27	62	0,322581	0
Vegetation	13	3403	207	3623	0,939277	0
Versiegelt	5	161	1149	1315	0,873764	0
Total	38	3579	1383	5000	0	0
P_Accuracy	0,526316	0,950824	0,830803	0	0,9144	0
Kappa	0	0	0	0	0	0,790448

Objektbasiert, Überwacht - 2015						
	Wasser	Vegetation	Versiegelt	Total	U_Accuracy	Kappa
Wasser	14	13	13	40	0,35	0
Vegetation	19	2840	699	3558	0,798201	0
Versiegelt	1	59	1342	1402	0,957204	0
Total	34	2912	2054	5000	0	0
P_Accuracy	0,411765	0,975275	0,653359	0	0,8392	0
Kappa	0	0	0	0	0	0,658106

Objektbasiert, Überwacht - 2018						
	Wasser	Vegetation	Versiegelt	Total	U_Accuracy	Kappa
Wasser	9	98	57	164	0,054878	0
Vegetation	4	3114	320	3438	0,905759	0
Versiegelt	4	73	1321	1398	0,944921	0
Total	17	3285	1698	5000	0	0
P_Accuracy	0,529412	0,947945	0,777974	0	0,8888	0
Kappa	0	0	0	0	0	0,754625

Objektbasiert, Überwacht - 2021						
	Wasser	Vegetation	Versiegelt	Total	U_Accuracy	Kappa
Wasser	14	19	60	93	0,150538	0
Vegetation	10	2651	747	3408	0,777876	0
Versiegelt	0	73	1426	1499	0,951301	0
Total	24	2743	2233	5000	0	0
P_Accuracy	0,583333	0,96646	0,638603	0	0,8182	0
Kappa	0	0	0	0	0	0,630559

Der Kappa-Koeffizient, der zur statistischen Bewertung der Übereinstimmung mit den Referenzdaten verwendet wird, zeigte Werte zwischen 0,630559 im Jahr 2021 und 0,790448 im Jahr 2012 (Abb. 34 und Tab. 13).




Abbildung 34: Kappa-Koeffizient für die objektbasierten, überwachten Klassifikationen von 2009 bis 2021. Eigener Entwurf.

4.3.5 Zusammenfassung der Ergebnisse

In diesem abschließenden Kapitel werden die Ergebnisse der vier Klassifikationsmethoden in Bezug auf zwei wesentliche Kennzahlen dargestellt: die Gesamtgenauigkeit und der Kappa-Koeffizient. Diese Kennzahlen geben Auskunft über die Leistung der Klassifikationsmethoden und ermöglichen einen direkten Vergleich ihrer Klassifikationseffektivität. Die Diagramme visualisieren die Werte über

die fünf verwendeten Orthophotos und verdeutlichen die Ergebnisse der Konfusionsmatrizen der letzten Unterkapitel.

Abbildung 35 zeigt die Gesamtgenauigkeit der vier Klassifikationsmethoden im Vergleich. Die Gesamtgenauigkeit ist das Verhältnis der korrekt klassifizierten Kontrollpunkte zur Gesamtanzahl der Kontrollpunkt. Höhere Werte in diesem Diagramm signalisieren eine bessere Leistung der Klassifikationen. Die Darstellung ermöglicht es, die Gesamtgenauigkeit für die Klassifikationsmethoden auf einen Blick zu erfassen.




Abbildung 35: Gesamtgenauigkeit für die pixel- und objektbasierten sowie unüberwachten und überwachten Klassifikationen von 2009 bis 2021 im Vergleich. Eigener Entwurf.

In Abbildung 36 kann der Kappa-Koeffizienten für jede der vier Klassifikationsmethoden und der durchgeführten Klassifikationen verglichen werden. Der Kappa-Koeffizient misst die statistische Korrelation zwischen den Klassifikationsergebnissen und den Referenzdaten, wobei er die Wahrscheinlichkeit einer zufälligen

Übereinstimmung berücksichtigt. Höhere Kappa-Werte deuten auf eine bessere Übereinstimmung hin.




Abbildung 36: Kappa-Koeffizient für die pixel- und objektbasierten sowie unüberwachten und überwachten Klassifikationen von 2009 bis 2021 im Vergleich. Eigener Entwurf.

5 Diskussion und Interpretation der Ergebnisse

Im nachfolgenden Kapitel werden die Ergebnisse der Klassifikationen und der durchgeführten Genauigkeitsanalysen interpretiert und die in Kapitel 1.3 beschriebenen Forschungsfragen beantwortet.

Die zur Oberflächenklassifikation trainierten Deep-Learning-Modelle erzielten insgesamt hohe Genauigkeiten, wobei die Gesamtgenauigkeit je nach Orthophoto zwischen 80,8 % und 86,4 % lag. Der höchste Wert wurde für das Orthophoto von 2012 (86,4 %) erreicht, während die niedrigste Genauigkeit für das Jahr 2015 (80,8 %) erreicht wurde. Die Modelle differenzierten zwischen den Klassen Wasser, Vegetation und versiegelten Flächen.

Die Deep-Learning-Modelle sind jedoch nicht fehlerfrei. Klassifikationsfehler und Ungenauigkeiten in den Grunddaten werden bei der Evaluierung der Klassifikationsmethoden automatisch miteinbezogen und beeinflussen die Genauigkeitsanalyse. Da jedoch kein alternativer Grunddatensatz zur Verfügung stand, an dem die Ergebnisse der Klassifikationsmethoden überprüft werden können, müssen diese Ungenauigkeiten in Kauf genommen werden. Dennoch bieten die erzeugten Klassifikationen eine solide Grundlage für den Vergleich und Evaluierung der benutzten Klassifikationsmethoden.

Da das Untersuchungsgebiet den gesamten politischen Bezirk Graz umfasst, mussten großflächige, heterogene Landbedeckungen erfasst werden. Die Befliegungen, die zur Aufnahme der Orthophotos durchgeführt wurden dauerten mehrere Stunden oder in manchen Fällen mehrere Tage, wodurch Unterschiede in den spektralen Eigenschaften einzelner Objekte entstanden. Dies resultierte aus variierenden Lichtverhältnissen und Einfallswinkeln, atmosphärischen Bedingungen und Änderungen im Oberflächenzustand während der Aufnahmezeiträume.

