



Master Thesis

im Rahmen des
Universitätslehrganges „Geographical Information Science & Systems“
(UNIGIS MSc) am Interfakultären Fachbereich für GeoInformatik (Z_GIS)
der Paris Lodron-Universität Salzburg

zum Thema

**„Ermittlung der Bodenversiegelung in Innsbruck
mittels flugzeuggestützten Fernerkundungsdaten“**

vorgelegt von

Gabriel Plangger

106758, UNIGIS MSc Jahrgang 2021

Betreuer/in:

Univ.-Prof. Mag. Dr. Thomas Blaschke

Zur Erlangung des Grades
„Master of Science – MSc“

Innsbruck, 14.05.2023

Danksagung

Besonderen Dank möchte ich meinem Betreuer Herr Prof. Dr. Blaschke aussprechen, der mir während der gesamten Arbeit immer zur Verfügung stand. Seine Ideen und Anregungen haben mir stets weiter geholfen. Ein fachlicher Austausch war während der gesamten Arbeit gegeben.

Weiters möchte ich mich an dieser Stelle beim gesamten UNIGIS-Team herzlich bedanken. Die Studieninhalte der einzelnen Module waren anspruchsvoll und bestens kommuniziert. Stets konnten die theoretischen und praktischen Modulinhalte gut in die Arbeitswelt übertragen werden. Alle administrativen und organisatorischen Fragen rund um das Studium wurden stets entgegen genommen. Durch das Fernstudium im Bereich der Geoinformatik konnte ich mein Wissen vertiefen und neue Inhalte für mein weiteres Berufsleben sammeln.

Auch möchte ich mich bei meinen Kollegen Dipl. Ing. Raimund Gasser und Dr. Klaus Legat bedanken. Sie konnten mir durch ihr breites Wissen im Bereich der Vermessung und Geoinformation immer einen guten Rat geben.

Zuletzt gilt auch ein großer Dank an Erik Bollmann PhD. Sein konstruktives Feedback zur geschriebenen Arbeit konnte mir nochmals gut helfen.

Zusammenfassung

Heutzutage spielt die Entwicklung und der Informationsgehalt von versiegelten Flächen sowohl im öffentlichen Raum, als auch im Bereich der Fernerkundung eine zentrale Rolle. Undurchlässige Flächen haben negative Folgen auf die natürliche Bodenfunktion. Beispiele wie der Rückgang der biologischen Vielfalt oder die natürliche Kühlung im städtischen Raum sind dabei zu nennen. Die zunehmende Weltbevölkerung führt zu einem steigenden Flächenverbrauch. Landflächen werden zu Wohnraum, Verkehrswegen und anderen Wirtschaftseinrichtungen umgewandelt. Die natürliche Bodenfunktion geht dabei verloren. Eine permanente Überwachung der Landschaftsveränderung ist daher von großer Bedeutung. Die Stadt Innsbruck ist für den erhöhten Siedlungsdruck und die Suburbanisierung bekannt.

Das Land Tirol verfügt über eine Vielzahl an historischen und aktuellen Aufnahmen. Digitale Orthophotos (DOP) im Raum Innsbruck sind in Echtfarbe seit dem Jahr 1999 zu finden. Die öffentlichen Rasterdatensätze haben eine Bodenauflösung zwischen 20 und 25 cm. Das Ziel dieser Masterarbeit besteht darin, historische und aktuelle Orthophotos hinsichtlich deren Bodenversiegelung zu klassifizieren. Mit Anwendung von überwachten Klassifizierungsverfahren wird der Bodenverbrauch zwischen 1999 und 2019 im Dauersiedlungsraum von Innsbruck erfasst. Die einzelnen Stadtteile von Innsbruck werden auf die Veränderung der Bodenversiegelung untersucht. Mit dem Versiegelungsgrad wird festgestellt, wie sich die Flächeninanspruchnahme in den letzten zwei Jahrzehnten entwickelt hat. Die Datensätze werden sowohl mit objektbasierter Bildanalyse als auch mit einem Deep Learning-Ansatz behandelt. Als Klassifizierungsalgorithmus werden die *Support Vector Machines (SVMs)* und das *Pyramid Scene Parsing Network (PSPNet)* in Betracht gezogen. Die Zeitreihe in Innsbruck soll zeigen, wie sich die Bodenversiegelung in den letzten zwanzig Jahren entwickelt hat.

Der aktuelle Datensatz aus 2019 verfügt über einen zusätzlichen Nahinfrarot (NIR) Kanal. Dieser wird eingesetzt, um Unterschiede zum 3-Kanal Rasterdatensatz in Echtfarbe herstellen zu können. Mit dem zusätzlichen NIR Kanal wird das Bildmaterial als *Normalized Difference Vegetation Index (NDVI)* und *Color Infrared (CIR)* dargestellt.

Heutzutage können Informationen zur Bodenversiegelung aus verschiedenen Verfahren und Programmen entnommen werden. Die Resultate aus dieser Arbeit werden einem nationalen und einem internationalen Datensatz gegenübergestellt. Der flugzeuggestützte Ansatz wird mit der Regionalinformation und dem europäischen Copernicus Programm *Imperviousness Density (IMD)* verglichen.

Beide Vergleichsverfahren nutzen unterschiedliche Techniken und Sensoren, um die Landschaftsnutzung und Landschaftsbedeckung zu erfassen. Die satellitengestützten Daten aus dem Copernicus Programm erreichen im besten Fall eine räumliche Auflösung von 10 m.

Abstract

The development and information of sealed surfaces plays a central role in public space and remote sensing. Impervious surfaces have negative consequences on the natural soil function. Examples like the decline of biodiversity or the natural cooling in urban areas can be mentioned. A growing world population leads to increasing land consumption. Land is being converted into housing, transport routes and other economic facilities. The natural soil function is lost in the process. Permanent monitoring of landscape changes plays therefore a big role. The city of Innsbruck is known for its increased settlement pressure and suburbanisation.

The land of Tyrol has a large number of historical and actual aerial images. Digital Orthophotos (DOP) in the area of Innsbruck can be founded in the visible spectrum since the year 1999. The public raster datasets have a ground resolution between 20 and 25 cm. The aim of this thesis is to classify historical and actual orthophotos with regard to their soil sealing. With the application of supervised classification methods, the soil consumption between 1999 and 2019 in the settlement area of Innsbruck is captured. All districts of Innsbruck are getting inspected for the change of soil sealing. The degree of sealing is used to determine how land use has changed over the last two decades. The datasets are treated with object-based image analysis and a deep learning approach. Support vector machines (SVMs) and the pyramid scene parsing network (PSPNet) are considered as classification algorithms. The time series in Innsbruck is intended to show how soil sealing has developed over the past twenty years.

The actual dataset from 2019 has an additional near-infrared (NIR) band. This is used to find differences to the three-band dataset in true color. With the additional near-infrared band, the image material is represented as Normalized Difference Vegetation Index (NDVI) and Color Infra-red (CIR).

Nowadays, impervious surfaces can be obtained from various methods and programmes. The generated results will be compared to national and international datasets. The used approach of this work is compared to the regional information and the European Copernicus programme Imperviousness Density (IMD).

Both comparison methods use different techniques and sensors to record the land use and land cover. The satellite-based data from the Copernicus programme achieve at best a spatial resolution of 10 meters.

Abkürzungsverzeichnis

BEV	Bundesamt für Eich und Vermessungswesen
CIR	Color Infrared
CNN	Convolutional Neural Network
DKM	Digitale Katastralmappe
DL	Deep Learning
DOP	Digitale Orthophotos
DSM	Digital Surface Model
DSR	Dauersiedlungsraum
DTM	Digital Terrain Model
GIS	Geoinformationssystem
IMD	Imperviousness Density
KI	Künstliche Intelligenz
ML	Machine Learning
nDSM	Normalized Digital Surface Model
NIR	Nahinfrarot
NDVI	Normalized Difference Vegetation Index
PSPNet	Pyramid Scene Parsing Network
ResNet	Residual Network
RF	Random Forest
SVM	Support Vector Machine

Abbildungsverzeichnis

1	Teilbereiche der Künstlichen Intelligenz	6
2	Einteilung der Stadtteile von Innsbruck	12
3	Dauersiedlungsraum der Stadt Innsbruck	13
4	Aktueller Datenstand der Orthophotos, Quelle: Land Tirol, Abteilung Geoinformati- on (Stand Mai 2022)	14
5	Historische Orthophotos (oben 2009 unten 1999) in der RGB Darstellung	16
6	Aktuelles Orthophoto in der RGB Darstellung	17
7	Aktuelles Orthophoto in der CIR Darstellung	18
8	Untersuchungsgebiet samt Blattschnitt	19
9	Fernerkundung der Erdoberfläche (Lillesand et al., 2015)	20
10	Elektromagnetische Welle mit Komponenten (Lillesand et al., 2015)	21
11	Elektromagnetisches Spektrum (Lillesand et al., 2015)	21
12	Spektrale Reflexionskurve für verschieden Objekte (Lillesand et al., 2015)	22
13	Fehlklassifizierung begründer Dächer	23
14	Versiegelungsarten	24
15	Stadt Innsbruck in der NDVI Darstellung	26
16	Darstellung mehrerer Teilklassen aus dem RGB Orthophoto 2009	28
17	Trainingsgebiete NDVI	30
18	Segmente der objektbasierten Bildanalyse RGB (links) und NDVI (rechts)	32
19	Trennung zweier Klassen über eine SVM-Hyperebene (Gunn et al., 1998)	33
20	Workflow objektbasierte Bildanalyse	34
21	Aufbau neuronales Netzwerk	36
22	Aufbau PSPNet (Zhao et al., 2017)	38
23	Datenaufbereitung Deep Learning	39
24	Aufbau der PSPNet Architektur mit dem ArcPy Packet von ArcGIS	40
25	Gegenüberstellung Ground Truth/Predictions	41
26	Ausgabe aller Teilklassen mittels Deep Learning	42
27	Workflow neuronale Netzwerke	43
28	Versiegelte Flächen aus der Regionalinformation 2019 Quelle: BEV - Bundesamt für Eich- und Vermessungswesen: Regionalinformation. Die Originaldaten liegen für Katastralgemeinden vor und werden zum jeweiligen Jahresende auf Gemeindeebene aggregiert.	45
29	Copernicus high-resolution layer imperviousness density	47
30	Orthophoto 2019 mit Referenzpunkte (rot)	49
31	Versiegelter Anteil im DSR	56
32	Versiegelungsraster Stadtteil Amras zwischen 1999-2019	58
33	Versiegelungsraster Stadtteil Gewerbegebiet Roßau zwischen 1999-2019	59
34	Versiegelungsraster Stadtteil Höttinger Au zwischen 1999-2019	60

35	Eingeschränkte Sicht auf die Bodenversiegelung durch flugzeuggestützte Fernerkundungsdaten	61
36	Versiegelungskartierungen im Dauersiedlungsraum (DSR) zwischen 1999 und 2019 mittels objektbasierter Bildanalyse	63
37	Versiegelungskartierungen im DSR zwischen 1999 und 2019 mittels Deep Learning. A zeigt den Versiegelungsgrad für 1999. B zeigt den Versiegelungsgrad für 2009. C zeigt den Versiegelungsgrad für 2019. D zeigt den Versiegelungsgrad für 2019 abgeleitet aus dem CIR Orthophoto.	64
38	Veränderung des Versiegelungsgrades zwischen 1999 (links) und 2019 (rechts)	64
39	Versiegelungsgrad der statistischen Stadtteile bezogen auf den DSR	65
40	Veränderung der Versiegelung zwischen 1999 und 2019	66

Tabellenverzeichnis

1	Flächeninanspruchnahme Innsbruck	3
2	Entwicklung der Wohnbevölkerung	4
3	Gebäudeanzahl	4
4	Metadaten der historischen Orthophotos	15
5	Metadaten des aktuellen Orthophoto	19
6	Unterteilung der Klassen in der NDVI Darstellung	26
7	Zuordnung der Versiegelungskoeffizienten für die Nutzungen im Grenzkataster . . .	44
8	Fehlermatrix objektbasierte Bildanalyse	51
9	Fehlermatrix Deep Learning	53
10	Gegenüberstellung verschiedener Methoden zur Bestimmung der Bodenversiegelung	55

Inhaltsverzeichnis

Danksagung	II
Zusammenfassung	III
Abstract	V
Abkürzungsverzeichnis	VII
Abbildungsverzeichnis	VIII
Tabellenverzeichnis	X
Inhaltsverzeichnis	XI
1 Einleitung	1
1.1 Hintergrund	1
1.2 Forschungsstand	8
1.3 Zielsetzung	10
2 Methodik	12
2.1 Untersuchungsgebiet	12
2.2 Datengrundlage	14
2.3 Historische Orthophotos	15
2.4 Aktuelles Orthophoto	17
2.5 Erfassung der Bodenversiegelung aus flugzeuggestützten Fernerkundungsdaten . .	20
2.6 Versiegelte Flächen	21
2.7 Überwachte Klassifizierung	28
2.8 Objektbasierte Bildanalyse	31
2.9 Neuronale Netzwerke	35
2.10 Bodenverbrauch aus anderen Methoden	44
2.10.1 Regionalinformation	44
2.10.2 Copernicus Imperviousness Density	46
3 Ergebnisse	48
3.1 Validierung der Klassifizierung	48
3.1.1 Validierung SVM	51
3.1.2 Validierung PSPNet	53
3.2 Entwicklung der Bodenversiegelung	55
3.2.1 Versiegelungsgrad	62
4 Diskussion	67
5 Schlussfolgerungen und Ausblick	70

6 Literaturverzeichnis

72

1 Einleitung

1.1 Hintergrund

Die Verschlechterung der Bodenqualität ist ein zentrales Umweltproblem. Eine nachhaltige Lösung steht auf vielen internationalen Tagesordnungen (Montgomery, 2012). Die Undurchlässigkeit der Bodenoberfläche bringt ein großes Risiko mit sich, da wichtige Ökosystemfunktionen zerstört werden (Scalenghe and Marsan, 2009). Darüber hinaus gilt die Bodenversiegelung als eine der Hauptursachen für die Verluste der Biodiversität (Seto et al., 2012). Die Reduzierung von landwirtschaftlichen Böden und Grünflächen führt zu einer Verschlechterung der Lebensqualität. Diese Flächen fallen oft dem Bau von Verkehrswegen, Gebäuden und anderen Bauwerken zu. Wie vom Bundesministerium für Landwirtschaft (2021) besagt, entsteht durch die hohe Anzahl an verschiedenen Nutzungsansprüchen ein hoher Druck für die Umwelt. Bevölkerungswachstum, Mobilität und wirtschaftliche Aktivitäten führen zu einem steigenden Bodenverbrauch.

Eine wichtige Rolle spielt die Überwachung dieser vom Menschen verursachten Veränderung, um eine Begrenzung der Bodenversiegelung zu erzielen (Langella et al., 2020). Die Flächenversiegelung führt dazu, dass ökologische Funktionen drastisch abnehmen oder sogar ganz vernichtet werden.

Die Kontrolle der Landschaftsveränderung ist ein wichtiger Bestandteil der Raumplanung und des Ressourcenmanagement (Liu and Yang, 2015). Die Umwandlung von Grünflächen, Ackerland und Wälder zu urbanen Flächen ist ein zentraler Faktor in der globalen Umweltveränderung (Briasoulis, 2020). Mehr als 50 Prozent der weltweiten Bevölkerung lebt mittlerweile im urbanen Raum. Durch die Erweiterung des städtischen Raumes, steigt der Bedarf an natürlichen Ressourcen. Die urbane Gesellschaft hat sich in Bezug auf Bevölkerungsdichte, Kulturvielfalt und einer steigenden Nachfrage an Leistungen verändert. Die zunehmende Bebauung in Verbindung mit dem Bevölkerungszuwachs führt zu komplexen Anforderungen in der Raumplanung (Boyle et al., 2010).

Künstliche Intelligenz (KI) und Fernerkundungsdaten bieten eine Möglichkeit an, um die Bodenversiegelung erfassen und deren Zustand analysieren zu können (Peroni et al., 2022). Die Fernerkundungstechnologie bietet einige Vorteile gegenüber den terrestrischen Methoden an. Eine räumliche Analyse kann für ein großes Untersuchungsgebiet erstellt werden (Weng, 2019). Die Daten sind meist frei zugänglich. Durch wiederholte Aufnahmezyklen kann das Untersuchungsgebiet über einen längeren Zeitraum überwacht werden (Peroni et al., 2022).

In den letzten Jahren nahm die Flächenversiegelung in ganz Österreich zu. Nach Angaben des Umweltbundesamt (2017) wird täglich eine Fläche von rund 12 ha verbaut. Das entspricht einer Größe von ungefähr 18 Fußballfeldern. Allein in ganz Österreich stehen etwa 40.000 ha an ungenützten Flächen in Form von leerstehenden Häusern und Gewerbeflächen zur Verfügung. Dies entspricht beinahe der Fläche von Wien.

Zudem ist die Auflösung und Entfernung der Bodenversiegelung ein aufwändiger Prozess. Dieser Vorgang ist mit hohen Kosten verbunden und die natürliche Bodenfunktion der entsiegelten Flächen bleibt gestört. Grund dafür sind zurückgebliebene Stoffe im Boden wie Beton, Asphalt, Kunststoff oder andere Fremdstoffe. Nur über einen längeren Zeitraum kann die Bodenkultur langsam wieder in ihren natürlichen Zustand zurückkehren. Wenn auch die vorherige Bodenqualität nicht mehr erreicht werden kann (Umweltbundesamt, 2022).

Die Stadt Innsbruck hat in den vergangenen Jahren einen kontinuierlichen Zuwachs an verbauten Flächen zu verzeichnen. Die Digitale Katastralmappe (DKM) bietet für ganz Österreich eine Abschätzung der Flächenversiegelung an. Dies ist ein Datensatz welcher vom Bundesamt für Eich und Vermessungswesen (BEV) als Regionalinformation der Grundstücksdatenbank frei zur Verfügung steht. Innerhalb der DKM werden verschiedene Nutzungskategorien festgelegt. Dabei werden Nutzungskategorien wie Gebäude, Straßenverkehrsanlagen oder Parkplätze zur Flächenversiegelung gezählt. Jährlich wird vom Umweltbundesamt eine Abschätzung der Flächenversiegelung basierend auf dem Datensatz der DKM aufgestellt.

Aus Tabelle 1 kann die Bodenversiegelung für die Stadt Innsbruck entnommen werden. Der Anteil an versiegelten Flächen stieg in den letzten Jahren an. Die Bundesregierung plant daher eine Reduzierung der Flächeninanspruchnahme. Der jährliche Zuwachs an versiegelten Flächen soll bis 2030 auf 2,5 ha pro Tag oder 9 km² pro Jahr sinken (Umweltbundesamt, 2023).

Tabelle 1: Flächeninanspruchnahme Innsbruck

Verwaltungseinheit	Stichtag	Versiegelte Flächen	
		ha	%
Innsbruck-Stadt	31.12.2012	893	29,0
Innsbruck-Stadt	31.12.2013	896	29,1
Innsbruck-Stadt	31.12.2014	896	29,1
Innsbruck-Stadt	31.12.2015	988	31,9
Innsbruck-Stadt	31.12.2016	991	32,0
Innsbruck-Stadt	31.12.2017	987	31,9
Innsbruck-Stadt	31.12.2018	995	32,2
Innsbruck-Stadt	31.12.2019	996	32,2

Quelle: BEV - Bundesamt für Eich- und Vermessungswesen: Regionalinformation. Die Originaldaten liegen für Katastralgemeinden vor und werden zum jeweiligen Jahresende auf Gemeindeebene aggregiert.

Aus Tabelle 2 ist ersichtlich, dass zwischen 1991 und 2021 die absolute Wohnbevölkerung in der Stadt Innsbruck deutlich zunahm. In diesem Zeitraum stieg die Wohnbevölkerung um etwa 10 %. Dennoch gab es zwischen 1991 und 2001 einen leichten Rückgang der absoluten Bevölkerung.

Tabelle 2: Entwicklung der Wohnbevölkerung

Jahr	Personen	
	Innsbruck-Stadt	Tirol
1991	118.112	631.410
2001	113.392	673.504
2011	119.617	709.319
2021	131.059	760.105

Quelle: Statistik Austria, (bis inkl. 2001) Volkszählung, (ab 2011) Registerzählung

Trotz sinkender Wohnbevölkerung zwischen 1991 und 2001 gab es einen Zuwachs an Gebäuden. Dementsprechend ergibt sich eine erhöhte Flächeninanspruchnahme. Die Anzahl an Gebäuden stieg fortlaufend an. Zwischen 2011 und 2021 kam es zu einem signifikanten Zuwachs an Gebäuden in Innsbruck.

Tabelle 3: Gebäudeanzahl

Jahr	Gebäude	
	Innsbruck-Stadt	Tirol
1991	11.448	138.537
2001	11.984	161.261
2011	12.656	177.745
2021	16.027	208.599

Quelle: Statistik Austria, Gebäude und Wohnungsregister

Rasterdaten können beansprucht werden, um versiegelte Flächen in Innsbruck zu erfassen. In dieser Arbeit werden frei verfügbare DOP des Landes Tirols eingesetzt. Historische Daten bieten eine Möglichkeit an, um das Untersuchungsgebiet über einen längerer Zeitraum zu beobachten (Martha et al., 2012). Die aktuellen Farborthophotos sind aus digitalen 4-Kanalbildern produziert. Fernerkundungsdaten bieten eine effektive Möglichkeit an, um die Veränderung der Bodenbedeckung wahrzunehmen. Mit Langzeitstudien kann eine Analyse und Auswertung des städtischen Raumes durchgeführt werden (Liu and Yang, 2015).

