

Evaluierung der Tatsächlichen Nutzung im ATKIS Basis-DLM mittels Digitaler Orthophotos und Deep Learning

Evaluation of the Actual Usage in the ATKIS Basic DLM using Digital Orthophotos and Deep Learning

Denis Reiter | Gotthard Meinel | Matthias Forkel

Zusammenfassung

Zur Erfassung von Landnutzung und deren Veränderungen können Informationen aus dem Objektartenbereich Tatsächliche Nutzung verwendet werden, welcher dem ATKIS Basis-DLM entstammt. Ziel dieser Arbeit war die Evaluierung der Genauigkeit der Tatsächlichen Nutzung in ATKIS. Dazu wurde eine visuelle Klassifikation der Tatsächlichen Nutzung in einer zufällig ausgewählten Stichprobe von jeweils 1000 Luftbildern aus den Jahren 2012 und 2020 durchgeführt, die als Referenz fungierte. Parallel dazu wurde ein teilautomatisiertes Verfahren entwickelt, in dem ein Deep Learning-Algorithmus (Convolutional Neural Network) anhand von Digitalen Orthophotos (DOP20) trainiert wurde, um die Tatsächliche Nutzung zu klassifizieren. Im Rahmen der Arbeit konnte festgestellt werden, dass ATKIS in 93,9 % der untersuchten Fälle die korrekte Tatsächliche Nutzung aufweist. Der Algorithmus konnte in 93,7 % der Fälle die korrekte Nutzung erkennen.

Schlüsselwörter: Landnutzung, Tatsächliche Nutzung, Orthophotos, Deep Learning, ATKIS Basis-DLM

Summary

For the recording of land use and its changes, information on the Actual Use can be used, which originates from the ATKIS (Authorative Topographic-Cartographic Information System) Basis-DLM (Digital basis landscape model). The aim of this work was to evaluate the accuracy of the Actual Use in ATKIS. For this purpose, a visual classification of the Actual Use was performed in a randomly selected sample of 1000 aerial images from each of the years 2012 and 2020, which acted as a reference. In parallel, a semi-automated Deep Learning algorithm (Convolutional Neural Network) was trained using Digital Orthophotos (DOP20) to classify the Actual Use. Both ATKIS and the algorithm were compared with the visually generated reference in order to evaluate the quality of the Actual Use in ATKIS and to check whether a Deep Learning approach could also be suitable for this task. It could be determined that ATKIS shows the correct Actual Use in 93.9 % of examined cases. The algorithm was able to detect the correct usage in 93.7 % of cases.

Keywords: land use, Actual Use, orthophotos, deep learning, ATKIS

1 Einführung

Das im Amtlichen Topographisch-Kartographischen Informationssystem (ATKIS) bereitgestellte Digitale Basis-Landschaftsmodell (Basis-DLM) ist die wichtigste und aktuellste Datengrundlage in Deutschland hinsichtlich der Modellierung der Erdoberfläche. Grundlegend hat ATKIS die geotopographische Abbildung der Landschaft und der zugehörigen Sachverhalte zum Ziel. Es stellt die öffentlich-rechtliche Datenbasis für die digitale Verarbeitung und Verknüpfung geotopologischer Fachdaten dar (AdV 2022). Genutzt wird ATKIS insbesondere für die Ableitung topographischer Darstellungsdienste wie TopPlus (BKG 2023) oder basemap.de (AdV 2023), Kartenprodukte (DTK5, DTK10, DTK25) sowie für eine Vielzahl räumlicher Analysen.

Auf Basis des im ATKIS Basis-DLM enthaltenen Objektartenbereichs Tatsächliche Nutzung (TN) werden z. B. im Monitor der Siedlungs- und Freiraumentwicklung, kurz IÖR-Monitor (Leibniz-Institut für ökologische Raumentwicklung 2023), zahlreiche Indikatoren berechnet, u. a. zur Flächenneuanspruchnahme, welche ein zentraler politischer Nachhaltigkeitsindikator ist. Zur Verlässlichkeit der TN im ATKIS Basis-DLM gibt es bis heute jedoch keine den Autoren bekannte veröffentlichte Untersuchung.

Eine mögliche Fehlerquelle bei der Erfassung der TN ist die objektartenabhängige, teilweise schwierige Abgrenzung zwischen Landbedeckung und Landnutzung. Darüber hinaus können migrationsbedingte Effekte des Wechsels der ATKIS-Modellierung vom sogenannten alten Datenmodell ins AFIS-ALKIS-ATKIS-Datenmodell Nutzungsänderungen vortäuschen, die keinen realen Änderungen entsprechen (Krüger et al. 2015). Zudem gibt es durch die mehrjährigen Aktualisierungszyklen eine verzögerte Änderungserfassung. Über Art und Umfang der resultierenden Ungenauigkeit liegen bisher nur wenige Erkenntnisse vor. Für ein verlässliches Monitoring von Landnutzungsänderungen böten diese jedoch einen signifikanten Mehrwert.

Die Fortführung von ATKIS erfolgt in zyklischen Abständen in Verantwortung der Bundesländer u. a. auf Basis von Digitalen Orthophotos, Gebietstopographien und Geofachdaten. Die Aktualität ist dabei abhängig von der

Objektart. Die Angabe »Aktualität in Monaten« umfasst den Zeitraum von der Entstehung der Veränderung in der Landschaft über die Aufdeckung, Beschaffung, Aufbereitung und Einarbeitung der Information in den vorhandenen Datenbestand bis zur Freigabe des fortgeführten Datenbestands. Besonders wichtige Objekte wie Straßen werden spitzgenaktuell gehalten, das heißt Veränderungen nach spätestens drei bis zwölf Monaten erfasst. Alle anderen Objektarten, welche nicht im Katalog der Spitzenaktualität gelistet sind, wurden bisher durch eine vollständige visuelle Durchmusterung innerhalb von maximal fünf Jahren grundaktualisiert, seit 01.01.2022 nach maximal drei Jahren (AdV 2022).

Eine flächenmäßig vollständige Erfassung einer Objektart erfolgt, wenn ihre topographische Bedeutung dem Maßstabsbereich 1 : 10.000 / 1 : 25.000 angemessen ist (Bundesministerium des Innern, für Bau und Heimat 2021). Für andere Objektarten gelten die Erfassungskriterien entsprechend dem ATKIS-Objektartenkatalog, grundsätzlich darf jedoch kein Objekt nicht deshalb unerfasst bleiben, weil es bei einer graphischen Ausgabe nicht dargestellt werden könnte (AdV 2022). Objekte mit Flächen unterhalb der Erfassungsuntergrenze werden, mit einigen Ausnahmen, einem angrenzenden Objekt zugeschlagen. Die Zuweisung der Eigenschaften erfolgt in diesem Fall durch das Dominanzprinzip (AdV 2022).

