



Abschlussbericht zum Projekt

EBOVE

Erfassung der landesweit versiegelten Fläche und Ermittlung des Indikators Bodenversiegelung für NRW

Laufzeit: 01.05.2023 bis 31.10.2024

Eine Kooperation von

Landesamt für Natur, Umwelt und Verbraucherschutz Nordrhein-Westfalen
(LANUV NRW)

und

Ruhr-Universität Bochum (RUB),
Geographisches Institut, AG Interdisziplinäre Geoinformationwissenschaften

unter Mitwirkung des

Landesbetriebs Information und Technik Nordrhein-Westfalen (IT.NRW)

Zitiervorschlag für diesen Projektbericht

Langenkamp, J.-P., Bamming, C., Escher, T., Kiani, S., Kreke, M., Meidler, E., Neite, H., Pieper, M., Radloff, L., Rienow, A., Roth, P., Waetke, M., Wolff, I., Herkt, M. (2025). Abschlussbericht zum Projekt EBOVE: Erfassung der landesweit versiegelten Fläche und Ermittlung des Indikators Bodenversiegelung für NRW. Hrsg: Landesamt für Natur, Umwelt und Verbraucherschutz NRW, Recklinghausen. URL: <https://www.lanuv.nrw.de/themen/boden/bodenschutz-beim-planen-und-bauen/bodenversiegelung>

Verfügbarkeit des erzeugten Datenprodukts

Der vorliegende Projektbericht beschreibt ein Verfahren zur behördlichen Herstellung eines Datenprodukts. Gemäß der Open.NRW-Strategie ist das erstellte Produkt frei verfügbar und kann über folgende Wege bezogen werden:

https://www.wms.nrw.de/wms/bodenversiegelung_luftbildbasiert

https://www.klimaatlas.nrw.de/klima-nrw-pluskarte?&itnrw_layer=BO_VGLBR

https://www.opengeodata.nrw.de/produkte/umwelt_klima/klima/boden/bodenversiegelung

Zitiervorschlag für das erzeugte Datenprodukt

LANUV NRW (2024). Luftbildbasierte Bodenversiegelung in NRW nach dem Berechnungsverfahren des Kooperationsprojekts EBOVE. Auswertungsstand Dezember 2024. URL: https://www.opengeodata.nrw.de/produkte/umwelt_klima/klima/boden/bodenversiegelung

Finanzierung

Ministerium für Umwelt, Naturschutz und Verkehr des Landes Nordrhein-Westfalen

Ministerium für Umwelt,
Naturschutz und Verkehr
des Landes Nordrhein-Westfalen



Bearbeitung

Jan-Philipp Langenkamp, M.Sc.

Max Kreke

Sohrab Kiani, B.Sc.

Eva Meidler, B.Sc.

Lara Radeloff, B.A.

Jun.-Prof. Dr. Andreas Rienow

Arbeitsgruppe Interdisziplinäre Geographische Informationswissenschaften

Geographisches Institut, Ruhr-Universität Bochum

Universitätsstraße 150

44801 Bochum

Tom Escher

Dr. Chris Bamminger

Dr. Philipp Roth

Dr. Ingo Wolff

Matthias Herkt

Dr. Heinz Neite

Die Fachbereiche 21, 32 und 37

Landesamt für Natur, Umwelt und Verbraucherschutz Nordrhein-Westfalen

Leibnizstr. 10

45659 Recklinghausen

Marcel Waetke

Melanie Pieper

Geoinformationszentrum

Landesbetrieb Information und Technik Nordrhein-Westfalen

Mauerstraße 51

40476 Düsseldorf

Danksagung

Wir bedanken uns bei der Stadt Wuppertal und der Emschergenossenschaft/ Lippeverband für die Bereitstellung von Referenzdaten.

Inhaltsverzeichnis

Abbildungsverzeichnis	VI
Tabellenverzeichnis	VII
Abkürzungsverzeichnis	VIII
I Einleitung	1
II Daten und Aufbereitung	3
1 Datengrundlage	3
1.1 Digitale Orthophotos (DOP)	3
1.2 Versiegelungsdaten	4
1.3 Amtliches Liegenschafts- und Katasterinformationssystem (ALKIS)	6
2 Trainingsdaten	7
2.1 Datenaufbereitung	8
2.2 Datensatzerweiterung	10
2.3 Trainings- und Testdatensatz	11
3 Validierungsdaten	11
3.1 Validierungsgebiete	11
3.2 Validierungsdatensatz	12
III Modelltraining	14
1 Modell	14
1.1 Modellarchitektur	14
1.2 Implementierung	16
2 Training	17
IV Software	20
1 Aufbau	20
2 Post-Processing	21
2.1 Überlagerung der Wahrscheinlichkeitskarten und ALKIS-Daten	21
2.2 Kachelweise Erstellung binärer Versiegelungskarten	22
3 Datenbereitstellung	22
V Ergebnisse und Validierung	25
1 Bewertungsmetriken	25

Inhaltsverzeichnis

2	Validierung der Versiegelungskarte	26
3	Visuelle Analyse der Ergebnisse	27
3.1	Stadtgebiet Münster	27
3.2	Stadtgebiet Dortmund	28
3.3	Stadtgebiet Köln	29
3.4	Spezielle Oberflächentypen	30
3.5	Fehlklassifikationen	30
VI	Fazit und Empfehlungen	33
1	Bilddaten	33
2	Trainingsdaten	34
3	Post-Processing	36
4	Folgeberechnungen und Versiegelungsstatistik	36
VII	Literaturverzeichnis	38
Anhang	42

Abbildungsverzeichnis

Abbildung 1: Versiegelungsdaten der EGLV (links) und der Stadt Wuppertal (rechts) (Datenquellen: Geobasis NRW 2024d, EGLV o. J., Stadt Wuppertal o. J.)	4
Abbildung 2: Trainingspaar aus DOP (links) und Ground-Truth-Maske (rechts) (Datenquellen: Geobasis NRW 2024d, EGLV o. J.)	8
Abbildung 3: UTM-Kachel-Vektordatensatz von NRW (Datenquellen: Geobasis NRW 2024d, Geobasis NRW 2019)	9
Abbildung 4: Erstellung von Patches (Datenquellen: Geobasis NRW 2024d, EGLV o. J.)	10
Abbildung 5: Validierungsgebiete der Versiegelungskarte (Datenquellen: Geobasis NRW 2024e, Mundialis GmbH & Co. KG 2021)	12
Abbildung 6: Modellarchitektur des UNetFormer Modells (Wang et al. 2022)	15
Abbildung 7: Allgemeiner Trainingsablauf (Datenquelle: Geobasis NRW 2024d, EGLV o. J.)	17
Abbildung 8: Aufbau der erstellten Software	20
Abbildung 9: Versiegelungskarte der Landesfläche NRW (Datenquelle: Geobasis NRW 2024d)	24
Abbildung 10: Detailausschnitt der Versiegelungskarte – Münster (Datenquellen: Geobasis NRW 2024d, Geobasis NRW 2024h)	27
Abbildung 11: Detailausschnitt der Versiegelungskarte – Dortmund (Datenquellen: Geobasis NRW 2024d, Geobasis NRW 2024h)	28
Abbildung 12: Detailausschnitt der Versiegelungskarte – Köln (Datenquellen: Geobasis NRW 2024d, Geobasis NRW 2024h)	29
Abbildung 13: Berechnete Versiegelung spezieller Oberflächentypen (von links nach rechts pro Zeile: Freiflächen Photovoltaik, Gartenhäuser (Fläche >15 m ²), Agrarfolien, Gleiskörper; Freibäder, Klärbecken, Versiegelte Flächen über Gewässer, Versiegelte Flächen über Gewässer und Offenland) (Datenquellen: Geobasis NRW 2024d, Geobasis NRW 2024h)	30
Abbildung 14: Beispiele für Fehlklassifikationen der Versiegelungskarte (Datenquellen: Geobasis NRW 2024d, Geobasis NRW 2024h)	31

Tabellenverzeichnis

Tabelle 1: Geodatendienste zur Ansteuerung von Bildinformationen	3
Tabelle 2: Übersicht der Aktualität von Versiegelungsdaten und DOP	5
Tabelle 3: Übersichtstabelle zur Berücksichtigung spezieller Oberflächentypen für die binäre Klassifikation „versiegelt / nicht-versiegelt“	6
Tabelle 4: Verwendete ALKIS-Objektarten und entfernte Wertarten	7
Tabelle 5: Geodatendienst zur Ansteuerung von ALKIS-Daten.....	7
Tabelle 6: Anzahl der Stichproben pro Klasse und je Validierungsgebiet.....	13
Tabelle 7: Gewichtung von ALKIS-Daten im Post-Processing.....	22
Tabelle 8: Übersicht erzielter Genauigkeiten in den Validierungsgebieten.....	26

Abkürzungsverzeichnis

B	Blau
bDOM	bildbasiertes digitales Oberflächenmodell
CDI	Copernicus Dateninfrastruktur
CNN	Convolutional Neural Network
DOP	Digitale Orthophotos
EGLV	Emschergenossenschaft und Lippeverband (Körperschaft ö.R.)
FRH	Feature Refinement Head
G	Grün
GLTB	Global Local Transformer Block
IoU	Intersection over Union (Jaccard's Ähnlichkeitsindex)
IT.NRW	Landesbetrieb Information und Technik NRW
KI	Künstliche Intelligenz
LANUV	Landesamt für Natur, Umwelt und Verbraucherschutz
MCC	Matthews Correlation Coefficient
NIR	Nahes Infrarot
OA	Overall Accuracy (Gesamtgenauigkeit)
PA	Producer's Accuracy (Herstellergenauigkeit bzw. Ausschlussfehler)
R	Rot
ResNet	Residual Neural Network
RUB	Ruhr-Universität Bochum
UA	User's Accuracy (Benutzergenauigkeit bzw. Einschlussfehler)
UNet Former	UNet-like Transformer
SuV	Siedlungs- und Verkehrsflächen

I Einleitung

Die Bodenversiegelung hat vielfältige negative Auswirkungen auf unsere Umwelt. Die Versiegelung von Flächen mithilfe künstlicher Baustoffe wie etwa Beton oder Asphalt beeinträchtigt die natürliche Bodenfunktion. So wird der Gasaustausch zwischen Boden und Atmosphäre verhindert und Wasser kann weder infiltrieren noch in das Grundwasser perkolieren (Arnold und Gibbons 1996). Beispielsweise führt dies zu einem erhöhten Oberflächenabfluss, was insbesondere bei Starkregenereignissen das Risiko von lokalen Überschwemmungen erhöht (Shuster et al. 2005). Darüber hinaus trägt die Versiegelung zur Zerstörung von Lebensräumen für Pflanzen und Tiere bei (Barnes et al. 2001) und verstärkt den städtischen Wärmeinseleffekt (Memon et al. 2008).

Deutschland verfolgt das Ziel, die tägliche Flächenneuanspruchnahme durch Siedlungs- und Verkehrsflächen (SuV) bis 2030 auf weniger als 30 Hektar zu reduzieren (Bundesregierung Deutschland 2020). Aktuell werden etwa 45% der SuV in Deutschland als versiegelte Fläche angenommen (UBA 2024). Die Bodenversiegelung wird dabei nicht unmittelbar gemessen, sondern auf Basis der Flächenstatistik durch die Umweltökonomische Gesamtrechnung der Länder näherungsweise berechnet (Friedrich und Hensel 2009).

In den vergangenen Jahren hat sich die Fernerkundung als geeignete Methode für die Erfassung von versiegelten Flächen bewährt. Dabei ist eine Auswertung nicht ausschließlich auf Satellitendaten beschränkt, sondern auch unter Nutzung räumlich sehr hochaufgelöster Orthophotos möglich (Schmidt und Barron 2020; Sandmann 2022; Langenkamp und Rienow 2023). Die flächendeckend verfügbaren, sehr hochauflösenden und frei zugänglichen Digitalen Orthophotos (DOP) des Bundeslandes Nordrhein-Westfalen (NRW) stellen in diesem Zusammenhang einen besonders geeigneten Datensatz dar. Eine zeitgleiche Befliegung der gesamten Landesfläche ist per Flugzeug jedoch nicht möglich. Die DOP weisen daher eine ausgeprägte räumliche und zeitliche Heterogenität auf, was eine große Herausforderung bei der Erfassung versiegelter Flächen darstellt. Durch den zunehmenden Einsatz von Methoden der künstlichen Intelligenz (KI), wird es möglich, diese umfangreichen Datenmengen effizient zu verarbeiten und zu analysieren. Dies eröffnet neue Möglichkeiten, um versiegelte Flächen direkt, landesweit und hochauflösend zu erfassen und das Monitoring der Bodenversiegelung zu verbessern.

Das Projekt EBOVE baut auf Ergebnissen einer Vorstudie „Zum aktuellen Forschungsstand der Auswertung von Fernerkundungsdaten sowie weiterer Datenquellen zur Ermittlung des Indikators Versiegelung“ auf, welche die Ruhr Universität Bochum (RUB) im Auftrag des Landesamtes für Natur, Umwelt und Verbraucherschutz (LANUV) NRW vom 01.11.2021 bis 31.07.2022 durchgeführt hat.

Ziel des Projekts EBOVE war die Entwicklung eines automatisierten Verfahrens zur hochaufgelösten und direkten Erfassung der landesweit versiegelten Fläche und zur Ermittlung des Indikators Bodenversiegelung für NRW. Die mit diesem Verfahren herstellbare Karte sollte u.a.

- versiegelte Flächen binär darstellen (versiegelt / nicht-versiegelt)
- eine räumliche Auflösung von 0,5 m erreichen und
- zur Fortführung der Versiegelungsstatistik alle zwei Jahre aktualisiert werden können.

Die Durchführung des Projekts erfolgte über einen Zeitraum von 18 Monaten unter Federführung des Fachbereichs 32 (Initiative und Projektmanagement) mit Einbindung von Fachbereich 21 (fernerkundliche Beratung) und Fachbereich 37 (Bereitstellung Endprodukt) des LANUV NRW, und in engem Austausch mit den Projektbeteiligten von der RUB (Entwicklung und Dokumentation der Methodik) sowie des Landesbetriebs Information und Technik NRW (IT.NRW) (Bereitstellung der zentralen GIS-Infrastruktur). Um eine behördenseitig eigenständige künftige Nutzung des Verfahrens sicherzustellen, wurde es in der Copernicus Dateninfrastruktur von IT.NRW (CDI@IT.NRW) implementiert, und die Berechnungsergebnisse (zweijährliche Bodenversiegelungskarten) werden über den Klimaatlas-NRW des LANUV und das Portal Open.NRW bereitgestellt.

II Daten und Aufbereitung

Die Erstellung eines Modells zur Erfassung versiegelter Flächen auf Basis künstlicher Intelligenz (KI) bedarf einer großen Menge an qualitativ hochwertiger und möglichst diverser Trainingsdaten. Neben den Trainingsdaten werden unabhängige Validierungsdaten benötigt, anhand derer die Versiegelungskarte für NRW bewertet werden kann. Nachfolgend wird die Datengrundlage, sowie die Erstellung von Trainings- und Validierungsdaten zur Erfassung versiegelter Flächen und Bewertung der Versiegelungskarte beschrieben.

1 Datengrundlage

1.1 Digitale Orthophotos (DOP)

Um die gewünschte räumliche Auflösung von 0,5 m zu erreichen, wurden DOP des Landes NRW verwendet. Die DOP liegen verzerrungsfrei in der Qualitätsstufe „True-DOP“ vor und bilden die Erdoberfläche mit einer räumlichen Auflösung von 0,1 m ab (Geobasis NRW 2024c). Die DOP enthalten Aufzeichnungen der zurückgeworfenen elektromagnetischen Strahlung in den vier Spektralbereichen Rot (R), Grün (G), Blau (B) und Nahes Infrarot (NIR).

Die DOP werden im Zuge von Befliegungen im Sommer (belaubt) und Frühling (unbelaubt) erstellt. Diese finden asynchron alle zwei Jahre statt, mit variierenden Belaubungs- und Belichtungszuständen (Geobasis NRW 2024c). Im Rahmen dieses Projekts wurden die DOP über Geodatendienste des Landes NRW bezogen. Diese standardisierten Dienste ermöglichen eine skriptbasierte Ansteuerung von Geodaten (Geobasis NRW 2024f). Die DOP wurden vom sogenannten Web-Coverage-Server (WCS) bezogen. Zusätzlich wurden die Metadaten der DOP in Form des Bildflugdatums über einen Web-Map-Service (WMS) abgerufen. Die verwendeten WCS- und WMS-Dienste werden in Tabelle 1 dokumentiert.

Tabelle 1: Geodatendienste zur Ansteuerung von Bildinformationen

Geodatendienst	URL
WCS (DOP)	https://www.wcs.nrw.de/geobasis/wcs_nw_dop
WMS (DOP - Metadaten)	https://www.wms.nrw.de/geobasis/wms_nw_dop

Quellen: Geobasis NRW 2024d

Die Verfügbarkeit der DOP des WCS-Dienstes bestimmt die Aktualität der verwendeten DOP. Für den Projektzeitraum waren im WCS-Dienst Daten aus den Jahren 2022, 2023 und 2024 mit insgesamt 52 unterschiedlichen Aufnahmezeitpunkten abrufbar. Somit ist auch die zweijährliche Berechnung der Versiegelungskarte an die Verfügbarkeit der DOP im WCS-Dienst gebunden. Neben den DOP des WCS-Dienstes wurden

ergänzend DOP mit NIR-Kanal aus dem Sommer 2021 für das Stadtgebiet Wuppertal herangezogen, da diese bereits aus der Vorstudie vorlagen.