Die steigende Verfügbarkeit an Fernerkundungsdaten zusammen mit einem Geoinformationssystem (GIS) bildet eine weitverbreitete Methode, um die Bodenversiegelung Kartieren und Bewerten zu können (Peroni et al., 2022). Diese Daten können über eine hohe räumliche Auflösung verfügen und ein großes Untersuchungsgebiet erfassen. Ein hoher Detailgrad vereinfacht die Erkennung und Ableitung von verschiedenen Objekten auf der Erdoberfläche (Lu and Weng, 2006).

Fortschritte in der Fernerkundung haben nicht nur die Datenverfügbarkeit erhöht, sondern auch die technischen Merkmale der Sensoren sind gestiegen. Mit hochauflösenden Fernerkundungsdaten kann die Landschaftsbedeckung mit einem hohem Detailgrad erfasst werden, auch wenn im städtischen Raum Dächer und andere Gebäude aus unterschiedlichen Materialien bestehen. Eine präzise und genaue Klassifizierung bleibt eine Herausforderung (N. et al., 2019).

Mehrere bekannte Programme in Kombination mit Fernerkundungsdaten und GIS stehen zur Verfügung. Diese werden eingesetzt, um die Städteentwicklung beurteilen zu können.

Mit dem Erdbeobachtungsprogramm Copernicus, kann die Stadtentwicklung in vielen europäischen Ländern verfolgt werden. Mit solchen Informationsdiensten kann die Landschaftsveränderung gesichtet und analysiert werden.

Unterschiedliche Erdobjekte zeigen verschiedene physikalische Eigenschaften. Je nach Form, Größe oder Struktur bieten sich unterschiedliche Klassifizierungsmethoden an (Wang and Li, 2019). Mehrere Methoden wurden in der Vergangenheit verwendet, um die Bodenversiegelung zu Kartieren. Von der visuellen Bildinterpretation bis hin zu fortgeschrittenen Modellierungen (Peroni et al., 2022).

Um die Bodenversiegelung in Innsbruck zu bestimmen, werden Verfahren aus dem Bereich der KI eingesetzt (Abbildung 1). Algorithmische Grundlage bilden die SVMs und das PSPNet. Beide Verfahren sind in der Fernerkundung bekannt, um eine Landschaftsklassifizierung durchführen zu können.




Abbildung 1: Teilbereiche der Künstlichen Intelligenz

Der Begriff KI stammt aus den 1950er Jahren und beschäftigt die Menschheit schon seit längerem. Die Verbindung von menschlicher Intelligenz und Computern ist ein Wunsch vieler Computerexperten. Der Fortschritt im Bereich der KI wird durch die große Verfügbarkeit an Datenmengen, eine steigende Rechenleistung und laufend verbesserte Algorithmen begünstigt. KI lässt sich für das Monitoring großer Datenmengen oder das Auffinden von Mustern nutzen (Scherk et al., 2017).

Machine Learning (ML) bildet einen Teilbereich der Künstlichen Intelligenz ab. Jordan and Mitchell (2015) beschreiben ML als eines der am schnellsten wachsenden technischen Gebiete der heutigen Zeit. Im Bereich der künstlichen Intelligenz hat sich die Methode des maschinellen Lernens für die Entwicklung von Computer Vision, Spracherkennung, Robotersteuerung und weiteren Anwendungen bewährt. Beim maschinellen Lernen erhält das KI-System Trainingsdaten, um das Modell laufend verbessern zu können. Dies geschieht mit allen notwendigen Funktionen und Entscheidungsregeln und passt dies anhand von Rückmeldungen an (Scherk et al., 2017).

Deep Learning (DL) verzeichnete in den vergangenen Jahren im Bereich der Fernerkundung einen enormen Aufschwung. Diese Algorithmen erzielen im Aufgabenbereich der Bildklassifizierung gute Erfolge. DL ist ein Verfahren, welches in Form von neuronalen Netzwerken angewendet wird. Speziell die Klassifizierung der Landbedeckung und die der Objekterkennung zeichnen dieses Verfahren aus (Ma et al., 2019).

DL-Ansätze nutzen Trainingsdaten um daraus Bildklassifizierungen zu ermöglichen. Die Klassifizierung der Landnutzung mit neuronalen Netzwerken hat in der Regel eine hohe Klassifizierungsgenauigkeit zur Folge (N. et al., 2019). Im Bereich der Computer Vision Domäne haben DL-Ansätze sich bewährt und haben in der Analyse von Fernerkundungsdaten ihren Platz gefunden (Krizhevsky et al., 2012).

1.2 Forschungsstand

In der Literatur findet man zum Thema Ableitung von versiegelten Flächen mit Fernerkundungsdaten eine große Anzahl an Publikationen. Es gibt viele Möglichkeiten und Verfahren, um die Bodenversiegelung mit Fernerkundungsdaten zu erfassen. Verschiedene Klassifizierungsverfahren im Zusammenhang mit hochauflösenden Daten werden daher von vielen Wissenschaftler herangezogen.

García et al. (2014) ermitteln versiegelte Flächen auf Basis von überwachten und unüberwachten Bildklassifizierungsmethoden. Datengrundlage bilden Satellitenaufnahmen in Madrid zwischen 1989 und 2010. Das Untersuchungsgebiet wurde bei der überwachten Bildklassifikation in zwei Kategorien (versiegelte und unversiegelte Böden) aufgeteilt. Die Zuverlässigkeit wurde mit den Ergebnissen einer manuellen Kartierung gegenübergestellt. In einigen Bereichen kommt es vor, dass versiegelte Flächen falsch erkannt werden. Einschränkungen aufgrund ähnlicher spektraler Eigenschaften können auftreten. Die Autoren bevorzugen die Anwendung einer überwachten Klassifizierungsmethode.

Mohamed et al. (2015) erfassen die Veränderung der Bodenversiegelung mit mehreren Algorithmen aus dem Bereich des maschinellen Lernens. Datengrundlage bilden Landsat 7 und Landsat 8 Satellitenaufnahmen. Dabei zeigt sich, dass die SVMs und die neuronalen Netzwerke die besten Ergebnisse erzielen. Bemessen an der Gesamtgenauigkeit erlangen beide Verfahren über 95 %. Somit kann von einer sehr guten Klassifizierung gesprochen werden.

Hendawy et al. (2019) verwenden SVM, um die Landschaftsnutzung zu bestimmen. Diese mathematische Methode baut auf einen statistischen Ansatz zur Klassifizierung von Objekten auf. Dieses Verfahren lässt eine zuverlässige Klassifizierung bei gemischter Landschaftsnutzung innerhalb eines Datensatzes zu.

Es gibt Studien, welche den NDVI mit Methoden des maschinellen Lernens verknüpfen. Zhao et al. (2022) klassifizieren die Landschaftsbedeckung mit NDVI und einer Deep Learning-Architektur. Der NDVI kann neben den herkömmlichen Bildbänder als zusätzliche Eingangsquelle genutzt werden. DL kann nicht nur spektrale Informationen extrahieren, sondern auch kontextbezogene semantische Merkmale lernen, welche für die Genauigkeit von hochauflösenden Fernerkundungsdaten entscheidend sind.

In vielen europäischen Ländern sind mehr als 10 % der Landfläche urbanisiert. Als Resultat werden große Landschaftsflächen zu künstlichen Flächen umgewandelt. Diese werden hauptsächlich als Transport und Siedlungsflächen genutzt. Die Ausbreitung städtischer Lebensform ist einer der Hauptgründe, warum der Boden mit undurchlässigen Oberflächen überlagert wird (EU-Kommision, 2012). Aus diesem Grund gibt es flächendeckende Erdbeobachtungsprogramme, welche die Bodenversiegelung beinahe in ganz Europa überwachen. Aus satellitengestützten Verfahren sind halbautomatisch abgeleitete Datensätze wie der IMD-Layer entstanden.

1.3 Zielsetzung

Ziel dieser Arbeit ist es, eine Zeitserie der Stadt Innsbruck zu entwickeln. Die Erfassung der Bodenversiegelung wird im Zeitraum von 1999 bis 2019 mit Anwendung der objektbasierten Bildanalyse und eines Deep Learning-Ansatzes in Form von neuronalen Netzwerken durchgeführt. Die Versiegelungsdatensätze liefern den Anteil an verbauten Flächen der letzten 20 Jahre. Diese Arbeit soll zeigen, in welchen Stadtteilen es zu einem Zuwachs an versiegelten Flächen kommt. Ausgangspunkt zur Erfassung der Bodenversiegelung bilden aktuelle und historische flugzeuggestützte Fernerkundungsdaten vom Land Tirol.

Die Wichtigkeit besteht primär darin, den versiegelten Anteil in der Stadt Innsbruck möglichst genau abschätzen zu können. National stammen Informationen zur Flächenversiegelung aus den Angaben der Regionalinformation. Diese Daten werden aus der DKM erhoben. Auf europäischer Ebene bietet das Copernicus Programm einen Datensatz an, um in zyklischen Abständen den Bodenverbrauch flächendeckend zu erfassen. Die gewählten Datensätze in dieser Arbeit haben im Vergleich zum Copernicus IMD-Layer eine höhere Detailstruktur. Die räumliche Auflösung der DOP liegt zwischen 20 und 25 cm.

Mit Anwendung von überwachten Klassifizierungsverfahren sollen die undurchlässigen Flächen aus öffentlichen Orthophotos abgeleitet werden. DOP in Echtfarbe aus den Jahrgängen 1999, 2009 und 2019 werden herangezogen. Zusätzlich wird untersucht, wie sich der Nahinfrarotkanal im aktuellen Datensatz aus 2019 auf das Klassifizierungsergebnis auswirkt. Insgesamt sollen für jeden methodischen Ansatz vier Versiegelungsraster entstehen.

Als erster methodischer Ansatz wird die objektbasierte Bildanalyse gewählt. Technische Grundlage bilden hier die SVMs. Als zweites Verfahren wird eine Deep Learning-Architektur behandelt. Das Erkennen und Klassifizieren von undurchlässigen Flächen wird mit dem PSPNet durchgeführt. Es wird untersucht, welche Methodik sich besser eignet. Nicht nur die erzielte Genauigkeit des Versiegelungsraster, sondern auch der zeitliche Aufwand wird berücksichtigt.

Neben der binären Unterscheidung ob ein Pixel Versiegelt oder Unversiegelt ist, wird zusätzlich der Versiegelungsgrad bestimmt. Die Modellierung des Versiegelungsgrades wird aus den klassifizierten Orthophotos abgeleitet. Der Versiegelungsgrad wird auf verschiedene Bezugseinheiten aggregiert.

Eine wichtige Rolle spielt der Vergleich mit bestehenden Methoden. Die erfasste Flächenversiegelung aus den flugzeuggestützten Fernerkundungsdaten wird einem nationalen und einem satellitengestützten Verfahren gegenübergestellt.

Die praktische Umsetzung soll es ermöglichen, versiegelte Flächen aus historischen und aktuellen Farborthophotos ableiten zu können.

2 Methodik

2.1 Untersuchungsgebiet

Die Stadt Innsbruck bietet aktuell für 130.000 Menschen einen Lebensraum. Die Stadt weist eine Fläche von insgesamt 105 km² auf. Innsbruck ist die Landeshauptstadt von Tirol und gleichzeitig die bevölkerungsdichteste Stadt im ganzen Bundesland. Ein Drittel der gesamten Tiroler Bevölkerung ist in Innsbruck wohnhaft. Das Untersuchungsgebiet hat insgesamt zwanzig Stadtteile, welche in Abbildung 2 zu finden sind. Die Region ist für die Suburbanisierung und den erhöhten Siedlungsdruck bekannt. Die genannten Daten werden von der Tiroler Landesregierung Abteilung Raumordnung und Statistik zur Verfügung gestellt (Tirol, 2022).

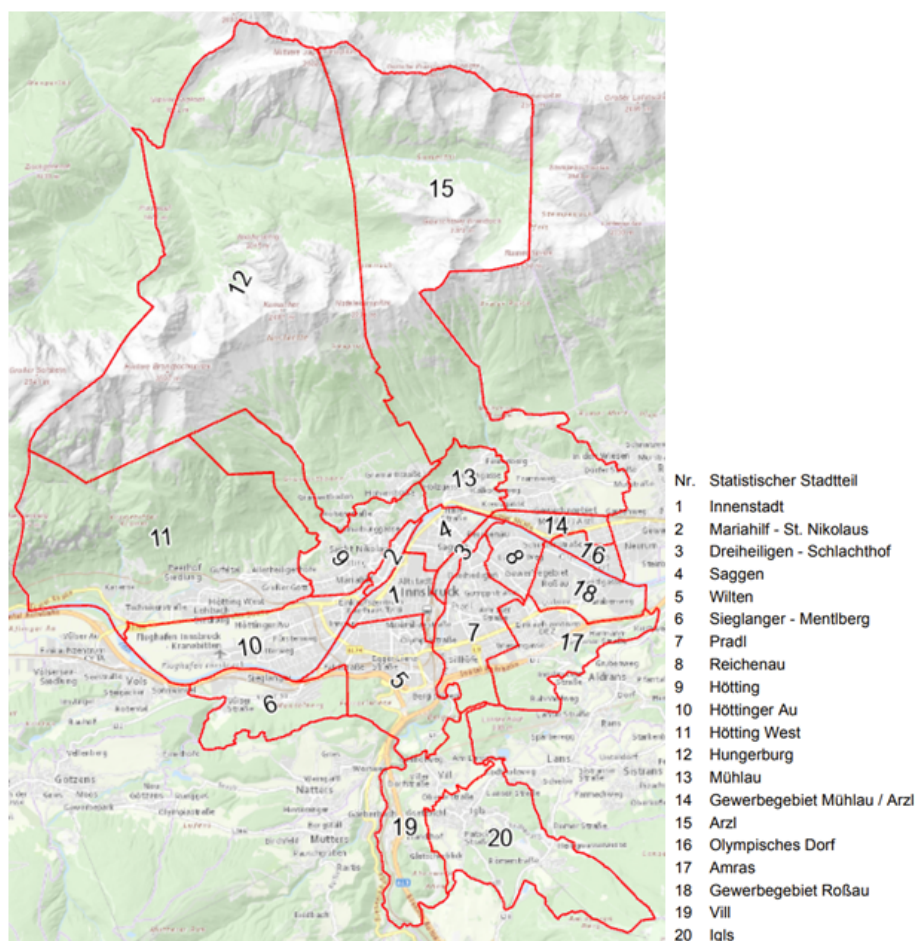


Abbildung 2: Einteilung der Stadtteile von Innsbruck

Aufgrund des hohen alpinen Flächenanteils in Tirol, spielt der DSR eine wichtige Rolle. Diese Abgrenzung inkludiert Siedlungen, Infrastruktureinrichtungen und landwirtschaftliche Flächen. Landschaftsklassen wie Wald, alpines Grünland oder Gewässer werden abgezogen. Grundsätzlich ist jener Raum zu werten, welcher vom Menschen dauerhaft als Lebensraum benutzt wird.

Mit der Zuordnung von statistischen Kennwerten wie Bevölkerungs- und Beschäftigtenzahlen durch die Statistik Austria und mit deren Zuweisung zu Rastern sind flexible Aggregationen möglich. Für die Erstellung sind Wohn- und Arbeitsplatzdichte, digitale Landnutzungsdaten aus dem CORINE Programm und Daten des Digital Terrain Model (DTM) berücksichtigt worden. (WONKA, 2008).

Der DSR wird in dieser Arbeit mit den DOP von Innsbruck verschnitten, so dass nur noch der Siedlungsraum innerhalb der Stadt Innsbruck überbleibt. Insgesamt fasst dieser eine Fläche von 35,2 km². Der stark bewohnte Teil von Innsbruck macht ein Drittel der gesamten Gemeindefläche aus. In Abbildung 3 ist der DSR ersichtlich. Im Norden von Innsbruck findet man größtenteils alpines Grünland, Waldflächen und Gebirgszüge. Aus diesem Grund baut diese Arbeit ausschließlich auf die Erfassung im DSR auf.

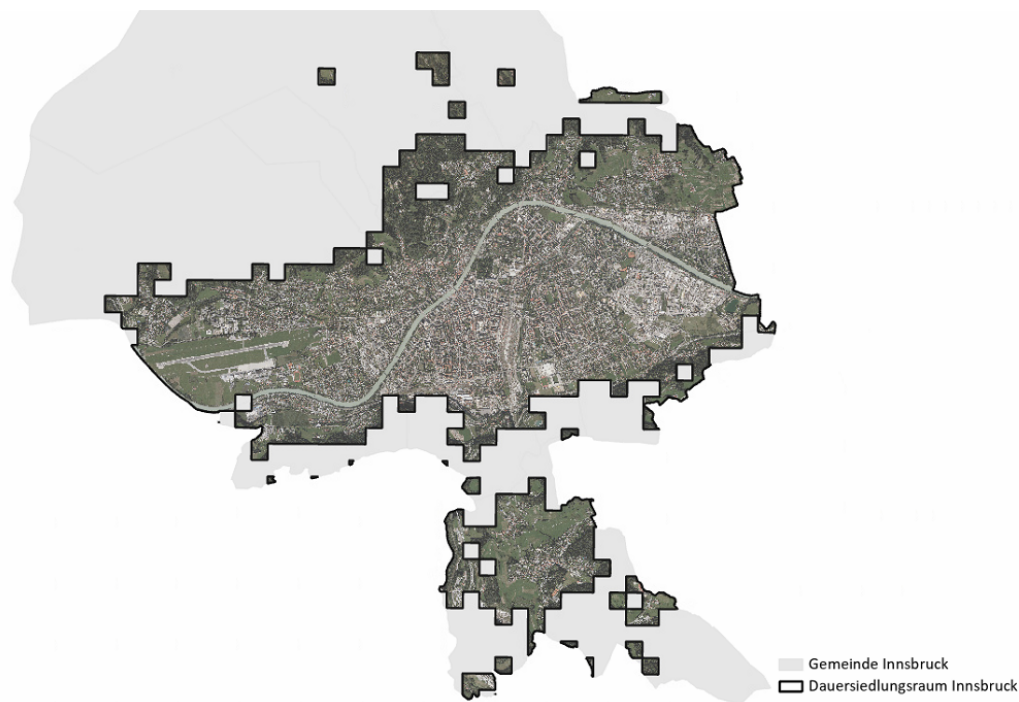


Abbildung 3: Dauersiedlungsraum der Stadt Innsbruck

2.2 Datengrundlage

Datengrundlage dieser Arbeit bilden hochauflösende Orthophotos aus verschiedenen Jahrzehnten. Grundsätzlich unterscheidet man bei geographischen Daten zwischen dem Vektormodell und dem Rastermodell. Beim Vektormodell werden räumliche Informationen durch Punkte aufgelöst, die dann als Koordinaten erfasst werden. Die Koordinaten werden als Zahlenwert kodiert. Beim Rastermodell wird raumbezogene Information durch ein Raster von kleinen Flächen repräsentiert. Digitale Luftbild- und Satellitenaufnahmen zeigen räumliche Informationen in Form von Rasterdaten. Das Interessengebiet wird als Matrix von Pixeln dargestellt. DOP aus Luftbildaufnahmen zählen zum Rastermodell (De Lange, 2006).

Im allgemeinen bildet ein Orthophoto die Erdoberfläche ab. Es ist ein entzerrtes und georeferenziertes Bildmosaik, welches aus Luftbildern erzeugt wird (Tirol, 2022). Um nun Rasterdaten zu visualisieren benötigt es Farbinformation. Der Mensch kann nur einen kleinen Teil des elektromagnetischen Spektrums wahrnehmen. Das sogenannte sichtbare Spektrum. Grundlegend für die Geoinformatik und die Fernerkundung ist das Verständnis von Farben. Das RGB-Farbmodell benutzt ein dreidimensionales kartesisches Koordinatensystem, dessen Achsen die Primärfarben Rot, Grün und Blau darstellen. Die Farben werden durch ihre drei Koordinaten kodiert. Für jede Achse (d.h. jede Grundfarbe) gilt eine ganzzahlige Skalierung von 0 (keine Farbe) bis 255 (voller Farbton). Bei einer Skalierung von 0 bis 255 pro Grundfarbe (8bit) gibt es insgesamt $2^{24} = 16.777.216$ mögliche Kombinationen bzw. Farben die kodiert und gespeichert werden (De Lange, 2006). Bei einer Farbtiefe von 16 bit erhält man 2^{16} mögliche Kombinationen pro Grundfarbe. Die Aktualisierung der Orthophotos erfolgt Bundesweit alle 3 Jahre. Abbildung 4 zeigt den aktuellen Datenbestand für das Bundesland Tirol. Die Rasterdaten sind frei zugänglich und können in ein GIS eingebunden werden.




