

# DIE ABLEITUNG DES LANDBEDECKUNGSMODELLS (LBM-DE) MITTELS DEEP LEARNING

Patrick Merita, Gabriel Cevallos, Julia Holzner, Michael Wurm

**Zusammenfassung:** Durch schnelle Entwicklungen im Hardwarebereich und die Möglichkeit zur Prozessparallelisierung rücken Deep-Learning-Verfahren zunehmend in den Fokus der Wissenschaft. Hierbei hat sich die semantische Segmentierung von Landbedeckung mittels Encoder-Decoder-Ansätzen als besonders leistungsfähig etabliert. Auf Basis des Landbedeckungsmodells Deutschland (LBM-DE) des Jahres 2021 wurde für das Bundesland Schleswig-Holstein evaluiert, inwieweit ein vortrainiertes Modell auf RapidEye-Daten zur Klassifizierung von PlanetScope-Daten genutzt werden kann. Mit klassenspezifischen F1-Scores von bis zu 0,95 zeigt sich das große Potenzial für die Ableitung von Landbedeckung mit Ansätzen der künstlichen Intelligenz.

**Schlüsselwörter:** Künstliche Intelligenz, Deep Learning, Fernerkundung, semantische Segmentierung, Residual Network 50, Feature Pyramid Network

## DERIVATION OF THE LAND COVER MODEL (LBM-DE) USING DEEP LEARNING

**Abstract:** Rapid developments in hardware and the possibility of process parallelization are bringing deep learning methods increasingly into the scientific spotlight. Semantic segmentation of land cover using encoder-decoder approaches has established as particularly powerful. With the land cover information of the Land Cover Model Germany (LBM-DE) of 2021 for the federal state of Schleswig-Holstein, it was evaluated to what extent a pre-trained model on RapidEye data can be used to classify PlanetScope data. With class-specific F1-scores of up to 0.95, the great potential for deriving land cover with artificial intelligence approaches is evident.

**Keywords:** Artificial intelligence, deep learning, remote sensing, semantic segmentation, Residual Network 50, Feature Pyramid Network

### 1 EINLEITUNG

Die Ableitung von Landbedeckungsinformationen hat eine lange Historie im Bereich des maschinellen Lernens (Hoeser et al. 2020). Durch den rasanten Anstieg an Deep-Learning-Verfahren (DL) für die Detektion von Objekten und/oder die Segmentierung von Bilddaten gab es im letzten Jahrzehnt zahlreiche Publikationen, die sich mit der Ableitung der Landbedeckung befassten.

Durch die steigende Anzahl von Erdbeobachtungsprogrammen, die damit verbundene Datenverfügbarkeit und die Entwicklung von Graphical Processing Units (GPUs) kann das Potenzial von Convolutional Neural Networks (CNNs) in der Bildanalyse genutzt werden. So ergaben sich nach Hoeser et al. (2020) 429 Publikationen mit DL für die Erdbeobachtung seit 2012. Hierbei spielen Encoder-Decoder-Ansätze eine zentrale Rolle in der Fernerkundung, insbesondere bei der Bildsegmentierung. ResNet von He et al. (2015) setzte mit seiner Einführung einen Meilenstein und dient häufig als Encoder („convolutional backbone“) in solchen Systemen. Der Encoder extrahiert Feature Maps, die vom Decoder beim Upsampling verwendet werden, um feine räumliche Strukturen besser zu segmentieren. Dies ist besonders vorteilhaft für die Analyse hochauflösender Fernerkundungsdaten.

### 2 SEMANTISCHE SEGMENTIERUNG

Die semantische Segmentierung ist ein Verfahren, das sich mit der Klassifizierung von Pixeln in einem Bild befasst. Hierbei wird jedem Pixel eine Klasse aus einer vorher definierten Klassenliste zugewiesen. So wird dem Algorithmus die Zugehörigkeit der einzelnen Pixel vermittelt. Als Ergebnis ergibt sich ein segmentiertes Bild, eingeteilt in die vordefinierten semantischen Klassen (Hao et al. 2020). Die semantische Segmentierung blickt auf eine umfangreiche Publikationshistorie zurück und ist ein essenzieller Bestandteil des maschinellen Sehens (Zhu et al. 2016). Aktuell existierende methodische Ansätze können je nach Überwachungsgrad in drei Hauptklassen eingeteilt werden: Unüberwachte, wenig/halb überwachte und voll überwachte Ansätze. Neben klassischen Verfahren (z. B. Random Forest (Breiman 2001) und Multi-Class Support Vector Machine (Wang & Xue 2014)) erleben DL-Ansätze wachsende Beliebtheit im Bereich der vollüberwachten Segmentierung. Eine gängige Netzarchitektur sind hier die Fully Convolutional Networks (FCNs) (Long et al. 2015). FCNs sind sog. Autoencoder- oder Encoder-Decoder-Systeme. Ziel dieser Systeme ist es, eine Synergie zwischen Outputs von tiefen und flachen Schichten in einem Netz zu schaffen. Der Encoder komprimiert die Eingangsdaten

## Autoren

M. Sc., M. Eng. Patrick Merita  
 Bundesamt für Kartographie und Geodäsie  
 Richard-Strauss-Allee 11  
 D-60598 Frankfurt am Main  
 E: patrick.merita@bkg.bund.de

M. Sc. Gabriel Cevallos  
 M. Sc. Julia Holzner  
 Dr. Michael Wurm  
 Deutsches Zentrum für Luft- und Raumfahrt (DLR)  
 Deutsches Fernerkundungsdatenzentrum (DFD)  
 D-82234 Oberpfaffenhofen  
 E: gabriel.cevallos@dlr.de  
 julia.holzner@dlr.de  
 michael.wurm@dlr.de | ORCID: 0000-0001-5967-1894

durch Faltungs- und Poolingoperationen, wodurch der semantische Wert mit jeder weiteren Schicht auf Kosten räumlicher Details zunimmt. Am Ende des Encoders folgt der Decoder, welcher die Eingangsdaten dekomprimiert und versucht, diese wiederherzustellen. Das Ergebnis wird im Anschluss mit dem erwarteten Wert verglichen. FCNs besitzen zur Steigerung der Performance sog. „Skip Connections“. Hierbei werden Feature Maps der mittleren Schichten des Encoders an den Decoder übergeben, um diesen im „Upsampling“ der Daten zu unterstützen (Badrinarayanan et al. 2017, Hao et al. 2020). Dadurch ist es möglich, sehr fein aufgelöste Segmentierungen mit gesteigerter Genauigkeit zu generieren (Yu et al. 2018). Neben den bekannten U-Nets (Ronneberger et al. 2015) haben sich im vergangenen Jahrzehnt zahlreiche Architekturen entwickelt (z. B. RefineNet (Lin et al. 2017), SegNet (Badrinarayanan et al. 2017) oder das FC-DenseNet (Jegou et al. 2017)). Hierbei werden unterschiedliche Konfigurationen des Encoders und des Decoders gewählt. Dies zeigt die Beliebtheit dieser Architekturen für Segmentierungsaufgaben. Zur Ableitung des Landbedeckungsmodells Deutschland wird hier ein ResNet50 als Encoder und ein Feature Pyramid Network (FPN) als Decoder verwendet.