Um dem Problem der unterschiedlichen radiometrischen Auflösungen durch die Mosaikierung der Orthophotos entgegenzuwirken, wurde bei der Erstellung der Trainingsdaten darauf geachtet, dass die Testgebiete gleichmäßig über die Rasterdatensätze verteilt wurden. Durch diese gleichmäßige Verteilung sollte sichergestellt werden, dass die Modelle nicht nur lokal spezifische Muster erkennen, sondern eine umfangreiche Klassifikation über das gesamte Untersuchungsgebiet möglich ist.

Im Anschluss an die Erstellung der Grunddaten mittels Deep-Learning-Klassifikation wurden die Orthophotos mit pixel- und objektbasierten Methoden klassifiziert, wobei sowohl überwachte als auch unüberwachte Ansätze angewendet wurden. Bei den ersten Klassifikationen, die mit der pixelbasierten, unüberwachten Methode (ISO-Cluster) durchgeführt wurden, zeigte sich, dass die genauesten Ergebnisse bei einer Klassifikation mit nur zwei Klassen (Vegetation und versiegelte Flächen) erzielt werden konnten. Ein ähnliches Ergebnis wurde auch bei der objektbasierten, unüberwachten Methode mittels ISO-Cluster beobachtet. Aufgrund dieser ersten, visuellen Beurteilung wurde entschieden bei der Validierung ebenfalls nur zwei Klassen zu verwenden. Hierfür wurden die Grunddaten entsprechend umklassifiziert, um die Vergleichbarkeit der Ergebnisse zu gewährleisten.

Die Reduzierung der Klassenanzahl von drei auf zwei führt dazu, dass die Klassifikationsgenauigkeit der unüberwachten Methoden im Vergleich zu den überwachten Klassifikationen mit drei Klassen höher ausfällt. Dies ist darauf zurückzuführen, dass weniger Klassen zu einer geringeren Verwechslungsrate zwischen den Klassen führen und somit die Präzision verbessert wird. Trotz dieser methodischen Unterschiede werden beim Vergleich der Klassifikationsergebnisse alle Klassifikationsmethoden gemeinsam betrachtet. Dadurch wird eine umfassende Bewertung der verschiedenen Ansätze ermöglicht.

Die pixelbasierte, unüberwachte Klassifikation (ISO-Cluster) zeigt eine Gesamtgenauigkeit zwischen 0,7572 im Jahr 2021 und 0,8598 im Jahr 2018. Der Kappa-Koeffizient, der die statistische Übereinstimmung mit den Referenzdaten bewertet, erreicht Werte zwischen 0,490752 im Jahr 2021 und 0,671405 im Jahr 2018, was auf eine mittelmäßige statistische Übereinstimmung mit den Orthophotos hinweist. Die Klasse "Vegetation" zeigt hohe Präzisionswerte in der Produzentengenauigkeit mit bis zu 0,945488 im Jahr 2018 und moderate bis hohe Werte in der Benutzergenauigkeit zwischen 0,716476 und 0,918838. Die Klasse "Versiegelt" weist dagegen schwankende Genauigkeitswerte auf, mit einer besonders niedrigen Produzentengenauigkeit von 0,544559 im Jahr 2021 (Tab. 10).

Die objektbasierte, unüberwachte Klassifikation (ISO-Cluster) zeigt eine Gesamtgenauigkeit zwischen 0,7342 im Jahr 2021 und 0,8436 im Jahr 2009. Auch hier zeigt sich eine deutliche Schwäche im Jahr 2021. Der Kappa-Koeffizient variiert zwischen 0,438715 im Jahr 2021 und 0,609127 im Jahr 2009, was mit den

Ergebnissen der pixelbasierten Methode vergleichbar ist. Die "Vegetation"-Klasse erreicht hohe Produzentengenauigkeiten bis 0,974864 im Jahr 2018, jedoch etwas niedrigere Benutzergenauigkeiten als die pixelbasierte Methode. Für "Versiegelt" sind die Produzentengenauigkeiten insgesamt geringer als bei der pixelbasierten Klassifikation mit maximal 0,592989 im Jahr 2015, die Benutzergenauigkeit ist hingegen höher und erreicht bis zu 0,92155 im Jahr 2018 (Tab. 11).

Die pixelbasierte, überwachte Klassifikation (Random Trees) zeigt eine höhere Gesamtgenauigkeit als die unüberwachten Methoden, mit Werten zwischen 0,7764 im Jahr 2021 und 0,8512 im Jahr 2012. Der Kappa-Koeffizient reicht von 0,572299 im Jahr 2015 bis 0,664785 im Jahr 2012, was eine größere Übereinstimmung mit den Referenzdaten bestimmt. Die "Vegetation"-Klasse zeigt durchgehend hohe Genauigkeitswerte, wobei die Benutzergenauigkeit bis 0,943936 im Jahr 2012 und die Produzentengenauigkeit bis 0,911411 im Jahr 2021 erreicht. Die "Versiegelt"-Klasse erzielt ebenfalls hohe Werte mit einer Benutzergenauigkeit bis 0,927161 im Jahr 2021, aber mit schwankenden Produzentengenauigkeiten zwischen 0,609942 im Jahr 2021 und 0,749096 im Jahr 2012. Auffällig ist, dass die "Wasser"-Klasse sehr niedrige Benutzergenauigkeiten aufweist mit maximal 0,06213 im Jahr 2012, während die Produzentengenauigkeiten stark variieren (Tab. 12).

Die objektbasierte, überwachte Klassifikation (Support Vector Machines) liefert die besten Gesamtgenauigkeitswerte, mit einem Minimum von 0,8182 im Jahr 2021 und einem Maximum von 0,9144 im Jahr 2012. Der Kappa-Koeffizient liegt zwischen 0,630559 im Jahr 2021 und 0,790448 im Jahr 2012, was auf eine gute Übereinstimmung mit den Referenzdaten hinweist. Die "Vegetation"-Klasse zeigt durchgehend hohe Werte in der Produzentengenauigkeit mit bis zu 0,975275 im Jahr 2015 und in der Benutzergenauigkeit mit bis zu 0,939277 im Jahr 2012. Die "Versiegelt"-Klasse erreicht die höchsten Benutzergenauigkeiten aller Methoden mit bis zu 0,957204 im Jahr 2015 und ebenfalls hohe Produzentengenauigkeiten. Die "Wasser"-Klasse hingegen bleibt auch hier problematisch, mit sehr niedrigen Benutzergenauigkeiten, die maximal 0,35 im Jahr 2015 erreichen (Tab. 13).