Abbildung 4: Aktueller Datenstand der Orthophotos, Quelle: Land Tirol, Abteilung Geoinformation (Stand Mai 2022)

2.3 Historische Orthophotos

Die Rekonstruktion und Erfassung von historischen Daten ist eine anspruchsvolle Aufgabe, welche in letzter Zeit an wissenschaftlicher Interesse gewonnen hat (Ratajczak et al., 2019). Zur Feststellung der Landschaftsveränderung in Bezug auf die versiegelten Flächen, wird eine Zeitreihe aus historischen Orthophotos ausgearbeitet. Historische Luftaufnahmen liefern uns wichtige Informationen zur Landschaftsbedeckung und Landschaftsnutzung aus den vergangenen Jahrzehnten. Historische Daten zeichnen sich durch begrenzte spektrale und geringe räumliche Informationen aus (N. et al., 2020). Dies macht es schwieriger, ein genaues Klassifizierungsergebnis zu erlangen. Die Feststellung der Landschaftsveränderung, lässt sich über einen längeren Zeitraum mit solchen Daten ermitteln. Dennoch ist die Verfügbarkeit und Nutzung dieser Datensätze oft sehr begrenzt. Seit den 1930er Jahren werden im Bereich der Photogrammetrie und Fernerkundung Luftbilder in verschiedensten Teilen der Welt aufgenommen (Luman et al., 1997).

Luftbilder und Orthophotos, welche nicht aus der aktuellen Befliegung entstammen, gelten als historisch. Im Zeitraum zwischen 1949 und 2009 wurden analoge Luftbilder durch das BEV hergestellt. Darunter mit Schwarz-Weiß-, Farbpositiv-, Farbnegativ- oder Infrarot Farbpositivfilm. Diese besitzen unterschiedliche Bildformate, Brennweiten, Flughöhen oder Überdeckungsverhältnisse. Die Farboroughphotos werden seit den 2000er Jahren aus Mehrzweckflug-Farbluftbildern produziert. Die räumliche Auflösung (Pixelgröße) dieser Daten liegt bei 25 cm (BEV, 2019).

In dieser Masterarbeit werden historische Orthophotos aus den Jahrgängen 1999 und 2009 verwendet. Diese Datensätze liegen in der RGB Kombination vor. Aus diesem Grund werden sowohl die historischen als auch der aktuelle Datensatz im sichtbaren Spektralbereich (0,4-0,7 μm) klassifiziert. Die Bodenversiegelung wird in einem Fortführungszyklus von 10 Jahren untersucht. Die Parameter der Rasterdatensätze können aus Tabelle 4 entnommen werden.

Tabelle 4: Metadaten der historischen Orthophotos

Räumliche Auflösung	25 cm
Flugjahr	1999, 2009
Quelle	BEV, Land Tirol
Zeitliche Auflösung	3-5 Jahres Zyklus
Spektralkanäle	Rot
	Grün
	Blau
Bittiefe	8bit/Kanal

Abbildung 5 zeigt beide historischen Datensätze, welche für die Klassifizierungen im DSR verwendet werden. Der Datensatz aus 1999 ist der älteste, welcher aus Mehrzweck-Farbluftbilder generiert wurde. Alle anderen Befliegungen zwischen 1940 und 1990 sind noch auf Basis von Schwarz-weiß Aufnahmen. Auf die Klassifizierung mit Schwarz-Weißorthophotos wird verzichtet, da diese Aufnahmen nur einen Kanal zur Verfügung haben.

(N. et al., 2020) zeigen, dass mit Anwendung von neuronalen Netzwerken und der objektbasierten Bildanalyse historische panchromatische Luftbilder klassifiziert werden können. Es wurden Klassen wie Gebäude, Vegetation und Ackerland gebildet. Gesamtgenauigkeiten von über 85 Prozent konnten mit den Daten aus 1940 und 1950 erreicht werden. Wenn bei panchromatischen Daten allerdings die Anzahl der Klassen steigt, nimmt die Schwierigkeit der Ableitung deutlich zu.

(Ratajczak et al., 2019) vergleichen mehrere Methoden und Algorithmen um historische monochromatische Luftbilder zwischen 1970 und 1990 zu klassifizieren. Darunter verschiedene ML-Algorithmen wie *K-nearest neighbors*, *Random Forest (RF)* oder auch die SVMs. Auch Deep Learning-Architekturen wurden in dieser Studie miteinbezogen.



Abbildung 5: Historische Orthophotos (oben 2009 unten 1999) in der RGB Darstellung

2.4 Aktuelles Orthophoto

Das aktuelle Orthophoto zeichnet sich durch verbesserte Parameter aus. Eine höhere räumliche Auflösung, bessere Überdeckungsverhältnisse und der zusätzliche Nahinfrarot Kanal bieten Vorteile gegenüber den historischen Datensätze. Ein homogener radiometrischen Farbverlauf ist durch das gesamte Interessengebiet gegeben. All diese Eigenschaften wirken sich positiv auf die Erstellung der Trainingsgebiete und die Klassifizierung aus.

Die aktuellste Befliegung im Raum Innsbruck stammt aus dem Jahr 2019. Dies kann aus Abbildung 4 entnommen werden. Neben den Schwarzweißaufnahmen, zählen auch die älteren Farborthophotos zu den historischen Datensätze (BEV, 2019).

Durch die Kombination der drei sichtbaren Kanälen Rot, Grün und Blau wird das RGB-Echtfarbenbild gebildet. Dies kann aus Abbildung 6 entnommen werden.



Abbildung 6: Aktuelles Orthophoto in der RGB Darstellung

Seit 2010 werden die Befliegungen mit digitalen, großformatigen Luftbildkameras durchgeführt. Die erzeugten Rasterdatensätze sind in Echtfarbe, Falschfarbe oder als 4-Kanalbild (RGBI) zu finden. Die CIR Kombination wird aus den Kanälen NIR, Rot und Grün zusammengesetzt. Ein zusätzlicher NIR Kanal bietet den Vorteil, um zwischen Vegetation und künstlichen Objekten unterscheiden zu können (Knudsen and Olsen, 2003). Die Vegetation wird im Orthophoto rötlich dargestellt, da der Pflanzenfarbstoff Chlorophyll oder Blattgrün im NIR Bereich besonders stark reflektiert wird (LGLN, 2023). Das Verhalten der Vegetation im NIR Bereich kann aus Abbildung 12 entnommen werden. Das DOP in der CIR Darstellung ist in Abbildung 7 zu sehen.



Abbildung 7: Aktuelles Orthophoto in der CIR Darstellung

Das aktuelle Orthophoto steht mit einer räumlichen Bodenauflösung von 20 cm zur Verfügung. Da die historischen Datensätze noch keinen NIR Kanal besitzen, wird das aktuelle Orthophoto aus 2019 auch in der Kombination RGB klassifiziert.

Tabelle 5 fasst die wichtigsten Metadaten des aktuellen Datensatzes aus 2019 zusammen. Dieser Rasterdatensatz ist der einzige, welcher über einen Kanal im Nahinfrarot Bereich verfügt.

Tabelle 5: Metadaten des aktuellen Orthophoto

Räumliche Auflösung	20 cm
Flugjahr	2019
Quelle	BEV, Land Tirol
Zeitliche Auflösung	3-5 Jahres Zyklus
Spektralkanäle	Rot
	Grün
	Blau
	Nahinfrarot
Bittiefe	16bit/Kanal

Das aktuelle Orthophoto steht mit einem Blattschnitt von 1:2000 zur Verfügung. Die Stadt Innsbruck wird insgesamt von 120 Kacheln erfasst. Abbildung 8 zeigt das Untersuchungsgebiet mit dem aktuellen Rasterdatensatz aus 2019. Die Blätter des Orthophotos sind mit dem Vektordatensatz des Dauersiedlungsraums verschnitten.

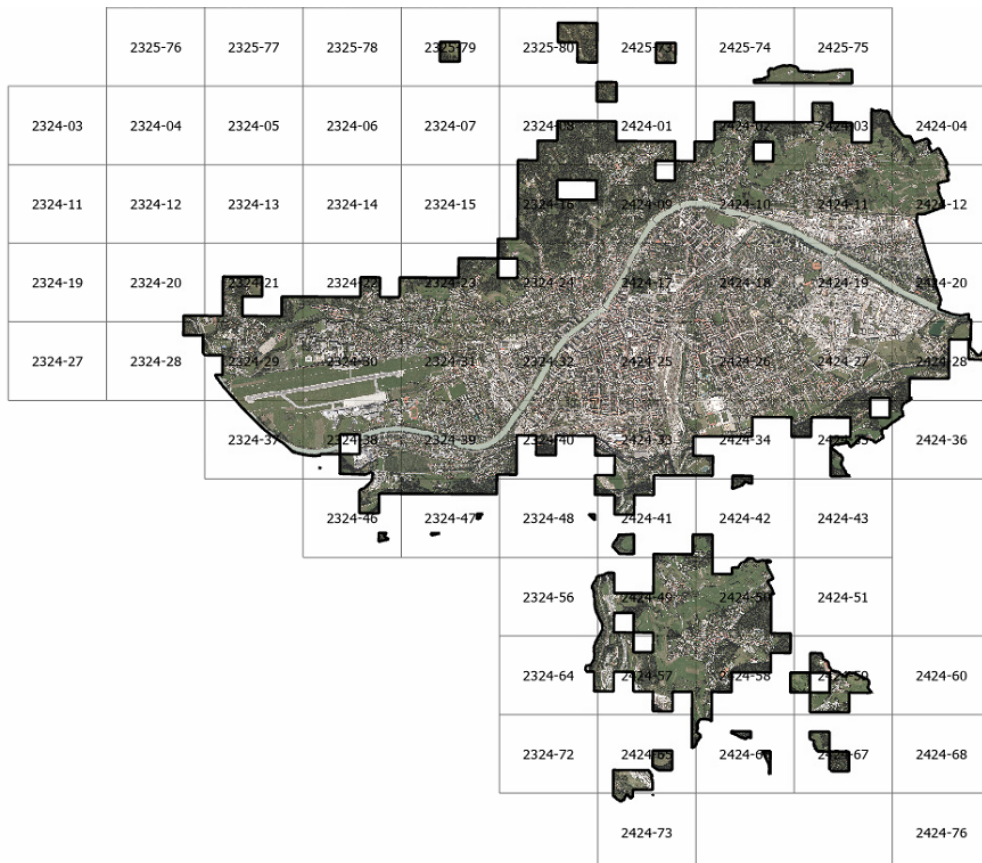


Abbildung 8: Untersuchungsgebiet samt Blattschnitt

2.5 Erfassung der Bodenversiegelung aus flugzeuggestützten Fernerkundungsdaten

Im Allgemeinen ist die Fernerkundung eine Wissenschaft, welche sich mit der Aufnahme und Schaffung von räumlicher Information beschäftigt. Dabei werden Objekte und Körper mit einem Sensor aufgenommen, welche nicht direkt in Kontakt stehen (Lillesand et al., 2015). Die Erfassung der Orthophotos ist auf Basis von passiven Sensoren generiert. Die Aufnahme wird in der Regel mit erdnahen Satelliten, Flugzeugen und Drohnen abgewickelt. Diese Systeme sind abhängig von der reflektierten Strahlung der Sonne oder der emittierten Strahlung anderer Objekte welche sich auf der Erdoberfläche befinden. Abbildung 9 zeigt den Ablauf von der passiven Datenbeschaffung bis hin zur Dateninterpretation.

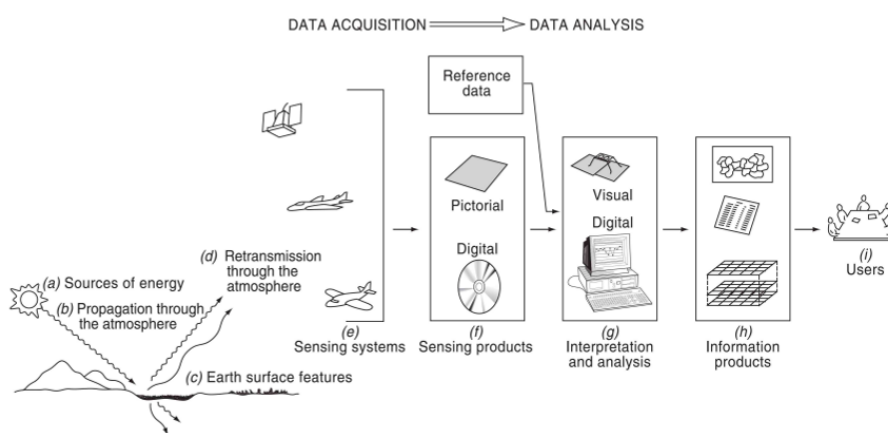


Abbildung 9: Fernerkundung der Erdoberfläche (Lillesand et al., 2015)

Die notwendigen Elemente für die Datenbeschaffung sind Energiequelle (a), Ausbreitung der Energie durch die Atmosphäre (b), Energie welche mit den Objekten der Erdoberfläche interagiert (c), Weiterübertragung der Energie durch die Atmosphäre (d), Sensorsystem (e), Erstellung und Prozess der räumlichen Daten in digitaler oder bildhafter Form (f). Allgemein werden Fernerkundungssensoren genutzt, um Objekte und Körper, welche sich auf der Erde befinden aufzunehmen. Dabei ist die reflektierte und emittierte elektromagnetische Strahlung des Körpers entscheidend (Lillesand et al., 2015).

2.6 Versiegelte Flächen

Sichtbares Licht ist eine von vielen Formen der elektromagnetischen Strahlung. Grundsätzlich wird die elektromagnetische Strahlung anhand der Wellenlänge beschrieben. Die Wellenlänge wird dabei mit folgender Formel beschrieben.

$$c = f\lambda \quad (1)$$

Die *Wellenlänge* λ ist die Distanz oder Entfernung von einer Wellenspitze bis zur nächsten Wellenspitze. Man spricht von einer Periode. Die *Frequenz* f ist dabei die Anzahl der Perioden oder Zyklen pro Sekunde. Die Lichtgeschwindigkeit c wird konstant mit $3 \times 10^8 \frac{m}{s}$ definiert (Lillesand et al., 2015).




Abbildung 10: Elektromagnetische Welle mit Komponenten (Lillesand et al., 2015)

Je nach Wellenlänge ergibt sich somit eine andere Form der elektromagnetischen Strahlung. Die Größenordnung der jeweiligen Strahlung wird in Zehnerpotenzen angegeben. Die Darstellung basiert auf einer logarithmischen Skalierung (Lillesand et al., 2015). Innerhalb des sichtbaren Spektrums bewegt sich die Wellenlänge zwischen $0,4\text{-}0,7 \mu\text{m}$, wie in Abbildung 11 ersichtlich. Die Farbborthophotos sind innerhalb des sichtbaren Bereichs. Der NIR Bereich weist eine Wellenlänge $> 0,7 \mu\text{m}$ auf. Dies kann aus Abbildung 11 entnommen werden. Seit 2010 steht den Rasterdatensätze dieser Kanal zusätzlich zur Verfügung.




Abbildung 11: Elektromagnetisches Spektrum (Lillesand et al., 2015)

Im generellen basiert die Erfassung der Erdoberfläche mit passiven Sensoren anhand der Reflexionskurve. Je nach Aufnahmekanal und elektromagnetischem Spektrum wird die reflektierte und emittierte Strahlungsleistung aufgezeichnet. Somit ist bei Fernerkundungsdaten festzuhalten, dass die Information in Abhängigkeit von der physikalischen Eigenschaft des Materials beziehungsweise des Erdkörpers steht (Üreyen and Thiel, 2017). Anhand der spektralen Reflexionskurve kann gesehen werden, wie sich versiegelte Flächen im sichtbaren Spektrum verhalten. Aus Abbildung 12 geht hervor, dass Asphalt im sichtbaren Bereich weniger als 20 Prozent der Strahlung wieder zurück reflektiert. Andere natürliche Objekte wie Boden, Grünflächen oder Schnee liefern deutlich mehr Reflexion. Im Zuge der Klassifizierung weisen die versiegelten Flächen eine genaue Charakteristik auf.

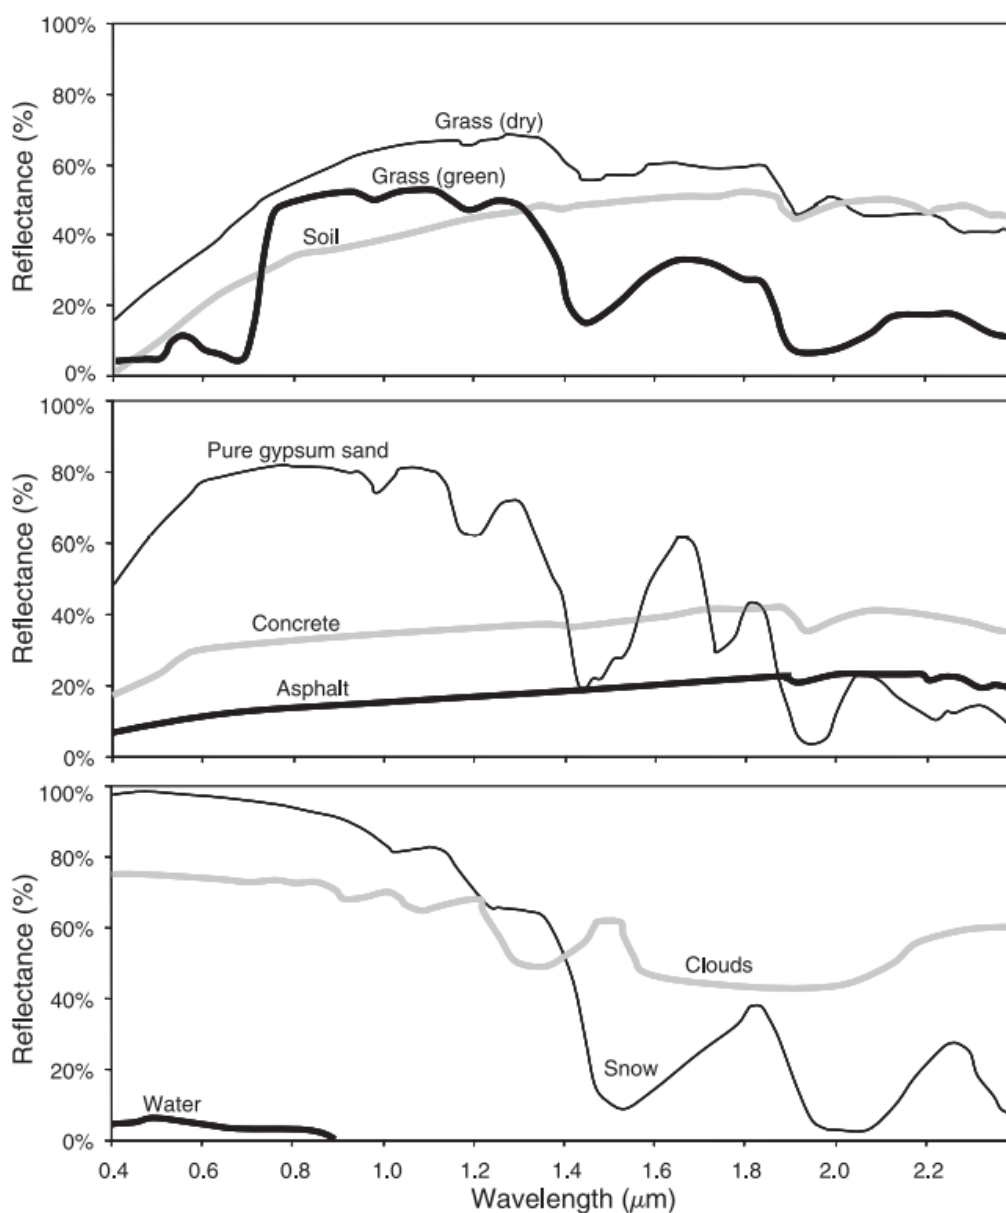


Abbildung 12: Spektrale Reflexionskurve für verschieden Objekte (Lillesand et al., 2015)

Mit zunehmender Umwandlung von landwirtschaftlichen Flächen und Grünland zu versiegelten Flächen, wird weniger Strahlung aus der Erdatmosphäre zurück reflektiert. Dies hat den negativen Effekt, dass sogenannte städtische Wärmeinseln gefördert werden. Durch einen großen Anteil an versiegelten Flächen bleibt die Hitze in der Stadt erhalten. Die natürliche Kühlung im städtischen Raum sinkt.

Bei hochauflösenden Orthophotos bleiben bei der Klassifizierung von versiegelten Flächen gewisse Unsicherheiten bestehen.

Im dichten Siedlungsraum muss man bei bestimmten Bereichen, mit sogenannten Mischpixeln rechnen. Diese entstehen, sobald mehrere Klassen sich ein Pixel teilen (Üreyen and Thiel, 2017).

Zudem kann es zu Verwechslungen kommen, wenn die Struktur zweier Materialien sich ähnelt. Beispielsweise hat die Farbe des Inns ähnliche spektrale Eigenschaften wie Straßenanlagen. Und Gebäudedächer mit Grünflächen werden als unversiegelt identifiziert. Wie in Abbildung 13 ersichtlich, werden Gebäudedächer mit Grünflächen automatisch falsch als unversiegelt klassifiziert.



Abbildung 13: Fehlklassifizierung begrünter Dächer

Alle anderen undurchlässigen Flächen wie Gebäude (ohne Gründach), Gebäudenebenflächen, Betriebsflächen, Straßenverkehrsanlagen, Verkehrsrandflächen, Parkplätze, Schienenverkehrsanlagen oder Freizeitanlagen können größtenteils richtig abgeleitet werden.

Im Untersuchungsgebiet gibt es mehrere verschiedene Arten der Bodenversiegelung. Versiegelte Flächen unterscheiden sich letztendlich anhand der Struktur und deren chemischen Zusammensetzung (Üreyen and Thiel, 2017). Verschiedene Arten der Versiegelung können aus Abbildung 14 entnommen werden.