Mit Techniken des maschinellen Lernens (Convolutional Neural Networks oder kurz CNNs, eine Methode aus dem Bereich Deep Learning) wird ein Algorithmus entwickelt, welcher automatisiert prüft, ob die TN für eine ausgewählte Fläche korrekt vergeben ist oder nicht. Als Ausgangsbasis für die Evaluierung dienen Digitale Orthophotos mit einer Bodenauflösung von 20 cm (DOP20). Diese besitzen gegenüber anderen Geodatenätzen den entscheidenden Vorteil, dass es sich um unverfälschte Primärdaten handelt, anhand derer sich die TN in den meisten Fällen durch eine visuelle Interpretation zweifelsfrei bestimmen lässt. Dabei bleibt aber die genaue geometrische Abgrenzung der TN zu den Nachbarflächen in bestimmten Fällen herausfordernd.

Der Fokus der folgenden Darstellungen liegt auf der (1) Generierung des Trainingsdatensatzes, (2) der Struktur und Performance des CNNs, (3) der Evaluierung von

ausgewählten Nutzungsänderungen im ATKIS Basis-DLM sowie (4) der Potenzialabschätzung der Methodik hinsichtlich weiterer Anwendungsmöglichkeiten.

2 Datengrundlagen

2.1 Objektartenbereich »Tatsächliche Nutzung«

Die Beschreibung der Landnutzung im ATKIS Basis-DLM erfolgt im Objektartenbereich TN. Die TN umfasst 36 Objektarten, die zusammengenommen eine lückenlose Abbildung der Erdoberfläche präsentieren. Die Klassifikation ist semantisch harmonisiert und die Erfassung wird nach dem Dominanzprinzip vorgenommen (AdV 2022). Die inhaltlichen TN-Definitionen basieren auf einer Vermischung von Informationen aus Landbedeckung (LB) und Landnutzung (LN), wobei in der Objektartengruppe »Siedlung« eher die LN betont wird und in der Objektartengruppe »Vegetation« eher die LB (Arnold et al. 2017). Die Notwendigkeit zur Trennung in LB und LN ist jedoch bekannt und ein entsprechendes Konzept liegt vor (Lucas et al. 2020).

Für die Evaluierung der TN mittels Orthophotos bringt dies einige Schwierigkeiten mit sich. Um die Landnutzung für einen Punkt zu bestimmen, muss zwingend dessen Nachbarschaft mit einer gewissen Mindestgröße einbezogen werden (Abb. 1). Eine ausreichend große Testfläche und eine kontextbasiert arbeitende Auswertemethode sind daher unverzichtbar, um zuverlässig die Landnutzung klassifizieren zu können.

2.2 Digitale Orthophotos

Als Referenzdatensatz für die Evaluierung wurden Digitale Orthophotos in der Bodenauflösung 20 cm (DOP20) verwendet. Dabei handelt es sich um verzerrungsfreie, georeferenzierte und maßstabstreue Luftbilder. Die Farbtiefe beträgt mindestens 8 Bit/Kanal, angeboten werden 3-Kanal-Echtfarbenvbilder (RGB), 3-Kanal-Colorinfrarotbilder (CIR) und 4-Kanal-Multispektralbilder (RGBI). Die




Abb. 1:
Bedeutung des Kontexts
für die Bestimmung der
Landnutzung. Der kleinere
Bildausschnitt suggeriert
fälschlicherweise eine Frei-
raumnutzung.




Abb. 2: Stand aktuell verfügbarer DOP20 zum Zeitpunkt dieser Arbeit (Juni 2021)

geometrische Genauigkeit beträgt für das DOP20 ca. 0,4 m (AdV 2020). Ein großer Vorteil der DOP gegenüber Satellitenbildern (z. B. Sentinel-2) ist insbesondere die hohe geometrische Auflösung. Digitale Orthophotos werden in zyklischen Abständen durch Befliegung erstellt. Verantwortlich für die Planung und Durchführung sind die Bundesländer. Dadurch ergeben sich in der Aktualität der Luftbilder Unterschiede (Abb. 2.).

Wegen der für diese Untersuchung erforderlichen guten Übereinstimmung von Befliegungsdatum und ATKIS-Grundaktualität wurde als Untersuchungsraum der Freistaat Bayern ausgewählt. Zudem bietet Bayern als flächenmäßig größtes Bundesland eine große Zahl und Diversität unterschiedlicher Nutzungsarten.

Da die Befliegung nicht in einem Jahr für das ganze Bundesland erfolgt, wurden die jeweils aktuellen vorliegenden Zeitschnitte zur einheitlichen Bezeichnung 2020 zusammengefasst und das entsprechende ATKIS Basis-DLM aus dem gleichen Jahr ausgewählt. Da für die spätere Stichprobe explizit auch die Änderung der TN gegenüber einem früheren Zeitpunkt evaluiert werden sollte, wurde als zusätzlicher historischer Zeitschnitt das Jahr 2012 ausgewählt. Die Befliegungen für diesen Zeitschnitt erfolgten zu je einem Drittel in den Jahren 2011, 2012 bzw. 2013.

3 Methodik

Aufgrund des Umfangs des ATKIS Basis-DLM (allein die Anzahl der Objekte mit der Nutzung »Wohnbaufläche« betrug im Zeitschnitt 2020 annähernd 200.000) musste die Anzahl der potenziell zu evaluierenden Objekte systematisch eingegrenzt werden. Gleichzeitig war es wichtig, einen hinsichtlich Größe und Qualität angemessenen Trainingsdatensatz für den KI-Algorithmus zu erzeugen. Das im Folgenden beschriebene und in Abb. 3 schematisch veranschaulichte Verfahren löste beide Herausforderungen parallel.




Abb. 3: Schematischer Abriss der Methodik

3.1 Flächenauswahl

3.1.1 Auswahl nach Nutzung

Zunächst wurden aus der TN vier Objektarten ausgewählt, da der Wechsel zwischen diesen Nutzungen von höchster Bedeutung für den Nachhaltigkeitsindikator »Anstieg der Siedlungs- und Verkehrsfläche« ist. Zudem wiesen diese Objektarten in dem betrachteten Zeitraum den größten Flächenzuwachs bzw. die größten Flächenverluste auf. Die ausgewählten Objektarten waren: 41001 Wohnbaufläche, 41002 Industrie- und Gewerbefläche, 43001 Landwirtschaft mit den attributiven Wertearten des Vegetationsmerkmals 1010 Ackerland und 1020 Grünland.

Vereinfachend wurden die Objektarten Wohnbaufläche sowie Industrie- und Gewerbefläche zur Landnutzungs-kategorie (LNK) »Siedlung« bzw. Ackerland und Grünland zur LNK »Freiraum« zusammengefasst. Grund dafür war, dass die Unterscheidung der zugrunde liegenden Objektarten insbesondere im Freiraum

visuell sehr schwer war, und durch die Zusammenführung die Klassifikationsgüte wesentlich verbessert wurde (in ATKIS wird inzwischen die Unterscheidung zwischen Acker- und Grünland durch die Nutzung von INVEKOS-Daten (Bay.StMELF 2023) deutlich verbessert). Grundsätzlich steigt darüber hinaus mit zunehmender Zahl zu unterscheidender Objektarten der Anspruch an die Leistungsfähigkeit des Algorithmus und somit an die bereitzustellenden Computerressourcen. Durch die Fokussierung auf die LNK »Siedlung« und »Freiraum« konnte die komplexe Aufgabe deutlich vereinfacht werden.