Die Ergebnisse zeigen, dass überwachte Methoden insgesamt bessere Klassifikationsergebnisse liefern als unüberwachte Methoden. Besonders die objektbasierte Klassifikation mit Support Vector Machines erzielt die besten Gesamtgenauigkeits- und Präzisionswerte. Allerdings bleibt die Klassifikation der

Wasserflächen in allen Methoden ein Problem. Dies führt zu der Frage, warum Schwierigkeiten bei der Trennung von Wasser und anderen Landbedeckungen auftreten.

Die fehlerhafte Klassifikation der Wasserflächen lässt sich auf mehrere Faktoren zurückführen. Zum einen sind die Grunddaten nicht fehlerfrei und der U-Net-Algorithmus analysiert und klassifiziert jedes Pixel einzeln. Ähnlich wie bei den pixelbasierten Klassifikationsmethoden kommt es in einem geringeren Ausmaß zu einem Salz-und-Pfeffer-Effekt. Durch die zufällige Verteilung der Kontrollpunkte pro Klasse werden eben diese auch als Wasser klassifiziert und in der Evaluierung der anderen Methoden als Fehlklassifikation erkannt. Zum anderen wurden die Kontrollpunkte so verteilt, dass jede Klasse proportional zur Fläche eine bestimmte Anzahl an Punkten zugewiesen bekam, die anschließend normalverteilt wurden. Da die Wasserfläche im Verhältnis die kleinste Klasse darstellt, wurde ihr die geringste Anzahl an Kontrollpunkten zugeteilt. Dies führt dazu, dass jeder falsch zugeordnete Punkt das Gesamtergebnis stärker beeinflusst als bei den anderen Klassen.

Ein weiterer Faktor ist die temporale Auflösung. Beispielsweise kam es bei einer Befliegung des Projektgebietes zu einem Abbruch der Aufnahme. Bei der folgenden Befliegung hatte sich die Mur auf Grund des Schlechtwetters der vorangegangenen Tage bräunlich verfärbt und konnte in der im Zuge dieser Masterarbeit durchgeführten Klassifikation nur als Vegetation klassifiziert werden. Die Kombination dieser Faktoren trägt dazu bei, dass die Klassifikation von Wasser in der Genauigkeitsanalyse schlechter abschneidet.

Die erste Leitfrage befasst sich mit der Rolle verschiedener Parameter und Einstellungen und deren Einfluss auf die Genauigkeit der Klassifikationsmethoden. Bei der überwachten Klassifikation spielen Parameter wie die Anzahl und Qualität der Trainings- und Testdaten eine tragende Rolle. Die Genauigkeit der Klassifizierung wird durch sie maßgeblich beeinflusst. Wesentliche Einstellungen sind hierbei die Wahl des Klassifikationsalgorithmus, die Anzahl der Klassen sowie das Training mit relevanten Oberflächenmerkmalen. Bei der unüberwachten Klassifikation sind dagegen die Anzahl der Cluster und die Distanzmaße entscheidende Parameter. Hinsichtlich der Methodik beeinflussen pixelbasierte Ansätze primär spektrale Werte einzelner Pixel. Objektbasierte Klassifikationen hingegen nutzen zusätzliche Parameter wie

Segmentierungsgröße, Formmerkmale und Kontextinformationen, um die Klassenergebnisse zu verbessern.

Zur Identifizierung versiegelter Flächen anhand von Orthophotos wurde analysiert, welche Klassifikationsmethoden die besten Ergebnisse liefern. Die Evaluierung der verschiedenen Klassifikationsmethoden zeigt, dass die objektbasierte, überwachte Klassifikation mit Support Vector Machines die besten Ergebnisse bei der Klassifizierung versiegelter Flächen liefert. Unter den getesteten Methoden konnten mit dieser die höchsten Gesamtgenauigkeits-, Kappa- und Präzisionswerte erzielt werden.

Um die Unterschiede zwischen pixelbasierten und objektbasierten Klassifikationsmethoden zu bewerten, wurde ihre Genauigkeit bei der Klassifikation systematisch verglichen. Die Ergebnisse der Evaluierung zeigen, dass die objektbasierte, überwachte Klassifikation mit den Support Vector Machines die höchste Gesamtgenauigkeit erreichte. Durch die Berücksichtigung zusammenhängender Objektstrukturen konnte mithilfe der SVM eine präzise Klassenzuordnung erreicht werden. Die pixelbasierte, überwachte Klassifikation mit dem Random Trees Algorithmus folgt dem SVM Algorithmus. Aufgrund der Schwächen bei der Trennung der Klassen, bilden die pixel- und objektbasierte, unüberwachten Klassifikationen das Schlusslicht in betracht ihrer Gesamtgenauigkeiten. Diese Ergebnisse verdeutlichen die Vorteile überwachter Verfahren und die Bedeutung objektbasierter Ansätze für eine präzise Bildklassifikation.

Wäre die Evaluierung anhand eines kleineren Testgebietes durchgeführt worden, hätten bessere Ergebnisse bei den Klassifikationen erzielt werden können. Ein kleineres Gebiet würde zudem die Möglichkeit bieten, einen präzisen Referenzdatensatz mithilfe eines GIS zu erstellen und die Deep-Learning-Klassifikation mit diesem zu vergleichen. Darüber hinaus würde ein kleineres Gebiet die Abweichungen in Bezug auf die spektrale Auflösung und die Mosaikierung minimieren. Das umfangreiche Projektgebiet ist jedoch wertvoll, um zu analysieren wie die Klassifikationen bei einer hohen räumlichen Auflösung und einer großen zu klassifizierenden Fläche reagiert.

6 Zusammenfassung

Da für den politischen Bezirk Graz kein validierter Grunddatensatz vorlag, mussten zunächst Referenzdaten erstellt werden, um die Ergebnisse der durchgeführten Klassifikationen vergleichen zu können. Die entwickelten Deep-Learning-Modelle zeigten hohe Genauigkeiten, waren jedoch nicht fehlerfrei, was sich auch auf die Ergebnisse der Genauigkeitsanalyse auswirkte.

Die Evaluierung der überwachten und unüberwachten Klassifikationsmethoden zeigte, dass überwachte Verfahren sowohl in der Klassen- als auch in der Gesamtgenauigkeit sowie im Kappa-Koeffizienten den unüberwachten Methoden überlegen sind (Abb. 34 und 35). Zudem konnten Unterschiede zwischen pixel- und objektbasierten, überwachten Klassifikationen festgestellt werden. Die pixelbasierte, überwachte Klassifikation mit dem Random-Trees-Algorithmus erreichte über fünf Klassifikationen hinweg Gesamtgenauigkeiten von 0,7764 bis 0,8512 sowie Kappa-Werte zwischen 0,5723 und 0,6648 (Tab. 12). Im Vergleich dazu erzielte die objektbasierte, überwachte Klassifikation mit Support Vector Machines Gesamtgenauigkeiten zwischen 0,8182 und 0,9114 sowie Kappa-Werte von 0,6306 bis 0,7904 (Tab. 13). Die Ergebnisse der Genauigkeitsbewertung stimmen mit den Erkenntnissen von García et al. überein.