Durch Einführung der sog. „Residual Units“, aus denen ResNets aufgebaut sind, sollen minimale Gradienten im Rahmen der Backpropagation reduziert werden. Residual Units zeichnen sich durch „Skip Connections“ aus. Hier wird dem Ergebnis aus jedem Faltungsblock das Ergebnis der vorherigen Schicht hinzugefügt. Diese Skip Connection ermöglicht eine stabilere Backpropagation, da es eine direkte Verbindung vom Klassifizierungslayer in die oberen Schichten des Netzwerks gibt (He et al. 2015). Die Unterscheidung der ResNets richtet sich nach der Anzahl der Schichten, demnach besitzt ein ResNet50 entsprechend 50 Schichten. Um Overfitting zu vermeiden, tendiert man somit eher zu flacheren Netzen. Das Modelldesign muss hier der gewünschten Aufgabe inkl. Daten angepasst werden.

Die extrahierten Feature Maps jedes Faltungsblocks des ResNets fließen nun durch laterale Verbindungen an den Decoder (hier: das FPN). Damit werden sog. „Feature Image Pyramids“ aufgebaut, welche einen großen Mehrwert für die Objekterkennung und Segmentierung darstellen, da die hochaufgelösten Schichten vom höheren semantischen Wert der tieferen Schichten profitieren (Lin et al. 2017). Zur Erstellung der Feature Pyramids werden ein sog. „Bottom-Up-Pathway“ (hier: das

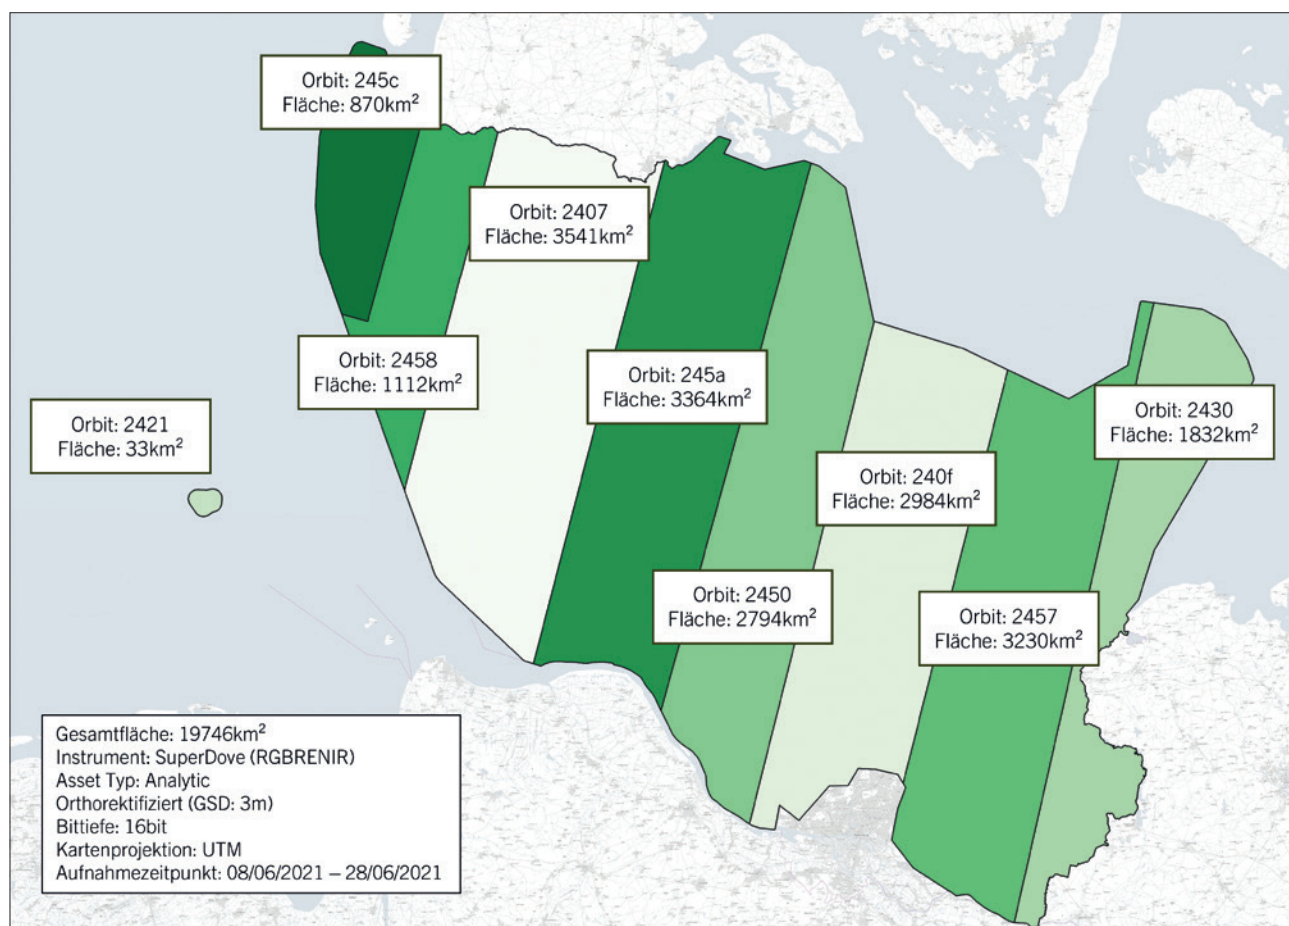
ResNet50 als „Convolutional Backbone“) und ein „Top-Down-Pathway“ (hier: das FPN) verwendet. Die erstellten Feature-Image-Pyramiden des Top-Down-Pathway tragen speziell bei der Rechnung der Inferenz zur Steigerung der Genauigkeit bei und werden in vielen Ansätzen zur Objekterkennung oder -segmentierung verwendet (z. B. Seferbekov et al. 2018, Wang & Zhong 2021, Lin et al. 2017).