Abbildung 14: Versiegelungsarten

Abbildung 14A zeigt in der Maria-Theresien Straße die Nutzungsarten Gebäude (blau) und Straßenverkehrsanlagen (rot). Der Hauptbahnhof von Innsbruck (Abbildung 14B) zeigt in Orange die Schienenverkehrsanlagen. Grün im Bild, stellt eine unversiegelte Fläche dar.

Üreyen and Thiel (2017) nutzen für die Erzeugung der Trainingsdaten von versiegelten Flächen und letztendlich deren Klassifizierung den NDVI. Grundsätzlich zeigt sich, dass gesunde Vegetation im roten Kanal (Wellenlänge zwischen 0,6-0,7 μm) noch wenig reflektiert. Hingegen wird im NIR Bereich (Wellenlänge $> 0,7 \mu\text{m}$) ersichtlich, dass relativ viel Strahlung reflektiert wird. Die Kombination aus beiden Kanälen, bildet die Grundlage der Darstellung. Mit folgender Formel lässt sich der Rasterdatensatz als NDVI beschreiben.

$$NDVI = \frac{NIR - ROT}{NIR + ROT} \quad [-1, 1] \quad (2)$$

Die Klassifikation auf Basis des NDVI dient dazu, um den erfassten Bodenverbrauch mit dem RGB Datensatz gegenüberstellen zu können. Dies soll zeigen, ob mit zusätzlichem NIR Kanal ein verbessertes Ergebnis hinsichtlich der Klassifizierungsgenauigkeit erzielt werden kann.

Der NDVI bildet ein Spektrum ab, welches den Zustand und die Dichte der Vegetation zeigt. Diese Darstellung bietet eine Hilfestellung an, um zwischen Vegetation und versiegelten Flächen unterscheiden zu können (Hiscock et al., 2021). Dieser Index kann herangezogen werden, um die Klassen Wasser, Vegetation und Ackerland zusammen als Klasse der unversiegelten Flächen zu identifizieren (Üreyen and Thiel, 2017). Grundsätzlich liefert die Darstellung des NDVI Werte zwischen 1 und -1. Positive Werte repräsentieren einen erhöhten Grünanteil und zeigen gesunde Vegetation an. Dagegen zeigen kleine Werte wenig bis keine Vegetation. Dieser Index steht für die photosynthetische Aktivität und ist maßgeblich für die Biomasse, Kohlenstoffbindung und Artenvielfalt (Nagendra et al., 2013).

Die vegetationsbedeckten Flächen gelten als unversiegelt. Die vegetationslosen Flächen wie Asphalt und Beton, lassen sich daher gut von den unversiegelten Flächen unterscheiden. Aus Abbildung 12 kann das Verhalten verschiedener Objekte anhand des elektromagnetischen Spektrums für versiegelte und unversiegelte Objekte entnommen werden. Grünflächen und Böden zeigen eine hohe Reflexion im NIR Bereich an. Diese Objekte reflektieren etwa die Hälfte ihrer elektromagnetischen Strahlung wieder zurück. Asphalt reflektiert im sichtbaren Bereich ungefähr 10 Prozent und nimmt im Nahinfrarot Bereich noch etwas zu. Die unversiegelten und versiegelten Flächen lassen sich in der NDVI Darstellung gut trennen.

Abbildung 15 zeigt Innsbruck in der NDVI Darstellung. Die vegetationsbedeckten Klassen wie Grasland und Wald sind in der Abbildung Grün dargestellt. Ein Schwellenwert nahe 1 zeigt eine hohe Vegetationsbedeckung und deutet auf eine gesunde Vegetation hin. Die Klasse Ackerland zeigt einen gelben Farbverlauf und ist nahe dem Schwellenwert 0. Die vegetationstoten Klassen wie Gebäude, Infrastruktureinrichtungen oder Straßenverkehrsanlagen zeigen einen orange-roten Farbverlauf im Untersuchungsgebiet.

Im Gegensatz zur Klassenbildung der RGB Daten, werden Gebäude und andere versiegelte Flächen wie Verkehrswege nicht getrennt klassifiziert. Alle versiegelte Flächen werden zusammen in einer Klasse angelegt. Mit Hilfe der NDVI Darstellung verfügen sowohl verschiedene Gebäudedächer als auch Straßen über ähnliche Schwellenwerte. Die versiegelten Flächen befinden sich im negativen Wertebereich.

Die Wasserflächen wie der Inn, der Baggersee oder die Sill sind Rot dargestellt und verfügen auch über einen negativen Wert. Diese sind als Unterklasse der unversiegelten Flächen anzusehen.



Abbildung 15: Stadt Innsbruck in der NDVI Darstellung

Mit den Schwellenwerten lassen sich die vegetationsbedeckten und vegetationslosen Objekte voneinander abgrenzen (Üreyen and Thiel, 2017). Die erstellten Klassen und die dazugehörigen Werte für die Erfassung der versiegelten Flächen sind in Tabelle 6 zusammengefasst.

Tabelle 6: Unterteilung der Klassen in der NDVI Darstellung

Oberflächentyp	Klasse	NDVI Wert
Wasser	Unversiegelt	[-1,-0.5]
Versiegelung	Versiegelt	[-0.8,-0.1]
Ackerland	Unversiegelt	[0,0.1]
Vegetation	Unversiegelt	[0.2,0.6]

Hiscock et al. (2021) erzeugen eine Klassifizierung im Raum Innsbruck mit Hilfe des normalisierten Vegetationsindex. Dabei sind verschiedene Oberflächentypen wie Gewässer, Grasland oder undurchlässige Flächen definiert, um die Landschaftsbedeckung zu erfassen. Die Oberflächentypen sind anhand ihres NDVI und *Normalized Digital Surface Model (nDSM)* Wertes aufgebaut. Mit verfügbarem *Digital Surface Model (DSM)* und *DTM* kann ein nDSM erstellt werden. Unter Anwendung des NDVI und des nDSM werden multifunktionale Klassifizierungen der städtischen Bodenbedeckung erzeugt, die für verschiedene Stadtplanungsinstrumente wie der Wasserwirtschaft dienen.

$$nDSM = DSM - DTM \quad [0, \infty] \quad (3)$$

Das DTM beschreibt die Erdoberfläche ohne Bebauung, Vegetation und andere natürliche oder künstliche Objekte.

Das DSM beinhaltet alle Objekte, welche sich auf der Erdoberfläche befinden. Wo keine Objekte auffindbar sind, wird die Geländeoberfläche dargestellt.

Qin and Fang (2014) zeigen ebenfalls, dass ein zusätzliches Oberflächenmodell in Verbindung mit sehr hochauflösenden Bilddaten das Klassifizierungsergebnis im Interessengebiet steigern kann. Höheninformationen aus Laserscan-Punktwolken bieten beispielsweise die Möglichkeit der Gebäudeerkennung an. Mit dem berechneten nDSM können Punkte außerhalb des Geländes für die Gebäudeerkennung genutzt werden.

Sun and Wang (2018) nutzen Höheninformationen. Schwarze Bereiche in den Daten wie Schatten, können durch den Einsatz von Höhenmodellen teilweise verbessert werden. Da DSM und Bilddaten unterschiedliche Informationen besitzen, müssen beide in getrennten Netzwerken behandelt werden.

Eine Kombination aus Höheninformation und Bilddaten wird in dieser Arbeit nicht behandelt, da keine Höhenmodelle für die historischen Daten zur Verfügung stehen. Im Raum Innsbruck sind öffentliche Gelände- und Oberflächenmodelle erst seit dem Jahr 2006 verfügbar.

2.7 Überwachte Klassifizierung

Aus dem Teilbereich des maschinellen Lernens ist die überwachte Klassifizierung (*Supervised Classification*) das am meisten verbreitete Verfahren, um die Landnutzung klassifizieren zu können (Wang and Li, 2019).

Die Ableitung der Bodenversiegelung beruht auf Basis des sichtbaren RGB Spektrums und dem NIR Bereich. Die Durchführung erfolgt mit der Software ArcGIS Pro von ESRI.

Um primär zwischen versiegelten und unversiegelten Flächen unterscheiden zu können und um schlussendlich einen Versiegelungsraster zu erzeugen, werden die zwei Hauptklassen Versiegelt und Unversiegelt generiert. Wie Garcia and Perez (2016) zeigen, benötigt es mehrere Teilklassen, um versiegelte Flächen ableiten zu können. Dies ist vor allem im sichtbaren RGB Bereich notwendig. Im Allgemeinen wird zwischen verschiedenen Gebäudetypen und Infrastruktureinrichtungen wie Straßenverkehrsanlagen oder asphaltierten Flächen mit ähnlichen spektralen Eigenschaften unterschieden.

Das Material und die chemische Zusammensetzung einzelner Gebäude variiert stark. Die verschiedenen spektralen Charakteristiken müssen in der Klassifizierung berücksichtigt werden. Die unterschiedlichen Dächertypen wie Ziegel, Dachstein, Beton oder Blech sind als eigene Teilklassen definiert. In Abbildung 16 sind verschiedene Teilklassen ersichtlich. Die Gebäude sind von den Verkehrswegen getrennt. Die Differenzierung zwischen den Gebäuden und anderen bebauten Flächen ist im sichtbaren Spektrum möglich.



Abbildung 16: Darstellung mehrerer Teilklassen aus dem RGB Orthophoto 2009

Im gesamten Untersuchungsgebiet und vermehrt in der Innenstadt sind in der Nähe von hohen Gebäuden lange Schatten ersichtlich. Diese sind als eigene Teilklasse der versiegelten Flächen zugeordnet. Analog dazu werden die Schatten im Wald und der Graslandschaft auch als eigene Unterklasse der unversiegelten Flächen zugewiesen. Der spektrale Informationsgehalt dieser Teilklassen ist sehr gering und führt zu Schwierigkeiten in der Klassifikation. Eine exakte Trennung und richtige Klassifizierung dieser Teilklassen ist im gesamten Untersuchungsgebiet schwer einzuhalten.

Bachofer et al. (2009) haben bei der Unterscheidung zwischen Schattenflächen und Objekten mit dunklen Oberflächen auch Probleme. Mögliche Ursachen sind der fehlende Informationsgehalt des NIR Kanals, sowie eine geringe Datenqualität.

Auch führt die Ähnlichkeit von Wasserflächen und versiegelten Flächen wie Asphalt zu Fehlern. Diese Fehlklassifikationen sind vor allem bei den RGB Daten ersichtlich. Mit dem zusätzlichen NIR Kanal kann dies größtenteils behoben werden.

Ein anderer Ansatz bildet die unüberwachte Klassifizierungsmethode (*Unsupervised Classification*). Dieses Verfahren wird für die Ableitung von undurchlässigen Oberflächen aufgrund der geringeren Klassifizierungsgenauigkeiten nur selten verwendet. Die Schwierigkeit besteht darin, die passende Anzahl an Klassen zu schätzen. Eine Über oder Unterschätzung verringert die Genauigkeit des Ergebnisses. Im Vorhinein sind keine repräsentativen Trainingsgebiete nötig und die Anzahl der Klassen kann vom Operateur festgelegt werden (Wang and Li, 2019). Diese Methode der Bildklassifizierung wird nicht herangezogen.

Die meisten ML-Verfahren beruhen auf einer überwachten Klassifizierung (Wang and Li, 2019). Die Grundlage für die überwachte Klassifizierung bilden die Trainingsgebiete (Abbildung 17). Alle eingesetzten Algorithmen in dieser Arbeit bauen auf Trainingsdaten auf. Der Operateur kann somit direkten Einfluss auf die Klassifizierung nehmen. Die Trainingsgebiete sollen dabei möglichst gut über das gesamte Untersuchungsgebiet verteilt sein. Der Anwender muss möglichst gleiche Pixel innerhalb des erzeugten Trainingsgebiet definieren. Der Lernvorgang beruht auf dem erneuten trainieren dieser Daten. Auf Basis der NDVI Darstellung und dem Orthophoto in Echtfarbandarstellung ergeben sich unterschiedliche Trainingsgebiete.



Abbildung 17: Trainingsgebiete NDVI

Die Ergebnisse der überwachten Klassifizierung hängen von der Anzahl der definierten Trainingsgebiete und der Verteilung ab. Je repräsentativer die Gebiete gewählt sind, desto höher ist die Erkennungsleistung der Klasse (Wang and Li, 2019). Die resultierende Klassifizierungsgenauigkeit wird daher von der Qualität und Quantität der Trainingsstichproben beeinflusst (Lu et al., 2011).

2.8 Objektbasierte Bildanalyse

Die objektbasierte Bildanalyse bietet gegenüber der pixelbasierten Methode einige Vorteile an, um die Bodenversiegelung im Untersuchungsgebiet erfassen zu können. Bei der pixelbasierten Variante wird jeder individuelle Pixel einzeln klassifiziert (Wang and Li, 2019). Bei der objektbasierten Variante werden beieinander liegende Pixel die ähnliche Eigenschaften aufweisen, zu einem Bildsegment gruppiert. Bildsegmente mit bestimmten Formen, Spektralen- und räumlichen Eigenschaften lassen sich weiter in Objekte zusammenfassen. Die Objekte können anschließend in Klassen zusammengefasst werden (ArcGIS, 2022b). Der Wechsel von einzelnen Pixel zu Bildobjekten vermeidet den sogenannten „Salt and Pepper Effekt“, der für die pixelbasierte Methode recht typisch ist (Liu and Xia, 2010).

Segmentierungsverfahren gibt es schon seit den 1970er Jahren. Etwa ab dem Jahr 2000 wird die Bildsegmentierung im Bereich der Fernerkundung eingesetzt. Zuvor brachten diese Verfahren auf Basis von gering aufgelösten Satellitenaufnahmen keine Vorteile und scheiterten bei Luftbildern aufgrund der Komplexität der Bildobjekte. Die Bildsegmentierung stellt eine Zwischenstufe bei der Klassifikation dar. Durch diesen Schritt wird die Geometrie für die zu klassifizierenden Objekte gestellt (Neubert and Blaschke, 2004).

Es gibt mehrere verschiedene Arten von Segmentierungsverfahren. Nach Neubert and Blaschke (2004) kann zwischen einer kantenbasierten (*edge based*) und einer regionalbasierten (*region based*) Segmentierungsmethode unterschieden werden.

Das objektbasierte Verfahren unterscheidet sich dadurch, dass als Einheit in der Klassifizierung ein Objekt oder ein Segment erzeugt wird. Dieses Segment besteht aus einer Gruppe von Pixeln und hat den Vorteil, dass Segmente und Objekte mehr Information als ein einzelner Pixel enthalten.

Im Gegensatz zur pixelbasierten Klassifizierung, welche nur auf einzelne Pixel beschränkt ist, nutzt die objektbasierte Bildanalyse strukturelle Eigenschaften der physikalischen Segmente. Diese bauen auf räumliche und funktionelle Beziehungen auf (M. et al., 2009). Abbildung 18 zeigt die Bildsegmente im Untersuchungsgebiet.




Abbildung 18: Segmente der objektbasierten Bildanalyse RGB (links) und NDVI (rechts)

Der Vorgang zur Bestimmung der Segmente besteht aus mehreren Schritten. Zuerst werden die Objekte benachbarter Pixel auf Basis von spektralen Eigenschaften selektiert. Anschließend folgt die Bildsegmentierung, Klassifizierung und Kombinierung. Am Ende erfolgt noch die Merkmalextraktion (Wang and Li, 2019).

Innerhalb der ArcGIS Pro Umgebung kann auf die spektralen und räumlichen Eigenschaften des Datensatzes eingegangen werden. Grundlage bei der Segmentierung bilden Spektraldetail, räumliches Detail und die minimale Segmentgröße. Ein hoher spektraler Wert eignet sich, um Objekte getrennt zu klassifizieren, welche ähnliche spektrale Eigenschaften aufweisen. Um Gebäude und Straßen getrennt zu klassifizieren ist auch ein hoher räumlicher Detailwert gebräuchlich (ArcGIS, 2022b).

Die gewählten spektralen und räumlichen Eingaben haben einen großen Einfluss auf das Ergebnis. Die minimale Segmentgröße bezieht sich auf die Pixelgröße des Rasters. Die Pixelgröße unterscheidet sich beim aktuellen und den historischen Datensätze. Beim aktuellen Datensatz aus 2019 geht eine Pixelgröße von 20 cm hervor. Die historischen Orthophotos sind mit einer Pixelgröße von 25 cm produziert.

Oczipka (2007) zeigt, dass auch fehlerhafte Segmentierungen entstehen können. Hier ist die Rede von einer Unter- oder Übersegmentierung. Mit steigender Heterogenität der Daten nehmen die Probleme einer nützlichen Segmentierung zu. Bei der Untersegmentierung werden die Segmente zu groß erzeugt. Die Objekte können somit die Umgebung nicht mehr richtig abbilden und sind nicht sinnvoll. Bei der Übersegmentierung werden die erzeugten Segmente zu klein dargestellt und die Objekte sind nicht richtig abgebildet. Ein Objekt besteht dann aus mehreren Segmenten. Es zeigt sich, dass die Übersegmentierung weniger Problematisch ist.

Durch mehrfaches Testen wird nach geeigneten Parametern gesucht, um eine Minimierung dieser Einflüsse zu erreichen. Dadurch dass sich die Datensätze farblich und räumlich unterscheiden, ergeben sich unterschiedliche Werte. In der Fernerkundung sind solche Segmentierungen nicht mehr aus den Bilddaten wegzudenken (Neubert et al., 2003).

Technische Grundlage zur Identifizierung und Erfassung der versiegelten Flächen aus flugzeuggestützten Daten bilden die SVMs. Dies ist ein mathematisch komplexes und rechenintensives Verfahren aus dem Teilbereich des maschinellen Lernens (Suthaharan, 2016). In der Fernerkundung kommt dieser Algorithmus zur Bestimmung der Landbedeckung und Landnutzung zum Einsatz. SVM erwies sich in der Vergangenheit als eine effektive Methode, nicht nur für komplexe Landschaftsstrukturen, sondern auch für verschiedene räumliche Auflösungen. Dieses statistische Verfahren kann gute Klassifizierungsergebnisse aus komplexen Daten liefern (Mohamed et al., 2015).

SVM Algorithmen können dabei lineare als auch nicht- lineare Zusammenhänge in einem separaten Lernprozess trainieren. Durch mehrfaches Training und Anwenden des erlernten Wissens, stellt dieser Algorithmus eine Form der überwachten Klassifizierung dar (Üreyen and Thiel, 2017).

Bachofer et al. (2009) beschreiben diesen Algorithmus als sehr robust. Auch wenn nur relativ wenig Trainingsdaten zur Verfügung stehen, können hohe Genauigkeiten erreicht werden. Über Kernel-Funktionen wird die Trennfläche zwischen den Klassen gebildet (Abbildung 19).




Abbildung 19: Trennung zweier Klassen über eine SVM-Hyperebene (Gunn et al., 1998)

Das Klassifizierungsergebnis der Zeitreihe auf Basis des SVM Algorithmus kann in Kapitel 3.1.1 betrachtet werden.

Die praktische Umsetzung für die Ermittlung der versiegelten Flächen ist in Abbildung 20 zu finden. Eingangsdaten bilden die flugzeuggestützten RGB(I) Rasterdaten. Zu Beginn werden in allen Orthophotos die Trainingsgebiete manuell erzeugt. Unabhängig davon, wird in ArcGIS Pro eine Segmentierung des gesamten Bildinhaltes durchgeführt. Sobald Trainingsdaten und Segmentierung für den jeweiligen Datensatz zur Verfügung stehen, kann die eigentliche Klassifizierung gestartet werden. Basis bei der Klassifizierung bildet der SVM Algorithmus. Wenn nach visueller Betrachtung ein plausibles Ergebnis vorliegt, können die zuvor definierten Unterklassen den zwei Hauptklassen Versiegelt und Unversiegelt zugeordnet werden. Die Genauigkeitsanalyse kann anschließend für den Versiegelungsraster durchgeführt werden. Wenn der Versiegelungsraster die nötige Genauigkeit erreicht hat, kann der versiegelte Anteil im Interessensgebiet bestimmt werden. Die praktische Umsetzung erfolgt für alle vier Datensätze identisch. Dreimal im sichtbaren Spektrum für die Daten aus 1999, 2009 und 2019. Und eine Umsetzung mit normalisiertem Vegetationsindex für das Jahr 2019.



Abbildung 20: Workflow objektbasierte Bildanalyse

Im nächsten Kapitel 2.9 wird eine weitere Methode vorgestellt. Diese nutzt neuronale Netzwerke, um die Bodenversiegelung im Untersuchungsgebiet erfassen zu können.

2.9 Neuronale Netzwerke

Als zweiter methodischer Ansatz für die Bestimmung der Flächenversiegelung kommen neuronale Netzwerke zur Geltung. Dieses Verfahren stellt einen Vergleich zur objektbasierten Bildanalyse. Im Bereich des maschinellen Lernens bildet Deep Learning eine populäre und erfolgreiche Methodik. Es ist eine Nachahmung der Funktionsweise des menschlichen Gehirns durch künstliche neuronale Netzwerke (Scherk et al., 2017).

Die Interpretation von Fernerkundungsdaten ist für das menschliche Gehirn eine leichte Aufgabe. Das Einordnen von verschiedenen Landschaftsklassen oder das extrahieren von bestimmten Merkmalen kann für den Computer eine schwierige Aufgabe darstellen (Sasidhar et al., 2019).

Neuronale Netzwerke lernen Aufgaben zu lösen, ohne zwingend dafür programmiert zu sein. Sofern Beispieldaten zur Verfügung stehen, können neuronale Netzwerke selbstständig lernen. Wichtig ist dabei, dass die Eingangsdaten eindeutig zwischen den verschiedenen Objekten unterscheiden (Wennker, 2020).