Hinsichtlich der Klassengenauigkeiten konnten bei allen Klassifikationsmethoden hohe Werte erzielt werden, wobei die objektbasierte, überwachte Klassifikation die besten Ergebnisse lieferte. Auffällig waren jedoch die geringen Klassengenauigkeiten der Klasse „Wasser“. Mögliche Ursachen dafür sind Ungenauigkeiten in den erstellten Grunddaten, enthaltene Fehlklassifikationen sowie die gewählte Verteilungsstrategie der Kontrollpunkte in der Genauigkeitsanalyse.

Für zukünftige Evaluierungen von Klassifikationsmethoden könnte ein kleineres Testgebiet vorteilhaft sein. Es würde präzisere Referenzdaten ermöglichen, spektrale Abweichungen minimieren und eine Vergleichbarkeit mit Deep-Learning-Methoden ermöglichen. Dennoch bleibt ein großes Untersuchungsgebiet wertvoll, um die Leistung der Klassifikationen bei hoher Auflösung und großflächiger Anwendung zu analysieren.

7 Einsatz generativer KI-Tools

Für das Verfassen dieser Masterarbeit wurde ChatGPT eingesetzt, um die Formulierungen stilistisch, grammatikalisch und orthografisch zu optimieren. Zur Erstellung einer ersten englischen Fassung des Abstracts auf Basis des von mir verfassten deutschen Textes, habe ich DeepL verwendet.

8 Quellen

- Abdulla, A.; Baryannis, G.; Badi, I. (2023): An integrated machine learning and MARCOS method for supplier evaluation and selection. In: Decision Analytics Journal 9, S. 11.
- Abu-Hashim, M.S.D. (2011): Impact of land-use and land-management on the water infiltration capacity of soils on a catchment scale. Quedlinburg: Julius-Kühn-Inst., Bundesforschungsinst. für Kulturpflanzen, S. 170.
- Adli, M.; Schöndorf, J. (2020): Macht uns die Stadt krank? Wirkung von Stadtstress auf Emotionen, Verhalten und psychische Gesundheit. In: Bundesgesundheitsblatt - Gesundheitsforschung - Gesundheitsschutz 63, 8, S. 979–986.
- Al-amri, S.S. (2011): Contrast Streching Enhancement in Remote Sensing Image. In: BIOINFO Sensor Networks, 1,1, S. 6-9.
- Albertz, J. (2007): Einführung in die Fernerkundung: Grundlagen der Interpretation von Luft- und Satellitenbildern. 3., aktualisierte und erw. Aufl. Darmstadt: Wiss. Buchges, S. 254.
- Arcgis.com (o.A.): Bildklassifizierungen mit der Erweiterung „ArcGIS Spatial Analyst“—ArcMap | Dokumentation. <https://desktop.arcgis.com/de/arcmap/latest/extensions/spatial-analyst/image-classification/image-classification-using-spatial-analyst.htm>, zuletzt geprüft am 24.10.2024.
- Bachhofer, F.; Esch, T.; Klein, D. (2009): Ableitung von Versiegelungsgraden basierend auf hochaufgelösten Fernerkundungsdaten mittels Support Vector Machines. Salzburg, S. 432-441.
- Bardgett, R.D.; Van Der Putten, W.H. (2014): Belowground biodiversity and ecosystem functioning. In: Nature 515, 7528, S. 505–511.
- Bev.gv.at (o.A.): Orthophoto Farbe. <https://www.bev.gv.at/Services/Produkte/Luftbildprodukte/Orthophoto-Farbe.html>, zuletzt geprüft am 25.01.2025.
- Böcker, R. (1985): Bodenversiegelung - Verlust vegetationsbedeckter Flächen in Ballungsräumen - am Beispiel von Berlin (West). In: Landschaft + Stadt 17, S. 57–61.

- Böttner, R.; Fischer, R.; Kuhr, D. (2012): Abgrenzung und Intensität der urbanen Hitzeinsel und der Überwärmungsgebiete. Zustand und Perspektive für Bielefeld hergeleitet aus Infrarot-Satellitenaufnahmen und numerischen Extrapolationen bis 2100. S. 76.
- Brandenburg, C.; Damyanovic, D.; Reinwald, F.; Allex, B.; Gantner, B.; Czachs, C. (2015): Urban Heat Islands. Strategieplan Wien. S. 116.
- Breiman, L. (2001): Random forests. *Machine Learning*, 45, 1, S. 5-32.
- Brussaard, L.; De Ruiter, P.C.; Brown, G.G. (2007): Soil biodiversity for agricultural sustainability. In: *Agriculture, Ecosystems & Environment* 121, 3, S. 233–244.
- Bundesministerium für Verkehr, Bau und Stadtentwicklung, B., Bundesamt für Bauwesen und Raumordnung, (BBR). (2008): 5 Jahre Stadtumbau Ost – eine Zwischenbilanz. Berlin: Bundestransferstelle Stadtumbau Ost, S. 95.
- Campbell, J.B.; Wynne, R.H., Thomas, V.A. (2023): Introduction to remote sensing. 6. edition. New York: Guilford Press.
- Chauhan, A. (Hg.) (2024): Random Forest Classifier and its Hyperparameters. <https://medium.com/analytics-vidhya/random-forest-classifier-and-its-hyperparameters-8467bec755f6>, zuletzt geprüft am 31.01.2025.
- Congalton, R.G. (1991): A review of assessing the accuracy of classifications of remotely sensed data. In: *Remote Sensing of Environment* 37, 1, S. 35–46.
- Dallhammer, E., Neugebauer, W., Novak, S., Schuh, B., Essig, S., Plha, S., Dumke, H., Schaffer, H., Schneider, U., Öttl, F. (2011): Energieeffiziente Entwicklung von Siedlungen – planerische Steuerungsinstrumente und praxisorientierte Bewertungs-tools.
- Data.gv.at (2025): Bezirksgrenzen Steiermark - data.gv.at. <https://www.data.gv.at/-katalog/-dataset/aa22cd20-395f-11e2-81c1-0800200c9a66#resources>, zuletzt geprüft am 28.01.2025.
- De Sousa, C.A. (2004): The greening of brownfields in American cities. In: *Journal of Environmental Planning and Management* 47, 4, S. 579–600.