1.2 Versiegelungsdaten

Als Referenzdaten (ground truth) wurden qualitativ hochwertige Versiegelungsdaten der Emscher-Genossenschaft und des Lippeverbands (EGLV) sowie der Stadt Wuppertal verwendet (EGLV o. J.; Stadt Wuppertal o. J.). Diese Versiegelungsdaten repräsentieren durch photogrammetrische Auswertung erhobene und kontinuierlich gepflegte Versiegelungsinformationen und wurden als georeferenzierte Vektordaten bereitgestellt. Die Datensätze beinhalten Informationen zu Gebäuden, öffentlichen Verkehrsflächen und privaten Flächen. In diesem Projekt wurden die Daten in die Kategorien „versiegelte Flächen“ und „nicht-versiegelte Flächen“ unterteilt. Beispielhaft werden die Datensätze der EGLV und der Stadt Wuppertal in Abbildung 1 visualisiert.



Abbildung 1: Versiegelungsdaten der EGLV (links) und der Stadt Wuppertal (rechts) (Datenquellen: Geobasis NRW 2024d, EGLV o. J., Stadt Wuppertal o. J.)

Die genutzten Versiegelungsdaten aus dem Stadtgebiet Wuppertal und dem Teilbereich der Emscher-Lippe Region – den Stadtgebieten Bochum, Gelsenkirchen, Herne und Herten – datieren auf das Jahr 2021. Die Daten wurden zunächst auf ihre Aktualität hin geprüft und ggf. manuell aktualisiert. Tabelle 2 zeigt die Aktualitätsunterschiede zwischen den als Referenz genutzten regionalen Versiegelungsdaten und den zur landesweiten Versiegelungsmodellierung herangezogenen DOP.

Tabelle 2: Übersicht der Aktualität von Versiegelungsdaten und DOP

Datensatz	Bereich	Aktualität der Versiegelungsdaten	Verwendete DOP
EGLV	Bochum, Gelsenkirchen, Herne, Herten	2021	2022, 2023, 2024
Stadt Wuppertal	Wuppertal	2021	2021, 2023

Quelle: EGLV o. J., Stadt Wuppertal o. J.

Im Rahmen dieses Projekts wurden versiegelte Flächen (wie in den o.g. Referenzdaten) zunächst als Flächen definiert, die mit künstlichen Baustoffen wie etwa Asphalt oder Beton befestigt wurden und den natürlichen Boden dadurch vollständig oder teilweise wasser- und luftundurchlässig versiegeln (Arnold und Gibbons 1996; UBA 2024). Typische Beispiele sind Straßen, Gebäude und Parkplätze. Angesichts der Nutzung von Fernerkundungsdaten wurden unterirdische Bauwerke nicht berücksichtigt und von einer Abstufung zwischen Voll- und Teilversiegelung abgesehen.

Während der Projektlaufzeit wurde diese Definition von Versiegelung für den Indikator Bodenversiegelung präzisiert und die als Referenz beschafften Versiegelungsdatensätze entsprechend angepasst bzw. ergänzt. Als Grundlage diente hierfür eine LANUV-interne Abfrage zu Fachbedarfen an Bodenversiegelungsdaten und weiteren potenziellen Verwendungsbereichen der Karte. Insbesondere wurde ermittelt, inwieweit bisher unberücksichtigte spezielle Oberflächentypen mit Versiegelungscharakter in die Definition von „Bodenversiegelung“ integriert werden könnten / sollten, um einen breiten Einsatz des Endprodukts auch jenseits der Versiegelungsstatistik zu ermöglichen. Teilweise handelte sich dabei um Flächen, die aufgrund ihrer spektralen und/oder semantischen Eigenschaften eine besondere fernerkundliche Herausforderung darstellen bzw. deren Einstufung als „(un)versiegelt“ auch von der konkreten fachlichen Fragestellung abhängt. In Tabelle 3 (Stand 03.07.2024) werden diese speziellen Oberflächentypen und ihre Bewertung im Sinne von Bodenversiegelung aufgeführt.

Der Oberflächentyp „Gleiskörper, Schotterwege und –gärten“ wurde vom LANUV zwar nach Abwägung der verschiedenen fachlichen Perspektiven als „versiegelter Boden“ eingestuft, aber im Projekt dennoch als „unversiegelter Boden“ modelliert. Diese Entscheidung fiel aus pragmatischen Gründen, weil insbesondere Gleiskörper in den als Referenz beschafften Versiegelungsdaten des EGLV bereits der Klasse „unversiegelt“ zugewiesen waren, und eine Reklassifikation mit beträchtlichem Aufwand verbunden gewesen wäre. Mit einer entsprechenden Anpassung der Trainingsdaten könnte mit dem entwickelten Verfahren somit eine Kartenvariante erstellt werden, die bodenschutzbezogene Fachfragen noch besser adressiert (vgl. auch Kapitel V3.4).

Tabelle 3: Übersichtstabelle zur Berücksichtigung spezieller Oberflächentypen für die binäre Klassifikation „versiegelt / nicht-versiegelt“

Oberflächentyp	Fachliche Bewertung des LANUV
Freiflächen Photovoltaik Anlagen	nicht-versiegelt
Gewächshäuser (Fläche >15 m ²)	versiegelt
Agrarfolien	nicht-versiegelt
Gleiskörper, Schotterwege und -gärten	versiegelt
Freibäder	versiegelt
Kläranlagentanks	versiegelt
Brücken über Gewässern	nicht-versiegelt
Brücken über Offenland (Höhe >50 m)	nicht-versiegelt

1.3 Amtliches Liegenschafts- und Katasterinformationssystem (ALKIS)

In diesem Projekt wurden Landnutzungsinformationen des Amtlichen Liegenschafts- und Katasterinformationssystems (ALKIS) verwendet. ALKIS-Daten stellen einen einheitlichen, katastergenauen und regelmäßig aktualisierten Vektordatenbestand dar (Geobasis NRW 2024a). Da ALKIS-Daten Landnutzungsinformationen widerspiegeln, sind Mischklassen, in denen sowohl versiegelte als auch nicht-versiegelte Flächen vorzufinden sind, nicht auszuschließen. Daher wurden in diesem Projekt nur bestimmte Wertarten, die (fast) vollständig versiegelte Oberflächen darstellen, aus gezielt ausgewählten ALKIS-Objektarten verwendet. Die in diesem Schritt aus dem vorläufigen Trainingsdatensatz entfernten Wertarten sind in Tabelle 4 dokumentiert.

Tabelle 4: Verwendete ALKIS-Objektarten und entfernte Wertarten

Objektart	Entfernte Wertarten
AX_Gebaeude (31001)	Bergwerk (2171) Tiefgarage (2465) Gebäude zum U-Bahnhof (3094)
AX_TagebauGrubeSteinbruch (41005)	-
AX_Straßenverkehr (42001)	Verkehrsbegleitfläche Straße (2312)
AX_Weg (42006)	Fußweg (5220) Gang (5230) Reitweg (5260) Sonstiges (9999)
AX_Landwirtschaft (43001)	Brachland (1200)
AX_Fließgewaesser (44001)	-

Quelle: AdV 2022

Der automatisierte Datendownload der gefilterten ALKIS Vektordaten erfolgt über einen Web-Feature-Service (WFS). Dieser WFS-Dienst wird in Tabelle 5 dokumentiert.

Tabelle 5: Geodatendienst zur Ansteuerung von ALKIS-Daten

Geodatendienst	URL
WFS (ALKIS)	https://www.wfs.nrw.de/geobasis/wfs_nw_alkis_nas-konform

Quelle: Geobasis NRW 2024h

2 Trainingsdaten

Die Trainingsdaten bestehen aus mehreren Trainingspaaren, die jeweils aus Eingabe- und zugehörigen Ausgabedaten bestehen. Die Eingabedaten sind DOP (Kapitel II1.1). Diese bilden die Basis, auf deren Grundlage das Modell Informationen extrahiert, um Vorhersagen über die Klassenzugehörigkeit der Bildpixel zu treffen. Die Ausgabedaten bestehen aus Versiegelungsdaten (Kapitel II1.2) in Form von rasterisierten Ground-Truth-Masken. Diese Masken zeigen die korrekte Klassifikation jedes Pixels im Eingabebild. Sie dienen dem Modell als Referenz und definieren, ob ein Pixel als "versiegelt" oder "nicht versiegelt" gelten soll. Durch den Vergleich der Vorhersagen mit den Ground-Truth-Daten lernt das Modell, Pixel korrekt zu klassifizieren. In Abbildung 2 ist ein Trainingspaar, bestehend aus Eingabe- und Ausgabedaten, visualisiert.

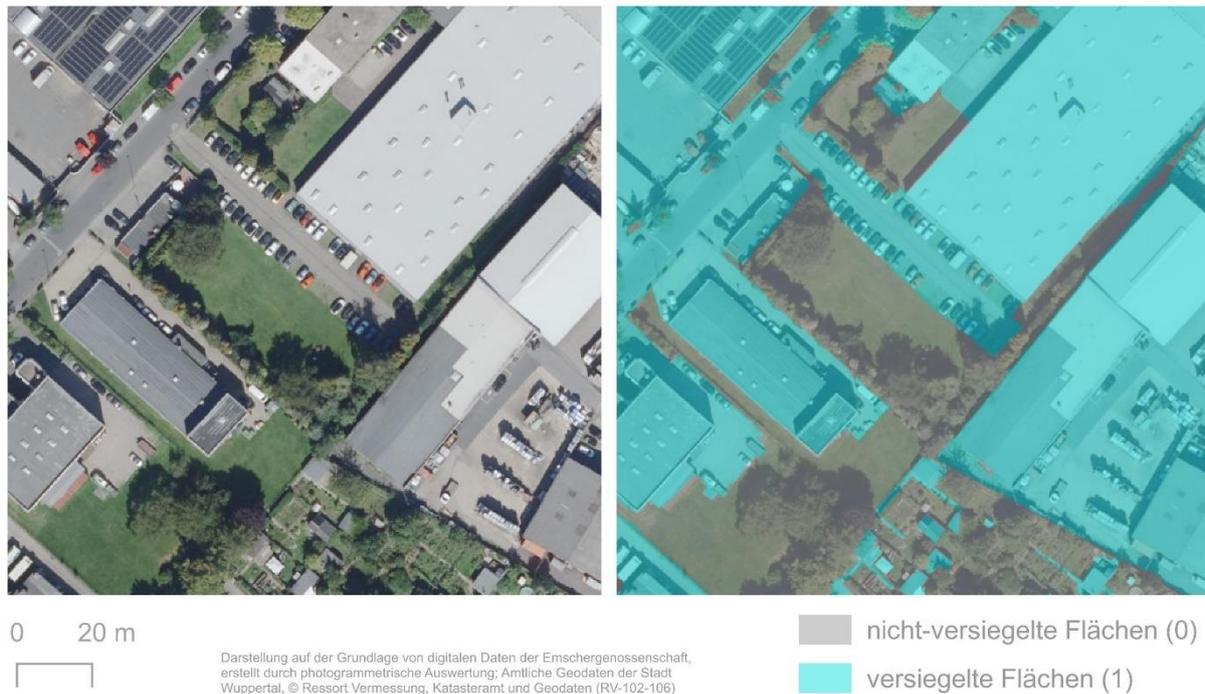


Abbildung 2: Trainingspaar aus DOP (links) und Ground-Truth-Maske (rechts) (Datenquellen: Geobasis NRW 2024d, EGLV o. J.)

2.1 Datenaufbereitung

Die grundlegende Datenverarbeitungseinheit von EBOVE bilden quadratische Gebiete von 1 km² Größe, die als Kacheln bezeichnet werden. Diese Kacheln liegen als ein Vektordatensatz vor, der 35.022 Kacheln umfasst und NRW im UTM-Koordinatenreferenzsystem (ETRS:25832) repräsentiert. Innerhalb der Koordinaten einer Kachel werden Daten heruntergeladen, aufbereitet und verarbeitet. Die Grundidee war, die Abgabereinheit der DOP des Landes NRW für die Bearbeitung beizubehalten, um Konsistenz und eine einfache Integration mit bestehenden Geodaten zu gewährleisten (Geobasis NRW 2024g). Abbildung 3 zeigt den Kachel-Vektordatensatz als grundlegende Datenverarbeitungseinheit.

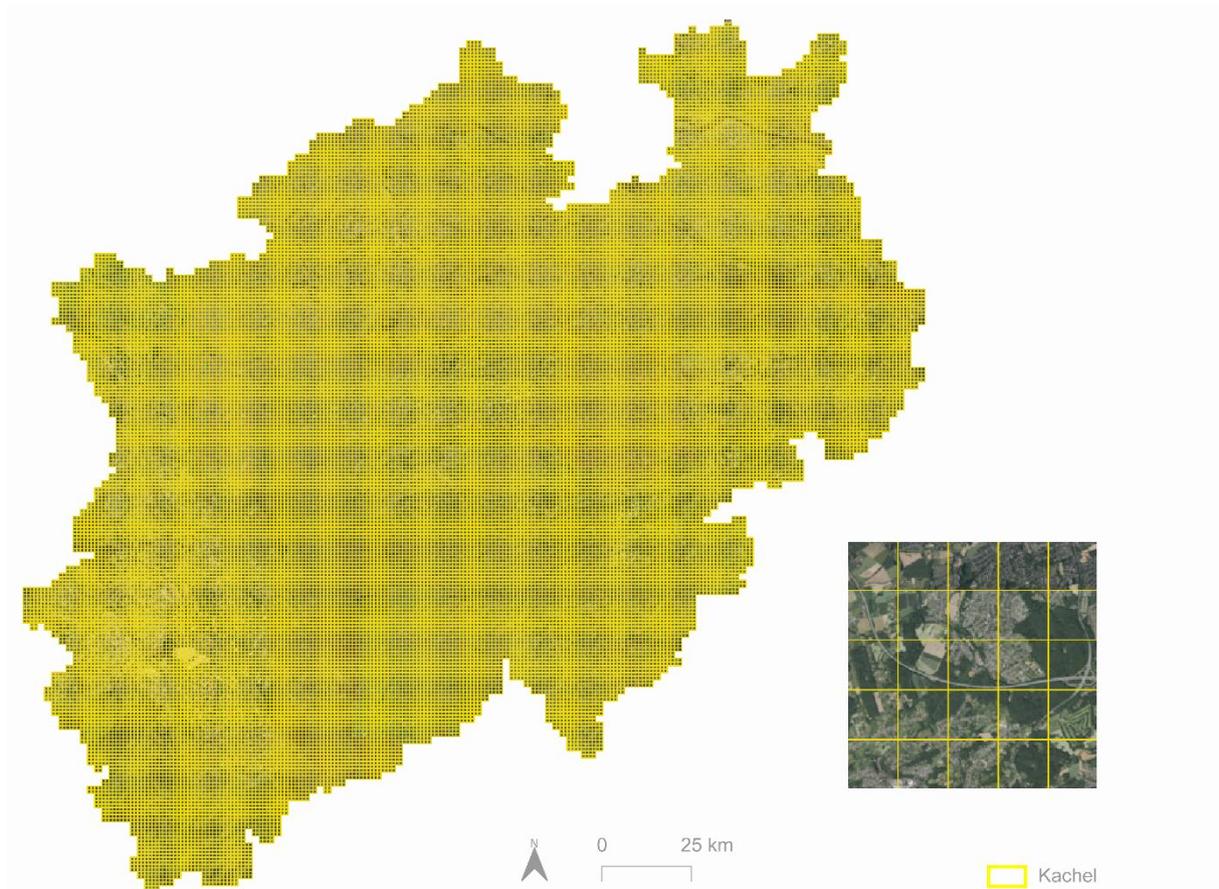


Abbildung 3: UTM-Kachel-Vektordatensatz von NRW (Datenquellen: Geobasis NRW 2024d, Geobasis NRW 2019)

Innerhalb dieser Kacheln werden die verfügbaren Versiegelungsdaten und DOP verarbeitet, um Trainingspaare für den Aufbau des Trainingsdatensatzes zu erzeugen. Die DOP wurden kachelweise vom WCS-Dienst mit den Kanälen R, G, B und NIR heruntergeladen und auf eine räumliche Auflösung von 0,5 m vergrößert. Diese Anpassung erfolgte automatisiert durch bilineares Resampling. Jedes DOP einer Kachel besteht aus 2.000 x 2.000 Pixeln und deckt eine Fläche von 1 km² ab. Die Ground-Truth-Masken wurden passend dazu in derselben Auflösung und Pixelanzahl erstellt, indem die vektorbasierten Versiegelungsdaten aus Kapitel II1.2 in Rasterdaten umgewandelt wurden. Dabei wurde jedem Pixel entsprechend seiner Klasse (versiegelt: 1, nicht versiegelt: 0) ein 8-Bit-Integer-Wert zugeordnet.

