

KÜNSTLICHE INTELLIGENZ IN DER FERNERKUNDUNG

Der Beitrag beleuchtet, welche Möglichkeiten sich in der Fernerkundung durch den Einsatz von Künstlicher Intelligenz (KI) ergeben. Im Fokus stehen Grundlagen und Anwendungsbeispiele zur KI in der Fernerkundung. Wie lässt sich eine konsistente und grenzübergreifende Datenbasis zu zentralen Fragen der Stadt- und Raumbearbeitung schaffen?

Silas Eichfuss

ist Projektleiter im Referat „Stadt-, Umwelt- und Raumbearbeitung“ des BBSR. Seine Arbeitsschwerpunkte sind unter anderem die Weiterentwicklung des Siedlungsflächenmonitorings mit neuen hochauflösenden Daten sowie die Entwicklung und Betreuung von Forschungsprojekten.
silas.eichfuss@bbr.bund.de

Anna Hellings

ist wissenschaftliche Mitarbeiterin im Referat „Europäische Raum- und Stadtentwicklung“ des BBSR. Neben der Mitarbeit in der Laufenden Raum- und Stadtbeobachtung sowie im europäischen Forschungsnetzwerk ESPON beschäftigt sie sich im Rahmen ihres Promotionsvorhabens mit der Entwicklung von städtischen Hitzeinseln (Surface Urban Heat Islands) im Kontext der Urbanisierung und des Klimawandels in Europa.
anna.hellings@bbr.bund.de

Martina Hollen

ist studentische Hilfskraft im Referat „Stadt-, Umwelt- und Raumbearbeitung“ des BBSR. Hauptsächlich unterstützt sie das Projekt incora (Inwertsetzung von Copernicus-Daten für die Raumbearbeitung). Sie studiert Geografie im Master an der Rheinischen Friedrich-Wilhelms-Universität Bonn.
s6maholl@uni-bonn.de

Thomas Tschirner

ist für die inhaltliche Betreuung des Projekts „Informationen zu Gebäuden aus Fernerkundungsdaten“ verantwortlich. Er ist Projektleiter im Referat „Energieoptimiertes Bauen“ des BBSR mit dem Schwerpunkt erneuerbare Energien in Nichtwohngebäuden.
thomas.tschirner@bbr.bund.de

Dr. Fabian Dosch

betreut derzeit zwei Projekte zur Fernerkundung (Monitoring des Stadtgrüns, incora: Inwertsetzung von Copernicus-Daten für die Raumbearbeitung). Er leitet das Referat „Stadt-, Umwelt- und Raumbearbeitung“ des BBSR.
fabian.dosch@bbr.bund.de

Die Stadt- und Raumentwicklungspolitik ist auf verlässliche Daten angewiesen, zum Beispiel, um den Fortschritt des 30-ha-Ziels zu kontrollieren. Dieses Ziel ist Teil der deutschen Nachhaltigkeitsstrategie, bei der die Neuinanspruchnahme mit Siedlungs- und Verkehrsfläche bis 2030 auf unter 30 ha pro Tag reduziert werden soll. Ein weiteres Beispiel ist die Grünausstattung von Städten, die im Kontext des Klimawandels immer mehr an Bedeutung gewinnt. Die amtliche Flächenstatistik stößt bei der Lieferung dieser Informationen in hoher zeitlicher und räumlicher Auflösung an ihre Grenzen. Die Fernerkundung kann diese Daten als mögliche Al-

ternative bereitstellen. Immer mehr private öffentliche Unternehmen und Start-ups bieten ihre Dienstleistungen auf Basis von über Fernerkundung gewonnenen Informationen an, auch für den Bereich der Stadt- und Raumentwicklung. Ermöglicht hat das die rasante Entwicklung der Rechengeschwindigkeit und Speicherkapazitäten von Computern in den vergangenen zehn Jahren. Unter den Sammelbegriffen Künstliche Intelligenz (KI), maschinelles Lernen und Deep Learning bilden heute viele – teilweise schon seit Jahrzehnten bekannte – Verfahren die Basis der massenhaften und schnellen Auswertung von Fernerkundungsdaten.