- De Sousa, C.A. (2006): Unearthing the benefits of brownfield to green space projects: An examination of project use and quality of life impacts. In: Local Environment 11, 5, S. 577–600.
- Deer, P. (1995): Digital change detection techniques in remote sensing. Australia: DSTO Electronics and Surveillance Research Laboratory, S. 55.
- Developers.arcgis.com (Hg.) (o.A.): How U-net works? | ArcGIS API for Python. <https://developers.arcgis.com/python/latest/guide/how-unet-works/>, zuletzt geprüft am 11.02.2025.
- Doick, K.J.; Sellers, G.; Hutchings, T.R.; Moffat, A.J. (2006): Brownfield sites turned green: realising sustainability in urban revival. S. 140.
- Dudley, N.; Alexander, S.; Johnson, I. (Hg.) (2017): Global land outlook. First edition. Bonn, Germany: UNCCD, S. 336.
- Ec.Europa.eu (Hg.) (2015): CIRCUSE: Das Verwalten der Landnutzung zum Wohle aller. https://ec.europa.eu/regional_policy/de/projects/austria/circuse-managing-land-use-for-the-benefit-of-all, zuletzt geprüft am 26.11.2024.
- Eliasson, I. (2000): The use of climate knowledge in urban planning. In: Landscape and Urban Planning 48, 1–2, S. 31–44.
- Emrich, H. (2013): Flächenverbrauch im ländlichen Raum. In: Wirtschaft & Umwelt 3, S. 36.
- Epa.gov (2008): Reducing Urban Heat Islands: Compendium of Strategies. U.S. Environmental Protection Agency.
- Esri.com (Hg.) (o.A.): About Esri | The Science of Where. <https://www.esri.com/en-us/about/-about-esri/overview>, zuletzt geprüft am 29.10.2024.
- European Commission (Hg.) (2012): Guidelines on best practice to limit, mitigate or compensate soil sealing. Luxembourg: Publications Office, 1.
- FAO, ITPS (2015): Status of the world's soil resources: main report. Rome: FAO : ITPS, S. 650.
- Fe-Lexikon.info (o.A.): Klassifizierung. <https://www.fe-lexikon.info/lexikon/klassifizierung>, zuletzt geprüft am 16.12.2024.

- Fiedler, H.J. (1996): Umweltschutz: Grundlagen, Planung, Technologien, Management; mit 45 Tabellen. Jena: G. Fischer, S. 620.
- Foody, G.M. (2024): Ground Truth in Classification Accuracy Assessment: Myth and Reality. In: Geomatics 4, 1, S. 81–90.
- Foody, G.M., Mathur, A. (2004): A relative evaluation of multiclass image classification by support vector machines. In: IEEE Transactions on Geoscience and Remote Sensing 42, 6, S. 1335-1343.
- García, P.; Pérez, M.E.; Guerra, A. (2014): Using TM images to detect soil sealing change in Madrid (Spain). In: Geoderma 214–215, S. 135–140.
- Geol260.Academic.wlu.edu (o.A.): Unsupervised Classification – EEG 260 – GIS & Remote Sensing. <https://geol260.academic.wlu.edu/course-notes/image-classification/un-supervised-classification/>, zuletzt geprüft am 31.01.2025.
- Geosystems.de (o.A.): ERDAS IMAGINE | Funktionen. <https://www.geosystems.de/-produkte/erdas-imagine/funktionen>, zuletzt geprüft am 07.02.2025.
- Github.com (o.A.): Deep Learning Libraries Installers for ArcGIS. <https://github.com/-Esri/deep-learning-frameworks>, zuletzt geprüft am 11.02.2025.
- Graz.at (2024): Zahlen + Fakten: Bevölkerung, Bezirke, Wirtschaft, Geografie. https://www.graz.at/cms/beitrag/10034466/7772565/Zahlen_Fakten_Bevoelkerung_Bezirke_Wirtschaft.html, zuletzt geprüft am 15.10.2024.
- Green, K.; Kempka, D.; Lackey, L. (1994): Using remote sensing to detect and monitor land-cover and land-use change. In: Photogrammetric Engineering & Remote Sensing 60, S. 331–337.
- Groc, L. (2023): Die Verbündete unseres Klimas: Die Rolle der Natur im Sechsten IPCC-Sachstandsbericht. S. 36.
- Gruber, M.; Kanonier, A.; Pohn-Weidinger, S.; Schindelegger, A. (2018): Raumordnung in Österreich und Bezüge zur Raumentwicklung und Regionalpolitik. Wien: Geschäftsstelle der Österreichischen Raumordnungskonferenz (ÖROK), S. 172.

- Hachmann, R. (2020): Kommunales Grünflächenmanagement – ein wichtiger Beitrag auf dem Weg zur Smart City. In: Etezadzadeh, C. (Hg.): Smart City – Made in Germany. Wiesbaden: Springer Fachmedien Wiesbaden, S. 259–267.
- Han, E.; Kautz, T.; Perkons, U.; Lüsebrink, M.; Pude, R.; Köpke, U. (2015): Quantification of soil biopore density after perennial fodder cropping. In: Plant and Soil 394, 1–2, S. 73–85.
- Harris, J.A.; Birch, P.; Palmer, J.P. (1998): Land restoration and reclamation: principles and practice. Reprinted. Harlow: Addison Wesley Longman, S. 230.
- Heise, P.; Hallermayr, S. (2022): Gesundheitliche Auswirkungen des Stadtlebens. In: Heise, P., Hallermayr, S. (Hg.): Grüne Stadt - Gesunder Mensch: Herausforderungen, Lösungsansätze und Handlungsfelder. Berlin, Heidelberg: Springer, S. 1–10.
- Hendawy, E.; Belal, A.A.; Mohamed, E.S.; Elfadaly, A.; Murgante, B.; Aldosari, A.A.; Lasaponara, R. (2019): The Prediction and Assessment of the Impacts of Soil Sealing on Agricultural Land in the North Nile Delta (Egypt) Using Satellite Data and GIS Modeling. In: Sustainability 11, 17, S. 4662.
- Heritage, G.L.; Andrew R.G. (2009): Laser Scanning for the Environmental Sciences. Chichester, UK: Wiley-Blackwell.
- Hexagon.com (Hg.) (o.A.): Global leader in sensor and software technologies | Hexagon. <https://hexagon.com/>, zuletzt geprüft am 11.02.2025.
- Hooper, D.U.; Bignell, D.E.; Brown, V.K.; Brussard, L.; Mark Dangerfield, J.; Wall, D.H.; Wardle, D.A.; Coleman, D.C.; Giller, K.E.; Lavelle, P.; Van Der Putten, W.H.; De Ruiter, P.C.; Rusek, J.; Silver, W.L.; Tiedje, J.M.; Wolters, V. (2000): Interactions between Aboveground and Belowground Biodiversity in Terrestrial Ecosystems: Patterns, Mechanisms, and Feedbacks. In: BioScience 50, 12, S. 1049.
- Howard, L. (1820): The Climate of London: Deduced from Meteorological Observations Made at Different Places in the Neighbourhood of the Metropolis, S. 360.
- Jensen, J.R. (2005): Introductory digital image processing: a remote sensing perspective. 3rd ed. Upper Saddle River, NJ: Pearson/Prentice Hall, S. 526.