Für das Training des Modells wurden diese Trainingspaare bestehend aus DOP und Ground-Truth-Maske einer Kachel in kleinere Bildabschnitte, sogenannte Patches, zerlegt. Dazu wurden beide Datensätze, in 4 x 4 sich überlappende Patches von 512 x 512 Pixeln zerteilt. Das Patching der 1 km² großen Kacheln ist notwendig, um die Verarbeitung der Daten zu erleichtern und die Rechenlast während des Modelltrainings zu reduzieren. Abbildung 4 visualisiert die Erstellung von Patches aus DOP und Ground-Truth-Maske (in blau hervorgehoben).

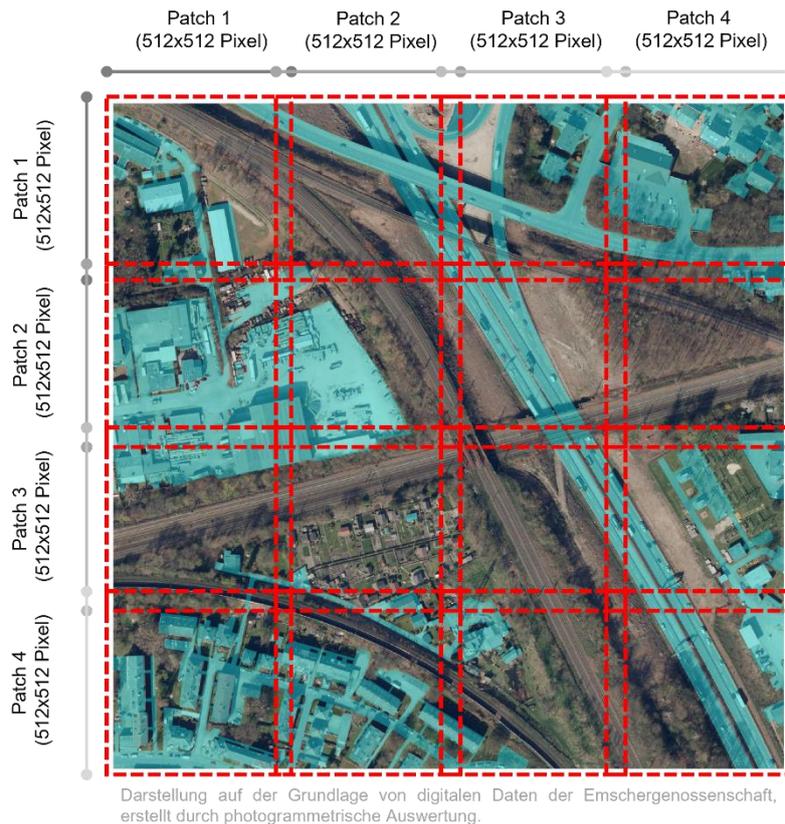


Abbildung 4: Erstellung von Patches (Datenquellen: Geobasis NRW 2024d, EGLV o. J.)

Anschließend wurde eine visuelle Überprüfung der Patches durchgeführt, um sicherzustellen, dass keine fehlerhaften Trainingspaare in das Modell eingehen. Dazu wurden die DOP und Ground-Truth-Masken visuell verglichen und fehlerhafte Paare aussortiert oder Ground-Truth-Masken manuell angepasst.

2.2 Datensatzerweiterung

Da die beschriebenen Trainingspaare räumlich und thematisch zu begrenzt waren, um ein robustes Modell für ganz NRW zu entwickeln, wurde eine Erweiterung des Datensatzes vorgenommen. Hierzu wurde vorab ein Modell auf den bereits vorliegenden Daten trainiert (s. Kapitel III.2). Dieses Modell diente dazu weitere Ground-Truth-Masken zu erstellen. Dazu wurden Klassifikations-Vorhersagen in zufällig ausgewählten Kacheln durch das Modell erzeugt. Die Auswahl der Kacheln zur Erzeugung weiterer Ground-Truth-Masken basierte auf den 52 Aufnahmezeitpunkten der DOPs, den speziellen Oberflächentypen aus Tabelle 3 sowie Beobachtungen in Bereichen, in denen suboptimale Klassifikations-Vorhersagen getroffen wurden.

Die erzeugten Klassifikations-Vorhersagen wurden durch Verschneidung mit gefilterten Wertarten ausgewählter Objektarten nach Tabelle 4 optimiert. Die ALKIS-Daten wurden zunächst vom WFS-Dienst heruntergeladen, danach rasterisiert und die Pixel

ihren jeweiligen Klassen „versiegelte Flächen“ und „nicht-versiegelte Flächen“ zugeordnet. Anschließend wurden die erzeugten ALKIS-Masken mit den Klassifikationsvorhersagen des Modells verschnitten. Um die Qualität dieser erzeugten Ground-Truth-Masken aufgrund nicht erfasster oder falsch klassifizierter Flächen nachträglich zu optimieren, wurden die Masken aufwändig anhand von DOP manuell nachdigitalisiert.

2.3 Trainings- und Testdatensatz

Für den Aufbau des Trainingsdatensatzes wurde ein Gleichgewicht zwischen DOPs aus unbelaubten und belaubten Zuständen angestrebt, um ein ausgewogenes Modell zu erstellen. Insgesamt umfasste der Datensatz 2282 Patches, die eine Fläche von etwa 150 km² abbildeten. Diese Paare aus DOP und Ground-Truth-Masken wurden in einen Trainings- und einen Testdatensatz unterteilt: Der Trainingsdatensatz, bestehend aus 2053 Patches (90%), diente ausschließlich dem Modelltraining, während der Testdatensatz mit 229 Patches (10%) zur Überwachung der Modellentwicklung während des Trainings genutzt wurde.

3 Validierungsdaten

Um die Generalisierbarkeit des Modells auf ungesehene und damit unabhängige Daten (Gebiete in NRW) zu testen und somit die Qualität des Datenprodukts zu beurteilen, wurden drei Gebiete in NRW ausgewählt, die räumlich jenseits der zwei Gebiete liegen, in denen das Modell trainiert wurde. Eine Validierung der Modellgüte auf der gesamten restlichen Landesfläche war aufgrund fehlender, qualitativ hochwertiger Referenzdaten (ground truth) nicht möglich.

3.1 Validierungsgebiete

Als Validierungsgebiete wurden drei Stadtgebiete in NRW anhand unterschiedlicher Landnutzungen und Landbedeckungen ausgewählt. Betrachtet wurden die Stadtgebiete Münster, Dortmund und Köln. Abbildung 5 lokalisiert die drei Validierungsgebiete und ihre Landbedeckung in NRW.

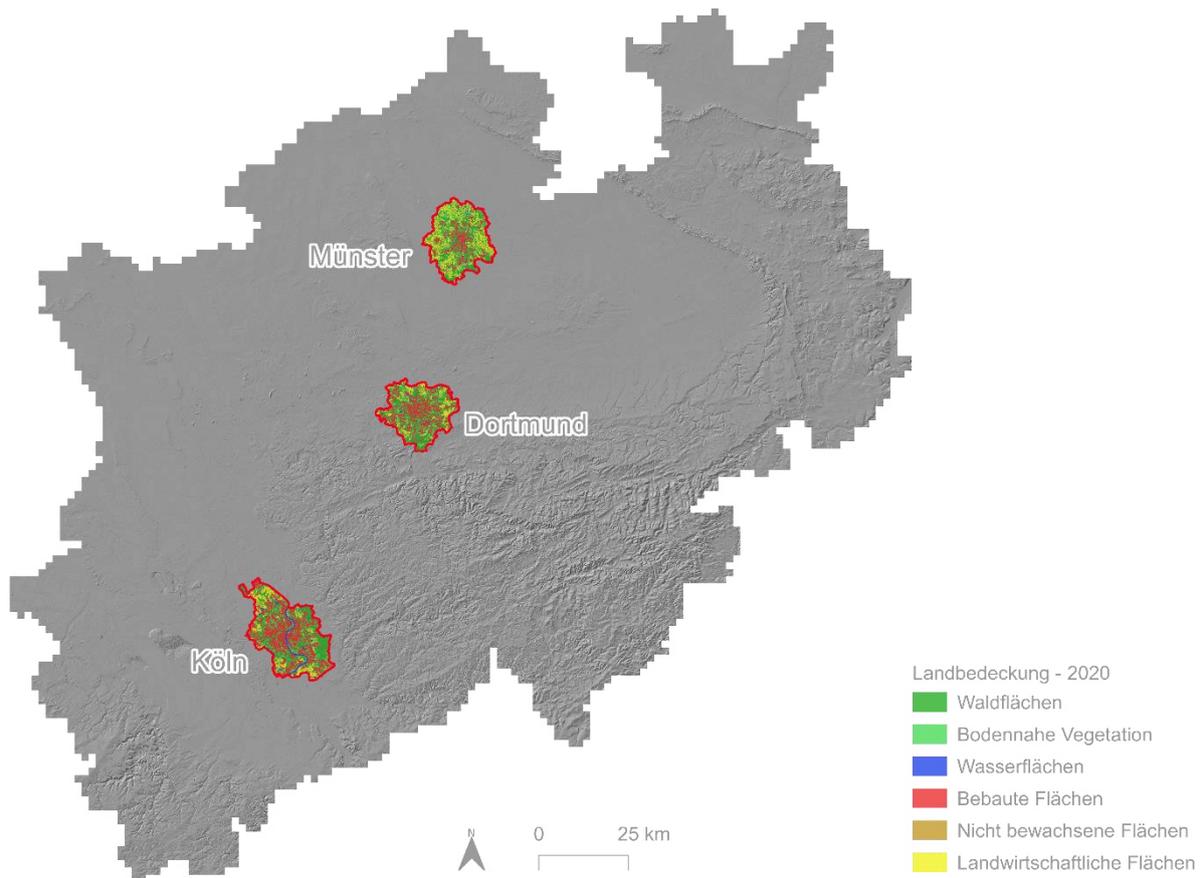


Abbildung 5: Validierungsgebiete der Versiegelungskarte (Datenquellen: Geobasis NRW 2024e, Mundialis GmbH & Co. KG 2021)

Diese Validierungsgebiete wurden ausgewählt, weil sie eine repräsentative Vielfalt an Landnutzungs- und Landbedeckungsarten in NRW bieten. Münster, Dortmund und Köln unterscheiden sich in ihrer urbanen und ländlichen Struktur sowie der relativen Anteile versiegelter und nicht-versiegelter Flächen, was eine umfassende Evaluierung der Versiegelungskarte ermöglicht. Münster zeichnet sich durch einen hohen Anteil an landwirtschaftlich geprägten Flächen und Grünflächen aus. Zudem weist Münster einen historischen Stadtkern auf. Dortmund, als Großstadt im Ruhrgebiet, zeichnet sich durch Industrie- und Gewerbeflächen, einen Binnenhafen sowie weitreichende urbane, baumreiche Grünflächen aus. Köln, als größte Stadt in NRW, weist neben weitreichenden Grünflächen und landwirtschaftlich genutzten Flächen im Umland weitere markante Merkmale wie den Kölner Dom, den Rhein und den Flughafen Köln/Bonn auf. Alle drei Gebiete enthalten darüber hinaus eine Vielzahl unterschiedlich feiner bis grober Texturen versiegelter Oberflächen (Verzahnungen mit unversiegelten Flächen).

3.2 Validierungsdatensatz

Zur Bewertung der binären Versiegelungskarte wurden Validierungsdatensätze für die drei Validierungsgebiete erstellt. Die Erstellung der Validierungsdatensätze erfolgte auf Basis der weitverbreiteten Random-Sampling-Methode (Olofsson et al. 2014). Bei

der Random-Sampling-Methode werden zufällig einzelne Pixel als Stichproben in einem Testgebiet ausgewählt. Um alle drei Gebiete gleichwertig zum Validierungsergebnis beitragen zu lassen, wurden aus jedem Gebiet dieselbe Stichprobengröße gezogen (1.500 Pixel). Da jedoch landesweit – und auch in jedem der drei Stadtgebiete – mehr unversiegelte als versiegelte Flächen existieren, enthält diese Stichprobe eine Klassenungleichheit, welche die Aussagekraft mancher Bewertungsmetriken einschränkt. Aus diesem Grund wurde zur Bewertung der Modelleleistung auch eine Metrik (Mathews Correlation Coefficient) herangezogen, die unempfindlich gegenüber ungleich großer Klassen ist (s. Kapitel V1). Unter einer sorgfältigen visuellen Analyse wurde jeder Pixel manuell anhand von DOPs klassifiziert und entweder der Klasse „versiegelte Flächen“ oder „nicht-versiegelte Flächen“ zugeordnet. Tabelle 6 dokumentiert die Anzahl der Stichproben pro Klasse und je Validierungsgebiet.

Tabelle 6: Anzahl der Stichproben pro Klasse und je Validierungsgebiet

Klasse	Münster	Dortmund	Köln
Versiegelte Flächen	260	464	497
Nicht-versiegelte Flächen	1240	1036	1003
Gesamt	1500	1500	1500

III Modelltraining

Die Herausforderungen dieses Projekts ergeben sich aus der temporalen Diversität der DOP, der Heterogenität der Landoberfläche NRWs und der großen Datenmenge, die verarbeitet werden muss. Für die Landesflächen liegen unterschiedliche Belau-bungs- und Belichtungszustände in den DOP vor. Darüber hinaus führt die Gebiets-größe NRWs in Kombination mit der hohen räumlichen Auflösung der DOP zu einem hohen Detailgrad in Bezug auf Landnutzung und Landbedeckung. Diese Faktoren erschweren die Erfassung versiegelter Flächen und erfordern: 1) eine skalierbare Me-thodik, 2) ein robustes KI-Modell, das auf ungesehene Daten generalisieren kann, und 3) qualitativ hochwertige sowie vielfältige Trainingsdaten.

Hinsichtlich dieser Anforderungen wurde das Verfahren der semantischen Segmentie-rung als Methode zur Erfassung der landesweit versiegelten Flächen gewählt. Die se-mantische Segmentierung ist eine Bildverarbeitungstechnik, bei der jedem Pixel eines Bildes eine bestimmte Klasse zugeordnet wird (Hao et al. 2020). Für diese Aufgabe kommen zunehmend KI-Modelle, insbesondere neuronale Netze, zum Einsatz. In den nachfolgenden Kapiteln wird das verwendete Modell beschrieben.

1 Modell

Im Verlauf des Projekts hat sich das UNetFormer Modell nach Wang et al. (2022) als geeignetes Modell hinsichtlich der genannten Herausforderungen herausgestellt. In der Literatur zeigte das Modell in vergleichbaren Segmentierungsaufgaben auf Basis von Orthophotos State-of-the-Art Ergebnisse (Wang et al. 2022).

1.1 Modellarchitektur

Das UNetFormer Modell kombiniert zwei leistungsstarke Ansätze des Deep Learnings: Es nutzt sowohl bewährte Convolutional Neural Networks (CNNs) als auch die neue-ren Transformer-Architekturen, die CNNs in Bildverarbeitungsaufgaben bereits über-treffen konnten (Vaswani Ashish et al. 2017). Die Modellarchitektur wird in Abbildung 6 dargestellt.

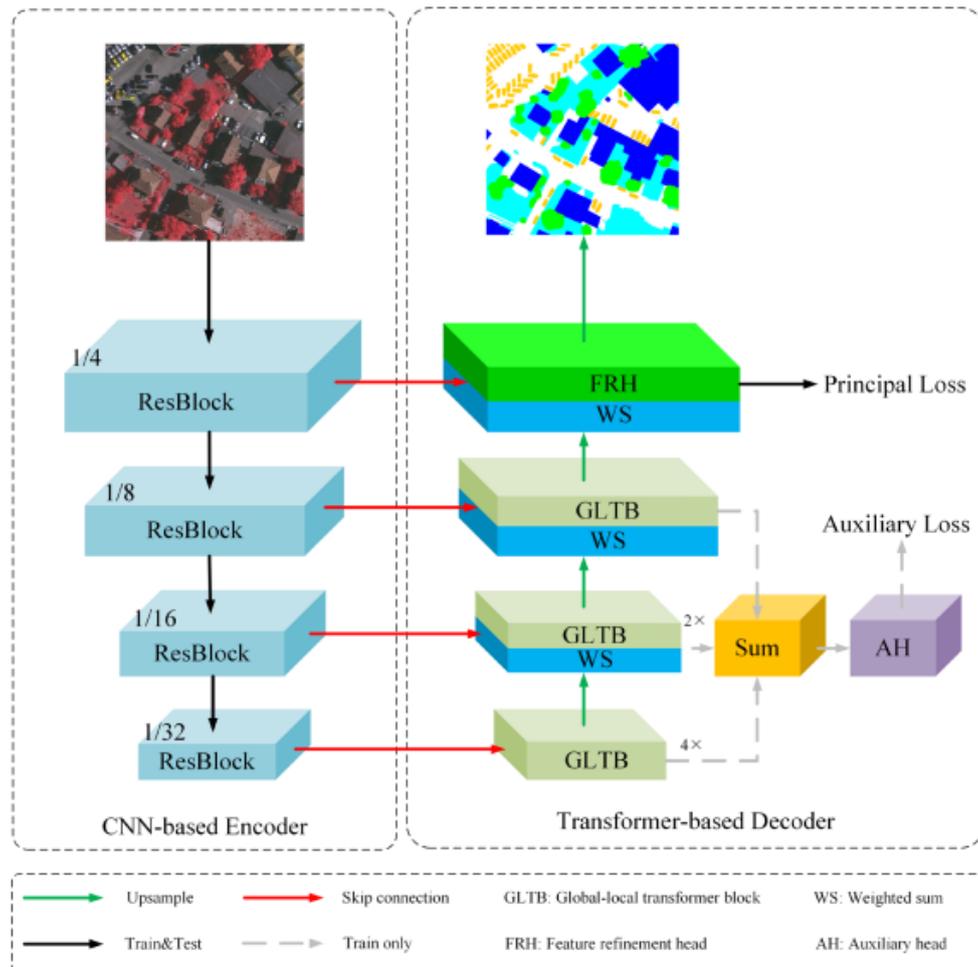


Abbildung 6: Modellarchitektur des UNetFormer Modells (Wang et al. 2022)

Die Modellarchitektur basiert dabei auf der grundlegenden Modellarchitektur des U-Net Modells nach Ronneberger et al. (2015). Das Modell besteht aus einem Encoder und einem Decoder, die über sogenannte Skip-Connections miteinander verbunden sind. Der Encoder ist dabei CNN-basiert und der Decoder Transformer-basiert.