### 3 ZIELSETZUNG, DATENGRUNDLAGE UND METHODIK

In diesem Beitrag wird durch semantische Segmentierungsverfahren die Landbedeckung (LBM-DE) für das Bundesland Schleswig-Holstein für das Jahr 2021 abgeleitet. Hierbei wird ein auf Basis von RapidEye-Daten entwickeltes Modell mittels Transfer Learning auf PlanetScope-Daten angepasst. Das initiale Modell wurde vom Deutschen Zentrum für Luft- und Raumfahrt (DLR) trainiert und getestet. Es handelt sich um ein Encoder-Decoder-System und eignet sich für die Lösung von Bildsegmentierungsaufgaben (z. B. Wurm et al. 2019, Voelsen et al. 2022). Die Wahl des Untersuchungsgebiets fiel auf Schleswig-Holstein, da zu Beginn der Ausarbeitung das LBM-DE lediglich für diesen Bereich Deutschlands für das Jahr 2021 fertig bearbeitet und somit als Referenzdatensatz nutzbar war. Der Schwerpunkt der Untersuchung liegt auf der Bewertung der Qualität der Klassifizierungsergebnisse. Unterteilt wird hier zwischen der Interpretation der klassenspezifischen Genauigkeiten und der Schlussfolgerung der Ergebnisse in Bezug auf die Aktualisierung des LBM-DE. Ein spezieller Fokus liegt auf dem Erlangen von Erfahrungswerten im Rahmen des Sensorübertrags von RapidEye zu PlanetScope. Dies ist entscheidend für zukünftige Überträge und die Anwendung des Verfahrens auf weitere Sensoren.

#### 3.1 PLANETSCOPE

Das PlanetScope-Programm ist neben RapidEye eine Erdbeobachtungsmission von Planet Labs (Planet Labs 2023). Seit 2014 wurden in mehreren Starts ca. 130 Dove-Satelliten in eine Erdumlaufbahn gebracht, die pro Tag einmal die gesamte Landoberfläche aufnehmen können. Die verbauten Instrumente haben sich von Dove Classic mit vier aufgenommenen Bändern (R-G-B-NIR) zu den neueren SuperDove-Satelliten mit acht Bändern entwickelt. Seit März 2020 nehmen diese Satelliten neben R-G-B-NIR auch „New Red Edge“, „Green 1“, „Coastal Blue“ und „Yellow“ auf und tragen damit zu einer Abdeckung eines größeren Wellenlängenbereichs bei. Je nach Sensor unterscheiden sich die aufgenommenen Szenengrößen



**Abbildung 1:** Übersicht der verwendeten PlanetScope-Daten. Dargestellt sind die verwendeten Orbits mit deren räumlicher Ausdehnung. Die Orbit IDs wurden von Planet Labs übernommen. Weiterhin wurden die Größe der Orbits in km<sup>2</sup> sowie generelle Eigenschaften (AssetTyp, Aufnahmezeitpunkt, beobachtete Gesamtfläche, Bittiefe und Projektion) der PlanetScope-Daten hinzugefügt (eigene Darstellung).

Kategorie	Landbedeckungsklasse	Code (BKG)	Code (M)
A	Bebauung	B110	1
	Anlagen	B121	2
	Versiegelte gebäudelose Flächen	B122	3
	Mischflächen	B242	4
B	Ackerland	B211	5
	Weinbau	B221	6
	Obst- und Beerenobst	B222	7
	Hopfen	B224	8
C	Homogenes Grünland	B231	9
	Inhomogenes Grünland	B321	10
	Grasland mit Bäumen (< 50 %)	B233	11
D	Zwergsträucher (Heide)	B322	12
	Büsche, Sträucher	B324	13
	Aufforstung	B310	14
	Laubbäume	B311	15
	Nadelbäume	B312	16
	Nadel- und Laubbäume	B313	17

Kategorie	Landbedeckungsklasse	Code (BKG)	Code (M)
E	Sand, Steine, Erde	B330	18
	Fels	B332	19
	Brandfläche	B334	20
	Schnee und Eis	B335	21
F	Sumpf	B411	22
	Moor	B412	23
	Sumpf mit Büschen/Bäumen	B413	24
	Moor mit Büschen/Bäumen	B414	25
G	Watt	B423	26
	Wasserlauf	B511	27
	Wasserfläche	B512	28
	Lagune	B521	29
	Mündungstrichter	B522	30
	Offenes Meer	B523	31

**Tabelle 1:** Übersicht der unterschiedlichen Klassen des Landbedeckungsmodells Deutschland (LBM-DE). Die Klassen sind in die sieben Hauptkategorien eingeteilt: Bebaute Flächen (A), Landwirtschaft (B), Grünland (C), höhere Vegetation (D) sowie vegetationslose Flächen (E), feuchte Flächen (F) oder Wasserflächen (G). Zusätzlich wurde die Beschreibung (2. Spalte), der BKG interne Code pro Landbedeckungsklasse (3. Spalte) sowie der im Modell vergebene Code (4. Spalte) angegeben (modifiziert nach BKG 2023).

von ca. 280 km<sup>2</sup> (Dove Classic) bis hin zu 630 km<sup>2</sup> (SuperDove) (Planet Labs 2023). Für die Ableitung wurden SuperDove-Daten bezogen, die sich auf die Bildkanäle Rot, Grün, Blau, Red Edge und NIR beschränken. Für den Aufnahmezeitpunkt war es wichtig, möglichst wolkenfreie Bilder aus derselben Jahreszeit zu erhalten. Für das Jahr 2021 eignete sich der Monat Juni, da in diesem Zeitrahmen die Wolkenbedeckung minimal war. Es wurden orthorektifizierte oder radiometrisch korrigierte Orthoszenen der Prozessierungsstufe L3B verwendet.

Für die Abdeckung der gesamten Landesfläche von Schleswig-Holstein waren die Daten von neun Orbits notwendig (Abbildung 1). Es handelt sich um Top of Atmosphere (TOA) korrigierte Daten, die durch mitgelieferte Kalibrierungskoeffizienten in TOA-Reflektanzen umgerechnet wurden.