3.1.2 Auswahl nach Änderung der TN

Im Anschluss an die erste Auswahl anhand der Nutzung wurden jeweils die entsprechenden ATKIS-Objekte aus den Jahren 2012 und 2020 miteinander verglichen und aufgeteilt in solche, die keine TN-Änderung aufwiesen (= Trainingsdaten für das CNN), und jene, bei denen nach ATKIS ein Nutzungswechsel stattfand (= Prüfdaten). Grundannahme dabei war, dass eine unveränderte TN eine sicher bestimmte TN ist, denn diese wurde 2012 bestimmt und 2020 nochmals bestätigt. Zwischenzeitliche Hin- und Rückänderungen der TN konnten wegen des relativ kurzen Zeitintervalls ausgeschlossen werden.

3.1.3 Auswahl der Trainingsdaten

Aus der zuvor beschriebenen grundlegenden Flächenauswahl für die Trainingsdaten (ATKIS-Objekte mit gleichbleibender TN) wurde eine zufällige Stichprobe (Stichprobe 1, vgl. Abb. 3) von 10.000 ATKIS-Objekten für jede Objektart in beiden Zeitschnitten gezogen, also insgesamt 80.000 Trainingsdatensätze (10.000 ATKIS-Objekte * 4 Objektarten * 2 Zeitschnitte = 80.000). Die Aufteilung dieser Gesamtmenge in Trainings-/Validierungsdatensatz für das Training des Algorithmus betrug 80/20.

Die Trainingsdaten wurden nicht visuell validiert, weshalb grundsätzlich die Möglichkeit bestand, dass einzelne Bilder eine andere Nutzung als die ausgewählten beiden LNK zeigen. Daher wurde eine vergleichsweise hohe Zahl an Trainingsdatensätzen gewählt, um Sicherheit für den Algorithmus zu gewinnen. Durch die gewählte Menge an Datensätzen beeinflussten einzelne Bilder fremdartiger Nutzungen das Training des Algorithmus sehr viel weniger als in einer kleineren Stichprobe.

3.1.4 Auswahl der Prüfdaten

Um ansatzweise Schätzungen zur Genauigkeit des Indikators »Anstieg der Siedlungs- und Verkehrsfläche« treffen zu können, wurde die bisher getroffene Vorauswahl für die Prüfdaten (ATKIS-Objekte mit sich ändernder TN) noch weiter eingegrenzt auf solche Flächen, die 2012 die LNK »Freiraum« und 2020 LNK »Siedlung« aufwiesen. Aus den betreffenden Flächen wurde dann eine zufällige Stichprobe (Stichprobe 2, vgl. Abb. 3) von 1000 ATKIS-Objekten für jeden Zeitschnitt gezogen. Der exakte Umfang betrug 1999 Prüfdatensätze (1000 ATKIS-Objekte * 2 Zeitschnitte, abzüglich 1 falsch zugeordnetes Bild = 1999). Ein Bild zeigte eine LN, die keiner der ausgewählten LNK zugeordnet werden konnte und deshalb aussortiert wurde. Auf eine nachträgliche Auffüllung wurde verzichtet, da das Fehlen eines einzelnen Bildes auf die Auswertung keinen Einfluss hatte.

3.2 Referenzklassifikation

Um die benötigte Referenz zur Evaluierung der TN zu schaffen, wurde für die 1999 Prüfdatensätze eine visuelle Klassifikation der TN auf den Orthophotos für die Jahre 2012 und 2020 durchgeführt. Mit dieser Referenz wurden sowohl ATKIS als auch der entwickelte KI-Algorithmus abgeglichen.

Im Verlauf der Klassifikation ergab sich eine Reihe von Sonderfällen, weswegen jedes Bild einzeln auf seine Klassenzugehörigkeit anhand eines Entscheidungsbaums (Abb. 4) geprüft wurde. Im Gegensatz zum KI-Algorithmus, der bei der Klassifikation ausschließlich einen 51,2 m x 51,2 m großen Bildausschnitt zur Einschätzung der Klassenzugehörigkeit zur Verfügung hatte (siehe dazu Punkt 3.3.), konnte für die visuelle Klassifikation auch die Umgebung zu Hilfe genommen werden, um auch Grenzfälle sicher zuordnen zu können.

Zunächst wurde das Vorhandensein von Siedlungsstrukturen allgemein geprüft. Darunter fielen Häuser mit Gärten, Industrieanlagen, Parkplätze, Verkehrseinrichtungen, Hallen und ähnliche Bauwerke. Waren auf einem Bild mehr als 50 % solcher




Abb. 4: Entscheidungsbaum für die visuelle Klassifikation der ATKIS-Objekte

Strukturen vorhanden, wurde das Bild der Siedlungsklasse zugeordnet. Der erste Sonderfall behandelte (Neu-)Baugebiete in Entstehung. Dort wurden meist noch nicht die 50 % Bebauung erreicht, aber es war offensichtlich, dass dies in Zukunft der Fall sein würde. Oft waren die Verkehrswege schon angelegt und die ungefähre zukünftige Ausdehnung ließ sich gut erkennen. War der Fall noch uneindeutiger, entschied die ATKIS-Ortslagegeometrie. Befand sich eine Fläche außerhalb der definierten Ortslage, wurde sie dem Freiraum zugerechnet. Tat sie dies nicht, entschied der subjektive Eindruck, ob es sich um einen sogenannten »Außenbereich im Innenbereich« (BVerwG 2005) handelte. Mit diesem Schema ließ sich eine eindeutige Zuordnung aller Flächen durchführen. Bilder, die sich mittels dieses Schemas nicht zuordnen ließen, wurden aus dem Datensatz entfernt.

3.3 Erzeugung der Bildausschnitte

Für jedes der ausgewählten ATKIS-Objekte aus beiden Stichproben wurde der Zentroid bestimmt und um diesen ein Quadrat erzeugt, da das CNN zwingend quadratische Trainingsbilder benötigt. Die Seitenlänge dieser Quadrate

betrug 51,2 m, bedingt durch die Auflösung der Orthophotos von 20 cm, multipliziert mit der Größe eines Bildausschnittes von 256×256 Pixeln. Diese Größe für einen Bildausschnitt bildete einen guten Kompromiss zwischen ausreichender Erkennbarkeit des Landnutzungskontextes bei gleichzeitig relativ großer Nutzungshomogenität. Zudem bewegte sich der Wert in einem Rahmen, der mit dem entwickelten CNN technisch gut durchführbar war. Bei stichprobenartiger Kontrolle der Bilder konnten keine nennenswerten Mengen an Fehlzuordnungen ganzer Bilder zur falschen LNK festgestellt werden. Beispiele für Trainingsbilder der Nutzungsart »Wohnbaufläche« zeigt Abb. 5.

Da die erzeugten Quadrate nicht in jedem Fall gänzlich innerhalb eines ATKIS-Objekts lagen, wurde zusätzlich eine Überprüfung der flächenhaften Anteile der TN innerhalb der Quadrate durchgeführt, um einen Einfluss von Randeffekten auszuschließen. Die Ergebnisse dieser Überprüfung sind in Tab. 1 dargestellt; es konnte kein nennenswerter Einfluss von Randeffekten festgestellt werden. Die durchschnittliche TN-Homogenität aller Trainingsbilder betrug (unter Berücksichtigung von Nachbarflächen identischer Nutzung) für alle vier betrachteten LNK über 80 %.