Encoder

Der Encoder ist für die Extraktion von Merkmalen aus den Inputdaten zuständig. Für die Extraktion von Merkmalen wird ein weiterentwickeltes CNN verwendet, das Residual Network (ResNet). Dabei werden die Inputdaten in mehreren Schichten der abgeschlossenen ResNet-Blöcken verarbeitet. In einem ResNet-Block werden die Inputdaten schrittweise verkleinert. Dabei werden wichtige Merkmale in verschiedenen Maßstäben erfasst wie beispielsweise Kanten und Texturen. Im UNetFormer Modell wird eine bereits vortrainierte Version des ResNet-Modells verwendet. Das bedeutet, dass das ResNet bereits auf einem Datensatz trainiert wurde und über grundlegende Segmentierungsfähigkeiten verfügt (Wang et al. 2022). Das hat den Vorteil, dass das Modell auf dieser Basis nachtrainiert werden kann und potenziell weniger Trainingszeit

und Trainingsdaten benötigt. Im Rahmen dieses Projekts war dies ein nützlicher Faktor hinsichtlich der begrenzten Menge an Trainingsdaten.

Decoder

Der Decoder wandelt die vom Encoder extrahierten Merkmale schrittweise in eine Segmentierungskarte der Ausgangsgröße der Inputdaten um. Der Decoder verwendet dabei Global-Local Transformer Blocks (GLTB), die die globalen und lokalen Informationen des Encoders kombinieren und verarbeiten (Wang et al. 2022). Jeder GLTB arbeitet mit sogenannten Self-Attention-Mechanismen, die es dem Modell ermöglichen, sich auf verschiedene Teilbereiche der Merkmalskarte zu fokussieren (Vaswani Ashish et al. 2017; Oktay et al. 2018; Wang et al. 2022). Dabei werden die Beziehungen zwischen Pixeln im gesamten Bild sowie lokale Details berücksichtigt. Im Rahmen des Projekts ist diese Funktionalität nützlich, um zwischen belaubten und unbelaubten Zuständen zu generalisieren und unter Umständen, den verdeckenden Effekt durch Baumkronen durch verbesserte Kontextinformationen zu reduzieren.

Skip-Connections

Encoder und Decoder werden über sogenannte Skip-Connections miteinander verbunden. Die Skip-Connections tragen dazu bei, räumliche Informationen während der Verarbeitung zu erhalten, die bei der schrittweisen Verkleinerung der Inputdaten im Encoder verloren gehen könnten (Ronneberger et al. 2015). Die Merkmale des Encoders und die Ausgaben der GLTBs werden mit einer gewichteten Summenoperation zusammengeführt, sodass das Modell Merkmale aus den unterschiedlichen Schichten lernen kann (Wang et al. 2022). Abschließend wird ein Feature Refinement Head (FRH) angeschlossen, der die extrahierten Merkmale optimiert, um die Qualität der endgültigen Segmentierungsausgabe zu verbessern (Wang et al. 2022).

Ein weiterer Vorteil des Modells ist, dass es trotz Komplexität wenig Hardware-Ressourcen benötigt, was das Training und die Modellanwendung erleichtern. Der Quellcode des UNetFormer-Modells steht unter der GPL-3.0-Lizenz als Open Source auf GitHub zur Verfügung (<https://github.com/WangLibo1995/GeoSeg>). Um den Lizenzbestimmungen gerecht zu werden, ist eine Veröffentlichung der entwickelten Prozesse seitens des LANUV NRW vorgesehen.

1.2 Implementierung

Das UNetFormer Modell ist für die Nutzung von Bildern mit drei Kanälen ausgelegt. Um die gesamte Informationstiefe der DOP nutzen zu können, wurde der Source-Code entsprechend angepasst. Der Encoder des UNetFormer Modells basiert ursprünglich auf dem vortrainierten ResNet18 Modell. Das ResNet18 besteht dabei aus 18 Schichten, in denen die Eingangsdaten verarbeitet werden. Im Rahmen dieses Projekts

wurde jedoch das ResNet50 Modell verwendet, um eine tiefere Erfassung von Merkmalen zuzulassen. Die Einstellungen des in diesem Projekt implementierten Modells werden im Anhang A dokumentiert.

Im Rahmen dieses Projekts wurde die Programmiersprache Python verwendet. In der Modellentwicklung wurde auf die Python-Bibliothek PyTorch zurückgegriffen, die speziell für die Entwicklung von Anwendungen im Bereich des maschinellen Lernens und der künstlichen Intelligenz konzipiert ist (The Linux Foundation 2024).

2 Training

Der allgemeine Trainingsablauf wird in Abbildung 7 visualisiert.

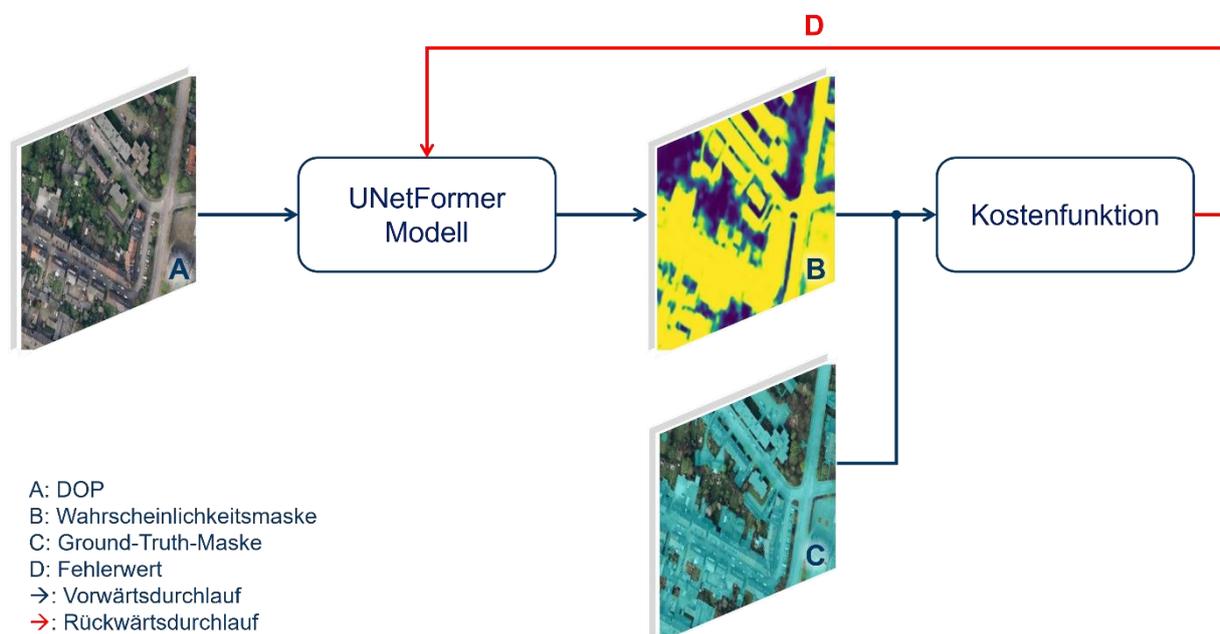


Abbildung 7: Allgemeiner Trainingsablauf (Datenquelle: Geobasis NRW 2024d, EGLV o. J.)

Das Modelltraining erfolgt in sogenannten Epochen. In einer Epoche werden alle Trainingsdaten aus Kapitel II.2.3 durch das Modell verarbeitet. Die Trainingsdaten werden dabei in sogenannten Batches geladen. Jeder Batch besteht aus mehreren Patches der Trainingsdaten. Im Verlauf der Entwicklungen hat sich eine Batch Größe von 8 Patches als geeignet herausgestellt. Um die Vielfalt der Trainingsdaten künstlich zu erhöhen, werden die Trainingsdaten beim Einladen augmentiert. Das Ziel der Datenaugmentierung ist, die Leistungsfähigkeit und Robustheit des Modells zu verbessern, indem es mit einer größeren Vielfalt an Trainingsdaten ausgesetzt wird (Shorten und Khoshgoftaar 2019). Die Augmentierungen werden auf jedes Patch mit einer festlegbaren Wahrscheinlichkeit angewandt. Auf folgende Funktionen wurde zurückgegriffen:

- Vertikale und horizontale Spiegelung
- Zufällige Rotation

- Veränderung des Kontrasts und der Helligkeit
- Hinzufügen von Rauschen

Die Bildwerte werden anschließend auf einen einheitlichen Wertebereich von 0 bis 1 normalisiert, um die numerische Stabilität des Trainings zu gewährleisten und zu verhindern, dass sich das Modell zu stark auf einzelne Kanäle fokussiert.

Im Vorwärtsthroughlauf erstellt das Modell Klassifikations-Vorhersagen anhand der DOP eines Trainingspaars. Diese Klassifikations-Vorhersagen stellen zunächst Wahrscheinlichkeitskarten dar, in denen jeder Pixel einen kontinuierlichen Wert zwischen 0 und 1 aufweist, der die Wahrscheinlichkeit angibt, dass der Pixel zur Klasse „nicht-versiegelte Fläche“ oder „versiegelte Fläche“ gehört. Anschließend wird die Klassifikations-Vorhersage mit der zugehörigen Ground-Truth-Maske des Trainingspaars verglichen. Um eine binäre Vorhersagekarte zu erstellen, werden die Pixelwerte der Wahrscheinlichkeitskarte anhand eines Schwellwerts in versiegelte und nicht-versiegelte Flächen eingeteilt. Als Schwellwert wurde standardmäßig ein Wert von 0,5 gewählt.

Beim Vergleich der Klassifikations-Vorhersage mit der Ground-Truth-Maske wird mithilfe einer Kostenfunktion (Loss Function) ein Fehlerwert berechnet, der durch das Modell minimiert werden soll. Für das Training wurde eine allgemeine Kostenfunktion (Principal Loss) und eine zusätzliche Kostenfunktion (Auxillary Loss) verwendet (s. Abbildung 6). Der Principal Loss bezieht sich auf die übergeordnete Segmentierungsaufgabe, wobei der Auxillary Loss Einflüsse aus tieferen Schichten mit feineren Details berücksichtigt (Wang et al. 2022). Für den Principal Loss wurde der Dice-Focal Loss mit einem Gewichtungsverhältnis von 1:20 verwendet (Kirillov et al. 2023). Diese Kombination wurde gewählt, um das Klassenungleichgewicht von versiegelten zu nicht-versiegelten Flächen mithilfe der Focal Loss Komponente zu adressieren und gleichzeitig die Erstellung hochwertiger Versiegelungskarten durch die Dice Loss Komponente sicherzustellen. Der Auxillary Loss wurde ebenfalls wie in Wang et al. (2022) als Binary Cross Entropy Loss implementiert. Diese Kombination hat sich in vorangegangenen Testläufen am performantesten herausgestellt.

Im Rückwärtsthroughlauf werden die Modellparameter anhand des zurückgegebenen Fehlerwerts aktualisiert. Um diese Modellparameter effizient zu aktualisieren, wurde der AdamW Optimizer als Optimierungsalgorithmus verwendet (Loshchilov und Hutter 2017). Die Lernrate bestimmt dabei die Größe der Schritte, die der Optimierungsalgorithmus bei der Aktualisierung der Modellparameter unternimmt (Loshchilov und Hutter 2017). Für das Modell hat sich eine Lernrate (Learning Rate) von 0,0001 als gut geeignet erwiesen. Um die Learning Rate während des Trainings dynamisch anzupassen, wurde ein Learning Rate Scheduler implementiert. Dieser ermöglicht es dem Modell, zu Beginn des Trainings größere Änderungen vorzunehmen und später feinere

Anpassungen durchzuführen. Hierbei wurde ein Scheduler mit Cosine Annealing verwendet (Loshchilov und Hutter 2016).

Um eine Überanpassung des Modells an die Trainingsdaten (Overfitting) zu vermeiden, wurde ein Early-Stopping-Mechanismus implementiert. Dieser Mechanismus überwacht kontinuierlich die Leistung des Modells auf dem Validierungsdatensatz. Sobald keine Verbesserung mehr festgestellt wird, beendet er das Training automatisch und speichert die bis dahin besten Modellparameter.

Die getroffenen Konfigurationen des Modelltrainings werden in Anhang A dokumentiert. Um die Modellleistung während des Modelltrainings zu überwachen, wurde das Modell auf dem Testdatensatz aus Kapitel II.2.3 angewandt und Bewertungsmetriken berechnet. Die erreichten Ergebnisse der Bewertungsmetriken anhand des Testdatensatzes werden in Anhang B aufgeführt.

IV Software

Ziel des Projektes war die Erstellung eines Verfahrens, welches zentral bei IT.NRW innerhalb der CDI@IT.NRW betrieben werden kann. Zur Umsetzung dieses Ziels wurde das trainierte Modell in eine eigenständige Software integriert. Diese Software erstellt eine Versiegelungskarte mit einer räumlichen Auflösung von 0,5 m für die Landesfläche NRWs. Für eine nahtlose Integration innerhalb der CDI@IT.NRW wurde die Software als isoliertes Verfahren in Form eines Docker Containers implementiert (Docker Inc. 2024). Dieser Container wird auf dem offiziellen Pytorch-Base-Image (*pytorch/pytorch: 2.4.1-cuda12.4-cudnn9-runtime*) aufgebaut, in welchem benötigte Deep Learning Bibliotheken bereits vorinstalliert sind. Zudem gewährleistet dieses Base-Image den Zugriff auf die Graphikkarte (GPU) des Host-Systems. Nachfolgend wird der Aufbau der Software beschrieben.

1 Aufbau

Die Software baut auf vier grundlegenden Prozessschritten auf: 1) dem Pre-Processing, 2) der Modellanwendung, 3) dem Post-Processing und 4) der Datenbereitstellung. Abbildung 8 stellt den Aufbau der Software dar.

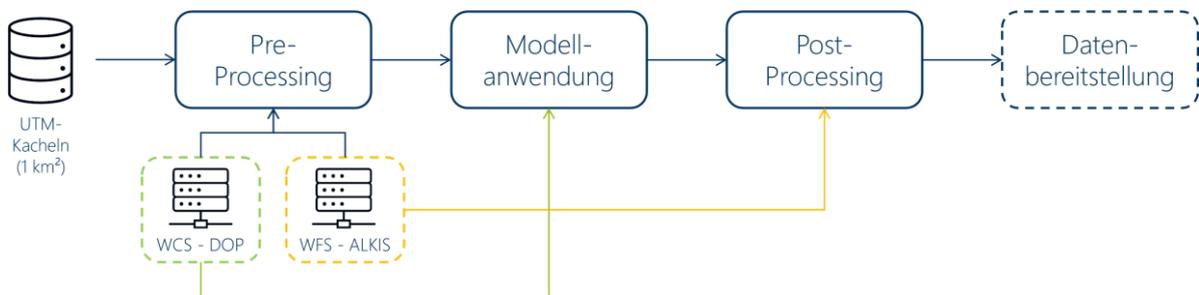


Abbildung 8: Aufbau der erstellten Software

Als einziger lokaler Inputdatensatz dient der in Kapitel II.2.1 beschriebene UTM-Kachel-Vektordatensatz, der in Form einer ESRI-Shapefile im Docker Container vorliegt. Für jede der 35.022 Kacheln werden das Pre-Processing, die Modellanwendung und das Post-Processing iterativ durchgeführt. Nach dieser kachelweisen Verarbeitung der Daten der Landesfläche, werden in der Datenbereitstellung alle einzelnen Kacheln zu einer Versiegelungskarte für die Landesfläche NRW zusammengeführt.