Machine Learning in Form von SVM oder RF sind bekannte Klassifizierungsverfahren im Bereich der Fernerkundung. Der technische Ansatz in Form von neuronalen Netzwerken zeigt in den Bereichen der visuellen Erkennung, Objekterkennung, Bildklassifizierung oder der semantischen Segmentierung gute Ergebnisse und gilt als besonders leistungsfähig. Neuronale Netzwerke wurden erfolgreich angewendet um hochauflösende Fernerkundungsdaten klassifizieren zu können (Xu et al., 2018).

Deep Learning ist eine Teilform des maschinellen Lernens, bei der mehrere Schichten zur Anwendung kommen. Geographische Objekte wie Gebäude oder Straßen, können durch Deep Learning-Modelle identifiziert werden. Dabei wird das Modell mit Bildern von entsprechenden Objekten trainiert. Diese Bilder werden durch Schichten innerhalb des neuronalen Netzwerkes verarbeitet. Ähnlich wie beim objektbasierten Verfahren müssen Trainingsgebiete im Vorhinein erstellt werden, damit das Erkennen von Objekten gewährleistet ist (ArcGIS, 2022a). Im Bereich der Fernerkundung bringt der Einsatz von DL-Methoden einen enormen Aufschwung.

Im Prinzip besteht die Architektur des Netzwerkes aus drei fundamentalen Schichten (Abbildung 21). Die Punkte in der Grafik symbolisieren die Neuronen. Links in der Architektur befindet sich die Eingangsschicht (*Input Layer*). Die dazugehörigen Neuronen werden als Eingangsneuronen bezeichnet. Die mittlere Schicht (*Hidden Layer*) wird als sogenannte versteckte Schicht bezeichnet. Diese Schicht hat die Namensgebung daher, dass diese Neuronen weder als Eingabe noch als Ausgabe angesehen werden. Rechts befindet sich die Ausgabeschicht (*Output Layer*), diese enthält die Ausgangsneuronen (Nielsen, 2015). Während die Eingabe- und die Ausgabeschicht eines neuronalen Netzwerkes klar ist, werden innerhalb der verborgenen Schicht die Eingabedaten transformiert, so dass diese mit der Ausgabeschicht stimmig sind (Kattenborn et al., 2021). Eingabeschicht bilden in dieser Arbeit die Fernerkundungsdaten im Sinne der RGB(I) Orthophotos. Als Ausgabeschicht und letztlich als Resultat werden die klassifizierte Versiegelungsraster erwartet.




Abbildung 21: Aufbau neuronales Netzwerk

In dieser Arbeit wird ein DL-Modell verwendet, welches auf die Anwendung von semantischen Segmentierungen zielt. Die semantische Segmentierung kategorisiert dabei jeden Pixel des Eingangsdatensatzes einer Klasse zu. Semantische Segmentierungen sind in zwei Kategorien aufgeteilt. Man unterscheidet zwischen Encoder-Decoder (*encoder-decoder*) und Pyramid-Pooling mit multiskaligem Kontextdesign (*pyramid pooling with multi-scale context design*) (Zhang et al., 2020).

Analog zu Kapitel 2.8 besteht die Klassifizierung aus den beiden Hauptklassen Versiegelt und Unversiegelt. In den letzten Jahren hat die semantische Segmentierung einen bemerkenswerten Erfolg in der Bildklassifizierung erreicht (Zhang et al., 2020).

Als DL-Architektur wird das PSPNet herangezogen. Zhao et al. (2017) haben dieses Netzwerk vorgeschlagen. Dieses gilt als eines der fortschrittlichsten semantischen Segmentierungsarchitekturen. Im Jahr 2016 erreichte dieses Netzwerk den ersten Platz bei der ImageNet Scene Parsing Challenge. Grundsätzlich baut das PSPNet auf einer modifizierten *Residual Network (ResNet)* Architektur auf, um Merkmalinformationen extrahieren zu können (Zhang et al., 2020). Das Kernmodul bildet das Pyramid-Pooling-Modul, welches kontextuelle Informationen auf verschiedenen Ebenen verarbeiten kann (Zhao et al., 2017).

Zhang et al. (2020) berichten, dass das PSPNet im Vergleich zu anderen Deep Learning-Algorithmen wie dem U-NET bessere Ergebnisse erzielen kann. Unter anderem bei der Erfassung der Vegetation und künstlichen Flächen.

Yang et al. (2019) und Yu et al. (2018) zeigen, dass das PSPNet in Betracht gezogen werden kann, um versiegelte Flächen aus hochauflösenden Fernerkundungsdaten erfassen zu können. In beiden Fällen gelingt es Gebäude und Infrastruktureinrichtungen mit einer hohen Gesamtgenauigkeit klassifizieren zu können.

Mit dem Pyramid-Pooling-Modul werden die Eingangsmerkmale in unterschiedliche Maßstäbe für die Klassifizierung gesetzt, um die Leistung bei kleinen Zielen zu verbessern. Seit Erscheinung dieser Architektur, wird diese häufig für die Klassifizierung der Landschaftsbedeckung eingesetzt. Speziell für mittel und hochauflösende Fernerkundungsdaten (Zhang et al., 2020).

Abbildung 22 zeigt den Aufbau der PSPNet Architektur. Zu Beginn wird das Eingabebild durch ein *Convolutional Neural Network (CNN)* durchlaufen. In diesem Fall das ResNet-50. Es werden Merkmale des Eingabebildes extrahiert. Das ResNet-50 ist ein neuronales Netzwerk mit einer Tiefe von 50 Schichten (Alzamily et al., 2022). Anschließend werden die erhaltenen Merkmale auch Feature Map genannt in verschiedenen Maßstäben "gepoolt". Dieser Schritt wird im Pyramid-Pooling-Modul durchgeführt (Yuan et al., 2022). Dieses Modul ist als gestricheltes Rechteck in der Abbildung 22 dargestellt.




Abbildung 22: Aufbau PSPNet (Zhao et al., 2017)

Der rote Teil in Abbildung 22 fasst die gesamten Merkmalinformation zusammen und wird durch Faltung auf die Tiefe von $1/4$ des Originals reduziert.

Das orange Modul teilt die Feature Map in vier Raster auf und fasst die Merkmale zusammen, wodurch eine Feature Map von $2 * 2$ Pixel entsteht. Die Faltungsschicht reduziert die Tiefe auf $1/4$ des ursprünglichen Wertes.

Der blaue Teil fasst die gesamte Feature Map in neun Raster auf, so dass eine Feature Map von $3 * 3$ Pixel entsteht. Durch Faltung wird eine Tiefe von $1/4$ des Originals erreicht.

Das grüne Modul unterteilt die Feature Map in 36 Raster, wodurch eine Feature Map mit einer Größe von $6 * 6$ Pixel entsteht. Wie bei den anderen Modulen wird durch Faltung die Tiefe erneut auf $1/4$ des ursprünglichen Wertes reduziert.

Am Ende werden die gepoolten Resultate auf die gleiche Größe wie die Eingabe Feature Map vergrößert (*upsample*) und mit der Eingabe Feature Map vernetzt um Vorhersagen zu erhalten. Die vom Pyramid-Pooling-Modul ausgegebene Feature Map wird direkt auf die Größe des Eingabebildes hochgerechnet (Yuan et al., 2022).

Datenaufbereitung

Um das PSPNet trainieren zu können, müssen zu Beginn die Eingangsdaten zurecht gelegt werden. Da dieses Netzwerk auf eine überwachter Klassifizierung aufbaut, werden die Eingangsdaten (Trainingsgebiete und Orthophotos) zunächst gekachelt. Das originale Orthophoto und die manuell erstellten Trainingsgebiete werden mit einer Kachelgröße von 256 x 256 Pixel zugeschnitten. Die entstandenen Bilder (*images*) und Objekte (*labels*) bilden nun die Eingangsdaten, um das Deep Learning-Modell trainieren zu können. Als Eingangsdaten liegen über 1.000 Bilder und 2.000 Objekte zur Verfügung. Abbildung 23 zeigt, wie die gekachelten Bilder und Objekte aus dem Orthophoto extrahiert werden. Die erzeugten Objekte sind in den roten Rechtecken zu finden.



Abbildung 23: Datenaufbereitung Deep Learning

Trainieren des Modells

Um versiegelte Flächen mit dem PSPNet abzuleiten zu können, muss das Modell trainiert und mehrfach durchlaufen werden. Wichtige Parameter und Einstellungen sind dabei die Anzahl der Epochen (*epochs*) und die Lernrate (*learning rate*).

Die Anzahl der Epochen gibt an, wie oft das Netzwerk unter Berücksichtigung aller Trainingsdaten durchlaufen wird. Sobald alle Trainingsdaten das Netzwerk einmal durchlaufen haben, ist eine Epoche erledigt (Scherk et al., 2017). Umso mehr Epochen ausgeführt werden, desto bessere Ergebnisse können für den klassifizierten Rasterdatensatz erwartet werden. In Summe werden 30 Epochen ausgeführt um das Modell zu trainieren. Dieser Vorgang nimmt mehrere Stunden in Anspruch. Die Rechenleistung des Computers ist hier von großer Bedeutung.

Die Lernrate kann während der gesamten Prozessierung konstant gehalten werden oder dabei variieren (Kanada, 2016). Das PSPNet ist mit einer variablen Lernrate im Bereich von wenigen Millisekunden durchlaufen.

Neben der Lernrate und der Anzahl der Epochen kann mit der Batch Size ein weiterer Parameter gesteuert werden. Die Batch Size gibt an, wieviele Eingangsdaten gleichzeitig durch das Netzwerk gesteuert werden. Die Trainingsdaten werden in mehrere kleine Segmente unterteilt (Scherk et al., 2017).

Das Tool *Train Deep Learning Model* kann auch in der Python Umgebung genutzt werden. Alle Parameter und Argumente der Toolbox können für weitere Durchgänge automatisiert werden. Mit dem ArcPy Packet von ArcGIS hat man Zugriff auf die Python Schnittstelle. Mit dieser Schnittstelle lassen sich ArcGIS Tools als Python-Script definieren (Abbildung 24). Alle Parameter welche für die Ausführung des ArcGIS Tools notwendig sind, können als Python Line übernommen werden und für weitere Geo-Verarbeitungen genutzt und gegebenenfalls modifiziert werden. Wichtige Parameter sind Anzahl der Epochen, Batch Size, Lernrate oder das gewählte CNN in diesem Fall das ResNet-50. Allgemein kann das ArcPy Packet herangezogen werden um geographische Datenanalysen, Datenkonvertierungen oder Kartenautomatisierung mit Python durchzuführen (ArcGIS, 2021).

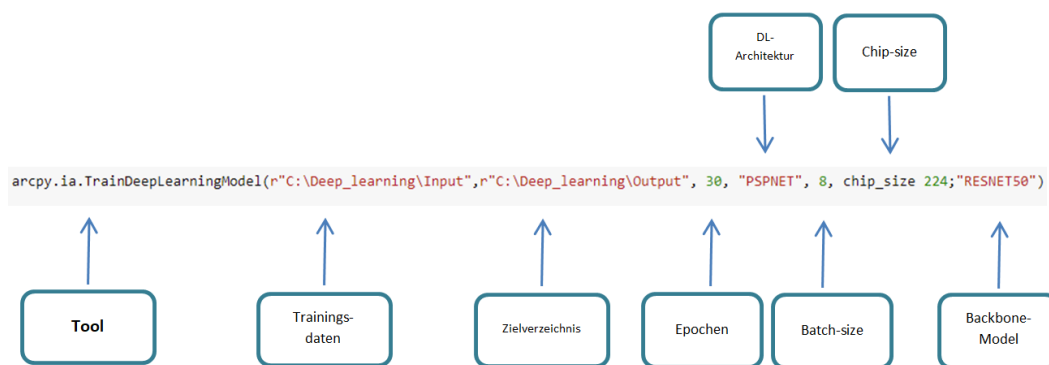


Abbildung 24: Aufbau der PSPNet Architektur mit dem ArcPy Packet von ArcGIS

Der Bildinhalt (*Ground Truth*) kann mit der Vorhersage (*Predictions*) verglichen werden (Abbildung 25). Aus diesen Grafiken kann man für einige Bereiche die Vorhersagen entnehmen. Dies ist eine visuelle Überprüfung des trainierten Modells.




Abbildung 25: Gegenüberstellung Ground Truth/Predictions

Anwendung und Ausgabe des Modells

Der letzte Schritt kümmert sich um die Ausgabe des Versiegelungsrasters. Am Ende wird das trainierte Modell verwendet, um das Orthophoto zu klassifizieren. Jedem Pixel im Untersuchungsgebiet wird eine Klasse zugeordnet.

Als Ausgabe erhält man in ArcGIS Pro eine Modelldefinitionsdatei (emd). Die emd Datei ist eine JSON-Datei, die das trainierte Deep Learning-Modell darlegt. Alle Informationen die notwendig sind um den Bildinhalt zu bestimmen, sind in der emd-Datei enthalten ArcGIS (2022a). Ein Vorteil von diesem Klassifizierungsverfahren besteht darin, dass das trainierte Modell auf andere Rasterdatensätze übertragbar ist. Die Klassen und der Sensor sollten in den Datensätzen identisch sein.



Abbildung 26: Ausgabe aller Teilklassen mittels Deep Learning

Wie schon in Kapitel 2.7 angedeutet, wird primär zwischen den beiden Hauptklassen Versiegelt und Unversiegelt unterschieden. Somit folgt das Resultat, dass bei den Pixelklassifizierungen alle Unterklassen wie Wasser, Ackerland, Grasland, Wald, Infrastruktur und die verschiedenen Gebäudetypen ihren Hauptklassen zugeordnet werden.

Viele Studien bauen im Bereich DL auf 3-Kanalbilder auf. Als Input werden Daten in Echtfarbe RGB und Falschfarbe CIR eingesetzt. Die PSPNet Architektur kann gleichzeitig 3-Kanalbilder verarbeiten. Um den NIR Kanal für die Klassifizierung zu nutzen, wird in diesem Fall die CIR Darstellung in Anspruch genommen (Abbildung 7). Bei der CIR Klassifizierung kommen die gleichen Klassen und Trainingsdaten wie bei der objektbasierten Bildanalyse mit dem NDVI zum Einsatz.

Beide Algorithmen (SVM und PSPNet) zählen zum Teilbereich der künstlichen Intelligenz und gehören zu den überwachten Klassifizierungsverfahren.

Der Workflow für den DL-Ansatz kann in Abbildung 27 betrachtet werden. Grundlage bilden die öffentlichen Orthophotos. Die Erzeugung der Eingangsdaten wird mit dem Tool *Classify Objects Using Deep Learning* durchgeführt. Das Netzwerk wird mit dem Tool *Train Deep Learning Model* trainiert. Nach abgeschlossenem Training und mit erzeugter Modelldefinitionsdatei kann die Klassifizierung für den jeweiligen Datensatz durchgeführt werden. Nach visueller Kontrolle aller Teilklassen erfolgt die Zuweisung zu den Hauptklassen. Die Genauigkeitsanalyse kann anschließend durchgeführt werden, um die Versiegelungsraaster zu prüfen. Am Ende erfolgt die Ermittlung der versiegelten Flächen. Die Ergebnisse sind im Kapitel 3 zu finden.

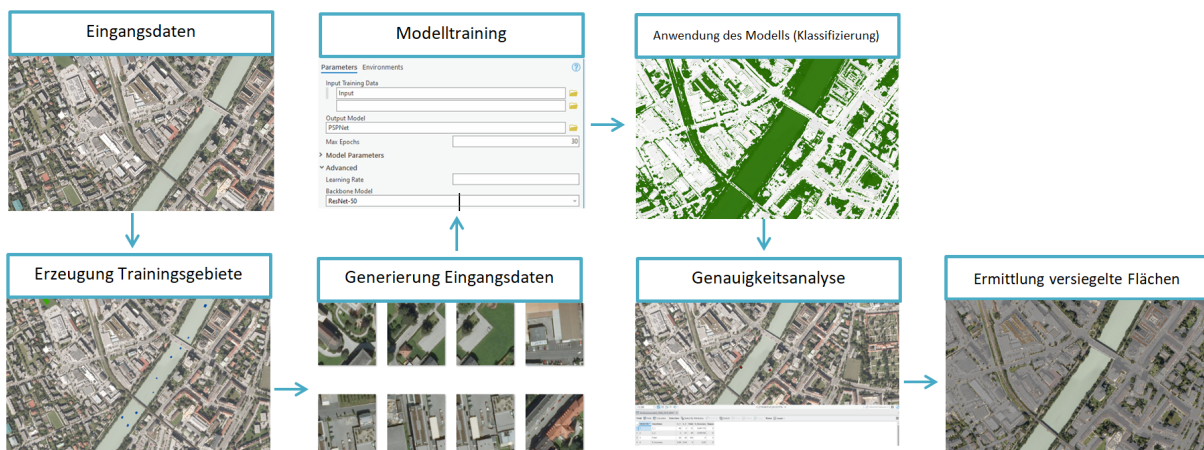


Abbildung 27: Workflow neuronale Netzwerke

2.10 Bodenverbrauch aus anderen Methoden

2.10.1 Regionalinformation

Die Regionalinformation gibt grundlegende Informationen zu den Nutzungsarten in Österreich an. Dieser Datensatz ist ein verfügbare Datengrundlage zur quantitativen Abschätzung der Flächeninanspruchnahme. Diese Nutzungsinformation wird aus der DKM abgeleitet und vom BEV als Regionalinformation der Grundstückdatenbank gehalten. Dabei werden unterschiedliche Nutzungskategorien wie Gebäude, Betriebsflächen, Parkplätze oder Verkehrsrandflächen erfasst. Aus der DKM können sämtliche versiegelte Flächen für jede Katastralgemeinde abgeschätzt werden. Dieser Datensatz erscheint jeweils zum Jahresende (ÖROK, 2018).

Jede Nutzungskategorie wird vom Umweltbundesamt mit einem spezifischen Versiegelungskoeffizient ausgestattet (Tabelle 7).

Tabelle 7: Zuordnung der Versiegelungskoeffizienten für die Nutzungen im Grenzkataster

BANU-VO			BANU-V	
Benützungsart	Nutzung	Versiegelungskoeffizient	Nutzung	Versiegelungskoeffizient
Baufläche	Gebäude	100%	Gebäude	100%
	befestigt	100%	Gebäudenebenflächen	75%
	nicht näher unterschieden	30%	Straßenverkehrsanlagen	60%
Sonstige	Straßenanlagen	60%	Verkehrsrandflächen	15%
	nicht näher unterschieden	10%	Parkplätze	80%
			Schienenverkehrsanlagen	50%
			Betriebsflächen	60%
			Freizeitflächen	20%

Eine österreichweite Abschätzung der Flächeninanspruchnahme erfolgt mit den Daten aus der DKM. Da die Grundstücksdatenbank nur im Ausnahmefall, wie bei Bauvorhaben, Neuvermessungen oder andere Angelegenheiten des Katasters aktualisiert wird, sind die Daten der DKM in Bezug auf Bauflächen der tatsächlichen Bebauung immer etwas hinterher. Daten aus dem Zeitraum zwischen 1995-2012 (BANU-VO) und Daten nach 2012 (BANU-V) unterscheiden sich sehr. Somit sind diese Nutzungsinformationen nur schwer vergleichbar. Aufgrund von Definitionsänderungen bestehen Inkonsistenzen. Dennoch kann auf die Daten für die Abschätzung nicht verzichtet werden. Die Angaben zu den Bauflächen in absoluten Zahlen ist ein Anhaltspunkt für die beanspruchten Flächen (Umweltbundesamt, 2023).

Seit 2012 ist die BANU-V in Kraft getreten. Priorität ist die flächendeckende Nutzungserhebung aus aktuellen DOP und Erfahrungen von Datennutzern einzuarbeiten. Durch Definitionsänderungen sind Zeitvergleiche nur vor oder nach 2012 in sich stimmig. Erkennungen von Trends über diese Zeitperiode sind daher nur eingeschränkt möglich, da sich die Zuordnung einzelner Klassen vor und nach dieser Umstellung nicht eindeutig bestimmen lässt (Umweltbundesamt, 2023).

Aus Abbildung 28 kann der bebaute Anteil aus der DKM für das Jahr 2019 entnommen werden. Die Zahlen legen den versiegelten Anteil aller neun Katastralgemeinden Amras, Arzl, Hötting, Igls, Innsbruck, Mühlau, Pradl, Vill und Wilten dar.




Abbildung 28: Versiegelte Flächen aus der Regionalinformation 2019

Quelle: BEV - Bundesamt für Eich- und Vermessungswesen: Regionalinformation. Die Originaldaten liegen für Katastralgemeinden vor und werden zum jeweiligen Jahresende auf Gemeindeebene aggregiert.

Ein internationaler Vergleich kann mit diesen Daten nicht aufgestellt werden. Die Aktualisierung der Daten erfolgt von Jahr zu Jahr nicht systematisch, sondern regional. Ein Vorteil dieser Methode ist die jährliche Verfügbarkeit (ÖROK, 2018).

2.10.2 Copernicus Imperviousness Density

Copernicus ist das europäische Erdbeobachtungsprogramm. Dieser Informationsdienst stellt den Nutzern verschiedene thematische Datensätze zur Verfügung. Diese sind aus Satellitenbeobachtungen abgeleitet. Copernicus bietet geografische Information über die Landschaftsbedeckung und deren Veränderung an. Darunter auch den Datensatz IMD.