Abb. 5: Beispiele für Trainingsbilder (51,2 m × 51,2 m) der Nutzungsart »Wohnbaufläche«

Tab. 1: TN-Homogenität der Trainingsbilder. Die Spalten zeigen die vier ausgewählten Objektarten, die ein Trainingsbild haben konnte, die Zeilen die durchschnittlichen Flächenanteile von TN-Objektarten an den Bildern der entsprechenden Kategorie. Dabei werden aus Gründen der Vollständigkeit auch TN-Objektarten aufgeführt, die nicht den ausgewählten vier Objektarten entstammen (Straßenverkehr, Nadelholz, Mischnutzung, Hauptwirtschaftswege). Dargestellt werden nur Anteile ≥ 1 %.

	Landnutzungsklassen im Trainingsbild			
	Ackerland	Grünland	Industrie- und Gewerbeflächen	Wohnbauflächen
Durchschnittlicher Flächenanteil TN-Objektarten	90,1 % Ackerland	80,1 % Grünland	83,0 % Industrie- und Gewerbeflächen	81,2 % Wohnbauflächen
	3,1 % Grünland	4,8 % Ackerland	5,6 % Straßenverkehr	10,1 % Straßenverkehr
	1,5 % Straßenverkehr	2,7 % Nadelholz	3,2 % Grünland	3,6 % Grünland
	1,1 % Nadelholz	2,6 % Straßenverkehr	1,9 % Ackerland	2,0 % Ackerland
	1,0 % Hauptwirtschaftswege	2,0 % Mischholz	1,0 % Mischnutzung	1,0 % Mischnutzung

3.4 Deep Learning-Klassifikation

3.4.1 Grundlegende Eigenschaften von CCNs

Bei einem CNN handelt es sich um ein künstliches neuronales Netz, das besonders gut dafür geeignet ist, Daten mit gitterähnlicher Topologie zu verarbeiten (LeCun et al. 2015). Darunter fallen auch 2D-Bilder, wie die hier verwendeten DOP20-Bildausschnitte.

Prinzipiell sind CNNs neben den obligatorischen Input- und Outputlayern aus Convolution-, Pooling- und je nach Anwendung einigen anderen Typen von Layern aufgebaut. Ein Vorteil gegenüber anderen neuronalen Netzen ist die wesentlich geringere Modellkomplexität auch bei umfangreichen Eingabedatensätzen. Dies hält die Anzahl der Rechenoperationen gering, auch wenn die Tiefe des Netzwerks hoch ist, was letzten Endes für eine Verbesserung der Rechenzeiten und Robustheit der Klassifikation sorgt (O'Shea und Nash 2015 sowie Skansi 2018).

Um die eigentliche Klassifikation von Bildern durchführen zu können, müssen die in der Regel zunächst mehrdimensionalen Ausgaben in eine eindimensionale Form überführt werden. Dafür wird ein sogenannter Flattening-Layer verwendet, der die verarbeiteten Bildausschnitte in einen eindimensionalen Vektor umwandelt (Reiß et al. 2019). Mit diesem Vektor kann dann im letzten Schritt die Wahrscheinlichkeitsverteilung der Klassenzugehörigkeit eines Bildausschnittes ausgegeben werden (beispielsweise für ein ATKIS-Objekt: 99 % Wahrscheinlichkeit LNK »Siedlung«, 1 % LNK »Freiraum«). Zu beachten ist dabei, dass die ermittelte Klassenzugehörigkeit für das gesamte Bild gilt.

3.4.2 Design des verwendeten CNN

Neben den grundlegenden Basisfunktionen sind noch vielfältige weitere Möglichkeiten der Optimierungen der Netzwerkstruktur möglich, die je nach Komplexität der Fragestellung zur Anwendung kommen können bzw. müssen. Für den vorliegenden Anwendungsfall mit nur zwei unterschiedlichen LNK und unter Berücksichtigung von Zeit- und Ressourcenlimits wurde ein Netzwerk entwickelt, das sowohl in der Programmierung als auch im Training einfach umzusetzen war und eine gute Effizienz bot. Diesen Ansprüchen entsprach die VGG16-Architektur (Simonyan und Zisserman 2015), es wurden jedoch einige zusätzliche Modifikationen an dem Netzwerk vorgenommen, um die Klassifikationsgüte und Effizienz zu verbessern.

Das Basisnetzwerk wurde in der Zahl der Convolution-Layer halbiert, da die volle Ausprägung bei längerer Rechenzeit nahezu identische Ergebnisse lieferte. Somit bestand das angepasste Netzwerk insgesamt aus acht Convolution-Layern, die jeweils in Zweiergruppen zusammengefasst wurden. Der verwendete Kernel war dabei stets 3×3 Pixel groß, die Aktivierungsfunktion war rectified linear unit (ReLU). Abweichend zum Original folgte im Anschluss an jeden dieser Layer unmittelbar eine sogenannte

Batch normalization. Standardmäßig schloss jeder der Verarbeitungsblöcke mit einem Max-Pooling-Layer ab.

Insgesamt wurden vier dieser Verarbeitungsblöcke hintereinander eingesetzt. Zum Abschluss erfolgte ein Global-Average-Pooling, bevor die bereits erwähnte Wahrscheinlichkeitsverteilung bestimmt wurde. Eine Übersicht der Netzwerkstruktur zeigt Abb. 6. Die verwendete Kostenfunktion war die binäre Kreuzentropie (binary cross entropy) und als Optimizer wurde Adam (adaptive moment estimation, nach Kingma und Ba 2017) mit einer Lernrate (learning rate) von 0,001 genutzt.




Abb. 6: Schematische Darstellung des CNN. Dargestellt sind die Layertypen (ConvL: Convolution-Layer, BN: Batch-Normalization-Layer, MaxPool: Maximum-Pooling-Layer, GlobalAvgPool: Global-Average-Pooling-Layer), Dimension eines Bildes in Pixel sowie die Anzahl an Feature Maps.

Vor dem Durchlaufen des Hauptmodells wurden die Trainingsdaten künstlich erweitert (sog. Data augmentation), indem jedes Bild zufällig bis zu 25 % rotiert sowie horizontal und vertikal gespiegelt wurde. Dies hatte eine Stabilisierung der Ergebnisse zum Ziel. Zudem wurden alle Bilder von der ursprünglichen 8 Bit Farbtiefe auf den Wertebereich 0 bis 1 normiert.

Als Metriken, die während des Trainings aufgezeichnet bzw. nach denen die Performance des Modells bewertet wurde, dienten Präzision (precision) und Loss. Die Präzision gibt für jede mögliche ausgegebene Klasse den Anteil korrekter Zuordnungen an der Gesamtmenge der Zuordnungen (zu dieser Klasse) an. Loss ist eine Funktion, die anzeigt, wie gut das Modell funktioniert. Sie wird während des Trainings auf das bestmögliche Minimum optimiert.

Die Programmierung des CNN erfolgte in TensorFlow v2.5 mittels der Keras-API, welche auf Python basiert. Als Entwicklungsumgebung wurde JupyterLab genutzt. Zur Berechnung kam ein System mit einer Nvidia GeForce RTX 3080Ti (Grafikprozessor) zum Einsatz.