### 3.2 LANDBEDECKUNGSMODELL DEUTSCHLAND (LBM-DE)

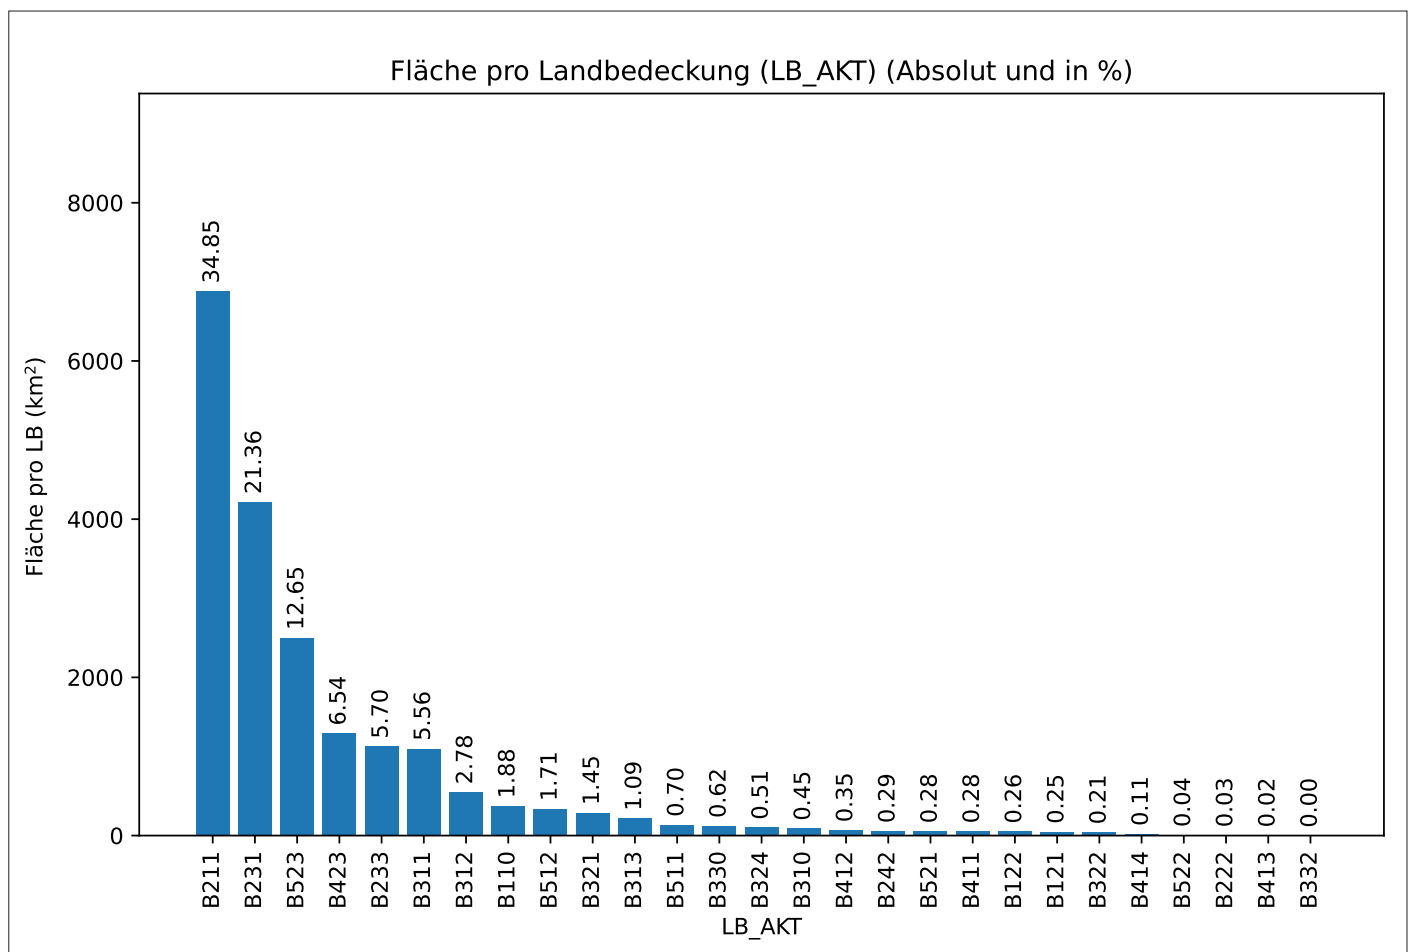
Das digitale Landbedeckungsmodell (LBM-DE) wird seit 2009 als Standardprodukt des Bundesamts für Kartographie und Geodäsie (BKG) geführt. Es ist in Landnutzung und Landbedeckung unterteilt und beschreibt die zugehörige Geometrie flächendeckend für das gesamte Bundesgebiet im Vektorformat. Zielsetzung hierbei ist, den Zustand der Umwelt zum Erfassungszeitpunkt festzuhalten. Die Erfassung und die damit verbundene Aktualisierung erfolgt dreijährig mit Bezug auf ein bestimmtes Referenzjahr.

Tabelle 1 zeigt die 31 Landbedeckungsklassen des LBM, eingeteilt in sieben Hauptkategorien. Diese erstrecken sich von bebauten Flächen (A) und Landwirtschaft (B) über Grünland (C) und höherer Vegetation (D) bis hin zu vegetationslosen Flächen (E), feuchten Flächen (F) oder Wasserflächen (G). Im Modell wird statt des BKG internen Codes eine fortlaufende Nummer als ID verwendet.

### 3.3 METHODISCHE HERANGEHENSWEISE

Vor dem Modelltraining müssen die Daten in die für die Modellarchitektur passende Form gebracht werden. Für die semantische Segmentierung sind Labels notwendig. Aus diesem Grund wird das LBM aus dem Jahr 2021 vom Vektorformat in das Rasterformat transformiert. Hierdurch wird eine flächendeckende Rastermaske erstellt, wodurch jedem Pixel der Trainingsdaten ein eindeutiges Label zugewiesen werden kann.