Für die Produktion des IMD-Layer kommt eine überwachte Klassifizierung um Einsatz. Es wird zwischen versiegelten/nicht versiegelten Flächen unterschieden mit anschließender visueller Korrektur. Als finales Ergebnis steht ein Rasterdatensatz mit versiegelten und nicht versiegelten Flächen dar inklusive Versiegelungsgrad (EU, 2018).

Seit dem Jahr 2006 liefert dieser Datensatz Informationen zum Versiegelungsgrad. Dieser Layer ist in über 30 europäischen Länder darunter auch in Österreich verfügbar. Der Versiegelungsgrad (0-100%) pro Pixel, wird durch eine halbautomatische Klassifizierung von Sentinel-2 Fernerkundungsdaten erzeugt. Die satellitengestützte Methodik basiert auf der Grundlage des NDVI (Strand, 2022)

Abbildung 29A zeigt den Versiegelungsstand für das Jahr 2009 und Abbildung 29B für das Jahr 2018. Beide Datensätze sind auf das Untersuchungsgebiet zugeschnitten.

In Kapitel 3.2 werden die Datensätze aus 2009 und 2018 den Ergebnissen dieser Arbeit gegenübergestellt. Der Datensatz aus 2018 bietet eine räumliche Auflösung von 10 m. Somit stellt ein Pixel mit 1 % Versiegelung eine Größe von 1 m² dar. Der Layer aus 2009 besitzt eine räumliche Auflösung von 20 m. 1 % an Versiegelung entsprechen dann 4 m². Alle Rasterzellen beim IMD, welche einen Versiegelungsgrad unter 10 % aufweisen, werden nicht miteinbezogen. Diese Rasterzellen beinhalten nahezu keine Bodenversiegelung. Die versiegelte Fläche dieser Rasterzellen liegt bei beiden Datensätze unter 15.000 m².

Diese Datensätze gelten europaweit als vergleichbare Datengrundlage. Zudem wird laufend die Methodik zur Erfassung der versiegelten Flächen verbessert und eine immer höhere räumliche Auflösung steht zur Verfügung. Mit einer Rastergröße von 10 x 10 m im Jahr 2018 ist die Auflösung höher als bei den vergangenen Datensätzen. Trotzdem ist diese Auflösung noch zu grob, um enge Verkehrswege und kleinere versiegelte Flächen ordnungsgemäß erfassen zu können (ÖROK, 2018).




Abbildung 29: Copernicus high-resolution layer imperviousness density

3 Ergebnisse

3.1 Validierung der Klassifizierung

Die Validierung der Ergebnisse gibt eine wichtige Auskunft über die Qualität und Funktionalität der verwendeten Verfahren. Die erzeugten Versiegelungsraster werden auf ihre Genauigkeit geprüft. Der abgeleitete Versiegelungsgrad aus Kapitel 3.2.1 steht in Abhängigkeit von der Qualität der Klassifizierung.

Um nun Aussagen zur Qualität und der Genauigkeit des methodischen Ansatzes treffen zu können, wird ein gängiges Verfahren aus der Fernerkundung eingesetzt. Um die Klassifizierungsmethoden zu prüfen, kann die sogenannte Genauigkeitsanalyse (*Accuracy Assesment*) durchgeführt werden (Congalton and Green, 2019).

Um eine Auskunft über die Klassifizierungsgenauigkeit zu erhalten, ist eine möglichst große Anzahl an Referenzpunkten im Untersuchungsgebiet notwendig. Je mehr Klassen die Klassifizierung beinhaltet, desto mehr Referenzpunkte sollen erzeugt werden. Da der Versiegelungsraster letztendlich nur mehr aus den zwei Klassen Versiegelt und Unversiegelt besteht, spielen die Unterklassen wie Grasland, Ackerland oder Wald keine Rolle mehr. Für jede Klasse werden 50 Referenzpunkte erzeugt.

Dazu werden 100 zufällig verteilte Punkte im Untersuchungsgebiet generiert (Abbildung 30). Mit Hilfe dieser Punkte können alle erzeugten Versiegelungsraster auf ihre Genauigkeit geprüft werden. Man begibt sich zu einem zufällig verteilten Punkt und begutachtet die reele Bodenbedeckung auf dem Orthophoto.



Abbildung 30: Orthophoto 2019 mit Referenzpunkte (rot)

Auf Basis einer Konfusionsmatrix oder auch Fehlermatrix (Tabelle 8 und 9) kann zugewiesen werden, ob der Punkt richtig oder falsch auf dem Orthophoto platziert wurde. Die Konfusionsmatrix gibt Auskunft über die korrekten und falsch klassifizierten Pixel (Üreyen and Thiel, 2017). Es gibt mehrere Metriken um eine Klassifizierung zu Prüfen.(Congalton, 1991).

Die Nutzergenauigkeit (*User Accuracy*) fasst die Anzahl aller richtig klassifizierten Referenzpunkte dividiert durch die Gesamtanzahl aller verfügbaren Punkte, die der entsprechenden Klasse zugeordnet wurden. Diese Metrik zeigt, wie viel Prozent der Pixel innerhalb des Versiegelungsraster auch wirklich der richtigen Klasse zugeordnet sind (Üreyen and Thiel, 2017).

Die Herstellergenauigkeit (*Producer Accuracy*) gibt die Anzahl aller richtig klassifizierten Referenzpunkte gebrochen durch die Summe aller Referenzpunkte, welcher der betrachteten Klasse in der Referenz angehören (Üreyen and Thiel, 2017).

Die Gesamtgenauigkeit (*Overall Accuracy*) beschreibt den Anteil aller richtig klassifizierten Referenzpunkte (Üreyen and Thiel, 2017). Alle Metriken erwarten einen Wert zwischen 0 und 1.

Der Kappa Index ist ein zusätzliches Maß, das seit den 1980er Jahren in der Fernerkundung eingesetzt wird (Congalton et al., 1983).

Foody (2020) beschreibt diesen Index nicht als ein Maß für die Genauigkeit, sondern als ein Index für den Grad der allgemeinen Übereinstimmung. Der Kappa-Koeffizient ist somit ein ungeeigneter Wert um die Klassifizierungsgenauigkeit zu beschreiben. Innerhalb des Fachbereiches der Fernerkundung gilt der Kappa-Koeffizient als umstritten und die Größe des Indexes ist schwer interpretierbar. Ein Wert nahe 1 liefert eine hohe Übereinstimmung. Ein kleiner Wert zeigt eine geringe Übereinstimmung, oder dass eine zufällige Klassifizierung vorliegt. Dieser Index lässt sich anhand der Fehlermatrix bestimmen.

3.1.1 Validierung SVM

Die Ergebnisse der objektbasierten Methode erreichen für alle Versiegelungsraster einen Wert über 85 % bezogen auf die Gesamtgenauigkeit. Generell muss das Resultat der Genauigkeitsanalyse mit der Anzahl der Klassen und den zu klassifizierenden Objekte in Relation gesetzt werden. Eine Unterscheidung zwischen verschiedenen Baumarten oder Dächermaterialien muss anders betrachtet werden, als eine binäre Unterscheidung zwischen zwei Zuständen oder Objekten.

Aus Tabelle 8 können die erzielten Klassifizierungsergebnisse in Bezug auf die Metriken der Genauigkeitsanalyse entnommen werden.

Tabelle 8: Fehlermatrix objektbasierte Bildanalyse

Klasse	Versiegelt	Unversiegelt	Total	U_Accuracy	Kappa
Versiegelt	48	3	51	0,94	0
Unversiegelt	2	47	49	0,96	0
Total	50	50	100	0	0
P_Accuracy	0,96	0,94	0	0,95	0
Kappa	0	0	0	0	0,9

Versiegelungsraster 2019 (NDVI)

Klasse	Versiegelt	Unversiegelt	Total	U_Accuracy	Kappa
Versiegelt	47	3	50	0,94	0
Unversiegelt	3	47	50	0,94	0
Total	50	50	100	0	0
P_Accuracy	0,94	0,94	0	0,94	0
Kappa	0	0	0	0	0,88

Versiegelungsraster 2019

Klasse	Versiegelt	Unversiegelt	Total	U_Accuracy	Kappa
Versiegelt	43	7	50	0,86	0
Unversiegelt	2	48	50	0,96	0
Total	45	55	100	0	0
P_Accuracy	0,96	0,87	0	0,91	0
Kappa	0	0	0	0	0,82

Versiegelungsraster 2009

Klasse	Versiegelt	Unversiegelt	Total	U_Accuracy	Kappa
Versiegelt	43	7	50	0,86	0
Unversiegelt	4	46	50	0,92	0
Total	47	53	100	0	0
P_Accuracy	0,91	0,87	0	0,89	0
Kappa	0	0	0	0	0,78

Versiegelungsraster 1999

Die Gesamtgenauigkeit aller Datensätze liegt zwischen 89 und 95 %.

Die Herstellergenauigkeit der Klasse Versiegelt liegt bei allen Datensätzen über 90 %. Die geringste Herstellergenauigkeit (0,91) liegt im Jahr 1999 vor.

Die klassifizierten Daten aus 2019 (RGB und NDVI) erreichen bei den Metriken Nutzergenauigkeit, Herstellergenauigkeit und Gesamtgenauigkeit über 90 %. Auch ist der Kappa Wert höher als bei den historischen Datensätze aus 2009 und 1999. Dies steigert die Wahrscheinlichkeit, dass kein zufälliges Klassifizierungsergebnis vorliegt. Mit dem zusätzlichen NIR Kanal konnte das Ergebnis gesteigert werden.

Die Klasse der unversiegelten Flächen, schneidet beim Versiegelungsraster aus dem Jahr 1999 in Bezug auf die Nutzergenauigkeit am schlechtesten ab. Insgesamt wurden vier Referenzpunkte falsch der Klasse Versiegelt zugewiesen. Zudem neigt der geringe Kappa Wert von 0,78 auf ein zufälliges Ergebnis hin.

Die Nutzergenauigkeit der Klasse Versiegelt, fällt bei 3/4 allen Datensätzen gegenüber der Klasse Unversiegelt geringer aus. Die einzige Ausnahme bildet der Versiegelungsraster (RGB) aus dem Jahr 2019. In diesem Fall gilt für beide Klassen ein Wert von 94 %. Somit liegen mehr Fehlklassifikationen der Klasse Versiegelt vor. Die richtige Ableitung der Klasse Versiegelt erwies sich auch anspruchsvoller, als jene der unversiegelten Flächen.

3.1.2 Validierung PSPNet

Wie schon in Kapitel 3.1 erläutert gibt es mehrere Metriken um einen Datensatz auf seine Richtigkeit zu prüfen. Analog dazu wird für den Deep Learning-Ansatz ebenfalls eine Genauigkeitsanalyse durchgeführt. Für die Prüfung der Datensätze werden 100 Zufallspunkte generiert. Aus Tabelle 9 können die Ergebnisse der Fehlermatrix entnommen werden.

Tabelle 9: Fehlermatrix Deep Learning

Klasse	Versiegelt	Unversiegelt	Total	U_Accuracy	Kappa	
Versiegelt	47	3	50	0,94	0	
Unversiegelt	1	49	50	0,98	0	
Total	48	52	100	0	0	
P_Accuracy	0,98	0,94	0	0,96	0	
Kappa	0	0	0	0	0,92	Versiegelungsraster 2019 (CIR)
Klasse	Versiegelt	Unversiegelt	Total	U_Accuracy	Kappa	
Versiegelt	43	7	50	0,86	0	
Unversiegelt	3	47	50	0,94	0	
Total	46	54	100	0	0	
P_Accuracy	0,93	0,87	0	0,9	0	
Kappa	0	0	0	0	0,8	Versiegelungsraster 2019
Klasse	Versiegelt	Unversiegelt	Total	U_Accuracy	Kappa	
Versiegelt	47	3	50	0,94	0	
Unversiegelt	8	42	50	0,84	0	
Total	55	45	100	0	0	
P_Accuracy	0,85	0,93	0	0,89	0	
Kappa	0	0	0	0	0,78	Versiegelungsraster 2009
Klasse	Versiegelt	Unversiegelt	Total	U_Accuracy	Kappa	
Versiegelt	39	11	50	0,78	0	
Unversiegelt	5	45	50	0,9	0	
Total	44	56	100	0	0	
P_Accuracy	0,89	0,80	0	0,84	0	
Kappa	0	0	0	0	0,68	Versiegelungsraster 1999

Der Raster aus 1999 erreicht eine Gesamtgenauigkeit von 84 %. Folglich ergeben sich mehrere Fehlzugeordnungen der Klasse Versiegelt. Insgesamt wurden elf Referenzpunkte falsch der Klasse Unversiegelt zugeordnet. Dies resultiert in einer Nutzergenauigkeit von 78 %. Der Kappa Index mit 0,68 gewährleistet eine geringe Übereinstimmung.

Der Versiegelungsraster aus 2009 liefert eine Gesamtgenauigkeit von knapp 90 %. Ein höherer Kappa Wert nahe 0,8 zeigt eine bessere Übereinstimmung. Hier wurden drei Referenzpunkte falsch der Klasse Versiegelt zugeordnet und eine Nutzergenauigkeit von 94 % liegt vor. Dem entgegen sind acht Referenzpunkte falsch der Klasse Unversiegelt zugeordnet.

Bei der RGB Klassifizierung aus 2019 wurden von 100 Referenzpunkte, insgesamt zehn falsch zugewiesen. Dies führt zu einer Gesamtgenauigkeit von 90 %. Bei der Klasse der versiegelten Flächen wurden sieben Referenzpunkte falsch interpretiert, dies zeugt eine Nutzergenauigkeit von 86 %. Der Kappa Index ist höher als bei den Orthophotos aus 1999 und 2009.

Analog zur objektbasierten Bildanalyse führt der zusätzliche NIR Kanal zum besten Ergebnis. Bei den unversiegelten Flächen wurde nur ein Referenzpunkt falsch der Klasse Versiegelt zugewiesen. Daher sind 98 % richtig der Klasse Unversiegelt zugeordnet. Die CIR Darstellung erlaubt es, die Vegetation gut von anderen (künstlichen) Objekten zu unterscheiden. Dies führt zur hohen Nutzergenauigkeit. Mit 96 % erzielt dieser Versiegelungsraster die höchste Gesamtgenauigkeit. Ein Kappa Wert von 0,92 zeigt die höchste Übereinstimmung aller klassifizierten Datensätze.

Aus beiden Genauigkeitsanalysen (SVM und PSPNet) lässt sich ableiten, je aktueller der Datensatz, desto bessere Ergebnisse sind zu erwarten. Dies hängt mit der verbesserten Auflösung und der steigenden radiometrischen Qualität des DOP zusammen.

3.2 Entwicklung der Bodenversiegelung

Bereits aus den statistischen Daten der Regionalinformation lässt sich eine steigende Zunahme an versiegelten Flächen entnehmen. Parallel dazu, hat sich in allen klassifizierten Orthophotos ebenfalls eine Steigerung der Bodenversiegelung ergeben. Wie schon in Kapitel 1 angedeutet, gibt es mehrere Gründe für den steigenden Bodenverbrauch. Eine wachsende Bevölkerungsanzahl führt zu einem erhöhten Wohnanspruch. Dies hat eine kontinuierlich veränderte Landschaftsstruktur zur Folge. Der Anteil an natürlichen Flächen sinkt und die vom Menschen erzeugten Strukturen nehmen zu. Ein steigender Raumanspruch begünstigt den Ausbau neuer Verkehrswege, Wirtschaftsgebäude und anderen Baueinrichtungen.

Dieses Kapitel zeigt in Zahlen und Grafiken, wie sich der Bodenverbrauch im DSR von Innsbruck in den letzten 20 Jahren entwickelt hat. Die Rasterdaten weisen eine quadratische Pixelgröße auf. Um Flächenangaben aus den Rasterdaten ableiten zu können, müssen alle versiegelten Pixel aus dem Versiegelungsraster summiert werden. Die Summe wird anschließend mit der Fläche des Bodenpixels multipliziert. In Abhängigkeit der räumlichen Auflösung kann der versiegelte Anteil so bestimmt werden. Die Flächenangaben zur Bodenversiegelung für verschiedene Methoden sind in Tabelle 10 und Abbildung 31 dargestellt.

Tabelle 10: Gegenüberstellung verschiedener Methoden zur Bestimmung der Bodenversiegelung

Methodischer Ansatz	Jahr	Versiegelte Flächen	
		ha	%
Regionalinformation	1999	756	20,8
Regionalinformation	2009	808	26,45
Regionalinformation	2019	996	32,2
Imperviousness density	1999	keine Daten	keine Daten
Imperviousness density	2009	1163	33,09
Imperviousness density	2018	1268	36,06
Support vector machine	1999	1107	31,48
Support vector machine	2009	1240	35,27
Support vector machine	2019	1284	36,52
Support vector machine (NDVI)	2019	1260	35,84
Pyramid scene parsing network	1999	1010	28,73
Pyramid scene parsing network	2009	1026	29,18
Pyramid scene parsing network	2019	1229	34,95
Pyramid scene parsing network (CIR)	2019	1387	39,45

Dauersiedlungsraum aus Regionalinformation (BANU-VO): Benutzungsarten Baufläche, landwirtschaftlich genutzt, Gärten, Weingärten; Nutzungen Straßenanlagen, Bahnanlagen, Abbauflächen, Sonstige nicht näher unterschieden

Dauersiedlungsraum aus Regionalinformation (BANU-V): Gebäude, Gebäudenebenflächen, Gärten, Straßenverkehrsanlagen, Verkehrsrandflächen, Parkplätze, Schienenverkehrsanlagen, Betriebsflächen, Friedhöfe, Abbauflächen, Halden, Deponien, Freizeitflächen, Äcker, Wiesen, Weiden, Dauerkulturen, Erwerbsgärten, verbuschte Flächen und Weingärten




Abbildung 31: Versiegelter Anteil im DSR

Die Daten aus Tabelle 10 und Abbildung 31 stammen aus der Regionalinformation, dem Copernicus Programm und dem eigenständig erstellten Ansatz mit SVM und dem PSPNet.

Die Angaben in der Tabelle 10 beziehen sich auf den Zeitraum 1999 bis 2019. Beim Copernicus Programm ist für das Jahr 1999 kein Datensatz zur Verfügung. Zusätzlich gibt es nur für das Jahr 2018 eine Abschätzung. Die Bodenversiegelung ist in ha angegeben und der prozentuale versiegelte Anteil ist auf den DSR bezogen.

Als Haupttendenz lässt sich feststellen, dass alle Methoden einen kontinuierlichen Anstieg an versiegelten Flächen liefern. Der versiegelte Anteil ist zwischen 1999 und 2019 um mehr als 4 % gestiegen. Das lässt sich aus den Ergebnissen der SVM Klassifizierung ableiten. Das entspricht einer Fläche von ungefähr 150 ha.

Auffällig ist, dass die Daten der Regionalinformation immer die geringsten Werte aufweisen. Bei der Erfassung der Flächeninanspruchnahme aus der DKM wird die Bodenversiegelung im generellen etwas unterschätzt.

Die Werte des satellitengestützten IMD-Layer zeigen ähnliche Resultate wie die Versiegelungsrasster auf Basis der SVMs und dem PSPNet.

Bei Betrachtung der Ergebnisse für das Jahr 2019 liefert das PSPNet mit 39,45 % prozentualer Versiegelung den höchsten Wert. Alle anderen Ergebnisse aus dem Jahr 2019 befinden sich zwischen 32 und 36 %.

Eine starke Schwankung der Resultate zwischen SVM und dem PSPNet liegt für das Jahr 2009 vor. Wie schon in Kapitel 2.7 erwähnt, gab es bei der Klassifizierung mittels SVM in den Waldbereichen Schwierigkeiten. Der geringe Kappa Index für das PSPNet Modell deutet auf eine unstimmige Klassifizierung hin. Dies kann auf die unterschiedlichen Ergebnisse führen. 1999 fällt der Unterschied zwischen SVM und PSPNet geringer aus.

Bei den RGB Klassifizierungen lässt sich feststellen, dass der SVM Algorithmus im Gegensatz zum PSPNet bei allen drei Orthophotos einen höheren Anteil an versiegelten Flächen erfasst.

Aus jedem Klassifizierungsverfahren (SVM und PSPNet) sind vier binäre Versiegelungsraster entstanden. Die nachfolgenden Abbildungen 32 bis 34 visualisieren einige Beispiele der objektbasierten Bildanalyse und des Deep Learning-Ansatzes in verschiedenen Stadtteilen. Die Entwicklung der Bodenversiegelung ist zwischen 1999 und 2019 abgebildet.




Abbildung 32: Versiegelungsraster Stadtteil Amras zwischen 1999-2019



Abbildung 33: Versiegelungsraster Stadtteil Gewerbegebiet Roßau zwischen 1999-2019



Abbildung 34: Versiegelungsraster Stadtteil Höttinger Au zwischen 1999-2019

Wie schon in Kapitel 2.6 erwähnt, bleiben beim flugzeuggestützten Verfahren Unsicherheiten bei der Erfassung der Bodenversiegelung über.

Bäume und Sträucher in unmittelbarer Nähe von Straßenverkehrsanlagen können die Sicht auf die Bodenversiegelung verdecken und damit eine Unterschätzung der Bodenversiegelung verursachen (Üreyen and Thiel, 2017). Wie in Abbildung 35 ersichtlich, können asphaltierte Flächen und Straßensegmente nicht ganz erfasst werden.