4 Ergebnisse

4.1 Auswertung der Referenzklassifikation

Die visuelle Klassifikation der 1999 Bilder des Prüfdatensatzes ergab eine Referenzverteilung der Bilder von 838 (Freiraum) zu 1161 (Siedlung). Insgesamt konnten 93 % der Bilder sicher ohne Zusatzinformationen zugeordnet werden, bei 7 % musste ein größerer Bildausschnitt betrachtet werden, um eine korrekte Entscheidung fällen zu können.

4.2 Auswertung der Tatsächlichen Nutzung in ATKIS

Bei der Auswertung der TN in ATKIS anhand der betrachteten Stichprobe ergab sich im Vergleich zur Referenz eine Übereinstimmungsquote von ca. 91 % für die LNK »Freiraum« und 96 % für die LNK »Siedlung« (Tab. 2). Die Interpretation dieser Zahlen muss jedoch unterschiedlich erfolgen, da bei der Auswahl der Untersuchungsflächen nur eine Änderungsrichtung betrachtet wurde.

Ein Fehler in der Kategorie Siedlung ist weniger als Fehler, sondern vielmehr als Datenkorrektur zu verstehen. Wenn ein Bild aus dem älteren DOP-Zeitschnitt durch die

Referenz als Siedlung klassifiziert wurde, bedeutet dies, dass auf dieser Fläche keine reale Änderung stattgefunden hat, da die alte und die neue reale Nutzung identisch waren. Demnach handelt es sich bei den »Fehlern« in dieser Kategorie um Korrekturen zuvor falsch bestimmter Flächen. Zusätzlich muss beachtet werden, dass für beide betrachteten Nutzungsarten des Freiraums eine Erfassungsuntergrenze von 1 ha gilt. Alle Flächen kleiner diesem Wert konnten bei der Anzahl der Fehler daher nicht berücksichtigt werden.

Im Umkehrschluss bedeutet das, dass jede im neueren Zeitschnitt als Freiraum bestimmte Fläche, die laut Referenz jedoch zur Siedlung gehört, einen echten Fehler hervorruft. Für beide Nutzungsarten der Siedlung gilt darüber hinaus keine Erfassungsuntergrenze.

4.3 Auswertung der CNN-Klassifikation der Tatsächlichen Nutzung

Das Netzwerk erreichte seine optimale Performance hinsichtlich der Präzision nach 47 Trainingsdurchläufen. Es erreichte in der Spitze eine Präzision von 95,2 % (Trainingsdatensatz) bzw. 94,96 % (Validierungsdatensatz) (Abb. 7).

Tab. 2: Konfusionsmatrix zwischen der Referenzbestimmung und ATKIS. Angegeben ist die Anzahl der Bilder bzw. in Klammern der Anteil in Prozent im Vergleich zur Referenz. Die Gesamtgenauigkeit beträgt 94,3 %.

		Referenz			
		Freiraum	Siedlung	Summe	Benutzergenauigkeit
ATKIS	Freiraum	766 (91,4 %)	42 (3,6 %)	808	94,8 %
	Siedlung	72 (8,6 %)	1119 (96,4 %)	1191	6,0 %
Summe		838 (100,0 %)	1161 (100,0 %)	1999	
Produzentengenauigkeit		91,4 %	3,6 %		




Abb. 7:
Trainingsmetriken des CNNs für die optimale Anzahl von 47 Trainingsdurchläufen.
Rechts: Präzision in Prozent abgetragen über Trainingsdurchläufe (Epochen).
Links: Loss-Wert abgetragen über Trainingsdurchläufe (Epochen)

Tab. 3: Konfusionsmatrix zwischen Referenzbestimmung und CNN. Angegeben ist die Anzahl der Bilder bzw. in Klammern der Anteil in Prozent im Vergleich zur Referenz. Die Gesamtgenauigkeit beträgt 93,7 %.

		Referenz			
		Freiraum	Siedlung	Summe	Benutzergenauigkeit
CNN	Freiraum	779 (93,0 %)	66 (5,7 %)	845	92,2 %
	Siedlung	59 (7,0 %)	1095 (94,3 %)	1154	5,1 %
Summe		838 (100,0 %)	1161 (100,0 %)	1999	
Produzentengenauigkeit		93,0 %	5,7 %		

Die Auswertung der Stichprobe durch das CNN ergab im Vergleich zur Referenz eine Übereinstimmungsquote von 93 % für die Nutzung »Freiraum« und 94 % für die Nutzung »Siedlung« (Tab. 3). Das CNN produzierte dabei aber im Gegensatz zu ATKIS in beiden Fällen ausschließlich echte Fehler.

Im Gegensatz zu ATKIS lieferte das CNN zusätzlich zur reinen Klassifikation auch eine Wahrscheinlichkeitsangabe für die bestimmte Klasse. Diese kann als eine Art Sicherheitsmaß interpretiert werden. Tab. 4 zeigt die Anteile falsch bzw. korrekt klassifizierter Bilder in Abhängigkeit von der vom Netzwerk ausgegebenen Klassenwahrscheinlichkeit beispielhaft für die Nutzungsart »Freiraum«.

Es ist deutlich zu erkennen, dass niedrigere Klassenwahrscheinlichkeiten (unter 90 %) mit einem höheren Anteil falsch klassifizierter Bilder korrelieren. Für Werte zwischen 90 % und 99 % liegt der Anteil bei ca. 94 %, für Werte größer 99 % bei 99,6 %. Daraus ist abzuleiten, dass eine hohe oder sehr hohe Klassenwahrscheinlichkeit mit einer in der Realität entsprechend guten Klassifikation in Zusammenhang steht.

4.4 Vergleich ATKIS – CNN

Im Vergleich zwischen ATKIS und dem CNN lieferten beide sehr ähnliche Ergebnisse. Die Gesamtgenauigkeit unterscheidet sich nur um 0,6 % (Tab. 2 und Tab. 3), beide lagen also auf einem sehr hohen Genauigkeitsniveau mit nur marginalen Unterschieden.

In etwa 2 % der Fälle wiesen sowohl ATKIS als auch das CNN eine Fehlklassifikation auf. Fallbeispiele sind in Abb. 8 gezeigt. In diesen Fällen zeigte sich kein eindeutiges Muster, auch aufgrund der geringen Anzahl der Fälle. Tendenziell waren es vor allem Grenzbereiche zwischen Nutzungen wie Baustellen, Brachflächen und Ähnliches, die von beiden nicht korrekt erkannt wurden, oder die Flächen befanden sich gerade im Wandel zwischen zwei Nutzungen. Diese Fälle waren jedoch auch händisch nicht leicht zu bestimmen, eine Betrachtung über den Bildausschnitt hinaus war daher in diesen Fällen zumeist erforderlich.

Tab. 4: Verhältnis falsch vs. korrekt klassifizierter Bilder in Abhängigkeit von der ausgegebenen Klassenwahrscheinlichkeit des CNN für Nutzung »Freiraum« (n_gesamt = 838).