Die Verfeinerung des bestehenden Modells und die Evaluierung der Güte erfolgen in dieser Arbeit per Kreuzvalidierung. Der geringe Datenbestand kann den Domänenübertrag von RapidEye zu PlanetScope trotz der Nutzung eines vortrainierten Modells potenziell erschweren. Aus diesem Grund soll der Datensatz nicht weiter dezimiert werden. Bei der Kreuzvalidierung wird iterativ über die Orbits gegangen, sodass jeder Orbit einmal Testgebiet war. Mittelt man die Treffergenauigkeit pro Orbit in Bezug auf deren absolute Fläche, erhält man eine Gesamtgenauigkeit für Schleswig-Holstein. Abseits des Testorbits werden die restlichen



**Abbildung 2:** Fläche pro Landbedeckung im Untersuchungsgebiet Schleswig-Holstein. Aufgetragen sind die Landbedeckungsklassen des LBM-DE. Zusätzlich zur absoluten Fläche wurde deren prozentualer Anteil an der Gesamfläche hinzugefügt (eigene Darstellung).

Orbits randomisiert als Trainings- und Validierungsdaten im Verhältnis 70/30 zugeteilt und in 320 x 320 Pixel als Rasterites gekachelt.

Für die Aufteilung der Eingangsdaten in Trainings-, Test- und Validierungsdaten ist die Landbedeckungsverteilung für Schleswig-Holstein entscheidend. Da Schleswig-Holstein eine regional heterogene Landbedeckung aufweist, treten manche Klassen nur in speziellen Gebieten der Landesfläche auf. Sind diese Bereiche Teil der Testorbits, wurden diese schlechter erkannt, was maßgeblich Einfluss auf die Güte des Modells hatte. Eine entscheidende Klasse, die regional zu starken Unterschieden in den Bildkanalstatistiken führt, ist B423 (Watt), da diese lediglich im Westen des Landes auftritt und daher nicht in allen Orbits vorhanden ist.

Solche Klassenverteilungen müssen ebenfalls bei der Erstellung der Gewichte und damit dem Einfluss einzelner Klassen auf die Gesamtgüte berücksichtigt werden. In Schleswig-Holstein liegt ein Klassenungleichgewicht vor. Klassen wie B211 (Ackerland: 34,85 %), B231 (Homogenes Grünland: 21,36 %) und B523 (Offenes Meer: 12,65 %) machen fast 70 % der betrachteten Fläche aus. Im Verhältnis dazu gibt es viele Klassen mit flächenhaftem Vorkommen von weniger als 1 % (Abbildung 2).

Für diese unterrepräsentierten Klassen ist ein Ausbalancieren über alle Klassen notwendig, sodass alle Klassen nahezu gleichmäßig berücksichtigt werden und keine Verzerrung in Richtung häufiger auftretender Klassen auftritt. Hierfür werden bei der Bildung der Gewichte pro LB-Klasse das 30%- und das 70%-Perzentil ausgegeben. Zur Balancierung werden Klassen, die unterhalb des 30%-Perzentils liegen, auf selbiges angehoben und präsentere Klassen oberhalb des 70%-Perzentils auf das 70%-Perzentil abgesenkt.

Vor dem eigentlichen Training erfolgt eine Hyperparameteroptimierung. Die Definition geeigneter Hyperparameter gibt dem Verfahren vor, wie schnell (Lernrate) und wie lange (Anzahl Epochen) es Informationen lernen soll. Zusätzlich wird die Menge an Bildkacheln definiert, die dem Modell in einem Zug präsentiert werden (Batch Size). Die durchgeführten Tests ergaben eine Trainingsdauer von zehn Epochen bei einer Lernrate von 0,001 und einer Batch Size von 16.

#### 4 AUSWERTUNG UND DISKUSSION

Der visuelle Vergleich der Klassifizierungsergebnisse mit den LBM-Labels (Abbildung 3) zeigt eine gute Übereinstimmung trotz des Domänenwechsels von RapidEye zu PlanetScope. Mit geringem Trainingsaufwand sind scharfe Abgrenzungen innerhalb der Landbedeckungstypen des LBM-DE möglich. Sowohl urbanere Bereiche als Kombination von B110 (Bebauung) und B233 (Grasland mit Bäumen), höhere Vegetation (B31x), Grünland (B231) als auch Ackerland (B211) und die Wasserflächen (B5xx) lassen sich deutlich voneinander abgrenzen.

Es zeigt sich allerdings auch, dass intrakategoriale Abgrenzungen, wie beispielsweise bei der höheren Vegetation (B31x), schwierig sind.

So fällt auf, dass die Abgrenzung zwischen den verschiedenen Vegetationsklassen B311 „Laubbäume“, B312 „Nadelbäume“ und B313 „Laub- und Nadelbäume“ unscharf ist. Dies muss nicht für eine unzureichende Qualität des Modells sprechen, sondern kann aus einem Zusammenspiel veränderter Ist-Zustände inner-

halb des Walds und schwierig modellierbarer Klassenbeschreibungen (z.B. B313 „Laub- und Nadelbäume“) resultieren. Die Mischwaldklasse B313 wäre ein Beispiel für eine umfangreichere Postprozessierung. Die festgesetzten Polygongrenzen, auf denen zurzeit das LBM-DE aktualisiert wird, tragen hier maßgeblich zur Klasse bei. Laut BKG (2023) handelt es sich bei B313 um „Flächen, die zu mindestens 50 % mit Bäumen bestanden sind. Keine Waldart darf mehr als 75 % dieser Fläche ausmachen. Es muss eine baumweise oder baumgruppenweise Durchmischung von Laub- und Nadelbäumen erkennbar sein.“ Das Verfahren tendiert auf Basis der reinen Bildinformation der PlanetScope-Daten zur Ausweisung von Laubbäumen oder Nadelbäumen. Hier wäre als weiterer Prozessierungsschritt die Verwendung der Labelpolygone des Mischwalds denkbar. Auf deren Basis könnten die prozentualen Anteile von Laub- und Nadelwald berechnet werden und eine Einteilung in die drei Vegetationsklassen erfolgen. Eine weitere Herausforderung ist die Klasse Bebauung (B110), die vom Verfahren in begrünten Vorstadtbereichen häufig der Klasse B233 „Grasland mit Bäumen“ zugeordnet wird.