Die verschiedenen Schritte des Prozesses benötigen unterschiedliche Hardwarekomponenten. Beim Pre-Processing wird das Internet genutzt, um Daten herunterzuladen. In der Modellanwendung kommt die GPU zum Einsatz, während das Post-Processing auf dem Hauptprozessor (CPU) durchgeführt wird. Die fertigen Daten werden schließlich auf der Festplatte gespeichert. Um diese Schritte effizienter und schneller ablaufen zu lassen, wurde eine parallele Ausführung der Teilprozesse implementiert. Hierbei

werden separate Threads verwendet, die es ermöglichen, dass verschiedene Aufgaben gleichzeitig bearbeitet werden. Dadurch können die verfügbaren Hardware-Ressourcen besser verteilt und genutzt werden. Während die GPU rechnet, kann die CPU gleichzeitig andere Aufgaben übernehmen, was den gesamten Prozess beschleunigt.

Im Folgenden werden die bislang noch nicht beschriebenen Komponenten des Post-Processings und der Datenbereitstellung behandelt. Das Pre-Processing und die Modellanwendung basieren grundlegend auf den Kapiteln II2.1 und III2 und werden im Folgenden nicht weiter erläutert.

2 Post-Processing

Um Fehlklassifikationen im Nachgang zu reduzieren und das Datenprodukt thematisch nach Tabelle 3 zu optimieren, wurde ein Post-Processing-Verfahren auf Basis von ALKIS-Daten implementiert. Das Post-Processing-Verfahren besteht insgesamt aus drei Arbeitsschritten: 1) dem ALKIS-Daten Download, 2) der gewichteten Überlagerung der ALKIS-Masken mit den Wahrscheinlichkeitskarten der Modellvorhersage und 3) der Erzeugung der binären Versiegelungskarte pro Kachel.

2.1 Überlagerung der Wahrscheinlichkeitskarten und ALKIS-Daten

Die ALKIS-Daten werden nach Kapitel II2.2 kachelweise heruntergeladen und verarbeitet. In das Post-Processing gehen die zuvor erstellten Wahrscheinlichkeitskarten aus der Modellanwendung ein. In der Modellanwendung wurden die einzelnen, vorhergesagten Bild-Patches über ein Blending-Verfahren auf die ursprüngliche Kachelgröße von 1 km² zurückgeführt. Dabei dient das Blending-Verfahren dazu, die Kantenbildung in den Überlappungsbereichen der Patches zu reduzieren (s. Abbildung 4). Die aufbereiteten ALKIS-Masken werden mit den Wahrscheinlichkeitskarten kachelweise überlagert und pixelweise, gewichtet verschnitten. Durch die Gewichtung nach ALKIS-Objektarten kann deren Einfluss auf die Versiegelungskarte gesteuert werden. Die Gewichtungen wurden im Rahmen des Projekts experimentell ermittelt.

Die Objektart AX_Gebaeude erhält eine Gewichtung von 30%, um durch Baumkronen verdeckte Gebäude zu berücksichtigen, und gleichzeitig Aktualitätslücken in den Daten entgegenzuwirken. Die Objektart AX_Straßenverkehr wird mit 10% gewichtet, wobei die Gewichtung zur Straßenachse hin kontinuierlich abnimmt, um den Fokus auf durch Baumkronen verdeckte Straßenränder zu legen und Straßenbegleitgrün dennoch zu berücksichtigen. Die Objektart AX_Wege erhält 45% Gewichtung aufgrund unzureichender Erfassungsmöglichkeiten durch Belaubung. Die Objektart AX_TagebauGrubeSteinbruch fließt zu 100% in das Ergebnis mit ein, da in diesen Bereichen Fehlklassifikationen aufgrund spektraler Ähnlichkeiten zu versiegelten Flächen trotz Berücksichtigung innerhalb der Trainingsdaten nicht verhindert werden konnten. Um

Fließgewässer wie in Tabelle 3 zu berücksichtigen, geht die Objektart AX_Fließgewässer ebenfalls zu 100% mit in das Ergebnis ein. Hinsichtlich Tabelle 3 fließen landwirtschaftliche Flächen zu 45% mit in das Ergebnis ein, um Probleme mit Agrarfolien zu minimieren. Die Gewichtungen der jeweiligen Objektarten mit Hinweis zu entfernten Wertarten werden in Tabelle 7 dokumentiert.

Tabelle 7: Gewichtung von ALKIS-Daten im Post-Processing

Objektart	Entfernte Wertarten	Gewichtung
AX_Gebaeude (31001)	Bergwerk (2171) Tiefgarage (2465) Gebäude zum U-Bahnhof (3094)	30%
AX_TagebauGrubeSteinbruch (41005)	-	100%
AX_Straßenverkehr (42001)	Verkehrsbegleitfläche Straße (2312)	10%
AX_Weg (42006)	Fußweg (5220) Gang (5230) Reitweg (5260) Sonstiges (9999)	45%
AX_Landwirtschaft (43001)	Brachland (1200)	45%
AX_Fließgewaesser (44001)	-	100%

Quelle: AdV 2022

2.2 Kachelweise Erstellung binärer Versiegelungskarten

Um eine binäre Versiegelungskarte zu erzeugen, werden die Pixelwerte der nachbereiteten Wahrscheinlichkeitskarten kachelweise mithilfe eines Schwellenwertes von 50% den Klassen „versiegelte Flächen“ oder „nicht-versiegelte Flächen“ zugeordnet. Alle Pixel, die unter diesem Schwellenwert liegen, werden nicht-versiegelten Flächen zugeordnet. Abschließend erfolgt eine zusätzliche Filterung, um nicht zusammenhängende Pixel und kleinere Pixelgruppen (< 20 Pixel, entspricht einer Fläche von bis zu 5 m²) aus der Versiegelungskarte zu entfernen. Am Ende des Post-Processing-Verfahrens liegen die binären Versiegelungskarten kachelweise mit einer räumlichen Auflösung von 0,5m Pixelkantenlänge in den Klassen „versiegelte Flächen“ mit Pixelwert 1 und „nicht-versiegelte Flächen“ mit Pixelwert 0 vor.

3 Datenbereitstellung

Um nachzuhalten welches Befliegungsdatum die Grundlage für die Berechnung der Versiegelungskarte pro Kachel war, wird der UTM-Kachel-Vektordatensatz (s. Kapitel II2) aktualisiert. Die Aktualisierung basiert auf den simultan beim Download der DOP

abgerufenen DOP Metadaten (s. Kapitel II1.1), die das jeweilige Befliegungsdatum kachelweise beschreibt. Der UTM-Kachel-Vektordatensatz wird für jede Anwendung der Software fortlaufend überschrieben. Zusätzlich wird eine CSV-Tabelle erzeugt, die auf Basis der Metadaten auflistet, welches Bildflugdatum und aufsummiert wie viele Kacheln des Bildflugdatums jeweils verarbeitet wurden.

Zur Erstellung einer landesweiten Versiegelungskarte werden die 35.022 Versiegelungskarten zusammengefügt. Die resultierende Versiegelungskarte für NRW wird als GeoTIFF-Datei mit einer räumlichen Auflösung von 0,5 m in 8-Bit-Integer-Werten gespeichert. In Abbildung 9 wird die erstellte Versiegelungskarte der Landesfläche NRWs mit zusätzlichen Detailausschnitten visualisiert.

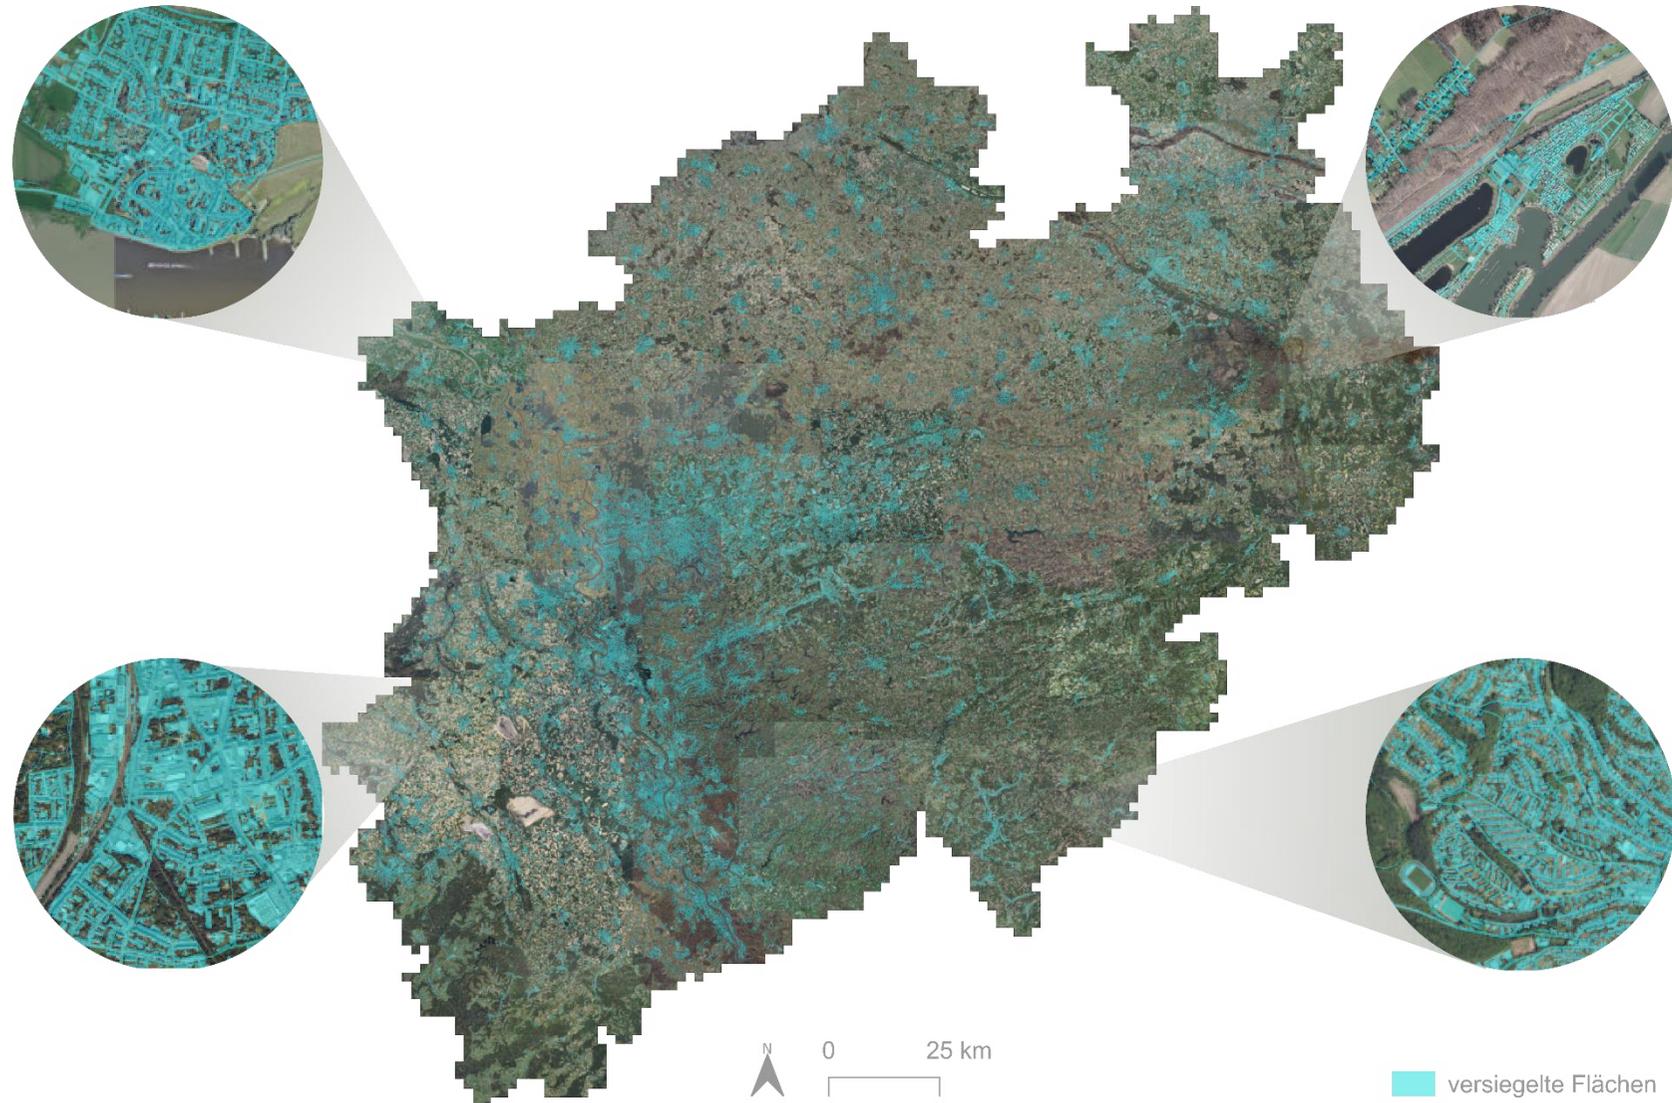


Abbildung 9: Versiegelungskarte der Landesfläche NRW (Datenquelle: Geobasis NRW 2024d)

V Ergebnisse und Validierung

Im Folgenden werden die Ergebnisse der empirischen Validierung der Versiegelungskarte NRW in den Validierungsgebieten Münster, Dortmund und Köln betrachtet. Zusätzlich erfolgt eine visuelle Analyse der Ergebnisse in den Validierungsgebieten.

1 Bewertungsmetriken

Zur Validierung der Versiegelungskarte wurden die Bewertungsmetriken Overall Accuracy (OA), Producer's Accuracy (PA), User's Accuracy (UA), F1-Score, Intersection Over Union (IoU) und Matthews Correlation Coefficient (MCC) verwendet. Nachfolgend werden die verwendeten Metriken kurz erläutert. Eine Dokumentation ihrer Berechnungsformeln findet sich in Anhang C.

- Overall Accuracy (OA): Die OA beschreibt das Verhältnis aller korrekt klassifizierten Pixel zur Gesamtanzahl aller Pixel im Bild. Ein hoher OA-Wert deutet auf ein genaueres Klassifikationsergebnis hin (Lange 2020).
- Producer's Accuracy (PA): Die PA gibt an mit welcher Wahrscheinlichkeit die Klasse richtig vorhergesagt wurde. Sie wird berechnet, indem die Anzahl der korrekt klassifizierten Pixel einer Klasse (hier: versiegelte Fläche) durch die Gesamtanzahl der tatsächlichen Pixel dieser Klasse geteilt wird (Lange 2020).
- User's Accuracy (UA): Die UA repräsentiert die Wahrscheinlichkeit, mit der die Klasse des Klassifikationsergebnisses tatsächlich vorliegt. Sie wird berechnet, indem die Anzahl der korrekt klassifizierten Pixel einer Klasse (hier: versiegelte Fläche) durch die Gesamtanzahl der vom Modell als diese Klasse vorhergesagten Pixel geteilt wird (Lange 2020).
- F1-Score: Der F1-Score ist das harmonische Mittel aus PA und UA. Er ist nützlich, wenn Übervorhersage und Untervorhersage ein gleich großes Informationsproblem darstellen. Genau wie PA und UA bewertet der F1-Score allerdings nur die Genauigkeit der positiven Klasse (hier: versiegelte Fläche), kennt nicht den Anteil der negativen Klasse (hier: korrekt als unversiegelt erkannte Pixel) und reagiert daher auf Klassenungleichheit (z.B. mehr unversiegelte als versiegelte Pixel im Gebiet) unabhängig vom Klassifikationserfolg (Sokolova et al. 2006).
- Intersection over Union (IoU): Die IoU (auch Jaccard Index (Jaccard 1912)) beschreibt (hier) das Verhältnis zwischen korrekt klassifizierter Versiegelungsfläche (Intersection) und der Vereinigungsfläche aus modellierter und tatsächlicher Versiegelung (Union). Diese Metrik ist besonders bei Segmentierungs- und Skalierungsaufgaben nützlich, da sie eine einfache Bewertung der Modelleleistung im Sinne von Objekterkennung bietet (Rahman und Wang 2016).
- Matthews Correlation Coefficient (MCC): Der Matthews Correlation Coefficient (MCC) berücksichtigt alle Elemente der Konfusionsmatrix (True Positives (TP), True

Negatives (TN), False Positives (FP) und False Negatives (FN)) und ist besonders geeignet in Fällen ungleicher Klassenverteilungen (Matthews 1975; Chicco et al. 2021). Im vorliegenden Projekt liegt ein Klassenungleichgewicht von versiegelten und nicht-versiegelten Flächen vor. Der MCC wurde herangezogen, um eine ausgewogenere Bewertung der Modelleleistung zu gewährleisten.

2 Validierung der Versiegelungskarte

Innerhalb des Projektzeitraums wurde die Versiegelungskarte in unterschiedlichen Bereichen NRWs getestet, um die Generalisierungsfähigkeit des Modells festzustellen und die Ergebnisse visuell zu prüfen.

Konkret wurde die Versiegelungskarte in den drei Validierungsgebieten Münster, Dortmund und Köln anhand der Validierungsdatensätze aus Kapitel II3.2 validiert. Für jedes Validierungsgebiet wurde eine Konfusionsmatrix erstellt und die zuvor beschriebenen Metriken berechnet. Tabelle 8 stellt OA, PA, UA, MCC, IoU und F1-Score der jeweiligen Klasse innerhalb der Validierungsgebiete gegenüber. Die Bereitstellung der ausführlichen Konfusionsmatrizen erfolgt im Anhang D.