Kiesling, A. (13.12.2024): E-Mail-Verkehr mit Brunner, B.

Kiesling, A. (21.10.2024): E-Mail-Verkehr mit Meixner, P.

Köckler, H.; Sieber, R. (2020): Die Stadt als gesunder Lebensort?!: Stadtentwicklung als ein Politikfeld für Gesundheit. In: Bundesgesundheitsblatt - Gesundheitsforschung - Gesundheitsschutz 63, 8, S. 928–935.

Kuttler, W. (2011): Climate change in urban areas. Part 2, Measures. In: Environmental Sciences Europe 23, 1, S. 21.

Land-Oberoesterreich.gv.at (Hg.) (o.A.): Land Oberösterreich - Landesplanung und Regionalentwicklung. <https://www.land-oberoesterreich.gv.at>, zuletzt geprüft am 02.11.2024.

Lang, N. (o.A.): Support Vector Machine (SVM) - einfach erklärt! <https://databasecamp.de/ki/support-vector-machine-svm>, zuletzt geprüft am 11.02.25.

de Lange, N. (2013): *Geoinformatik: in Theorie und Praxis*. 3. Aufl. 2013. Berlin, Heidelberg: Springer Berlin Heidelberg.

de Lange, N. (2020): *Geoinformatik in Theorie und Praxis: Grundlagen von Geoinformationssystemen, Fernerkundung und digitaler Bildverarbeitung*. 4. Aufl. 2020. Berlin, Heidelberg: Springer Berlin Heidelberg, 1.

Lemenkova, P. (2021): ISO Cluster classifier by ArcGIS for unsupervised classification of the Landsat TM image of Reykjavík. In: Bulletin of Natural Sciences Research 11, 1, S. 29-37.

Lewis, R. (2006): Acres of Art. In: The New York Times. <https://www.nytimes.com/2006/08/06/books/review/lewis.html>, zuletzt geprüft am 02.11.2024.

Liaw, A.; Wiener, M. (2002): Classification and Regression by randomForest. R News, 2, S. 21.

Lilienthal, H.; Schnug, E. (Hrsg.) (2008): *Hochwasserschutz durch ökologische Bodenbewirtschaftung. Klimawandel und Ökolandbau. - Situation, Anpassungsstrategien und Forschungsbedarf*. Darmstadt: Kuratorium für Technik und Bauwesen in der Landwirtschaft, S. 227.

- Lillesand, T.M.; Kiefer, R.W.; Chipman, J.W. (2015): Remote sensing and image interpretation. Seventh edition. Hoboken, NJ: Wiley, S. 720.
- Lu, D.; Hetrick, S.; Moran, E. (2011): Impervious surface mapping with Quickbird imagery. In: International Journal of Remote Sensing 32, 9, S. 2519–2533.
- Lu, D.; Mausel, P.; Brondízio, E.; Moran, E. (2004): Change detection techniques. In: International Journal of Remote Sensing 25, 12, S. 2365–2401.
- Menke, P. (2020): Integrierte Stadtentwicklung braucht lebendiges Grün. In: Etezadzadeh, C. (Hg.): Smart City – Made in Germany. Wiesbaden: Springer Fachmedien Wiesbaden, S. 251–256.
- Mohamed, E.S.; Belal, A.; Shalaby, A. (2015): Impacts of soil sealing on potential agriculture in Egypt using remote sensing and GIS techniques. In: Eurasian Soil Science 48, 10, S. 1159–1169.
- Morel, J.L.; Chenu, C.; Lorenz, K. (2015): Ecosystem services provided by soils of urban, industrial, traffic, mining, and military areas (SUITMAs). In: Journal of Soils and Sediments 15, 8, S. 1659–1666.
- National Forum on BioDiversity (Hg.) (2011): Biodiversity. Washington, D.C: National Academy Press, S. 521.
- Oerok.gv.at (Hg.) (2022): Flächeninanspruchnahme und Versiegelung in Österreich. <https://www.oerok.gv.at/raum/daten-und-grundlagen/ergebnisse-oesterreich-2022>, zuletzt geprüft am 02.11.2024.
- Oerok.gv.at (Hg.) (2015): Raumordnungsbericht / ÖROK, Österreichische Raumordnungs-konferenz. 15: 2012 - 2014, S. 247.
- Oliver, L.; Ferber, U.; Grimski, D.; Miller, K.; Nathanall, P. (2005): The Scale and Nature of European Brownfield. In: Proceedings of the CABERNET 2005—International Conference on Managing Urban Land LQM Ltd., Belfast, Northern Ireland, UK, 13–15 April
- Orgiazzi, A.; Bardgett, R.D.; Barrios, E.; Behan-Pelletier, V.; Briones, M.J.I.; Chotte, J.-L.; De Deyn, G.B.; Eggleton, P. (2016): Global soil biodiversity atlas. Luxembourg: Publications Office, 1.