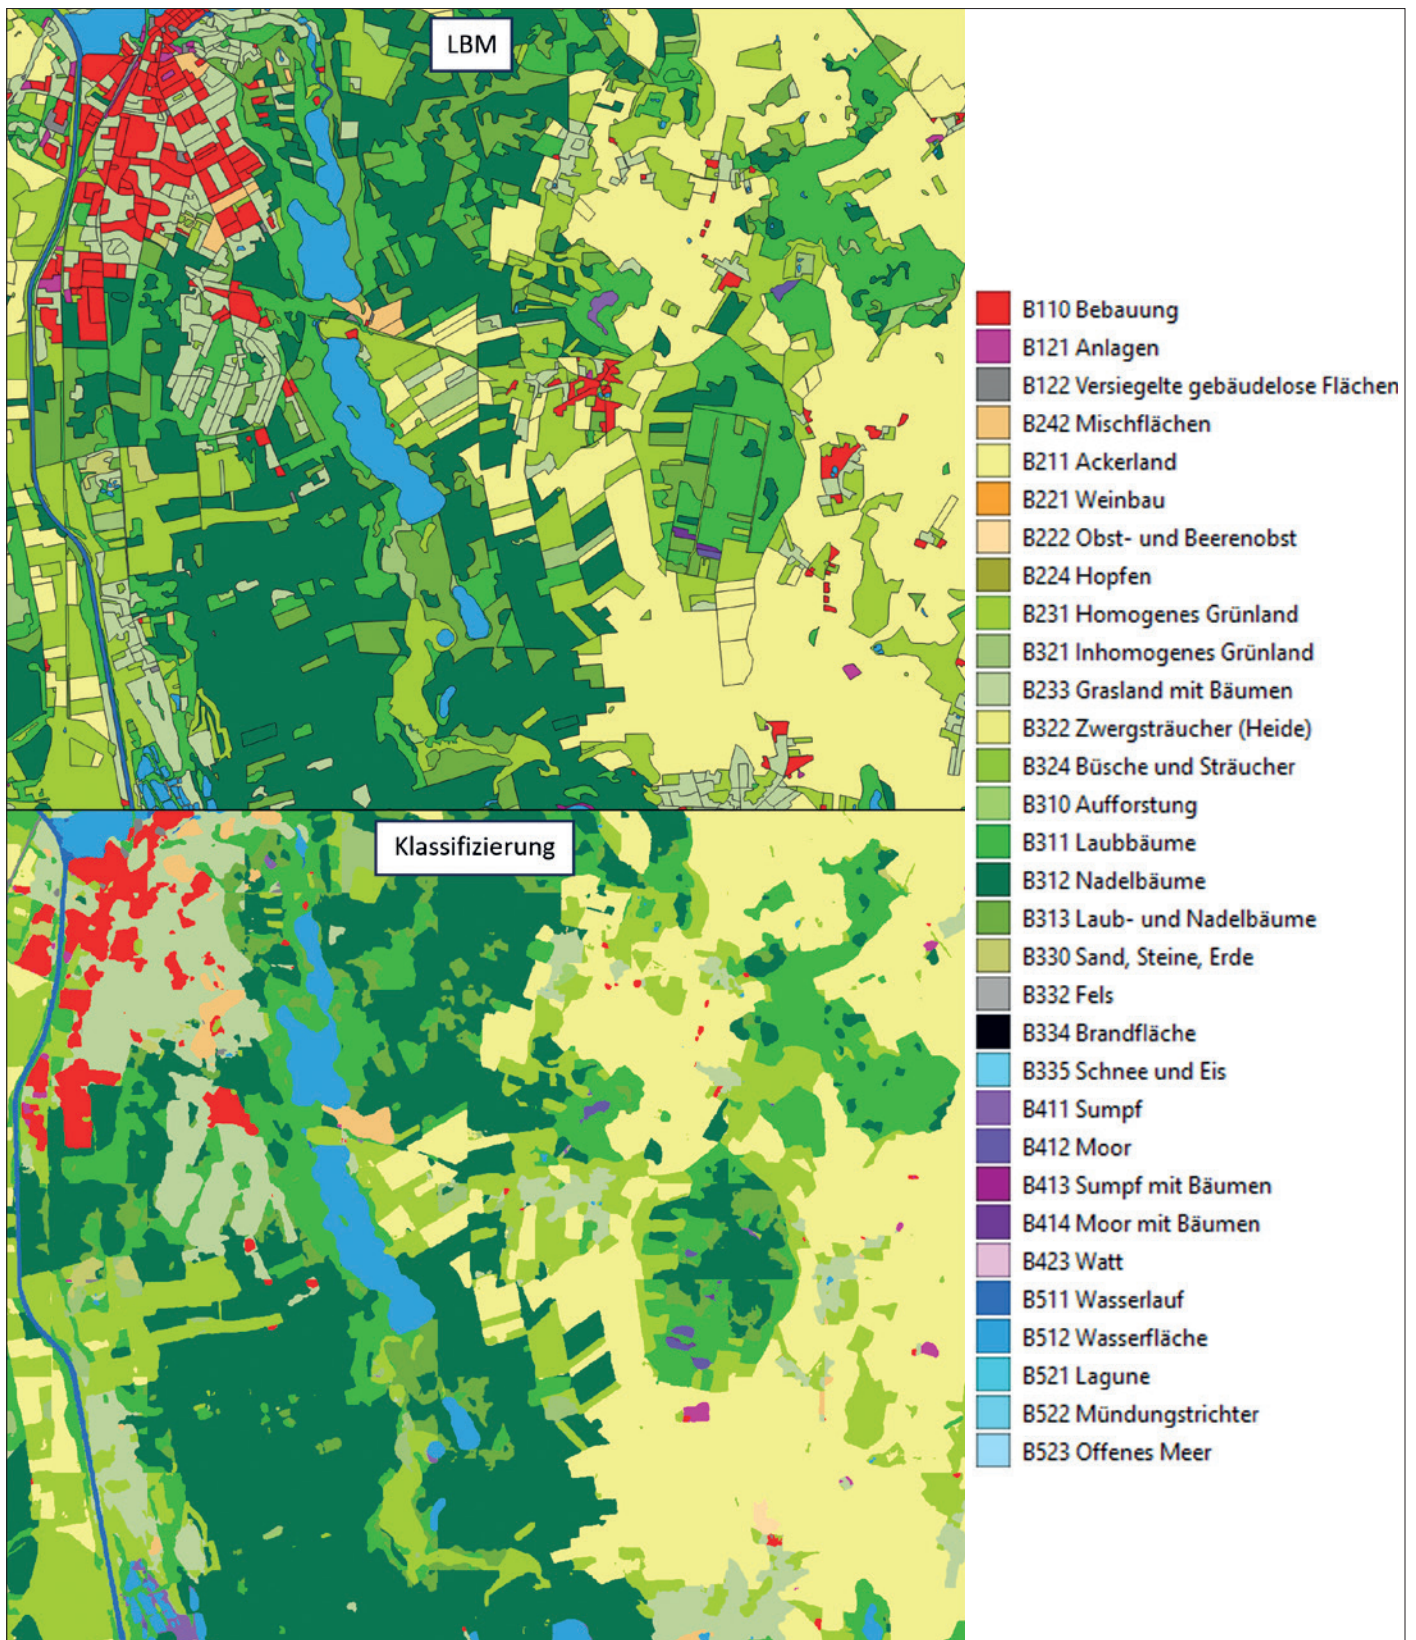
Diese Vorhersage deutet auf ein ungenaues Modell hin, was bei Sichtung der beiden Klassen aber nicht der Realität entspricht.