CNN-Wahr-scheinlichkeit	Anteil falsch klassifizierter Bilder	Anteil korrekt klassifizierter Bilder
< 80 % (n = 72)	41,1 %	58,9 %
80 % bis 90 % (n = 64)	25,0 %	75,0 %
90 % bis 99 % (n = 184)	6,0 %	94,0 %
> 99 % (n = 518)	0,4 %	99,6 %

Tab. 5: Absolute und relative Fehlerbetrachtung zwischen ATKIS und dem CNN. Angegeben ist der Anteil falsch klassifizierter Bilder

	Freiraum	Siedlung
Nur ATKIS falsch	53 (6,2 %)	42 (3,6 %)
Nur CNN falsch	40 (4,7 %)	44 (3,8 %)
Beide falsch	19 (2,2 %)	22 (1,9 %)




Abb. 8: Beispiele für Fehlklassifikationen durch sowohl ATKIS als auch das CNN

Hervorzuheben ist auch, dass die Schwächen bzw. Stärken beider Vorgehensweisen, zumindest innerhalb der hier betrachteten Stichprobe, komplementär zueinander zu sein scheinen. So konnte das CNN vor allem in kleinräumigeren Siedlungsstrukturen punkten, wo ATKIS stellenweise Defizite hinsichtlich der genauen Abgrenzung von Räumen aufwies. Auf größeren Freiraumflächen war es dagegen umgekehrt, was jedoch auf die in diesem Fall geringe Größe des Bildausschnitts im Vergleich zum entsprechenden ATKIS-Objekt zurückgeführt werden könnte.

4.5 Rechenzeiten

Den umfangreicheren Teil der Berechnungszeit nahm das Erzeugen der Trainings- und Prüfbilder ein. Auf einem durchschnittlichen Endbenutzersystem für GIS-Anwendungen dauerte das Ausschneiden und Abspeichern von 10.000 Bildern etwa 20 bis 24 Stunden. Genutzt wurden dabei Standardfunktionen von ArcGIS Pro 2.8 sowie selbst erarbeitete Python-Skripte.

Das Training des CNN dauerte mit der hier verwendeten GPU (Nvidia Geforce RTX 3080Ti) nur wenige Stunden, beeinflusst wird dies allerdings auch vom Rest des Systems (insbesondere CPU und Festplatte). Bei dieser Angabe ist natürlich der iterative Vorgang der zuvor notwendigen Parameteroptimierung nicht berücksichtigt, der je nach Nutzererfahrung mehrere Wochen des Testens und Verbesserns erfordern kann.

5 Diskussion

5.1 Datenbasis und Untersuchungsdesign

Das in dieser Arbeit vorgestellte Verfahren war vollständig abhängig von der Auswahl des Basisdatensatzes. Zum einen sollte es für Bestimmung der Flächenneuinanspruchnahme relevante Nutzungen abbilden, zum anderen, weil es die Basis für die Generierung der Trainingsdaten des CNN bildete.

Der gewählte Ansatz, die Trainingsdaten des CNN ohne zusätzliche visuelle Validierung direkt aus dem ATKIS Basis-DLM zu entnehmen, ist kritisch zu hinterfragen. In vergleichbaren Arbeiten wird die Erhebung der Ground-Truth-Daten meist manuell in situ oder am Computer vorgenommen (Bhosle und Musande 2019, Carranza-García et al. 2019 sowie Sameen et al. 2018). Im Unterschied zu der vorliegenden Arbeit sind deren (Trainings-)Datensätze jedoch deutlich weniger umfangreich, umfassen mehr Klassen und basieren nicht auf amtlichen, geprüften Standarddatensätzen, sondern auf Open-Data-Produkten. Insbesondere durch die Tatsache, dass es sich sowohl bei ATKIS als auch den DOP20 um amtliche Datensätze handelt, die Qualitätskontrollen unterliegen, wurde das entsprechende Vertrauen in den Ansatz gefasst.

Auch der Bezug auf zwei Zeitschnitte des ATKIS Basis-DLM gewährte zusätzliche Sicherheit. Auf einer Fläche, die auch nach mehreren Jahren eine identische Nutzung aufwies, war mit einer hohen Wahrscheinlichkeit davon auszugehen, dass diese auch tatsächlich korrekt bestimmt wurde. Die subjektive Erfahrung aus der Anwendung des Verfahrens bestätigt diese Theorie, denn in den erzeugten Trainingsdaten waren nur sehr wenige Fehlzusordnungen enthalten. Dies konnte jedoch aufgrund des enormen Aufwandes, der für 80.000 Bilder zu leisten gewesen wäre, nur stichprobenartig geprüft werden. Es ist jedoch davon auszugehen, dass wenige einzelne Bilder fremdartiger Nutzungen in der Masse der Trainingsdaten untergehen und das Training des CNN darum nicht negativ beeinflussen. Die am Ende erreichte, nahezu identische Zahl korrekter TN-Zuordnungen des CNN spricht ebenfalls dafür, dass das gewählte Verfahren zur Generierung der Trainingsdaten trotz fehlender visueller Validierung funktioniert hat.

Weiterhin zu reflektieren ist die Verwendung von quadratischen Bildausschnitten, da die Generierung der Trainingsdaten einen grundlegenden Einfluss auf das Ergebnis hat. Dieses Verfahren ist zwar mittlerweile zum Standardverfahren im Deep Learning geworden (Sharma et al. 2017), bringt aber in diesem konkreten Fall auch Schwierigkeiten mit sich. Zunächst sind die TN-Randeffekte zu nennen. Diese traten auf, wenn ein Bild nicht vollständig innerhalb eines ATKIS-Polygons lag und Teile des Bildes eine andere Nutzung abbildeten als die gewünschte. Dies war besonders für das CNN von Bedeutung, weil die Trennschärfe zwischen Siedlung und Freiraum möglicherweise hätte beeinflusst werden können. Ein Lösungsansatz wären kleinere Bildausschnitte gewesen, was jedoch bei anderen Beispielen wieder zu Fehlklassifikationen aufgrund mangelnder Informationen geführt hätte. Daher wurde die Bildgröße so festgelegt, dass die Fehlerquote so gering wie möglich war (die Flächenhomogenität betrug für alle Nutzungsarten über 80 %, siehe Tab. 1). Die erreichten hohen Zahlen korrekter Klassifikationen sprechen für eine gute Auswahl der Bildgröße und wenig Einfluss durch Randeffekte.

5.2 Umsetzung und Performance des Netzwerks

Zeitgemäße Deep Learning-Netzwerke können einen sehr hohen Ressourcenbedarf haben, daher muss bei der Programmierung auch immer die Angemessenheit der Netzwerkkomplexität in Bezug zur Fragestellung bedacht werden. Bei dem in dieser Arbeit betrachteten Fall kam ein relativ simples Netzwerk zum Einsatz, die Hardwareanforderungen waren daher moderat und mit handelsüblichen Komponenten zu erfüllen. Aus regulierungstechnischer Sicht war das Netzwerk ebenfalls wenig anspruchsvoll. Will man den Ansatz jedoch auf eine größere Auswahl von Landnutzungen/Objektarten anwenden, wird es notwendig, zusätzliche Regulierungstechniken anzuwenden und auf leistungsfähigere Hardware umzusteigen.