Fernerkundung – Programme, Ziele und verfügbare Daten

In Deutschland bieten die Landesvermessungsämter – je nach Open-Data-Politik der Bundesländer – frei verfügbare Daten an. Es gibt zudem weltweite und speziell europäische Angebote, die sich über verschiedene Datenportale abrufen lassen (CODE-DE; Google Earth Engine; GitHub ec-jrc/cbm). Neben den frei zugänglichen Daten verschiedener nationaler und internationaler Raumfahrtbehörden (DLR – Deutsches Zentrum für Luft- und Raumfahrt, NASA – National Aeronautics and Space Administration, ESA – European Space Agency) gibt es auch zahlreiche kommerzielle Produkte. Sie sind oft auf spezielle Themengebiete zugeschnitten – beispielsweise auf die Befliegung von Feldern und Plantagen durch Drohnen in der Agrarwirtschaft.

Im Bereich der frei zugänglichen Daten ist das ESA-Programm Copernicus besonders hervorzuheben. Es zielt darauf ab, eine moderne und effiziente Infrastruktur für Erdbeobachtungs- und Geoinformationsdienste aufzubauen. Im Vordergrund stehen Umwelt- und Klimaschutz, Zivilschutz und Sicherheit, neue Anwendungen und Dienste aus der Erdbeobachtung, eine kontinuierliche globale Umweltüberwachung und die freie und zeitnahe Bereitstellung von Daten.

Einer der wichtigsten Schritte während der Entwicklung des Programms war die Einigung des Europäischen Parlaments und des Rates, dass die Daten für jeden frei und offen zugänglich sein sollten. Anfang 2014 trat die Verordnung zur Einrichtung des Copernicus-Programms in Kraft, die zu seiner langfristigen Umsetzung als operationelles Erdbeobachtungssystem in Europa führte.

Die Daten werden methodisch unterschiedlich gewonnen, wobei Erdbeobachtungssatelliten eine zentrale Rolle ein-

nehmen (UBA 2017: 40). Die operative Phase des Programms begann nach dem Inkrafttreten der Verordnung mit dem Start des ersten Sentinel-Satelliten (Ehlert/Schweitzer 2018: 3). Mittlerweile befinden sich sieben Sentinel-Satelliten im Orbit, die bis auf Sentinel-5P als Satelliten-Paar (Tandem) unterwegs sind (Ehlert/Schweitzer 2018: 4 f.).

Je nach Missionsziel sind die Satelliten mit unterschiedlichen Sensoren ausgestattet und somit in der Lage, verschiedene Daten aufzunehmen. Hervorzuheben ist der Satellit Sentinel-2: Er dient der visuellen Landüberwachung und ist die zur Erfassung der Landbedeckung wichtigste Quelle.

Ein weiterer Teil des Copernicus-Programms ist die Aufbereitung und Bereitstellung der erhobenen Daten. In-situ-Beobachtungen, also Beobachtungen vor Ort, ergänzen die Satellitendaten. So lassen sich mit numerischen Modellen benutzerfreundliche Daten- und Informationsprodukte für die sechs Copernicus-Dienste erzeugen, die den Kern des Programms bilden (vgl. Abb. 1). Spezialisierte Dienstleister, die sogenannten „Entrusted Entities“, setzen diese Dienste im Auftrag der Europäischen Kommission um (Ehlert/Schweitzer 2018: 8).

Landbedeckung und Landnutzung zeigen an, wie menschliches Handeln die Umwelt belastet. Das Projekt CORINE Land Cover (CLC) liefert Daten über die europäische Landfläche im Zeitverlauf. Seit 1990 werden die Daten europaweit ab einer minimalen Kartierungseinheit (MMU – minimal mapping unit) von 25 ha für Flächen und 100 m für lineare „Phänomene“ betrachtet und gesammelt. Kleinere Flächen ordnet eine Matrix, die in 44 Landbedeckungs- und Landnutzungs-klassen eingeteilt ist, der nächstpassenden Klasse zu.