Tabelle 8: Übersicht erzielter Genauigkeiten in den Validierungsgebieten

Klasse	Münster		Dortmund		Köln	
	V*	N-V*	V*	N-V*	V*	N-V*
Kl.-Ungleichheit (V*:N-V*)	0,21		0,48		0,50	
OA	96,67%		95,33%		96,87%	
PA	92,31%	97,58%	95,04%	95,46%	93,96%	96,31%
UA	88,89%	98,37%	90,37%	97,73%	92,66%	96,99%
MCC	88,57%		89,29%		89,96%	
IoU	82,76%	96,03%	86,30%	93,39%	87,45%	93,51%
F1-Score	90,57%	97,97%	92,65%	96,58%	93,31%	96,65%

*: V = versiegelte Flächen; N-V = Nicht-versiegelte Flächen

Die Analyse der Klassifikationsergebnisse für Münster, Dortmund und Köln zeigt eine durchgehend hohe Gesamtgenauigkeit von über 95% in allen drei Städten. Köln erreicht mit 96,87% die höchste OA. Die OA weist sehr hohe Genauigkeiten aufgrund des Klassenungleichgewichts versiegelter zu nicht-versiegelter Stichproben auf. Im Vergleich der OA mit dem MCC, wird jedoch deutlich, dass auch unter Berücksichtigung des Klassenungleichgewichts hohe Genauigkeiten von über 88% erreicht werden. Nicht-versiegelte Flächen werden generell genauer klassifiziert als versiegelte Flächen, was auf das natürliche Klassenungleichgewicht in Trainings- und Validierungsdaten zurückgeführt werden kann. Münster weist infolgedessen den größten Unterschied zwischen den Klassen auf (Klassenungleichheit: 0,21), während dieser im

Fall von Dortmund und Köln geringer ist. Die F1-Scores von über 90% für alle Klassen und Städte sowie die ausgeglichenen und hohen MCC zwischen den Städten deuten auf ein robustes und generalisierungsfähiges Modell hin.

3 Visuelle Analyse der Ergebnisse

Um neben diesen Metriken eine umfangreichere Aussage tätigen zu können, wurden zusätzlich visuelle Analysen durchgeführt. Für einen visuellen Eindruck der Ergebnisse werden im Folgenden Detailausschnitte der berechneten Versiegelungskarte zu den charakteristischen Merkmalen der Validierungsgebiete in variierenden Maßstäben bereitgestellt.

3.1 Stadtgebiet Münster

Abbildung 10 zeigt Detailansichten des Stadtgebiets Münster. Jede Zeile stellt einen anderen Gebietsausschnitt dar, während die Spalten von links nach rechts eine abnehmende Zoom-Stufe aufweisen.

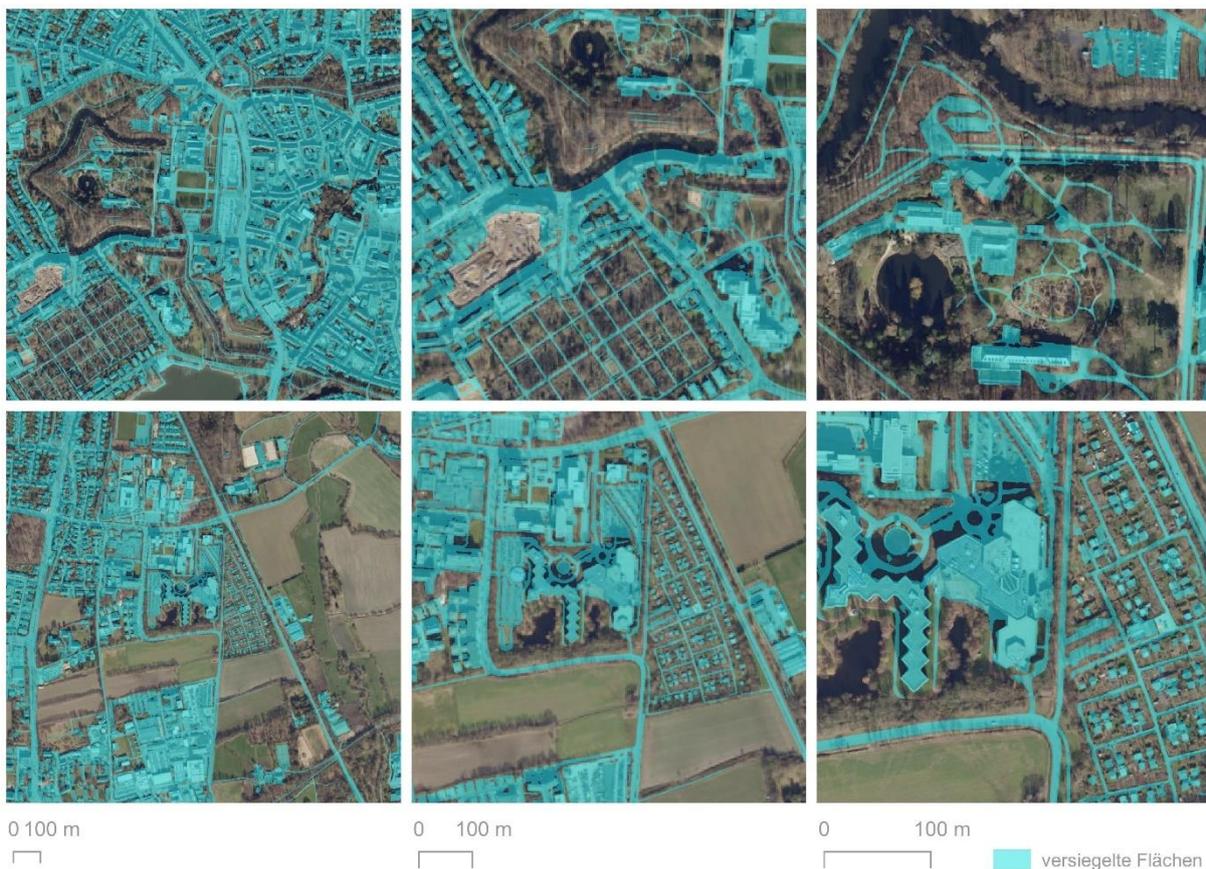


Abbildung 10: Detailausschnitt der Versiegelungskarte – Münster (Datenquellen: Geobasis NRW 2024d, Geobasis NRW 2024h)

In der ersten Zeile sind Teile des Stadtkerns sowie der Schlossgartenanlage zu erkennen. In diesen Bereichen liegen erschwerte Bedingungen durch dicht aneinander stehende unbelaubte Bäume vor, unter denen die Erfassung versiegelter Flächen nicht durchgehend erfolgen konnte. Die Strukturen des Zentralfriedhofs Münster im unteren

Bereich der Abbildungen der ersten Zeile werden hingegen robust erfasst. In der unteren Zeile liegt ein Abschnitt des Zentrum-Nords im Stadtgebiet Münster vor. Hier sind größere Gebäudekomplexe und deren Parkplatzflächen vorzufinden, die durch den Kleingärtnerverein Münsterblick e.V. östlich flankiert werden. Auch in diesem Gebietsausschnitt, der durch die variierenden Skalen versiegelter Flächen definiert wird, ist ein robustes Segmentierungsergebnis vorzufinden.

3.2 Stadtgebiet Dortmund

Die oberste Zeile der Abbildung 11 zeigt das Stadtzentrum Dortmund samt Hauptbahnhof und Fußgängerzone Westenhellweg. Anders als zuvor in Münster liegen im Stadtgebiet Dortmund hauptsächlich DOP im belaubten Zustand vor, die versiegelte Flächen verdecken. Dennoch ist zu erkennen, dass das Model mit ausreichend Kontext in der Lage ist, kleinere Abschnitte versiegelter Flächen zu verknüpfen. Dies zeigt sich deutlich am Beispiel des Stadtgartens. Obwohl für dieses Gebiet keine ALKIS-Daten für das Post-Processing zur Verfügung standen, wurden dennoch versiegelte Flächen unter Baumkronen erkannt und segmentiert.



Abbildung 11: Detailausschnitt der Versiegelungskarte – Dortmund (Datenquellen: Geobasis NRW 2024d, Geobasis NRW 2024h)

Die untere Zeile der Abbildung 11 zeigt den Westfalenpark Dortmund. Ebenfalls werden hier feine Strukturen im Park erfasst. Es ist zu erkennen, dass das Modell in Bereichen, in denen Baumkronen den räumlichen Kontext stark einschränken, an seine Grenzen kommt.

3.3 Stadtgebiet Köln

Die oberste Zeile der Abbildung 12 zeigt den Stadtkern Kölns samt Dom, Hauptbahnhof, Deutzer Brücke und Rheinpromenade. In den folgenden Zoom-Stufen erfolgt ein Einblick in die Neustadt-Nord und Media Park in denen markante Gebäudekomplexe und Hausstrukturen vorliegen. Aufgrund der Gegebenheiten der DOP in diesem Gebiet erschwert die nicht vorhandene Belaubung sowie die sichtbaren Schlagschatten die Segmentierung. Dennoch ist auch hier eine robuste Erfassung versiegelter Flächen vorzufinden. Die untere Zeile der Abbildung 12 zeigt den Flughafen Köln Bonn. Diese seltenere Landnutzungsart wurde im Rahmen der Trainingsdatenerweiterung (s. Kapitel III2) zusätzlich erfasst. Im Vergleich zu Straßen weisen diese Flughäfen eine deutlich größere Breite auf und zeigen zudem spektrale Variationen, durch Betonplatten oder sehr dunklen Asphalt. Durch die gezielte Aufnahme zusätzlicher Trainingsdaten für diese Bereiche konnte eine Verbesserung in der Segmentierung erzielt werden wie am Beispiel des Flughafens Köln/ Bonn ersichtlich wird.



Abbildung 12: Detailausschnitt der Versiegelungskarte – Köln (Datenquellen: Geobasis NRW 2024d, Geobasis NRW 2024h)

3.4 Spezielle Oberflächentypen

In Tabelle 3 wurden spezifische Oberflächentypen definiert, die bei DOP-basierter Auswertung als potentiell problematisch angesehen wurden und daher im Projekt besondere Beachtung erfahren sollten. Diese Oberflächentypen wurden deshalb innerhalb der drei Validierungsgebiete gezielt visuell überprüft. Einige Beispiele werden in Abbildung 13 gezeigt. Durch die Berücksichtigung dieser spezifischen Oberflächentypen sowohl in den Trainingsdaten als auch im Post-Processing wurde eine gezielte Segmentierung erreicht. Nur für Gleiskörper ist das nicht gelungen, weil diese in den für das Modelltraining genutzten Versiegelungsdatensätzen der Stadt Wuppertal und der EGLV bereits der Klasse 'unversiegelte Fläche' zugeordnet waren. Eine Verschneidung von ALKIS-Daten wurde für Gleiskörper nicht durchgeführt, weil die Objektart AX_Bahnverkehr neben Gleiskörpern auch angrenzende Grünflächen umfasst, was zu einer systematischen Überschätzung der Versiegelung infolge eines solchen Post-Processings geführt hätte.

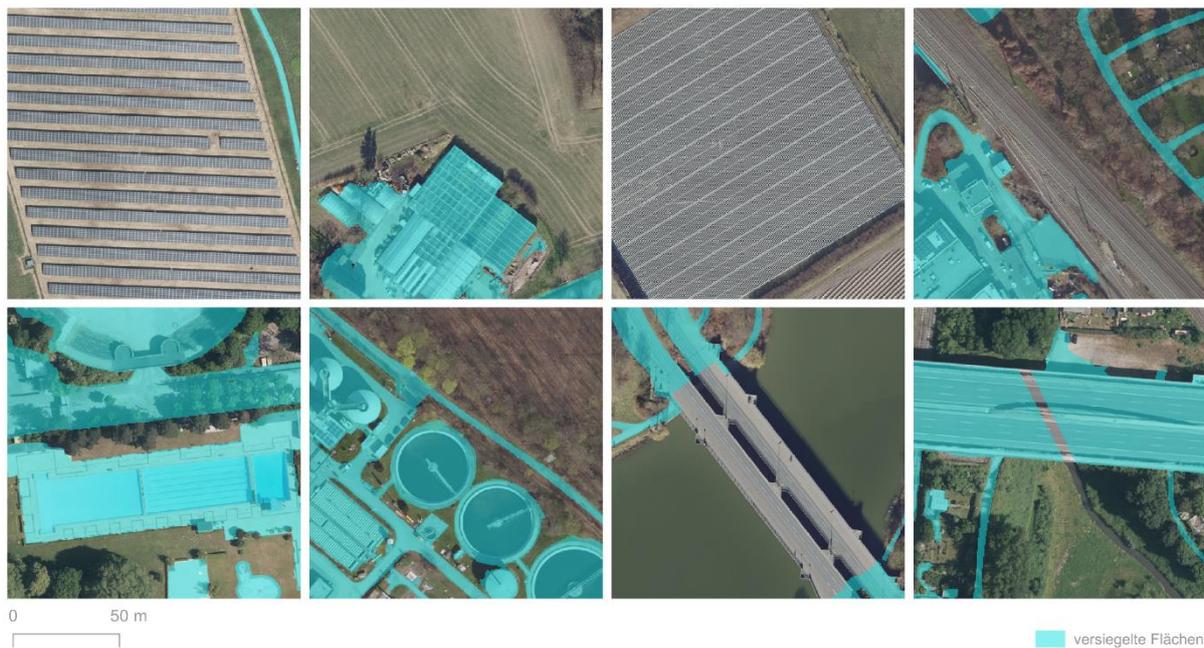


Abbildung 13: Berechnete Versiegelung spezieller Oberflächentypen (von links nach rechts pro Zeile: Freiflächen Photovoltaik, Gartenhäuser (Fläche >15 m²), Agrarfolien, Gleiskörper; Freibäder, Klärbecken, Versiegelte Flächen über Gewässer, Versiegelte Flächen über Gewässer und Offenland) (Datenquellen: Geobasis NRW 2024d, Geobasis NRW 2024h)

3.5 Fehlklassifikationen

Das trainierte Modell hat trotz unterschiedlicher Belaubungs- und Belichtungsfaktoren in den DOP versiegelte Flächen flächendeckend erfasst. Wie in Kapitel IV2 bereits angedeutet, sind Fehlklassifikationen jedoch nicht vollständig vermeidbar und können aufgrund der Gebietsgröße NRWs aus diversen Gründen auftreten. In Abbildung 14 werden einige Beispiele von Fehlklassifikationen visualisiert.

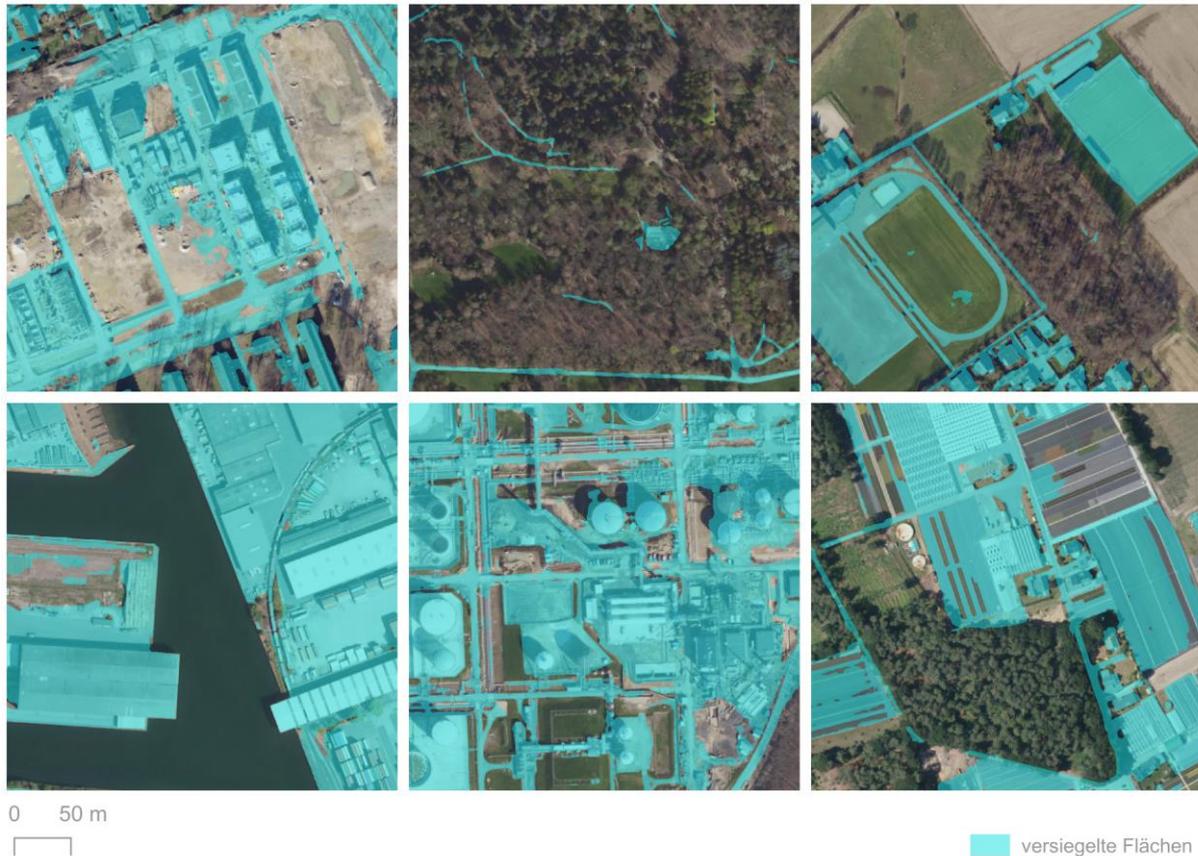


Abbildung 14: Beispiele für Fehlklassifikationen der Versiegelungskarte (Datenquellen: Geobasis NRW 2024d, Geobasis NRW 2024h)

Besonders in Bereichen hoher spektraler Ähnlichkeit treten Falsch-Positiv klassifizierte Flächen auf. Beispielsweise wird in Abbildung 14 Offenboden fälschlicherweise als versiegelte Fläche erfasst. Dieser Fall trat vor allem in Baustellen (z.B. Wohnungsbau und Straßenbau) sowie Häfen und Industriegebieten auf, wo die Abgrenzung von versiegelten Flächen und Offenboden trotz räumlichen Kontextes aufgrund von ähnlichem Oberflächenmaterial und/oder ungewöhnlicher Geometrie eine große Herausforderung ist. Falsch-Negativ klassifizierte Flächen treten zumeist in Bereichen mit fehlendem oder erschwertem räumlichem Kontext auf. In Abbildung 14 trifft das beispielsweise auf Parkanlagen zu, in denen Bäume und Schatten versiegelte Flächen verdecken. Dieser Effekt wurde sowohl in belaubten als auch unbelaubten Zuständen beobachtet.