- Parelius, E.J. (2023): A Review of Deep-Learning Methods for Change Detection in Multispectral Remote Sensing Images. In: Remote Sensing 15, 8, S. 2092.
- Powers, D. (2008): Evaluation: From Precision, Recall and F-Factor to ROC, Informedness, Markedness & Correlation. Mach. Learn. Technol., 2, S. 24.
- Pro.Arcgis.com (Hg.) (o.A. a): Accuracy Assessment—ArcGIS Pro | Documentation. <https://pro.arcgis.com/en/pro-app/3.3/help/analysis/image-analyst/accuracy-assessment.htm>, zuletzt geprüft am 01.02.2025.
- Pro.Arcgis.com (Hg.) (o.A. b): ArcGIS Pro-Erweiterungen—ArcGIS Pro | Dokumentation. <https://pro.arcgis.com/de/pro-app/latest/get-started/overview-of-extensions-in-arcgis-pro.htm>, zuletzt geprüft am 29.10.2024.
- Pro.Arcgis.com (Hg.) (o.A. c): Funktionsweise von „Iso Cluster“—ArcGIS Pro | Dokumentation. <https://pro.arcgis.com/de/pro-app/latest/tool-reference/spatial-analyst/how-iso-cluster-works.htm>, zuletzt geprüft am 31.01.2025.
- Pro.Arcgis.com (Hg.) (o.A. d): How Random trees classification and regression algorithm works—ArcGIS Pro | Documentation. <https://pro.arcgis.com/en/pro-app/latest/tool-reference/geoai/how-random-trees-classification-and-regression-works.htm>, zuletzt geprüft am 31.01.2025.
- Pro.Arcgis.com (Hg.) (o.A. e): Overview of image classification—ArcGIS Pro | Documentation. <https://pro.arcgis.com/en/pro-app/latest/help/analysis/image-analyst/-overview-of-image-classification.htm>, zuletzt geprüft am 29.10.2024.
- Pro.Arcgis.com (Hg.) (o.A. f): Stretch function—ArcGIS Pro | Documentation. <https://pro.arcgis.com/en/pro-app/latest/help/analysis/raster-functions/stretch-function.htm#:~:text=0%20and%20255.,Minimum%2Dmaximum,could%20be%2033%20and%20206.ap/latest/manage-data/raster-and-images/stretch-function.htm>, zuletzt geprüft am 28.01.2025.
- Pro.Arcgis.com (Hg.) (o.A. g): Überblick über Bildklassifizierung—ArcGIS Pro | Dokumentation. <https://pro.arcgis.com/de/proapp/latest/help/analysis/image-analyst/overview-of-image-classification.htm>, zuletzt geprüft am 16.12.2024.
- Qgis.org (Hg.) (o.A.): Spatial without Compromise. <https://qgis.org/>, zuletzt geprüft am 07.02.2025.

- Raven, P.H.; Hassenzahl, D.M.; Berg, L.R. (2013): Environment. 8. ed., internat. student version. Singapore: Wiley.
- Richards, J.; Jia, X. (2006): Remote Sensing Digital Image Analysis: An Introduction. Springer, Berlin. S. 439.
- Robinson, C., Malkin, K., Jojic, N., Chen, H., Qin, R., Xiao, C., Schmitt, M., Ghamisi, P., Hänsch, R., Yokoya, N. (2021): Global Land-Cover Mapping With Weak Supervision: Outcome of the 2020 IEEE GRSS Data Fusion Contest. In: IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing 14, S. 3185–3199.
- Ronneberger, O.; Fischer, P.; Brox, T. (2015): U-Net: Convolutional Networks for Biomedical Image Segmentation. P. 234-241.
- Salomon, M.; Brodner, B.; Hornberg, C. (2018): Umweltbezogener Gesundheitsschutz im städtischen Lebensraum. In: Public Health Forum 26, 3, S. 247–251.
- Saß, A.-C.; Niemann, H.; Straff, W.; Bunz, M. (2020): Health and the City. In: Bundesgesundheitsblatt - Gesundheitsforschung - Gesundheitsschutz 63, 8, S. 925–927.
- Satpalda.com (2024): Land Cover Change Detection. <https://satpalda.com/-blogs/land-cover-change-detection/>, zuletzt geprüft am 11.02.2025.
- Schmidt, M.W.I.; Torn, M.S.; Abiven, S.; Dittmar, T.; Guggenberger, G.; Janssens, I.A.; Kleber, M.; Kögel-Knabner, I.; Lehmann, J.; Manning, D.A.C.; Nannipieri, P.; Rasse, D.P.; Weiner, S.; Trumbore, S.E. (2011): Persistence of soil organic matter as an ecosystem property. In: Nature 478, 7367, S. 49–56.
- Schrumpf, M.; Trumbore, S. (2011): Unser wichtigster Kohlenstoffspeicher: Wie der Boden als dünne Haut der Erde globale Stoffkreisläufe und das Klima beeinflusst. https://www.mpg.de/4705567/Kohlenstoffspeicher_Boden?c=2191, zuletzt geprüft am 23.11.2024.
- Schutzwald.at (Hg.) (2023): Zahlen und Fakten 2023. https://www.schutzwald.at/-dam/jcr:bfc2cd32-dffa-4725-b3a1-ad1abbbb803dd/BML_Broschuere_Zahlen_und_Fakten_DE_2023_Barrierefrei-1.pdf, zuletzt geprüft am 11.02.2025.

- Sieker.de (Hg.) (o.A.): Wasserhaushalt. <https://www.sieker.de/fachinformationen/-article/-wasser-haushalt-65.html>, zuletzt geprüft am 23.11.2024.
- Smith, P.; Cotrufo, M.F.; Rumpel, C.; Paustian, K.; Kuikman, P.J.; Elliott, J.A.; McDowell, R.; Griffiths, R.I. (2015): Biogeochemical cycles and biodiversity as key drivers of ecosystem services provided by soils. In: SOIL 1, 2, S. 665–685.
- Statistik.at (Hg.) (2023): Einwohnerzahl und Komponenten der Bevölkerungsentwicklung. Graz. Statistik.
- Statistik.at (Hg.) (2024 a): Ein Blick auf die Gemeinde Graz. Bevölkerungsentwicklung 1869 - 2024. Statistik.
- Statistik.at (Hg.) (2024 b): Regionale Gliederungen. <https://www.statistik.at/services/-tools/services/regionales/regionale-gliederungen>, zuletzt geprüft am 11.02.2025.
- Statistikportal.de (Hg.) (o.A.): Startseite | Statistikportal.de. <https://www.statistikportal.de/de>, zuletzt geprüft am 23.11.2024.
- Steiermark.at (Hg.) (o.A.): GIS-Steiermark. <https://www.landesentwicklung.steiermark.at/-cms/ziel/141976122/DE/>, zuletzt geprüft am 15.10.2024.
- Steiermark.at (Hg.) (2024): Steirische Bevölkerung: Deutlicher Zuwachs durch internationale Zuwanderung. <https://www.kommunikation.steiermark.at/cms/-beitrag/12958207/-2861976/>, zuletzt geprüft am 15.10.2024.
- Suthaharan, S. (2016): Support Vector Machine. Machine Learning Models and Algorithms for Big Data Classification. Boston, MA: Springer US , S. 207–235.
- Tobias, S.; Conen, F.; Duss, A.; Wenzel, L.M.; Buser, C.; Alewell, C. (2018): Soil sealing and unsealing: State of the art and examples. In: Land Degradation & Development 29, 6, S. 2015–2024.
- Uca Avci, Z.D.; Karaman, M.; Ozelkan, E.; Papila, I. (2011): A Comparison of Pixel-Based and Object-Based Classification Methods, A Case Study: Istanbul, Turkey. S. 5.
- Umweltbundesamt.de (Hg.) (2013): Emissionen der Landnutzung, -änderung und Forstwirtschaft. <https://www.umweltbundesamt.de/daten/klima/treibhausgas-emissionen-in-deutschland/emissionen-der-landnutzung-aenderung>, zuletzt geprüft am 23.11.2024.