Beide Klassen sind in grünen Vorstadtbereichen spektral ähnlich. Schaut man sich die Ergebnisse in den Stadtkernen an, wo der Anteil an Grün abnimmt, sagt das Modell die richtige Klasse vorher. Solche Klassen würden durch eine höhere Auflösung sowie räumlich differenzierterer Labels profitieren, sodass Vegetation von urbanen Strukturen abgegrenzt werden kann. Eine solche Steigerung der räumlichen Auflösung könnte durch Nutzung weiterer Fernerkundungsdaten realisiert werden.

Neben der visuellen Interpretation zeigt Abbildung 4 als Ergebnis die gemittelten klassenspezifischen Metriken der Kreuzvalidierung über alle Orbits. Auffällig sind einige Klassen mit hohen F1-Scores  $\geq 0,70$ . Explizit Klasse 31 (B523 „Offenes Meer“) mit  $F1 = 0,95$  und Klasse 5 (B211 „Ackerland“) mit  $F1 = 0,84$  sind hier hervorzuheben.

Weiter zeigt Abbildung 4, dass einige Klassen (B121: „Anlagen“, B122: „Versiegelte gebäudelose Flächen“, B321: „Inhomogenes Grünland“, B324: „Büsche und Sträucher“, B310: „Aufforstung“, B313: „Nadel- und Laubbäume“, sowie einzelne Wasserflächen (B521 und B522) und feuchte Flächen (B411 bis B414)) durch niedrigere F1-Scores (unter 0,5) auffallen. Der F1-Score als harmonisiertes Mittel zwischen Präzision und Recall bestätigt die erwähnten Herausforderungen. Im Bereich der höheren Vegetation weisen die Klassen B311 (Laubbäume) und B312 (Nadelbäume) F1-Scores größer 70 % auf, wohingegen die Mischwaldklasse mit 0,29 vage ist.

Nicht sehr genaue Klassenbeschreibungen sind für die feuchten Flächen (unter 0,40) feststellbar. Auf Basis der reinen Bilddaten sind diese schwer von den Grünlandflächen zu differenzieren, da die spektralen Signale beider Klassen ähnlich sind. Weiterhin sieht man im Bereich der Wasserklassen, dass die Klassifizierung abseits von B523 mit  $F1 = 0,95$  erschwert ist. Hier fallen besonders B521 ( $F1 = 0,3$ ) und B522 ( $F1 = 0,35$ ) auf. Speziell für die Klassen B511, B512, B521 und B522 gibt die Beschreibung vor, welchen räumlichen Einschränkungen diese Flächen unterliegen. Beispielsweise handelt es sich bei der LB-Klasse B521 (Lagune) um „Salz- oder Brackwasserzonen im Küstenbereich,



**Abbildung 3:** Evaluation der Klassifizierung für das erste Szenario auf Basis von 31 Klassen. Vergleich der LBM-Labels (oben) mit dem Klassifizierungsergebnis (unten) am Beispiel eines Ausschnitts über Orbit 2430 (eigene Darstellung).

die vom Meer durch eine Landzunge o. Ä. getrennt sind“ (BKG 2023).

So könnte man nach der eigentlichen Klassifizierung noch spezielle Regionen ausweisen, wo vereinzelte Klassen auftreten können, um so die Qualität der Klassifikation zu steigern. Nach einem

detaillierten Blick auf die klassenspezifischen Unterschiede soll abschließend noch die Gesamtgenauigkeit des Modells bewertet werden. Hierfür wurden Top-K-Genauigkeiten für die 32 Klassen (31 LB-Klassen + NoData) dargestellt. Bei Top-1 muss die richtige Klasse in der Vorhersage getroffen werden. Bei Top-2 und Top-3



Abbildung 4: Klassenspezifische Gütemetriken für die 31 Klassen des LBM + NoData (0). Aufgetragen sind die gemittelten Werte für Präzision und Recall (oben) sowie F1 (unten) für die Kreuzvalidierung über alle Orbits. Die Klassenzuweisung zwischen Modell (M) und LBM ist in der Tabelle (rechts) zu entnehmen. Die Klassen 6, 8, 20, und 21 sind im Untersuchungsgebiet nicht vorhanden (eigene Darstellung).

muss die richtige Klasse lediglich unter den zwei bzw. drei wahrscheinlichsten Klassen zu finden sein, um als korrekt vorhergesagt zu zählen. Hohe Top-K-Scores stehen für eine gewisse Robustheit des Modells, da es sich nicht nur auf einzelne Vorhersagen bezieht und Alternativen berücksichtigt. Dies macht das Modell insgesamt zuverlässiger. In Tabelle 2 sind die Gesamtgenauigkeiten für das Modell aufgezeigt. Bei 31 Klassen erreicht das Modell bei Top-1 81,49 %, bei Top-2 92,29 % und bei Top-3 94,97 %.

Auswertungsschema	Gesamtgenauigkeit
Top-1	81,49 %
Top-1 (NoData)	93,53 %
Top-2	92,29 %
Top-3	94,97 %

Tabelle 2: Gesamtgenauigkeiten für die Kreuzvalidierung (in %); aufgetragen sind Top-1 bis Top-3 (31 Klassen)

Zusätzlich wurde die Genauigkeit unter Hinzunahme der NoData-Klasse präsentiert. Da es bei allen Orbits viele NoData-Werte in den Randbereichen der Szenen gibt und diese vom Modell nahezu vollständig erkannt werden, führt die Hinzunahme dieser Klasse zur Steigerung, aber gleichzeitig auch Verzerrung der Gesamtgenauigkeit. Diese NoData-Werte resultieren aus der fehlenden Verfügbarkeit der LBM-Daten auf dem Meer. Durch die Bildkachelung kann es nun an den Küstenbereichen oder an der Landesgrenze vorkommen, dass keine Labels zur Evaluation für Schleswig-Holstein vorliegen. Aus diesem Grund sollten diese Bereiche für die verzerrungsfreie Betrachtung der Gesamtgenauigkeit unberücksichtigt bleiben.