Abbildung 35: Eingeschränkte Sicht auf die Bodenversiegelung durch flugzeuggestützte Fernerkundungsdaten

3.2.1 Versiegelungsgrad

Ein wichtiger Punkt in Bezug auf undurchlässige Flächen ist die Erzeugung des Versiegelungsgrades. Diese Kartierungen zeigen den prozentualen versiegelten Anteil bezogen auf eine Bezugseinheit an.

Ausgangspunkt bilden die binären Versiegelungsraster aus Kapitel 2.8 und 2.9. Die klassifizierten Orthophotos können mit verschiedenen statistischen Bezugseinheiten aggregiert werden. Wie Esch et al. (2008) und Üreyen and Thiel (2017) zeigen, kann man den Versiegelungsgrad mit verschiedenen räumlichen Bezugseinheiten modellieren. Die räumliche Verschneidung erfolgt in dieser Arbeit mit zwei vektoriellen Bezugseinheiten. Die statistischen Stadtteile und eine kachelbezogene Einheit werden mit den binären Versiegelungsrastern (0=unversiegelt, 1=versiegelt) verschnitten. Die jeweiligen Pixel beider Hauptklassen Versiegelt und Unversiegelt werden innerhalb der Bezugseinheit aufsummiert und verglichen. Als Resultat erfolgt ein Versiegelungsmodell, welches einen Versiegelungsgrad zwischen 0% (völlig unversiegelt) und 100% (voll versiegelt) aufweist. Der dargestellte Versiegelungsgrad ist abhängig vom klassifizierten Versiegelungsraster. Fehler in der Klassifizierung haben direkten Einfluss auf die Versiegelungskartierung. Je besser das Klassifizierungsergebnis, desto treuer die Darstellung des Versiegelungsgrades.

Die binären Versiegelungsraster werden mit einer Kachelgröße von 20 x 20 m bzw. mit 25 x 25 m verschnitten. Abbildung 36 und 37 zeigt das Ergebnis der Versiegelungskartierung zwischen 0 und 100 %. Die graue Fläche im Hintergrund stellt die Gemeindegrenze dar und beinhaltet größtenteils Waldflächen. Dieser Bereich zählt zum Siedlungsfreien Raum.

Abbildung 39 und 40 zeigt den Versiegelungsgrad bezogen auf die Stadtteile. Grundlage bildet die objektbasierte Bildanalyse.

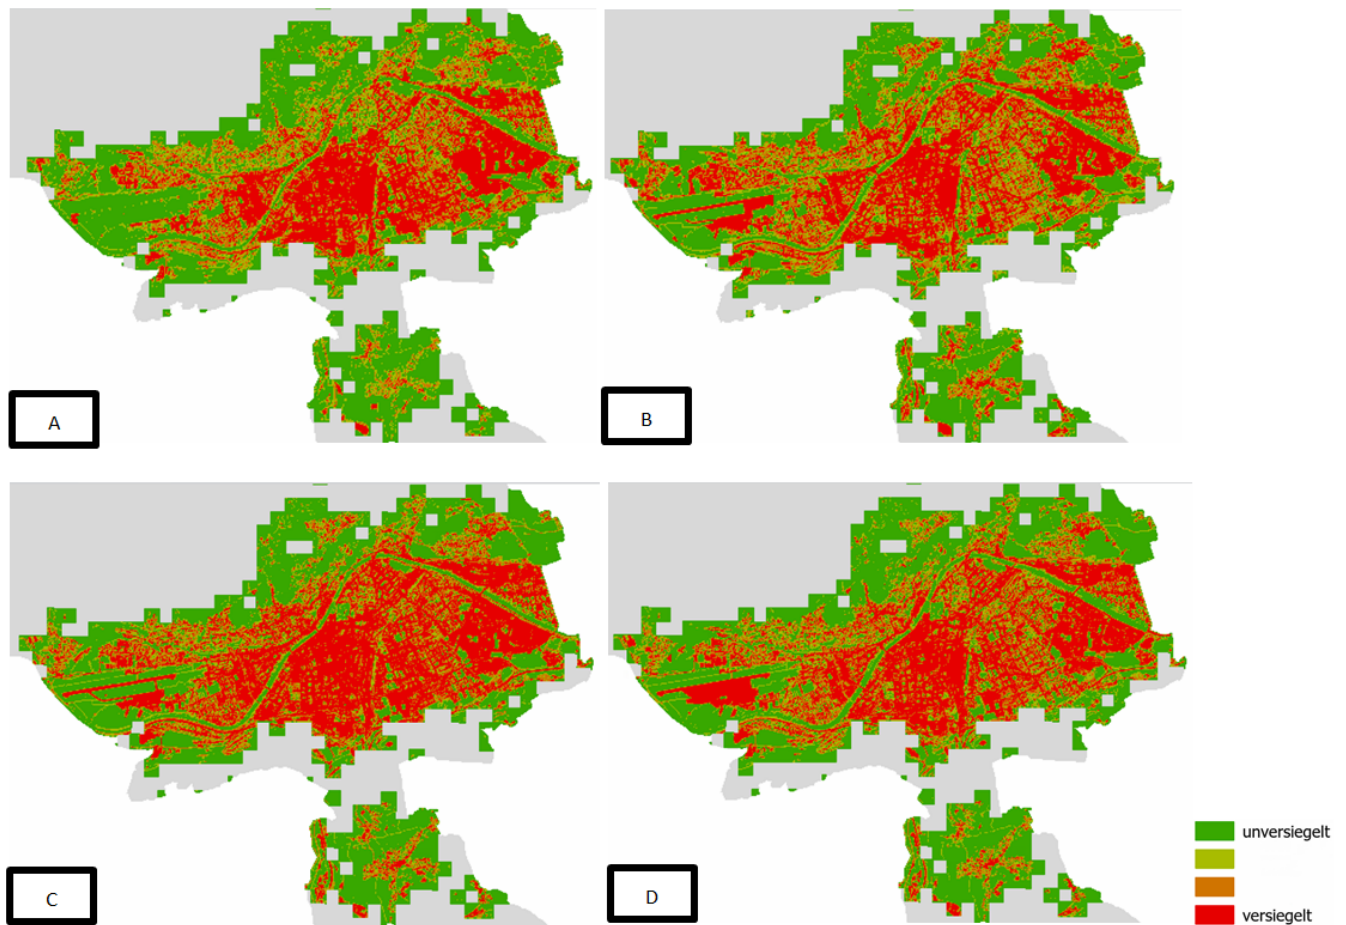


Abbildung 36: Versiegelungskartierungen im DSR zwischen 1999 und 2019 mittels objektbasierter Bildanalyse

Die Zeitreihe der Versiegelungskartierung zeigt den Siedlungs- und Verkehrsraum von Innsbruck. Abbildung 36A, welcher den geringsten versiegelten Anteil aufweist stammt aus dem Jahr 1999. Die Befliegung aus 2009 ist in Abbildung 36B dargestellt. Abbildung 36C und D zeigen den aktuellen Versiegelungsgrad aus 2019. Die linke Abbildung ist aus den RGB Daten abgeleitet und die Rechte aus dem NDVI.

Zwar erreichte der klassifizierte Datensatz in der NDVI Darstellung die höchste Gesamtgenauigkeit, so ist ein Fehler beim Versiegelungsgrad ersichtlich. Im westlichen Bereich entlang des Flughafens wurden Grasflächen falsch als Versiegelt erfasst.

Die Innenstadt veränderte sich in den vergangenen Jahren wenig und zeigt einen hohen Versiegelungsgrad in allen Darstellungen.

Abbildung 37 visualisiert die Versiegelungskartierungen auf Basis des PSPNet. Die grafischen Darstellungen sind analog aufgebaut, wie bei der objektbasierten Bildanalyse.

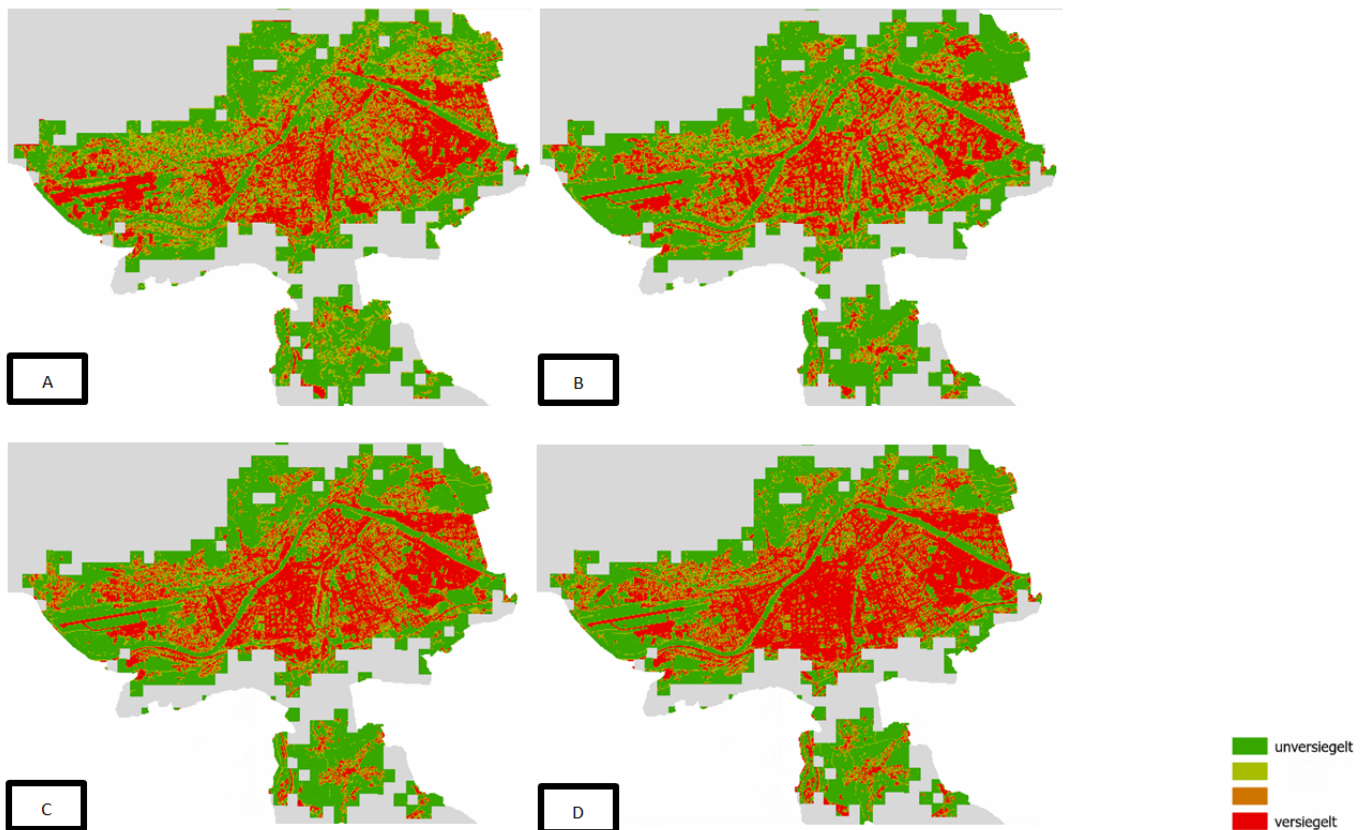


Abbildung 37: Versiegelungskartierungen im DSR zwischen 1999 und 2019 mittels Deep Learning. A zeigt den Versiegelungsgrad für 1999. B zeigt den Versiegelungsgrad für 2009. C zeigt den Versiegelungsgrad für 2019. D zeigt den Versiegelungsgrad für 2019 abgeleitet aus dem CIR Orthophoto.

Es lässt sich nicht nur der Versiegelungsgrad im gesamten DSR darstellen, sondern es können auch einzelne Stadtteile und Ausschnitte visualisiert und auf deren Versiegelungsgrad geprüft werden. Abbildung 38 schildert den veränderten Versiegelungsgrad im Stadtteil Gewerbegebiet Mühlau / Arzl.




Abbildung 38: Veränderung des Versiegelungsgrades zwischen 1999 (links) und 2019 (rechts)

Aus den klassifizierten Versiegelungsrastern kann die Größenordnung für jeden statistischen Stadtteil ermittelt werden (Abbildung 39). Das Säulendiagramm basiert auf den Ergebnissen der objektbasierten Bildanalyse. Mittels räumlicher Verschneidung kann der Bodenverbrauch für jeden Stadtteil bestimmt werden. Somit lässt sich sagen, wie sich der Bodenverbrauch in Innsbruck in den vergangenen 20 Jahren entwickelt hat.

Das Säulendiagramm visualisiert, dass in allen Stadtteilen ein Zuwachs der Flächenversiegelung entstanden ist. Eine größere Zunahme an versiegelten Flächen ergab sich in den Stadtteilen Hötting West oder Gewerbegebiet Mühlau / Arzl. Der Bodenverbrauch in den Stadtteilen Innenstadt oder Arzl veränderte sich nicht wesentlich. In der Innenstadt ist der Bodenverbrauch schon sehr hoch und es ergab sich kaum eine Veränderungen.

Der durchschnittliche Versiegelungsgrad stieg in den letzten zwanzig Jahren von 35 % auf 41 % an. 1999 lag der minimal Wert bei etwa 6 % und der maximale Versiegelungsgrad bei 71 %. 1999 hatten 3/4 der Stadtteile einen Versiegelungsgrad von weniger als 56 %.




Abbildung 39: Versiegelungsgrad der statistischen Stadtteile bezogen auf den DSR

Der minimal Wert liegt 2019 bei 8 % und als obere Grenze gelten 71%. In diesem Jahr findet man 3/4 aller Stadtteile mit einem Versiegelungsgrad von unter 59 % vor.

In der Innenstadt veränderte sich der Versiegelungsgrad in den letzten Jahre kaum. Zudem besitzt dieser Stadtteil den höchsten Wert aller Stadtteile. Am geringsten fällt der Versiegelungsgrad 2019 mit 8 % im Bereich der Hungerburg aus. In diesem Stadtteil sind viele Grün- und Waldflächen zu finden.

Im Stadtteil Gewerbegebiet Mühlau / Arzl stieg der Versiegelungsgrad um knapp 12% an. Im Stadtteil Höttinger Au zeigt sich, dass einige versiegelte Flächen aus dem Datensatz von 1999 nicht richtig erfasst wurden. Es kommt in diesem Stadtteil zu einem großen Unterschied.

Abbildung 40 visualisiert die räumliche Verteilung des Versiegelungsgrades erhoben aus den RGB Daten. Die Stadtteile sind auf den DSR zugeschnitten. Abbildung 40A zeigt den Versiegelungsgrad aus dem Jahr 1999 und Abbildung 40B aus 2019. Beide Darstellungen sind aus der objektbasierten Bildanalyse abgeleitet.

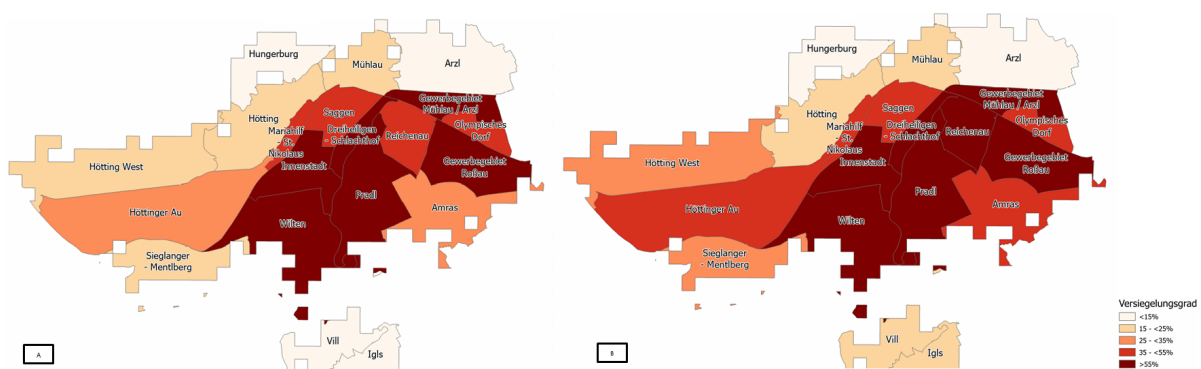


Abbildung 40: Veränderung der Versiegelung zwischen 1999 und 2019

Kein klassifiziertes Orthophoto erreichte eine Genauigkeit von 100 %. Somit bleibt ein Restrisiko für die Bestimmung der Angaben übrig. Beim Vergleich der Stadtteile in Abbildung 39 sind Unsicherheiten gegeben. Größere Unterschiede lassen sich auf die geringere Genauigkeit des Datensatzes aus 1999 zurückführen. Um ein sehr genaues Ergebnis zu erlangen, müsste eine manuelle Auswertung durchgeführt werden. Dennoch bietet diese Ableitung eine flächendeckende Abschätzung der versiegelten Flächen.

4 Diskussion

Das Hauptziel dieser Arbeit bestand darin, historische und aktuelle DOP hinsichtlich ihrer Flächenversiegelung zu untersuchen. Datengrundlage bildeten öffentliche Orthophotos des Landes Tirols. Die Daten verfügen über eine räumliche Auflösung zwischen 20 und 25 cm. Das primäre Ziel dieser Arbeit wurde erreicht, da alle Datensätze abgeleitet wurden und eine Abschätzung der Bodenversiegelung zustande kam.

Es wurden zwei Methoden eingesetzt, um die Rasterdatensätze zu klassifizieren. Beide Verfahren zählen zum Bereich der KI. Die Untersuchung der verbauten Flächen wurde mit einer objektbasierten Bildanalyse und einem Deep Learning-Ansatz durchgeführt. Beide Verfahren nutzten die identischen Trainingsgebiete. Die Methode mit den SVMs führte bei den RGB Datensätze zu besseren Resultaten. Anhand der Genauigkeitsanalyse lässt sich aber feststellen, dass bei der Klassifizierung mit dem zusätzlichen NIR Kanal der Deep Learning-Ansatz geringfügig bessere Ergebnisse erzielte.

Dennoch zeigte sich bei beiden Verfahren, dass Wasserflächen speziell im Inn schwer von versiegelten Flächen zu trennen sind, da ähnliche spektrale Eigenschaften bestehen. Entlang des Inns und der Sill sind die Wasserflächen korrigiert worden. Zusätzlich sind die Schattenbereiche im Wald und im städtischen Raum farblich sehr ähnlich.

Die Genauigkeitsanalyse zeigt, dass die objektbasierte Bildanalyse sowohl bei den historischen als auch beim aktuellen Datensatz aus 2019 im sichtbaren Spektrum besser abschneidet. Die RGB Klassifizierung erreicht 2019 mit der objektbasierten Bildanalyse 94 %, hingegen kam der DL-Ansatz auf 90 %. Zudem zeigt der Kappa Index beim objektbasierten Ansatz mit 0,88 eine höhere Übereinstimmung.

Die Klassifizierungen der Orthophotos auf Basis des SVM Algorithmus stimmt mit anderen Arbeiten und Publikationen überein. Zu ähnlichen Resultaten in der Genauigkeitsanalyse kamen Hiscock et al. (2021). Sie nahmen als Datengrundlage ebenfalls das 20 cm DOP vom Land Tirol. Die Autoren erreichten eine Gesamtgenauigkeit von 89 %. Hingegen wurden mehrere Hundert Referenzpunkte definiert und die Fehlermatrix ist mit insgesamt sieben Klassen durchgeführt worden. Eine hohe Genauigkeit mit mehreren Vergleichsklassen zu erreichen, ist anspruchsvoller als wie bei einer binären Unterscheidung.

Wie bereits Mohamed et al. (2015) zeigen, kann mit dem SVM Algorithmus ein gutes Resultat erreicht werden. Diese Studie baut auf satellitengestützte Daten des Landsat 7 und Landsat 8 auf. Die Autoren nahmen die Klassen Vegetation, Wasser und urbane Bereiche mit in die Klassifizierung. Zwar wurde eine Gesamtgenauigkeit bei den SVMs von über 95 % erreicht, verfügen die Landsat Daten nur über eine räumliche Auflösung von 30 m.

Das PSPNet nahm für die Ableitung der versiegelten Flächen deutlich mehr Zeit in Anspruch. Je mehr Epochen durchlaufen werden, desto mehr Zeit wird benötigt. Für jede durchgeführte Klassifizierung mit 30 Epochen, dauerte es ungefähr 24 Stunden. Das Training für die neuronalen Netzwerke hat somit deutlich längere Rechenzeiten zur Folge. Dies ist natürlich auch abhängig von der Rechenleistung des Computers. Gegenwärtig liegt der zeitliche Aufwand bei der objektbasierten Bildanalyse bei wenigen Stunden.

In dieser Arbeit muss man die SVM Methode bevorzugen. Auch wenn Zhang et al. (2018) mit DL-Ansätzen bessere Resultate erzielen. In dieser Publikation wurden mehrere DL-Algorithmen untersucht. Hochauflösende Satellitendaten des WorldView 2 und 3 mit einer Auflösung von etwa 50 cm standen als Datengrundlage zur Verfügung.

Beim Datensatz aus 2009 zeigt sich bei der visuellen Kontrolle, dass beim DL-Ansatz weniger Fehler in den Waldbereichen vorliegen. Die Schattenbildungen in den Wäldern wurden besser abgeleitet. Der DL-Algorithmus war robuster.