Auch defizitäre Trainingsdaten (zu geringe Diversität, fehlende thematische Erfassung oder Inkonsistenzen in der Datenerhebung) können zu Fehlklassifikationen führen. Beispielsweise werden Kleingartenanlagen, Wege in Parkanlagen und Friedhöfen lediglich im Versiegelungsdatensatz der Stadt Wuppertal erfasst, was für diese Bereiche eine geringere Anzahl und Diversität der Trainingspaare bedeutete. Beispiele für Ober-

flächentypen, die im gesamten Trainingsdatensatz inkonsistent als (un)versiegelt klassifiziert wurden sind Straßenbegleitgrün und Fußballplätze, bei denen eine etwaige Kunstrasenbelegung nicht systematisch berücksichtigt wurde.

Ein weiteres Beispiel für Fehlklassifikationen sind Blumenfelder an der niederländischen Grenze in der Stadt Geldern. Diese Flächen weisen spektral sehr starke Ähnlichkeit zu dunklem Asphalt auf. Für diese Flächen kann nicht genau definiert werden, ob Agrarfolien aufliegen. Trotz gesammelter Trainingsdaten in diesen Gebieten und Post-Processing mit landwirtschaftlichen Flächen aus ALKIS-Daten, fällt die Abgrenzung von versiegelten zu nicht-versiegelten Flächen in diesen Fällen schwer.

VI Fazit und Empfehlungen

Im Rahmen dieses Projekts wurde eine Software entwickelt, die eine landesweite, hochauflösende Versiegelungskarte aus multispektralen DOP und wenigen, ergänzenden ALKIS-Daten erstellt. Die DOP enthalten die Spektralkanäle Blau, Grün, Rot und NIR, und werden in der Qualitätsstufe TrueDOP derzeit alle zwei Jahre aktualisiert. Die Identifikation versiegelter Flächen erfolgt mit Hilfe des frei verfügbaren UNetFormer Segmentierungsmodells, das mit Referenzdaten der Stadt Wuppertal und der EGLV trainiert wurde. Die Software erzeugt eine zusammenhängende Versiegelungskarte der Landesfläche NRWs mit einer räumlichen Auflösung von 0,5 m. Hierzu werden ausschließlich Geodatendienste des Landes NRW verwendet, um einen automatisierten Datenabruf und eine autarke Software zu gewährleisten. Die Software wurde erfolgreich in die CDI@IT.NRW integriert. Die Berechnung der landesweiten Versiegelungskarte nahm ca. 58 Stunden in Anspruch. Die Anwendung des entwickelten Modells in verschiedenen Regionen NRWs zeigt eine robuste Generalisierungsfähigkeit, die auch unter wechselnden Belaubungs- und Belichtungsbedingungen der DOP nachgewiesen werden konnte. Die Validierung der Versiegelungskarte in den Stadtgebieten Münster, Dortmund und Köln lieferte Ergebnisse auf hohem Niveau. Im Folgenden werden – thematisch gruppiert – aktuelle Leistungsgrenzen der Software erläutert sowie Empfehlungen für weiterführende Arbeiten gegeben.

1 Bilddaten

Die verwendeten DOP entstammen einem Bildflugprogramm, das aufgrund der Gebietsgröße von NRW unweigerlich zu kleinteiligen Bilddaten mit jahres- und tageszeitlich unterschiedlichen Aufnahmezeitpunkten führt. Für die Bildanalyse (Versiegelungserfassung) ergeben sich daraus verschiedene methodische Herausforderungen. Hinzu kommt die landschaftliche Heterogenität von NRW und die damit verbundene spektrale und geometrische Vielfalt an Oberflächentypen, die so umfassend wie möglich im Trainingsdatensatz enthalten sein sollten.

- **Belaubungszustände:** Die unterschiedlichen Belaubungszustände (belaubt, unbelaubt) in den Aufnahmen führten zu variierenden Sichtbarkeitsbedingungen. In Sommeraufnahmen verdeckten Baumkronen oft versiegelte Flächen, während in Frühjahrsaufnahmen diese Flächen sichtbar waren, aber der spektrale Kontrast geringer ausfiel.
- **Belichtungsverhältnisse:** Die 52 verschiedenen Aufnahmezeitpunkte im Bildflugprogramm resultierten in unterschiedlichen Belichtungsverhältnissen und Schattenwürfen. Diese Variationen erschwerten eine konsistente Abgrenzung zwischen versiegelten und nicht-versiegelten Flächen.

- Heterogenität der Landesfläche: NRW zeichnet sich durch eine große Vielfalt an Landnutzungen und Landbedeckungen aus. Innerhalb des vorgegebenen Projektzeitraums war es jedoch nicht möglich, das gesamte Gebiet vollständig zu analysieren. Seltener auftretende Landnutzungs- und Landbedeckungsarten konnten nicht in ausreichendem Maße in verschiedenen Kontexten oder Belaubungszuständen als Trainingsdaten in das Modell einfließen. Obwohl eine gute Generalisierungsfähigkeit des Modells auf ungesehene Daten erreicht wurde, verbleiben aufgrund der Heterogenität der Landoberfläche einige Fehlklassifikationen.
- Spektral ähnliche Oberflächen: Besonders herausfordernd waren Übergangsbereiche, wie Baustellen oder Tagebaugelände, in denen versiegelte und nicht-versiegelte Flächen mit den verfügbaren DOP spektral nur schwer voneinander zu unterscheiden waren. Dies galt sowohl für Aufnahmen in der unbelaubten als auch belaubten Jahreszeit. Trotz des vorhandenen räumlichen Kontextes kam es in diesen Bereichen zu Fehlklassifikationen.

Empfehlungen:

Nach einer gezielten Erweiterung von Trainingsdaten in Bereichen, in denen das bisherige Modell keine optimalen Vorhersagen trifft, könnte das Modell nachtrainiert werden. Beispielsweise könnten Nutzende des Datenprodukts solche Gebiete priorisieren und melden.

2 Trainingsdaten

Hinsichtlich der zuvor beschriebenen Herausforderungen durch Belaubungs- und Belichtungsfaktoren sowie der Gebietsgröße wird deutlich, dass die Trainingsgrundlage möglichst divers sein muss, um ein robustes Modell erstellen zu können.

- Aktualität von Input- und Referenzdaten: Die verwendeten Referenzdaten der Stadt Wuppertal und der EGLV waren eine gut geeignete Datengrundlage. Die Menge der verwendbaren Referenzdaten hat sich jedoch stark reduziert, da die verfügbaren DOP mit NIR-Kanal aus einem aktuelleren Bildflugprogramm stammten als die Aufnahmen, die zur Erstellung der ursprünglichen Referenzdaten verwendet wurden. Diese Aktualitätsunterschiede schränkten die Verwendbarkeit der Referenzdaten ein.
- Unterschiede der Versiegelungsdatensätze: Festzuhalten sind Unterschiede in den Versiegelungsdatensätzen, da die Datensätze unterschiedlichen Erfassungsrichtungen folgen. Kleingartenanlagen, Wege in Parkanlagen und Friedhöfe werden im Datensatz der Stadt Wuppertal erfasst, jedoch nicht im Datensatz der EGLV. Zudem fluktuierte die Erfassung von Straßenbegleitgrün und Sportplätzen in beiden Datensätzen. Somit erhielt das Modell limitierte bzw. inkonsistente Beispiele für diese Bereiche, was eine konsequente Abgrenzung dieser Flächen durch das Modell beeinträchtigte.

- Spezielle Oberflächentypen: Festzuhalten ist, dass in den Versiegelungsdaten der Stadt Wuppertal und der EGLV nicht alle speziellen Oberflächentypen aus Tabelle 3 berücksichtigt sind. Dies betrifft Gleiskörper des Bahnverkehrs, die als nicht-versiegelte Flächen definiert werden, sowie Brücken über Gewässer und Offenland (Höhe > 50 m). Zeitlich begründet konnte eine flächendeckende Anpassung der Referenzdaten nach Tabelle 3 im restlichen Projektzeitraum nicht umgesetzt werden. Die Berücksichtigung von Brücken über Offenland (Höhe > 50 m) wurde aufgrund des nachteiligen Einflusses auf die Prozessierungsgeschwindigkeit nicht weiter berücksichtigt.
- Klassenungleichgewicht: nicht-versiegelte Flächen treten vergleichsweise häufiger auf als versiegelte Flächen. Dieses natürliche Klassenungleichgewicht spiegelt sich auch in den Trainingsdaten wider. Beim Vergleich der Genauigkeit von Versiegelungskarten, die verschiedene Landesteile abdecken und/oder eine Änderung des Flächenversiegelungsanteils im Zeitverlauf zeigen, sollte dieser Störfaktor daher kontrolliert werden (sei es durch die Nutzung geeigneter Metriken wie MCC, oder einer entsprechend stratifizierten Stichprobe).

Empfehlungen:

Der für dieses Projekt verwendete Trainingsdatensatz umfasste etwa 140 km² der Landesfläche Nordrhein-Westfalens, was lediglich 0,4% des gesamten Gebiets entspricht. Trotzdem konnte ein robustes Modell entwickelt werden. Um die Leistungsfähigkeit und Generalisierbarkeit des Modells weiter zu steigern, empfiehlt sich eine Erweiterung des Trainingsdatenbestandes nach Kapitel II.2.2. Dabei sollten folgende Aspekte berücksichtigt werden:

- Konsequente Abgrenzung: Bei der Datenerfassung ist besonders auf eine klare Unterscheidung zwischen versiegelten und nicht-versiegelten Flächen zu achten.
- Gezielte Datensammlung: Der Fokus sollte auf Bereichen liegen, in denen das Modell bisher suboptimale Ergebnisse liefert, um die Aussagekraft des Datenprodukts zu erhöhen.
- Ausgewogene Repräsentation: Es sollte ein Gleichgewicht zwischen Beispielen aus belaubten und unbelaubten Zuständen sowie verschiedenen Landnutzungs- und Landbedeckungstypen angestrebt werden. Auch wenn eine ausgewogene Gewichtung von versiegelten und nicht-versiegelten Flächen in den Datensätzen schwierig zu erreichen ist, könnten Gewichtungsfaktoren in die Loss Function integriert werden.

Hinsichtlich der Inputdaten bietet die Integration von Höheninformationen ein vielversprechendes Potenzial zur Verbesserung der Modellleistung hinsichtlich aufragender versiegelter Infrastruktur. Diese Daten sind zudem weniger anfällig für den Störfaktor Schattenwurf. Das bildbasierte digitale Oberflächenmodell (bDOM) wäre hierfür eine geeignete Datenquelle, da das bDOM als Zwischenprodukt in der Erhebung der DOP

erzeugt wird (Geobasis NRW 2024b). Das bDOM liegt als Punktwolke im LAS-Format vor und erfordert daher eine Vorverarbeitung (Geobasis NRW 2024b). Allerdings existiert für diese Daten kein separater Geodatendienst, was eine automatisierte Verarbeitung erschwert. Aus diesem Grund wurde das bDOM während der Projektbearbeitung nicht berücksichtigt. Dennoch könnte eine speziell angepasste Datenbereitstellung und -verarbeitung einen Mehrwert in der Erfassung versiegelter Flächen bieten.

3 Post-Processing

Aufgrund variierender Belaubungszustände innerhalb der DOP und zur Berücksichtigung spezieller Oberflächentypen aus Tabelle 3 wurde eine zusätzliche Verschneidung der Modellergebnisse mit ALKIS-Daten notwendig.

- Belaubungszustände: Besonderen Einfluss auf das Modelltraining und die endgültige Versiegelungskarte haben die variierenden Belaubungszustände. Im Sommer liegen Baumkronen vor, die versiegelte Flächen verdecken. Im Frühling liegt ein schwächerer Kontrast von versiegelten Flächen und Vegetation vor. Zusätzlich reduziert Schattenwurf die extrahierbaren Informationen in den DOP. Durch die gewichtete Überlagerung von ALKIS-Daten werden diese Effekte reduziert, allerdings nicht vollständig behoben.
- Einfluss von ALKIS-Daten auf die Versiegelungskarte: Trotz hoher Aktualisierungsraten weisen ALKIS-Daten Aktualitätslücken auf. Außerdem können lediglich auf die aktuell im WFS-Dienst vorliegenden ALKIS-Daten zurückgegriffen werden, was bedeutet, dass die ALKIS-Daten unter Umständen nicht synchron mit dem DOP aus dem Bildflugprogramm sind. Aufgrund dieser Situation können fehlerhafte Verschneidungen nicht völlig ausgeschlossen werden.

Empfehlungen:

Mittelfristig ist zu empfehlen den Einfluss von ALKIS-Daten zu reduzieren, um systematischen Fehlern im Datenprodukt vorzubeugen. Hierbei ist beispielsweise die Integration von Höheninformationen in Form des bDOM, sofern eine solche Datenintegration gehandhabt werden kann, aussichtsreich.

4 Folgeberechnungen und Versiegelungsstatistik

Trotz der beschriebenen Herausforderungen und der relativ geringen Menge an Trainingsdaten konnte ein robustes und generalisierungsfähiges Modell entwickelt werden. Die erzielten Ergebnisse ermöglichen eine Folgeberechnung der Versiegelungskarte so bald neue DOP vorliegen. Hinsichtlich solcher Folgeberechnungen und der Anfertigung und Fortschreibung einer Versiegelungsstatistik nach der hier entwickelten Methode sollten jedoch folgende Faktoren berücksichtigt werden, weil sie Einfluss auf das Ergebnis haben:

- Generalisierungsfähigkeit (Übertragbarkeit): Das Modell zeigt zwar gute Generalisierungseigenschaften, diese sind jedoch nicht unbegrenzt.
- Sensitivität gegenüber stark veränderten Bilddaten: Potenzielle Änderungen in den Inputdaten können die Ergebnisse beeinflussen (z.B. weiträumige Schneedecke im Frühlings-DOP, bisher nicht im Trainingsdatensatz berücksichtigt).
- Versiegelungsstatistik: Die erstellte Versiegelungskarte basiert auf dem jeweils vorliegenden Bildflugprogramm des WCS. Dies führt zu:
 - einem Jahresschnitt in der Versiegelungskarte
 - variierende Fehlklassifikationen durch Sommer- und Frühlings-DOP, die in der Statistik berücksichtigt werden sollten

Empfehlungen:

Um sicherzustellen, dass die Folgeberechnungen auf Grundlage künftiger DOP ebenfalls robuste Ergebnisse liefern, sollte nach dem ersten Zeitschnitt eine Evaluierung dieser Ergebnisse erfolgen. Insbesondere was die unterschiedlichen Belaubungszustände betrifft, ist eine gezielte Analyse der Unterschiede aus Sommer- und Frühlingsbereichen hinsichtlich der Erstellung einer Versiegelungsstatistik zu empfehlen, um systematischen Fehlern vorzubeugen.

Technisch bedeutsam für erfolgreiche Folgeberechnungen sind zudem die Aktualität der verwendeten Geodatendienste und die verwendeten Softwareabhängigkeiten in Form des Docker-Base-Images und der Python-Bibliotheken. Eine regelmäßige Prüfung dieser Voraussetzungen ist empfehlenswert. Dazu wurde ein Test-Modus in die Software integriert, mit dem ein Testlauf der Software im Stadtgebiet Herne durchgeführt werden kann.