- Umweltbundesamt.de (Hg.) (2016): Böden als Wasserspeicher. https://www.umweltbundesamt.de/sites/default/files/medien/377/publikationen/kbu_erhöhung_und_sicherung_der_infiltrationsleistung_von_boden_juli_2016.pdf, zuletzt geprüft am 11.02.2025.
- Umweltbundesamt.de (Hg.) (2024): Bodenversiegelung. <https://www.umweltbundesamt.de/daten/flaeche-boden-land-oekosysteme/boden/bodenversiegelung>, zuletzt geprüft am 17.11.2024.
- U.S. Environmental Protection Agency (Hg.) (2008): EPA's Report on the Environment. S. 366. <https://cfpub.epa.gov/ncea/risk/recordisplay.cfm?deid=190806>, zuletzt geprüft am 11.02.2025.
- Üreyen, S.; Thield, M. (2017): Satellitengestützte Erfassung der Bodenversiegelung in Bayern 2015. S. 74.
- Villella, J.; Sellers, G.; Moffat, A.J.; Hutchings, T.R. (2006): From contaminated site to premier urban greenspace: investigating the success of Thames Barrier Park, London. S. 10.
- Wagg, C.; Bender, S.F.; Widmer, F.; Van Der Heijden, M.G.A. (2014): Soil biodiversity and soil community composition determine ecosystem multifunctionality. In: Proceedings of the National Academy of Sciences 111, 14, S. 5266–5270.
- Walford, N. (2002): Geographical Data: Characteristics and Sources. Chichester: John Wiley & Sons.
- Wang, Y.; Li, M. (2019): Urban Impervious Surface Detection From Remote Sensing Images: A review of the methods and challenges. In: IEEE Geoscience and Remote Sensing Magazine 7, 3, S. 64–93.
- Wegscheider-Pichler, A.; Prettnner, C.; Lamei, N. (2021): Wie geht's Österreich? Indikatoren und Analysen von 2000 bis zum COVID-19-Krisenjahr 2020. https://www.statistik.at/fileadmin/publications/Wie_geht_s_OEsterreich__2021.pdf, zuletzt geprüft am 01.11.2024.
- Wen, D.; Huang, X.; Bovolo, F.; Li, J.; Ke, X.; Zhang, A.; Benediktsson, J.A. (2021): Change Detection From Very-High-Spatial-Resolution Optical Remote Sensing Images: Methods, applications, and future directions. In: IEEE Geoscience and Remote Sensing Magazine 9, 4, S. 68–101.

- Wiggering, H.; Fischer, J.U.; Penn-Bressel, G.; Eckelmann, W.; Ekardt, F.; Köpke, U.; Makeschin, F.; Lee, Y.H.; Grimski, D.; Glante, F. (2009): Flächenverbrauch einschränken – jetzt handeln. Empfehlungen der Kommission Bodenschutz beim Umweltbundesamt. S. 18.
- WWF.at (Hg.) (2022): Die Problemfelder der Verbauung Österreichs. <https://www.wwf.at/artikel/fotostrecke-die-problemfelder-der-verbauung-oesterreichs/>, zuletzt geprüft am 11.02.2025
- WWF.at (Hg.) (2023): WWF-BODENREPORT 2023. Die Verbauung Österreichs: Ursachen, Probleme und Lösungen einer wachsenden Umweltkrise. S. 44. https://www.wwf.at/wpcontent/uploads/2023/05/WWF_Bodenreport_2023_web.pdf, zuletzt geprüft am 01.11.2024.
- WWF.at (Hg.) (2024): WWF-BODENREPORT 2024. Die Verbauung Österreichs. S. 44. https://www.wwf.at/wpcontent/uploads/2023/05/WWF_Bodenreport_2023_web.pdf, zuletzt geprüft am 01.11.2024.
- Wolters, V.; Silver, W.L.; Bignell, D.E.; Coleman, D.C.; Lavelle, P.; Van Der Putten, W.H.; De Ruiter, P.; Rusek, J.; Wall, D.H.; Wardle, D.A.; Brussard, L.; Dangerfield, J.M.; Brown, V.K.; Giller, K.E.; Hooper, D.U.; Sala, O.; Tiedje, J.; Van Veen, J.A. (2000): Effects of Global Changes on Above- and Belowground Biodiversity in Terrestrial Ecosystems: Implications for Ecosystem Functioning. In: BioScience 50, 12, S. 1089.
- Yakubovskiy, P. (o.A.): Segmentation Models. <https://segmentation-models.readthedocs.io/en/latest/api.html>, zuletzt geprüft am 27.01.2025
- Zerobrownfields.eu (Hg.) (o.A.): Brownfield Regeneration: Holistic Management - HOMBRE Aims. <https://www.zerobrownfields.eu/aims.aspx>, zuletzt geprüft am 26.11.2024.
- Zhao, J.; Wang, L.; Yang, H.; Wu, P.; Wang, B.; Pan, C.; Wu, Y. (2022): A Land Cover Classification Method for High-Resolution Remote Sensing Images Based on NDVI Deep Learning Fusion Network. In: Remote Sensing 14, 21, S. 5455.
- Zhu, X.X.; Tuia, D.; Mou, L.; Xia, G.-S.; Zhang, L.; Xu, F.; Fraundorfer, F. (2017): Deep Learning in Remote Sensing: A Comprehensive Review and List of Resources. In: IEEE Geoscience and Remote Sensing Magazine 5, 4, S. 8–36.