Bei Betrachtung der Abbildung 36A, welche auf den Ergebnissen der objektbasierten Bildanalyse beruht, erzeugt die SVM Variante Fehler im Bereich des Flughafens (Stadtteil Höttinger Au). In diesem Bereich gab es beim DOP aus 1999 eine Unterschätzung an versiegelten Flächen. Dies wirkt sich bei der Gegenüberstellung der Stadtteile aus (Abbildung 39). Eine größere Abweichung zwischen 1999 und 2019 liegt für den Stadtteil Höttinger Au vor.

Die RGB Klassifizierungen, im speziellen bei der objektbasierten Methode erreichen größtenteils gute Klassifizierungsergebnisse. Das RGB Resultat aus 2019 kann mit dem Ergebnis des Versiegelungsrasters mit Anwendung des NDVI mithalten. Ein großer Unterschied besteht darin, dass bei der RGB Klassifizierung deutlich mehr Unterklassen benötigt werden. Sowohl bei der Hauptklasse Versiegelt als auch bei der Hauptklasse Unversiegelt. Für die RGB Datensätze wurden insgesamt elf Klassen definiert. Die NDVI Variante besteht aus fünf Klassen. Ein höherer Zeitaufwand bei der Erstellung der Trainingsgebiete ist die Folge.

Mit dem zusätzlichen NIR Kanal konnte die Zuverlässigkeit der Klassifikation mit beiden Algorithmen (SVM und PSPNet) gesteigert werden.

Das Teilziel der Erzeugung des Versiegelungsgrades kann folgendermaßen analysiert werden. Die Versiegelungskartierungen aus Abbildung 36 und 37 zeigen im Zentrum der Stadt eine gleichbleibende Bebauung. Zwischen 1999 und 2019 stieg der durchschnittliche Versiegelungsgrad der Stadtteile von 35 % auf 41 % an.

Wie auch die Daten der Regionalinformation und des europäischen Copernicus, konnten die eingesetzten Verfahren einen kontinuierlichen Anstieg an verbauten Flächen verzeichnen.

Die Resultate des IMD-Layer unterscheiden sich nicht allzu groß von den flugzeuggestützten Ergebnissen. Beide bauen auf den Grundprinzipien der passiven Fernerkundung auf.

Einzig unterscheidet sich das Verfahren der Regionalinformation zu den anderen Methoden. Die Angaben aus der DKM unterschätzen die Bodenversiegelung. Einige bebaute Flächen werden in der DKM nicht richtig der Bodenversiegelung zugeordnet. So werden teilweise Straßenverkehrsanlagen oder Parkplätze falsch bewertet. Zusätzlich sind wegen Definitionsänderungen der Nutzungsarten ab 2012 Vergleiche vor und nach dieser Verordnung nur bedingt durchführbar.

Eine österreichweite Abschätzungen der Bodenversiegelung könnte auf Fernerkundungsmethoden umgestellt werden. Im Schnitt wird Österreich alle 3 Jahre neu befliegen. Wie Üreyen and Thiel (2017) zeigen, kann auch eine Kombination aus satellitengestützten und flugzeuggestützten Eingangsdaten in Betracht gezogen werden.

5 Schlussfolgerungen und Ausblick

Die steigende Qualität der radiometrischen und geometrischen Eigenschaften der verwendeten Datensätze führt zu immer besseren Ergebnissen in der Klassifizierung. Zwischen dem Datensatz aus 1999 und 2019 ist ein großer radiometrischer Unterschied sichtbar. In den letzten 20 Jahren kam es zu einer stetigen Weiterentwicklung der technischen Komponenten. Die Erzeugung der Trainingsdaten für die Klassifizierung lässt sich aus dem aktuellen Datensatz am Besten durchführen. Je aktueller das DOP, desto bessere Ergebnisse kamen zustande.

Die Überwachung der Bodenversiegelung ist heutzutage ein wichtiges Thema. Dadurch dass die Orthophotos frei zum Download stehen, kann man in anderen Regionen die Bodenversiegelung aus flugzeuggestützten Daten erfassen und analysieren. Mit dem durchgeführten Workflow lassen sich sowohl historische Farbbilder als auch aktuelle Datensätze klassifizieren. Daher stellt sich die Frage nach der Automatisierbarkeit und Anwendung in anderen Teilen Österreichs. Das trainierte Deep Learning-Modell könnte genutzt werden, um in anderen Städten die Bodenversiegelung zu erfassen. Vorausgesetzt die Eigenschaften der zu klassifizierenden Orthophotos sind identisch. Darunter versteht sich die räumliche Auflösung und die Anzahl der Kanäle. Der manuelle Aufwand für die Erzeugung der Trainingsgebiete entfällt.

Die Ableitung der Flächenversiegelung mit der objektbasierten Bildanalyse benötigt für ein anderes Untersuchungsgebiet eine neue Bildsegmentierung und Trainingsgebiete. Nur die anschließende Klassifizierung läuft automatisiert.

Der Dauersiedlungsraum in Innsbruck ist eine Region, welche schon über eine hohe Versiegelung verfügt. Aus dem klassifizierten Ergebnis von 2019 lässt sich entnehmen, dass der versiegelte Anteil im DSR rund 1/3 der gesamten Fläche ausmacht.

Innsbruck verfügt über die höchste Bevölkerungsdichte in Tirol. Eine steigende Einwohnerzahl kann zur Ausweitung des Siedlungs- und Verkehrsraumes führen.

Zwischen 1940 und 1990 entstand eine große Erweiterung der Stadtfläche. In dieser Zeit findet man nur Schwarzweißaufnahmen. Möchte man die Landschaftsbedeckung in Innsbruck vor dem Jahr 1999 klassifizieren, muss man auf 1-Kanalbilder zurückgreifen. Zwar ist die Klassifizierung des städtischen Raumes mit panchromatischen Eingangsdaten wie N. et al. (2020) zeigen möglich, bleibt die technische Umsetzung ein eigenes Unterfangen.

Die Erfassung der versiegelten Flächen auf Basis von flugzeuggestützten Aufnahmen ergab einen Aufschluss über die Stadtentwicklung. Sowohl das Resultat der objektbasierten Bildanalyse als auch der DL-Ansatz liefern eine Möglichkeit, um die Bodenversiegelung analysieren zu können. Die Möglichkeit aus den öffentlichen Rasterdatensätze alle 3 Jahre einen weiteren Versiegelungsraster in Innsbruck zu generieren, bietet eine alternative zu der Regionalinformation. Zukünftige Orthophotos könnten mit dieser Methodik klassifiziert werden und der aktuellen Zeitreihe hinzugefügt werden.

Die hohe zeitliche Verfügbarkeit von Satellitendaten kann nicht erreicht werden. Da aber die Versiegelung und Bebauung von natürlichen Flächen meist ein Prozess über einen längeren Zeitraum ist, reicht die zeitliche Auflösung weniger Jahre.

Seit 2010 ist der NIR Kanal bei allen Befliegungen des BEV Voraussetzung. Erwartungsgemäß lieferte die Klassifizierung mit dem zusätzlichen NIR Kanal bessere Ergebnisse. Zukünftige Arbeiten können auf die Vorteile des 4-Kanalbildes aufbauen.

6 Literaturverzeichnis

- Alzamaly, J. Y. I., Ariffin, S. B., and Abu-Naser, S. S. (2022). Classification of encrypted images using deep learning–resnet50. *Journal of Theoretical and Applied Information Technology*, 100(21).
- ArcGIS (2021). Was ist arcpy? <https://desktop.arcgis.com/de/arcmap/latest/analyze/arcpy/what-is-arcpy-.htm>.
- ArcGIS (2022a). Einführung in deep learning. <https://pro.arcgis.com/de/pro-app/latest/help/analysis/deep-learning/what-is-deep-learning-.htm>.
- ArcGIS (2022b). Segmentierung und klassifizierung. <https://pro.arcgis.com/de/pro-app/latest/tool-reference/spatial-analyst/understanding-segmentation-and-classification.htm>.
- Bachofer, F., Esch, T., and Klein, D. (2009). Ableitung von versiegelungsgraden basierend auf hochaufgelösten fernerkundungsdaten mittels support vector machines. *Angewandte Geoinformatik 2009*, pages 432–441.
- BEV (2019). Bev - fernerkundung. *Bundesamt für Eich- und Vermessungswesen*. zuletzt geprüft am 25.05.2022.
- Boyle, C., Mudd, G., Mihelcic, J. R., Anastas, P., Collins, T., Culligan, P., Edwards, M., Gabe, J., Gallagher, P., Handy, S., et al. (2010). Delivering sustainable infrastructure that supports the urban built environment.
- Briassoulis, H. (2020). Analysis of land use change: theoretical and modeling approaches.
- Bundesministerium für Landwirtschaft, R. u. T. (2021). Zahlen und fakten zur österreichischen raumentwicklung. <https://info.bmlrt.gv.at/themen/regionen-raumentwicklung>.
- Congalton, R., Oderwald, R., and Mead, R. (1983). Assessing landsat classification accuracy using discrete multivariate analysis statistical techniques. *Photogrammetric Engineering Remote Sensing*, 49(12):1671 – 1678. Cited by: 562.
- Congalton, R. G. (1991). A review of assessing the accuracy of classifications of remotely sensed data. *Remote Sensing of Environment*, 37(1):35–46.
- Congalton, R. G. and Green, K. (2019). *Assessing the accuracy of remotely sensed data: principles and practices*. CRC press.
- De Lange, N. (2006). *Geoinformatik in Theorie und Praxis*, volume 2. Springer.
- Esch, T., Conrad, C., Schorcht, G., Thiel, M., Wehrmann, T., and Dech, S. (2008). Model-based estimation of impervious surface by application of support vector machines. pages 41–45.

-
- EU (2018). Copernicus land monitoring service. <https://land.copernicus.eu/user-corner/technical-library/imperviousness-2018-user-manual.pdf>.
- EU-Kommission (2012). Soil sealing. <https://ec.europa.eu/environment/archives/soil/pdf>.
- Foody, G. M. (2020). Explaining the unsuitability of the kappa coefficient in the assessment and comparison of the accuracy of thematic maps obtained by image classification. *Remote Sensing of Environment*, 239:111630.
- Garcia, P. and Perez, E. (2016). Mapping of soil sealing by vegetation indexes and built-up index: A case study in madrid (spain). *Geoderma*, 268:100–107.
- García, P., Pérez, M. E., and Guerra, A. (2014). Using tm images to detect soil sealing change in madrid (spain). *Geoderma*, 214:135–140.
- Gunn, S. R. et al. (1998). Support vector machines for classification and regression. *ISIS technical report*, 14(1):5–16.
- Hendawy, E., Belal, A., Mohamed, E., Elfadaly, A., Murgante, B., Aldosari, A. A., and 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. *Sustainability*, 11(17):4662.
- Hiscock, O. H., Back, Y., Kleidorfer, M., and Urich, C. (2021). A GIS-based land cover classification approach suitable for fine-scale urban water management. *Water Resources Management*, 35(4):1339–1352.
- Jordan, M. I. and Mitchell, T. M. (2015). Machine learning: Trends, perspectives, and prospects. *Science*, 349(6245):255–260.
- Kanada, Y. (2016). Optimizing neural-network learning rate by using a genetic algorithm with per-epoch mutations. In *2016 International Joint Conference on Neural Networks (IJCNN)*, pages 1472–1479.
- Kattenborn, T., Leitloff, J., Schiefer, F., and Hinz, S. (2021). Review on convolutional neural networks (CNN) in vegetation remote sensing. *ISPRS Journal of Photogrammetry and Remote Sensing*, 173:24–49.
- Knudsen, T. and Olsen, B. P. (2003). Automated change detection for updates of digital map databases. *Photogrammetric Engineering & Remote Sensing*, 69(11):1289–1296.
- Krizhevsky, A., Sutskever, I., and Hinton, G. E. (2012). ImageNet classification with deep convolutional neural networks. *Advances in neural information processing systems*, 25.
- Langella, G., Basile, A., Giannecchini, S., Moccia, F. D., Mileti, F. A., Munafó, M., Pinto, F., and Terribile, F. (2020). Soil monitor: an internet platform to challenge soil sealing in Italy. *Land Degradation & Development*, 31(18):2883–2900.

- LGLN (2023). Digitale orthophotos des atkis (atkis-dop) - aktuell und historisch. <https://www.lgln.niedersachsen.de/>.
- Lillesand, T., Kiefer, R. W., and Chipman, J. (2015). *Remote sensing and image interpretation*. John Wiley & Sons.
- Liu, D. and Xia, F. (2010). Assessing object-based classification: advantages and limitations. *Remote sensing letters*, 1(4):187–194.
- Liu, T. and Yang, X. (2015). Monitoring land changes in an urban area using satellite imagery, gis and landscape metrics. *Applied Geography*, 56:42–54.
- Lu, D., Hetrick, S., and Moran, E. (2011). Impervious surface mapping with quickbird imagery. *International journal of remote sensing*, 32(9):2519–2533.
- Lu, D. and Weng, Q. (2006). Use of impervious surface in urban land-use classification. *Remote sensing of environment*, 102(1-2):146–160.
- Luman, D. E., Stohr, C., and Hunt, L. (1997). Digital reproduction of historical aerial photographic prints for preserving a deteriorating archive. *Photogrammetric Engineering and Remote Sensing*, 63(10):1171 – 1179. Cited by: 10.
- M., D., M., B., and S., P. (2009). Object-based classification of very high resolution panchromatic images for evaluating recent change in the structure of patterned peatlands. *Canadian Journal of Remote Sensing*, 35(2):189 – 215. Cited by: 39.
- Ma, L., Liu, Y., Zhang, X., Ye, Y., Yin, G., and Johnson, B. A. (2019). Deep learning in remote sensing applications: A meta-analysis and review. *ISPRS journal of photogrammetry and remote sensing*, 152:166–177.
- Martha, T. R., Kerle, N., van Westen, C. J., Jetten, V., and Vinod Kumar, K. (2012). Object-oriented analysis of multi-temporal panchromatic images for creation of historical landslide inventories. *ISPRS Journal of Photogrammetry and Remote Sensing*, 67:105–119.
- Mohamed, E. S., Belal, A., and Shalaby, A. (2015). Impacts of soil sealing on potential agriculture in egypt using remote sensing and gis techniques. *Eurasian Soil Science*, 48(10):1159–1169.
- Montgomery, D. R. (2012). *Dirt: The erosion of civilizations*. Univ of California press.
- N., M., S., G., T., G., M., L., S., V., and E., W. (2019). Fully convolutional networks and geographic object-based image analysis for the classification of vhr imagery. *Remote Sensing*, 11(5). Cited by: 34; All Open Access, Gold Open Access, Green Open Access.
- N., M., T., G., S., G., S., V., B., S., O., D., E., W., and M., L. (2020). Fully convolutional networks for land cover classification from historical panchromatic aerial photographs. *ISPRS Journal of Photogrammetry and Remote Sensing*, 167:385 – 395. Cited by: 14.

- Nagendra, H., Lucas, R., Honrado, J. P., Jongman, R. H., Tarantino, C., Adamo, M., and Mairota, P. (2013). Remote sensing for conservation monitoring: Assessing protected areas, habitat extent, habitat condition, species diversity, and threats. *Ecological Indicators*, 33:45–59. Biodiversity Monitoring.
- Neubert, M. and Blaschke, T. (2004). Segmentierung von fernerkundungsdaten als grundlage zur ableitung von landschaftsstrukturmaßen. *Landschaftsstruktur im Kontext von naturräumlicher Vorprägung und Nutzung–Datengrundlagen, Methoden und Anwendungen. IÖR-Schriften*, 43:91–108.
- Neubert, M., Meinel, G., Strobl, J., Blaschke, T., and Griesebner, G. (2003). Segmentierungsansätze für fernerkundungsdaten im vergleich. *Heidelberg: Wichmann*, pages 323–329.
- Nielsen, M. A. (2015). *Neural networks and deep learning*, volume 25. Determination press San Francisco, CA, USA.
- Oczipka, M. E. (2007). *Objektbasierte Klassifizierung hochauflösender Daten in urbanen Räumen unter besonderer Berücksichtigung von Oberflächenmodellen*. PhD thesis.
- Peroni, F., Pappalardo, S. E., Facchinelli, F., Crescini, E., Munafò, M., Hodgson, M. E., and De Marchi, M. (2022). How to map soil sealing, land take and impervious surfaces? a systematic review. *Environmental Research Letters*, 17(5):053005.
- Qin, R. and Fang, W. (2014). A hierarchical building detection method for very high resolution remotely sensed images combined with dsm using graph cut optimization. *Photogrammetric Engineering & Remote Sensing*, 80(9):873–883.
- Ratajczak, R., Crispim-Junior, C. F., Faure, E., Fervers, B., and Tougne, L. (2019). Automatic land cover reconstruction from historical aerial images: An evaluation of features extraction and classification algorithms. *IEEE Transactions on Image Processing*, 28(7):3357–3371.
- Sasidhar, T. T., Sreelakshmi, K., Vyshnav, M., Sowmya, V., and Soman, K. (2019). Land cover satellite image classification using ndvi and simplecnn. In *2019 10th International Conference on Computing, Communication and Networking Technologies (ICCCNT)*, pages 1–5. IEEE.
- Scalenghe, R. and Marsan, F. A. (2009). The anthropogenic sealing of soils in urban areas. *Landscape and urban planning*, 90(1-2):1–10.
- Scherk, J., Pöchlacker-Tröscher, G., and Wagner, K. (2017). Künstliche intelligenz-artificial intelligence. *A Report commissioned by the German Federal Ministry of Transport and Infrastructure*.
- Seto, K. C., Güneralp, B., and Hutyrá, L. R. (2012). Global forecasts of urban expansion to 2030 and direct impacts on biodiversity and carbon pools. *Proceedings of the National Academy of Sciences*, 109(40):16083–16088.
- Strand, G.-H. (2022). Accuracy of the copernicus high-resolution layer imperviousness density (hrl imd) assessed by point sampling within pixels. *Remote Sensing*, 14(15):3589.

- Sun, W. and Wang, R. (2018). Fully convolutional networks for semantic segmentation of very high resolution remotely sensed images combined with dsm. *IEEE Geoscience and Remote Sensing Letters*, 15(3):474–478.
- Suthaharan, S. (2016). Support vector machine. In *Machine learning models and algorithms for big data classification*, pages 207–235. Springer.
- Tirol, L. (2022). Regionsprofil. <http://www.tirol.gv.at/regionsprofil>.
- Umweltbundesamt (2017). Bodenverbrauch gefährdet lebensgrundlage der nächsten generationen. <https://www.umweltbundesamt.at/aktuelles/presse/news2017>.
- Umweltbundesamt (2022). Bodenversiegelung. <https://www.umweltbundesamt.de/daten/flaechenboden-land-oekosysteme/boden/bodenversiegelung>.
- Umweltbundesamt (2023). Flächeninanspruchnahme Österreich. <https://www.umweltbundesamt.at/umweltthemen/boden/flaecheninanspruchnahme>.
- Üreyen, S. and Thiel, M. (2017). Satellitengestützte erfassung der bodenversiegelung in bayern 2015. Technical report, Bayerisches Landesamt für Umwelt (LfU).
- Wang, Y. and Li, M. (2019). Urban impervious surface detection from remote sensing images: A review of the methods and challenges. *IEEE Geoscience and Remote Sensing Magazine*, 7(3):64–93.
- Weng, Q. (2019). *Techniques and methods in urban remote sensing*. John Wiley & Sons.
- Wennker, P. (2020). *Künstliche Intelligenz in der Praxis: Anwendung in Unternehmen und Branchen: KI wettbewerbs- und zukunftsorientiert einsetzen*. Springer.
- WONKA, E. (2008). Neuabgrenzung des dauersiedlungsraums. *Statistik Austria*. https://www.oerok-atlas.at/documents/neuabgrenzung_aesa_dauersiedlungsraums.pdf.
- Xu, Y., Wu, L., Xie, Z., and Chen, Z. (2018). Building extraction in very high resolution remote sensing imagery using deep learning and guided filters. *Remote Sensing*, 10(1).
- Yang, H., Yu, B., Luo, J., and Chen, F. (2019). Semantic segmentation of high spatial resolution images with deep neural networks. *GIScience & Remote Sensing*, 56(5):749–768.
- Yu, B., Yang, L., and Chen, F. (2018). Semantic segmentation for high spatial resolution remote sensing images based on convolution neural network and pyramid pooling module. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 11(9):3252–3261.
- Yuan, W., Wang, J., and Xu, W. (2022). Shift pooling pspnet: Rethinking pspnet for building extraction in remote sensing images from entire local feature pooling. *Remote Sensing*, 14(19):4889.

-
- Zhang, P., Ke, Y., Zhang, Z., Wang, M., Li, P., and Zhang, S. (2018). Urban land use and land cover classification using novel deep learning models based on high spatial resolution satellite imagery. *Sensors*, 18(11):3717.
- Zhang, X., Han, L., Han, L., and Zhu, L. (2020). How well do deep learning-based methods for land cover classification and object detection perform on high resolution remote sensing imagery? *Remote Sensing*, 12(3).
- Zhao, H., Shi, J., Qi, X., Wang, X., and Jia, J. (2017). Pyramid scene parsing network. In *Proceedings of the IEEE conference on computer vision and pattern recognition*, pages 2881–2890.
- Zhao, J., Wang, L., Yang, H., Wu, P., Wang, B., Pan, C., and Wu, Y. (2022). A land cover classification method for high-resolution remote sensing images based on ndvi deep learning fusion network. *Remote Sensing*, 14(21):5455.
- ÖROK (2018). Bodenversiegelung in Österreich. <https://www.oerok-atlas.at/oerok/files/summaries/61.pdf>.