VII Literaturverzeichnis

- AdV (2022): Objektartenkatalog 'AFIS-ALKIS-ATKIS Anwendungsschema'. Arbeitsgemeinschaft der Vermessungsverwaltungen der Länder der Bundesrepublik Deutschland (AdV). Online verfügbar unter <https://www.adv-online.de/GeoInfoDok/Aktuelle-Anwendungsschemata/AAA-Anwendungsschema-7.1.2-Referenz-7.1/binarywriter-servlet?imgUid=aaf7a5be-17ae-4819-393b-216067bef8a0&uBasVariant=11111111-1111-1111-1111-111111111111>, zuletzt aktualisiert am 02.10.2024, zuletzt geprüft am 02.10.2024.
- Arnold, Chester L.; Gibbons, C. James (1996): Impervious Surface Coverage: The Emergence of a Key Environmental Indicator. In: *Journal of the American Planning Association* 62 (2), S. 243–258. DOI: 10.1080/01944369608975688.
- Barnes, Kent B.; Morgan, John M.; Roberge, Martin C. (2001): Impervious surfaces and the quality of natural and built environments. Online verfügbar unter <https://citeserx.ist.psu.edu/document?repid=rep1&type=pdf&doi=f8a7d8f4148029dca5a37cce9f7b67552ad6a95a>.
- Bundesregierung Deutschland (2020): Deutsche Nachhaltigkeitsstrategie. Weiterentwicklung 2021. Online verfügbar unter <https://www.publikationen-bundesregierung.de/resource/blob/2277952/1875176/9b7154e5739ecc19a2d1520d2a94a2c3/deutsche-nachhaltigkeitsstrategie-2021-langfassung-download-bpa-data.pdf?download=1>.
- Chicco, Davide; Warrens, Matthijs J.; Jurman, Giuseppe (2021): The Matthews Correlation Coefficient (MCC) is More Informative Than Cohen's Kappa and Brier Score in Binary Classification Assessment. In: *IEEE Access* 9, S. 78368–78381. DOI: 10.1109/access.2021.3084050.
- Docker Inc. (2024): Image Layer Details - pytorch/pytorch:2.2.2-cuda12.1-cudnn8-runtime | Docker Hub. Online verfügbar unter <https://registry.hub.docker.com/layers/pytorch/pytorch/2.2.2-cuda12.1-cudnn8-runtime/images/sha256-923f687790bec78081c357e71dcd5dcef80b0cc00f6c34484902a5e83362c854>, zuletzt aktualisiert am 29.07.2024, zuletzt geprüft am 29.07.2024.
- EGLV (o. J.): Digitale "Befestigte Flächen" EG (Stand 2021). Darstellung auf der Grundlage von digitalen Daten der Emschergenossenschaft, erstellt durch photogrammetrische Auswertung.
- Frie, Britta; Hensel, Ralph (2009): Schätzverfahren zur Bodenversiegelung: Ansatz der Umweltökonomischen Gesamtrechnungen der Länder: Shaker Verlag (Flächennutzungsmonitoring Konzepte - Indikatoren - Statistik). Online verfügbar unter <https://slub.qucosa.de/api/qucosa%3a4918/attachment/att-0/?l=1#page=21>.

- Geobasis NRW (2019): UTM-Kacheln NW. Datenlizenz Deutschland – Zero – Version 2.0. Online verfügbar unter https://www.wms.nrw.de/geobasis/wms_nw_utm_kacheln.
- Geobasis NRW (2024a): ALKIS – Standard. Online verfügbar unter <https://www.bezreg-koeln.nrw.de/geobasis-nrw/produkte-und-dienste/liegenschaftskataster/alkis-standard>, zuletzt geprüft am 29.07.2024.
- Geobasis NRW (2024b): Bildbasiertes Digitales Oberflächenmodell. Online verfügbar unter <https://www.bezreg-koeln.nrw.de/geobasis-nrw/produkte-und-dienste/hoehenmodelle/digitale-oberflaechenmodelle/bildbasiertes>, zuletzt geprüft am 07.10.2024.
- Geobasis NRW (2024c): Digitale Orthophotos. Online verfügbar unter <https://www.bezreg-koeln.nrw.de/geobasis-nrw/produkte-und-dienste/luftbild-und-satellitenbildung-informationen/aktuelle-luftbild-und-0>, zuletzt geprüft am 29.07.2024.
- Geobasis NRW (2024d): Digitale Orthophotos NW. Datenlizenz Deutschland – Zero – Version 2.0. Online verfügbar unter https://www.wms.nrw.de/geobasis/wms_nw_dop.
- Geobasis NRW (2024e): Digitales Geländemodell – Rasterweite 1 m (GeoTIFF). Datenlizenz Deutschland – Zero. Online verfügbar unter https://www.wms.nrw.de/geobasis/wms_nw_dgm-schummerung.
- Geobasis NRW (2024f): Geodatendienste. Online verfügbar unter <https://www.bezreg-koeln.nrw.de/geobasis-nrw/webdienste/geodatendienste>, zuletzt geprüft am 25.07.2024.
- Geobasis NRW (2024g): Übersichtsdienste. Online verfügbar unter <https://www.bezreg-koeln.nrw.de/geobasis-nrw/webdienste/uebersichtsdienste>, zuletzt geprüft am 05.08.2024.
- Geobasis NRW (2024h): WFS NW ALKIS NAS Konform. Datenlizenz Deutschland – Zero – Version 2.0. Online verfügbar unter https://www.wfs.nrw.de/geobasis/wfs_nw_alkis_nas-konform.
- Hao, Shijie; Zhou, Yuan; Guo, Yanrong (2020): A Brief Survey on Semantic Segmentation with Deep Learning. In: *Neurocomputing* 406, S. 302–321. DOI: 10.1016/j.neucom.2019.11.118.
- Jaccard, Paul (1912): The distribution of the flora in the alpine zone. 1. In: *New phytologist* 11 (2), S. 37–50.
- Kirillov, Alexander; Mintun, Eric; Ravi, Nikhila; Mao, Hanzi; Rolland, Chloe; Gustafson, Laura et al. (2023): Segment Anything. Online verfügbar unter <http://arxiv.org/pdf/2304.02643>.

- Lange, Norbert de (2020): Geoinformatik in Theorie und Praxis. Grundlagen von Geoinformationssystemen, Fernerkundung und digitaler Bildverarbeitung. 4. Aufl. 2020. Berlin, Heidelberg: Springer Berlin Heidelberg.
- Langenkamp, Jan-Philipp; Rienow, Andreas (2023): Exploring the Use of Orthophotos in Google Earth Engine for Very High-Resolution Mapping of Impervious Surfaces: A Data Fusion Approach in Wuppertal, Germany. In: *Remote Sensing* 15 (7), S. 1818. DOI: 10.3390/rs15071818.
- Loshchilov, Ilya; Hutter, Frank (2016): SGDR: Stochastic Gradient Descent with Warm Restarts. Online verfügbar unter <http://arxiv.org/pdf/1608.03983>.
- Loshchilov, Ilya; Hutter, Frank (2017): Decoupled Weight Decay Regularization. Online verfügbar unter <http://arxiv.org/pdf/1711.05101>.
- Matthews, B. W. (1975): Comparison of the predicted and observed secondary structure of T4 phage lysozyme. In: *Biochimica et biophysica acta* 405 (2), S. 442–451. DOI: 10.1016/0005-2795(75)90109-9.
- Memon, Rizwan Ahmed; Leung, Dennis Y. C.; Chunho, Liu (2008): A review on the generation, determination and mitigation of urban heat island. In: *Journal of Environmental Sciences* 20 (1), S. 120–128. DOI: 10.1016/S1001-0742(08)60019-4.
- Mundialis GmbH & Co. KG (2021): Deutschland 2020 – Landbedeckung auf Basis von Sentinel-2 Daten. Mundialis Lizenz. Datenlizenz Deutschland – Namensnennung – Version 2.0 (DL-DE->BY-2.0), oder. Online verfügbar unter <https://www.mundialis.de/deutschland-2020-landbedeckung-auf-basis-von-sentinel-2-daten/>.
- Nicolau, Andréa Puzzi; Dyson, Karen; Saah, David; Clinton, Nicholas (2024): Accuracy Assessment: Quantifying Classification Quality. In: Jeffrey A. Cardille (Hg.): *Cloud-Based Remote Sensing with Google Earth Engine. Fundamentals and Applications*. Unter Mitarbeit von Morgan A. Crowley, David Saah und Nicholas E. Clinton. 1st ed. Cham: Springer International Publishing AG, S. 135–145.
- Oktay, Ozan; Schlemper, Jo; Le Folgoc, Loic; Lee, Matthew; Heinrich, Mattias; Misawa, Kazunari et al. (2018): Attention U-Net: Learning Where to Look for the Pancreas. Online verfügbar unter <http://arxiv.org/pdf/1804.03999>.
- Olofsson, Pontus; Foody, Giles M.; Herold, Martin; Stehman, Stephen V.; Woodcock, Curtis E.; Wulder, Michael A. (2014): Good practices for estimating area and assessing accuracy of land change. In: *Remote Sensing of Environment* 148, S. 42–57. DOI: 10.1016/j.rse.2014.02.015.
- Rahman, Md Atiqur; Wang, Yang (2016): Optimizing Intersection-Over-Union in Deep Neural Networks for Image Segmentation. In: George Bebis (Hg.): *Advances in visual computing. 12th international symposium, ISVC 2016, Las Vegas, NV, USA, December 12-14, 2016 : proceedings. International Symposium on Visual Computing*. Cham: Springer (Lecture notes in computer science, 10072), S. 234–244. Online

- verfügbar unter https://link.springer.com/chapter/10.1007/978-3-319-50835-1_22?ref=https://githubhelp.com.
- Ronneberger, Olaf; Fischer, Philipp; Brox, Thomas (2015): U-Net: Convolutional Networks for Biomedical Image Segmentation. Online verfügbar unter <http://arxiv.org/pdf/1505.04597>.
- Sandmann, Stefan (2022): Cop4ALL NRW – Ableitung der Landbedeckung in Nordrhein-Westfalen mit Fernerkundung und künstlicher Intelligenz. In: *zfv – Zeitschrift für Geodäsie, Geoinformation und Landmanagement* (5/2022), S. 299–310. DOI: 10.12902/zfv-0407-2022.
- Schmidt, Sebastian; Barron, Christopher (2020): Mapping Impervious Surfaces Precisely—a GIS-Based Methodology Combining Vector Data and High-Resolution Airborne Imagery. In: *J geovis spat anal* 4 (1), S. 1–10. DOI: 10.1007/s41651-020-00055-6.
- Shorten, Connor; Khoshgoftaar, Taghi M. (2019): A survey on Image Data Augmentation for Deep Learning. In: *J Big Data* 6 (1), S. 1–48. DOI: 10.1186/s40537-019-0197-0.
- Shuster, W. D.; Bonta, J.; Thurston, H.; Warnemuende, E.; Smith, D. R. (2005): Impacts of impervious surface on watershed hydrology: A review. In: *Urban Water Journal* 2 (4), S. 263–275. DOI: 10.1080/15730620500386529.
- Stadt Wuppertal (o. J.): VerDIS-Daten als Shapefile (Stadtgebiet Wuppertal) Stand 2021. Amtliche Geodaten der Stadt Wuppertal, (C) Ressort Vermessung, Katasteramt und Geodaten (RV-102-106).
- The Linux Foundation (2024): PyTorch. Online verfügbar unter <https://pytorch.org/>, zuletzt aktualisiert am 13.08.2024, zuletzt geprüft am 13.08.2024.
- UBA (2024): Bodenversiegelung. Umweltbundesamt. Online verfügbar unter <https://www.umweltbundesamt.de/daten/flaeche-boden-land-oekosysteme/boden/bodenversiegelung#bodenversiegelung-in-deutschland>, zuletzt aktualisiert am 09.10.2024, zuletzt geprüft am 09.10.2024.
- Vaswani Ashish; Shazeer Noam; Parmar, Niki; Uszkoreit, Jakob; Jones, Llion; Gomez, Aidan N. et al. (2017): Attention is all you need. Online verfügbar unter <https://user.phil.hhu.de/~cwurm/wp-content/uploads/2020/01/7181-attention-is-all-you-need.pdf>.
- Wang, Libo; Li, Rui; Zhang, Ce; Fang, Shenghui; Duan, Chenxi; Meng, Xiaoliang; Atkinson, Peter M. (2022): UNetFormer: A UNet-like transformer for efficient semantic segmentation of remote sensing urban scene imagery. In: *ISPRS Journal of Photogrammetry and Remote Sensing* 190, S. 196–214. DOI: 10.1016/j.isprsjprs.2022.06.008.

Anhang

Anhang A	Konfigurationen im Modelltraining
Anhang B	Modelleistung anhand des Testdatensatzes im Modelltraining
Anhang C	Berechnungsformeln der Metriken
Anhang D	Konfusionsmatrizen

Anhang A: Konfigurationen im Modelltraining

Konfiguration des UNetFormer Modells

Parameter	Konfiguration
Decode_channels	64
Dropout	0,1
Backbone_Name	Swsl_resnet50
Window_size	8
Num_classes	1

Konfigurationen des Modelltrainings

Parameter	Konfiguration
Epochen	100
Patch Size	512 x 512
Batch Size	8
Channel Size	4 (R, G, B, NIR)
Learning Rate	1e-4
Learning Rate Scheduler	Cosine Annealing
Optimizer	AdamW
Weight Decay	1e-4
Principal Loss	Dice Focal Loss (Ratio 1:20)
Auxillary Loss	Binary Cross Entropy
Wichtungsfaktor (Aux. Loss)	0,4

Anhang B: Modelleistung anhand des Testdatensatzes im Modelltraining

Modelleistung anhand des Testdatensatzes (229 Patches)

Metrik	Versiegelte Flächen	Nicht-Versiegelte Flächen
Overall Accuracy	95,91%	95,91%
Producer's Accuracy	95,40%	96,22%
User's Accuracy	93,73%	97,24%
Intersection over Union	89,68%	93,66%
F1-Score	94,56%	96,73%

Anhang C: Metriken

Berechnungsformeln verwendeter Metriken

Metrik	Formel
Overall Accuracy (OA)	$\frac{TP + TN}{TP + TN + FP + FN}$
Intersection over Union (IoU)	$\frac{TP}{TP + FN + FP}$
F1-Score	$2 * \frac{\left(\frac{TP}{TP + FP}\right) * \left(\frac{TP}{TP + FN}\right)}{\left(\frac{TP}{TP + FP}\right) + \left(\frac{TP}{TP + FN}\right)}$
Matthews Correlation Coefficient (MCC)	$\frac{TP * TN - FP * FN}{\sqrt{(TP + FP) * (TP + FN) * (TN + FP) * (TN + FN)}}$

Anhang D: Konfusionsmatrizen

Konfusionsmatrix für das Stadtgebiet Münster

	Tatsächliche Klasse				UA
		Versiegelt	Nicht-Versiegelt	Summe (klassifiziert)	
Vorhergesagte Klasse	Versiegelt	240 (TP)	30 (FP)	270	88,89%
	Nicht-Versiegelt	20 (FN)	1210 (TN)	1240	98,37%
	Summe (Stichprobe)	260	1240	1500	
	PA	92,31%	97,58%		OA = 96,67%
	IoU	82,76%	96,03%		
	F1 Score	90,57%	97,97%		
	MCC	88,57%			

TP=True Positives, FP=False Positives, FN=False Negatives, TN=True Negatives, PA=Producer's Accuracy, UA=User's Accuracy, OA=Overall Accuracy, IoU=Intersection over Union, MCC=Matthews Correlation Coefficient; Aufbau vgl. Nicolau et al. 2024

Konfusionsmatrix für das Stadtgebiet Dortmund

	Tatsächliche Klasse				UA
		Versiegelt	Nicht-Versiegelt	Summe (klassifiziert)	
Vorhergesagte Klasse	Versiegelt	441 (TP)	47 (FP)	488	90,37%
	Nicht-Versiegelt	23 (FN)	989 (TN)	1012	97,73%
	Summe (Stichprobe)	464	1036	1500	
	PA	95,04%	95,46%		OA=95,33%
	IoU	86,30%	93,39%		
	F1 Score	92,65%	96,58%		
	MCC	89,29%			

TP=True Positives, FP=False Positives, FN=False Negatives, TN=True Negatives, PA=Producer's Accuracy, UA=User's Accuracy, OA=Overall Accuracy, IoU=Intersection over Union, MCC=Matthews Correlation Coefficient; Aufbau vgl. Nicolau et al. 2024

Konfusionsmatrix für das Stadtgebiet Köln

	Tatsächliche Klasse				UA
		Versiegelt	Nicht-Versiegelt	Summe (klassifiziert)	
Vorhergesagte Klasse	Versiegelt	467 (TP)	37 (FP)	504	92,66%
	Nicht-Versiegelt	30 (FN)	966 (TN)	996	96,99%
	Summe (Stichprobe)	497	1003	1500	
	PA	93,96%	96,31%		OA=96,87%
	IoU	87,45%	93,51%		
	F1 Score	93,31%	96,65%		
	MCC	89,96%			

TP= True Positives, FP=False Positives, FN=False Negatives, TN=True Negatives, PA=Producer's Accuracy, UA=User's Accuracy, OA=Overall Accuracy, IoU=Intersection over Union, MCC=Matthews Correlation Coefficient; Aufbau vgl. Nicolau et al. 2024