### 5 AUSBLICK

Die erreichten Gesamt- und klassenspezifischen Genauigkeiten zeigen das große Potenzial des Verfahrens in der Anwendung auf Fernerkundungsdaten. Für eine Landbedeckungsklassifikation mit 31 Klassen erreichte das Verfahren eine Gesamtgenauigkeit von 81,49 %. Gerade auch im Hinblick auf die hohe Klassenanzahl

ist dieses Ergebnis sehr vielversprechend. Die klassenspezifischen Genauigkeiten sind eher heterogen zu beurteilen. Es gibt gut modellierbare (gemessen am F1-Score) und weniger gut abbildbare Klassen. Mit einem F1-Score von 0,84 für B211 „Ackerland“ und 0,95 für B523 „Offenes Meer“ sind diese Klassen hervorzuheben. Weiterhin gibt es einige Klassen mit F1-Scores zwischen 0,69 und 0,80. Dies umfasst B231 „Grünland“, B233 „Grasland mit Bäumen“, B311 „Laubbäume“, B312 „Nadelbäume“ und B332 „Fels“. Besonders räumlich häufiger vorkommende Klassen mit hohen F1-Scores tragen maßgeblich zur Steigerung der Gesamtgenauigkeit bei. Neben den erwähnten Klassen weisen einige Klassen niedrigere F1-Scores auf. Hierbei sei speziell auf die inter- und intrakategoriale Unterscheidung der Landbedeckungsklassen des LBM-DE hingewiesen. Spektrale Ähnlichkeiten oder schwierig modellierbare Klassenbeschreibungen erschweren die Klassifizierung allein auf Basis der PlanetScope-Daten.

Diese Herausforderungen könnten durch Hinzunahme weiterer Fernerkundungsdaten (z. B. nDOM (normalisierte Digitale Oberflächenmodelle) für Höhendifferenzierung oder höher aufgelöste Bilddaten) kompensiert werden. In Zukunft muss am BKG evaluiert werden, wie die Klassifizierungsergebnisse weiterverarbeitet und genutzt werden und wie sich durch den geänderten methodischen Ansatz auch die Klassenzusammensetzung des LBM verändert. Der methodische Ansatz dieser Arbeit hat gezeigt, dass durch geringe Anpassungen verschiedene Fernerkundungsdaten mit hoher Gesamtgenauigkeit (81,49 %) genutzt werden können. Ohne weitere manuelle Anpassungen können teils genaue Landbedeckungsveränderungen ermittelt werden. Speziell im Hinblick auf die Nutzung verschiedener Sensortypen aus unterschiedlichen Erdbeobachtungsmissionen sind diese Ergebnisse vielversprechend.

## Literatur

Badrinarayanan, V.; Kendall, A.; Cipolla, R. (2017): Segnet: A deep convolutional encoder-decoder architecture for image segmentation. In: *IEEE Transactions on Pattern Analysis and Machine Intelligence* 39(12), S. 2481–2495.

BKG (2023): Dokumentation des LBM-DE 2018. [https://sg.geodatenzentrum.de/web\\_public/gdz/dokumentation/deu/lbm-de2018.pdf](https://sg.geodatenzentrum.de/web_public/gdz/dokumentation/deu/lbm-de2018.pdf) (12/2023).

Breiman, L. (2001): Random forests. In: *Machine Learning* 45, S. 5–32.

Hao, S.; Zhou, Y.; Guo, Y. (2020): A brief survey on semantic segmentation with deep learning. In: *Neurocomputing* 406, S. 302–321.

He, K.; Zhang, X.; Ren, S.; Sun, J. (2015): Deep residual learning for image recognition. In: *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, S. 770–778.

Hoeser, T.; Bachofer, F.; Kuenzer, C. (2020): Object detection and image segmentation with deep learning on Earth observation data: A review – Part II: Applications. In: *Remote Sensing* 12(18), 3053.

Jégou, S.; Drozdal, M.; Vazquez, D.; Romero, A.; Bengio, Y. (2017): The one hundred layers tiramisu: Fully convolutional densenets for semantic segmentation. In: *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition Workshops*, S. 11–19.

Lin, G.; Milan, A.; Shen, C.; Reid, I. (2017): Refinenet: Multi-path refinement networks for high-resolution semantic segmentation. In: *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, S. 1925–1934.

Long, J.; Shelhamer, E.; Darrell, T. (2015): Fully convolutional networks for semantic segmentation. In: *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, S. 3431–3440.

Planet Labs (2023): Sensor-Übersicht PlanetScope. <https://developers.planet.com/docs/data/planetscope/#constellation-and-sensor-overview> (12/2023).

Ronneberger, O.; Fischer, P.; Brox, T. (2015): U-net: Convolutional networks for biomedical image segmentation. In: *Medical Image Computing and Computer-Assisted Intervention – MICCAI 2015: 18th International Conference, October 5–9, 2015, Munich, Germany, Proceedings, Part III*. Springer International Publishing, Cham, S. 234–241.

Seferbekov, S.; Iglovikov, V.; Buslaev, A.; Shvets, A. (2018): Feature pyramid network for multi-class land segmentation. In: *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition Workshops*, S. 272–275.

Voelsen, M.; Teimouri, M.; Rottensteiner, F.; Heipke, C. (2022): Investigating 2D and 3D Convolutions for Multitemporal Land Cover Classification using Remote Sensing Images. In: *ISPRS Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences* 3, S. 271–279.

Wang, C.; Zhong, C. (2021): Adaptive feature pyramid networks for object detection. In: *IEEE Access* 9, S. 107024–107032.

Wang, Z.; Xue, X. (2014): Multi-class support vector machine. In: *Support Vector Machines Applications*, S. 23–48.

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

Yu, H.; Yang, Z.; Tan, L.; Wang, Y.; Sun, W.; Sun, M.; Tang, Y. (2018): Methods and datasets on semantic segmentation: A review. In: *Neurocomputing* 304, S. 82–103.

Zhu, H.; Meng, F.; Cai, J.; Lu, S. (2016): Beyond pixels: A comprehensive survey from bottom-up to semantic image segmentation and cosegmentation. In: *Journal of Visual Communication and Image Representation* 34, S. 12–27.