Positiv hervorzuheben ist neben den technischen Aspekten auch, dass das Netzwerk sich in der überwiegenden Zahl der Fälle sicher bis sehr sicher in seinen Klassifikationen war. In typischen Fällen, die es dem Grunde nach nicht bzw. nur sehr schwer erkennen konnte, hat es auch entsprechende Unsicherheit angezeigt. Daraus lässt sich schließen, dass der Wahrscheinlichkeitsangabe vertraut werden kann. Die einzige Ausnahme betrifft im konkreten Fall (Neu-)Baugebiete in Entstehung, die das Netzwerk trotz hoher Wahrscheinlichkeitsangabe falsch klassifiziert hat.

Im Kontext vergleichbarer Studien sind die erreichten Ergebnisse als gut bis sehr gut einzustufen. In einem methodisch ähnlichen Ansatz mit acht LN-Klassen konnte eine Genauigkeit (accuracy, nicht precision wie in dieser Arbeit) von 77,4 % erreicht werden (Yang et al. 2018). Unter Zuhilfenahme bereits vortrainierter Netzwerke mit anschließendem Feintuning waren sogar 98,35 % bei nur 2100 Trainingsbildern aus 21 Klassen möglich (Liang et al. 2020). Dies könnte auch ein probater Ansatz sein, die Performance für die in dieser Arbeit vorgestellte Methode weiter zu erhöhen. Allerdings ist davon auszugehen, dass dafür – abhängig vom genutzten vortrainierten Netzwerk – wesentlich mehr Rechenleistung benötigt wird.

5.3 Nutzen von Deep Learning für die Evaluierung der TN

Der allgemeine Mehrwert des Einsatzes von Deep Learning bei der Evaluierung der TN liegt vor allem darin begründet, dass es die Nutzung von Orthophotos ermöglicht, die nicht den Restriktionen der ATKIS-Grundaktualisierungszyklen unterworfen sind. Eine automatische Auswertung der DOPs könnte unmittelbar nach deren Bereitstellung erfolgen und Grundlage für eine schnellere Änderungsdetektion sein und damit die Grundaktualisierung unterstützen.

Bezogen auf das in dieser Arbeit vorgestellte Verfahren ist kritisch anzumerken, dass das CNN ausschließlich auf Basis von unvalidierten ATKIS-Informationen trainiert wurde. Für ein optimales Evaluierungsverfahren müssten dem Grunde nach zusätzliche Datenquellen genutzt werden, da das CNN nur auf Basis von ATKIS trainiert wurde und somit maximal ein identisches Level an Korrektheit erlangen konnte. Eine flächendeckend vorliegende gesicherte Referenz existiert jedoch bisher nicht. Das entwickelte CNN lieferte nachweislich bei einer Betrachtung der zwei LNK »Freiraum« und »Siedlung« nahezu identisch gute Klassifikationen wie ATKIS selbst (beide waren zu rund 94 % korrekt), was zeigt, dass der Lernprozess an sich funktioniert. Der Mehrwert für die Evaluierung der TN in ATKIS liegt in den Wahrscheinlichkeitsangaben, die das CNN ausgibt. Aus diesen lässt sich ableiten, wo eine Änderung der TN (von der LNK »Freiraum« zur LNK »Siedlung«) mit höherer Wahrscheinlichkeit inkorrekt bestimmt wurde.

Durch den Abgleich mit der visuell erzeugten Referenz könnte nun eine Korrektur der TN erfolgen, was insgesamt gesehen eine Verbesserung der TN-Genauigkeit für die untersuchten LNK zur Folge hätte. Eine automatische Korrektur bzw. eine Angabe, welche TN auf einer als inkorrekt identifizierten Fläche vorliegt, lässt sich mit dem hier vorgestellten CNN jedoch nicht durchführen. Eine entsprechende Modifikation mit zusätzlichen Trainingsdaten, die visuell oder anderweitig validiert sind, wäre jedoch grundsätzlich möglich. In der vorgestellten Fassung bietet das CNN zumindest soweit einen Effizienzvorteil, dass die TN nicht zwingend flächendeckend visuell evaluiert werden muss, sondern prioritär an Stellen, an denen möglicherweise inkorrekte Änderungen oder Datenkorrekturen durchgeführt wurden. Ähnliche Ansätze befinden sich bereits in der prototypischen Entwicklung (siehe Völker et al. 2015).

6 Fazit und Ausblick

Die Ergebnisse der Arbeit zeigen, dass die TN in ATKIS, bezogen auf die untersuchte Stichprobe aus den betrachteten LNK »Freiraum« und »Siedlung«, sehr gut erfasst ist. Es konnte durch eine visuelle Bestimmung ein durchschnittlicher Wert von ca. 94 % korrekter TN-Zuordnungen basierend auf einem Stichprobenumfang von 1999 geprüften Datensätzen in ATKIS festgestellt werden. Die festgestellten Fehler traten vor allem in Randbereichen von Siedlungsflächen, Sonderflächen (z. B. Halden) und (Neu-)Baugebiete in Entstehung auf, die auch bei visueller Bestimmung oftmals schwierig zu erkennen waren.

Das entwickelte CNN erreichte einen nahezu identisch hohen Wert korrekter TN-Zuordnungen innerhalb der betrachteten LNK »Freiraum« und »Siedlung«. Dies zeigt einerseits, dass das Training auch mit nicht visuell validierten ATKIS-Daten korrekt funktioniert hat. Zudem ist dieses Ergebnis ein Indiz dafür, dass automatisierte Deep-Learning-Methoden grundlegend in der Lage sein können, die TN anhand von Orthophotos zu klassifizieren. Inwieweit sich dies auch auf andere, außer den in dieser Arbeit betrachteten, vergleichsweise sehr gut unterscheidbaren ATKIS-Objektarten übertragen lässt, muss in weiterführenden Studien gezeigt werden.

Prinzipiell lässt sich jedoch trotz der bekannten Einschränkungen methodischer und technischer Natur ein potenzieller Mehrwert des Einsatzes von Deep Learning für die Bestimmung/Evaluierung der TN erkennen. Es wäre zumindest denkbar, automatisierte Verfahren zur Klassifikation »einfacher«, d. h. leicht erkennbarer und häufig vorkommender ATKIS-Objektarten zu nutzen, und punktuell dort nachzuarbeiten, wo der Algorithmus Unsicherheiten anzeigt. Langfristig betrachtet könnte damit eine bessere Effizienz und ggf. auch eine noch höhere Qualität der TN-Erfassung realisiert werden.

Literatur

- AdV – Arbeitsgemeinschaft der Vermessungsverwaltungen der Länder der Bundesrepublik Deutschland (2023): Basemap.de. <https://basemap.de/>, letzter Zugriff 01/2023.
- AdV – Arbeitsgemeinschaft der Vermessungsverwaltungen der Länder der Bundesrepublik Deutschland (2022): Dokumentation zur Modellierung der Geoinformationen des amtlichen Vermessungswesens (GeoInfoDok). www.adv-online.de/GeoInfoDok/binarywriterServlet?imgUid=16510ff7-77da-3381-6391-5bc7aff504d1&uBasVariant=11111111-1111-1111-1111-111111111111, letzter Zugriff 01/2023.
- AdV – Arbeitsgemeinschaft der Vermessungsverwaltungen der Länder der Bundesrepublik Deutschland (2020): Produkt- und Qualitätsstandard für Digitale Orthophotos. www.adv-online.de/AdV-Produkte/Standards-und-Produktblaetter/Standards-der-Geotopographie/binarywriterservlet?imgUid=75419114-249e-4711-1fea-f5203b36c4c2&uBasVariant=11111111-1111-1111-1111-111111111111, letzter Zugriff 01/2023.
- Arnold, S., Kurstedt, R., Riecken, J., Schlegel, B. (2017): Paradigmenwechsel in der Landschaftsmodellierung – von der Tatsächlichen Nutzung hin zu Landbedeckung und Landnutzung. In: *zfv – Zeitschrift für Geodäsie, Geoinformation und Landmanagement*, Heft 1/2017, 142. Jg., 30–37. DOI: 10.12902/zfv-0152-2016.
- Bauerle, A., van Onzenoodt, C., Ropinski, T. (2021): Net2Vis – A Visual Grammar for Automatically Generating Publication-Tailored CNN Architecture Visualizations. In: *IEEE Transactions on Visualization and Computer Graphics* 27 (6): 2980–2991.
- Bayerisches Staatsministerium für Ernährung, Landwirtschaft und Forsten (Bay.StMELF) (2023): Zentrale InVeKoS Datenbank (ZID). www.zi-daten.de, letzter Zugriff 01/2023.
- Bhosle, K., Musande, V. (2019): Evaluation of Deep Learning CNN Model for Land Use Land Cover Classification and Crop Identification Using Hyperspectral Remote Sensing Images. In: *Journal of the Indian Society of Remote Sensing* 47 (11), 1949–1958.
- Bundesamt für Kartographie und Geodäsie (2023): DOP20. <https://gdz.bkg.bund.de/index.php/default/wmts-digitale-orthophotos-bodenauflosung-20cm-wmts-dop.html>, letzter Zugriff 01/2023.
- Bundesamt für Kartographie und Geodäsie (2023): TopPlus-Produkte. <https://gdz.bkg.bund.de/index.php/default/webdienste/topplus-produkte.html>, letzter Zugriff 01/2023.
- Bundesministerium des Innern, für Bau und Heimat (2021): Bekanntmachung der Neufassung der Technischen Richtlinie zum Bundesgeoreferenzdatengesetz – TR BGeoRG. www.bkg.bund.de/SharedDocs/Downloads/BKG/DE/Downloads-Allgemein/TR-BGeoRG.html, letzter Zugriff 01/2023.
- Bundesverwaltungsgericht (BVerwG), Beschluss vom 15.9.2005 – 4 BN 37.05. www.bverwg.de/de/150905B4BN37.05.0, letzter Zugriff 01/2023.
- Carranza-García, M., García-Gutiérrez, J., Riquelme, J. (2019): A Framework for Evaluating Land Use and Land Cover Classification Using Convolutional Neural Networks. In: *Remote Sensing* 11 (3), 274.
- Kingma, D. P., Ba, J. (2017): Adam: A Method for Stochastic Optimization. <http://arxiv.org/abs/1412.6980>, letzter Zugriff 01/2023.
- Krüger, T., Hennersdorf, J., Meinel, G., Behnisch, M. (2015): Migration des ATKIS-Basis-DLM – Auswirkungen auf die Nutzung für das Flächenmonitoring. In: *KN – Journal of Cartography and Geographic Information* 65 (2): 59–66.
- Leibniz-Institut für ökologische Raumentwicklung (2023): IÖR-Monitor. www.ioer-monitor.de, letzter Zugriff 01/2023.
- LeCun, Y., Bengio, Y., Hinton, G. (2015): Deep learning. In: *Nature* 521 (7553), 436–444.
- Liang, J., Xu, J., Shen, H., Fang, L. (2020): Land-use classification via constrained extreme learning classifier based on cascaded deep convolutional neural networks. In: *European Journal of Remote Sensing* 53 (1), 219–232.
- Lucas, C., Rattmann, S., Kullmann, K.-H., Sandmann, S., Wiese, K., Kurstedt, R., Behr, C., Käker, R. (2020): Landbedeckung und Landnutzung – Realisierung neuer Geobasisdatenprodukte. In: *zfv – Zeitschrift für Geodäsie, Geoinformation und Landmanagement*, Heft 1/2020, 145. Jg., 56–66. DOI: 10.12902/zfv-0288-2019.
- O’Shea, K., Nash, R. (2015): An Introduction to Convolutional Neural Networks. <http://arxiv.org/abs/1511.08458>, letzter Zugriff 01/2023.
- Reiß, R. P., Huget, P., Kolb, T., Kohl, D., Glaser, A., Urban, D., Drechsel, L. A., Schiener, M., Heckel, M., Tammler, H., Schmidbauer, J., Schmitt, J., Ehrenberger, W., Beierlein, J., Kemnitzer, J., Kee-Man, P., Thalhammer, D., Scheler, A., Kinadeter, K., Cinar, K., Egelkraut, M., Kriegel, F., Solisch, M. (2019): Angewandtes maschinelles Lernen – SS2019. Hof. <https://opus4.kobv.de/opus4-hof/frontdoor/index/index/docId/111>, letzter Zugriff 01/2023.
- Sameen, M. I., Pradhan, B., Aziz, O. S. (2018): Classification of Very High Resolution Aerial Photos Using Spectral-Spatial Convolutional Neural Networks. In: *Journal of Sensors* 2018, 1–12.
- Sharma, A., Liu, X., Yang, X., Shi, D. (2017): A patch-based convolutional neural network for remote sensing image classification. In: *Neural Networks* 95, 19–28.
- Simonyan, K., Zisserman, A. (2015): Very Deep Convolutional Networks for Large-Scale Image Recognition. <http://arxiv.org/abs/1409.1556>, letzter Zugriff 01/2023.
- Skansi, S. (2018): Introduction to Deep Learning: From Logical Calculus to Artificial Intelligence. Undergraduate Topics in Computer Science. Cham. <http://link.springer.com/10.1007/978-3-319-73004-2>, letzter Zugriff 01/2023.
- Völker, A., Gerschütz, A., Bicsan, A., Fischer, M., Klink, A., Lucas, C., Müller, S., Schmidt, C., Strunck, S. (2015): DLM-Update. Integration von Erdbeobachtungstechnologien zur Aktualisierung des ATKIS*-Basis-DLM in die EDV-Strukturen des Landesamtes für Vermessung und Geoinformation Schleswig-Holstein. In: *DGPf Tagungsband* 24/2015.
- Yang, C., Rottensteiner, F., Heipke, C. (2018): Classification of land cover and land use based on convolutional neural networks. In: *ISPRS Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences* IV–3, 251–258.

Kontakt

Denis Reiter | Gotthard Meinel
Leibniz-Institut für ökologische Raumentwicklung (IÖR)
Weberplatz 1, 01217 Dresden
d.reiter@ioer.de | g.meinel@ioer.de

Matthias Forkel
Technische Universität Dresden, Institut für Photogrammetrie und Fernerkundung
Helmholtzstraße 10, 01069 Dresden
matthias.forkel@tu-dresden.de

Dieser Beitrag ist auch digital verfügbar unter www.geodaesie.info.