1

Copernicus-Dienste und ihre „Entrusted Entities“

Service	Entrusted Entity
Land monitoring	Global: JRC – Joint Research Centre; European: EEA – European Environment Agency
Marine monitoring	Mercator Océan
Atmosphere monitoring	ECMWF – European Centre for Medium-Range Weather Forecasts
Climate change	ECMWF
Emergency management	JRC
Security	FRONTEX, EMSA, SatCEN

Quelle: Ehler/Schweitzer 2018

Seit dem Jahr 2000 können sich Nutzerinnen und Nutzer nicht nur über die bestehenden Flächen informieren, sondern auch über die zeitliche Veränderung der Landnutzung und Landbedeckung seit 1990. Obwohl die Europäische Umweltagentur den Datensatz bereitstellt, ist sie hauptsächlich für die Koordination, Integration und Auswertung verantwortlich. Das Netzwerk „Eionet National Reference Centres on Land Cover“ (NRC LC) erstellt die nationalen CLC-Datenbanken (Copernicus Programme o. J.). In Deutschland nimmt das Fernerkundungsdatenzentrum des DLR diese Aufgabe im Auftrag des Umweltbundesamtes wahr (UBA 2020). Die meisten Datensätze werden mit hochauflösenden Satellitenbildern klassifiziert. Einige andere werden basierend auf halbautomatischen Prozessen erzeugt. Diese Prozesse bau-

en sowohl auf In-situ-Daten als auch auf Satellitenbildern, Generalisierungen und GIS-Integrationen auf.

Copernicus hat in den vergangenen Jahren zu einem rapiden Wachstum an verfügbaren Fernerkundungsdaten beigetragen. Wie Künstliche Intelligenz, insbesondere maschinelles Lernen, die Fernerkundung verbessern kann, stand auch im Zentrum des Nationalen Copernicus-Forum 2021. Anwendungsbeispiele – zum Beispiel zur morphologischen und semantischen Kartierung städtischer Gebiete, zur Unterstützung der gemeinsamen Agrarpolitik oder zur Erfassung der Grünausstattung von Städten – zeigen das Potenzial der KI für die Erdbeobachtung (DLR/EOC 2021).

Rohdaten aus der Fernerkundung

In der Fernerkundung misst ein Sensor, der nicht in physischem Kontakt zum Untersuchungsobjekt steht, bestimmte Objekteigenschaften der Erdoberfläche. Er erfasst dabei reflektierte und/oder emittierte elektromagnetische Strahlung von Objekten auf der Erdoberfläche, den Ozeanen oder der Atmosphäre (Lillesand et al. 2004: 1; Khorram et al. 2012: 2). Je nach Größe des zu erfassenden Gebiets kommen unterschiedliche Trägersysteme zum Einsatz: Drohnen und terrestrische Lösungen für kleinräumige Untersuchungen, Flugzeuge für Städte oder Bundesländer, Satelliten für die kontinuierliche, großflächige Beobachtung der Erdoberfläche. Oft werden mehrere Sensoren kombiniert, um das Trägersystem optimal auszunutzen.


Die eingesetzten Sensoren lassen sich je nach Quelle der gemessenen Strahlung in aktive und passive Fernerkundungs-

systeme unterteilen (vgl. Abb. 2). Passive Systeme, auch optische Systeme genannt, messen Strahlung im Wellenlängenbereich der ultravioletten, sichtbaren und Infrarot-Strahlung. Dabei geht es um die an der Erdoberfläche reflektierte Sonneneinstrahlung oder die Thermalstrahlung, die jeder Körper aufgrund seiner Oberflächentemperatur emittiert. Für die Messung der reflektierten Strahlung braucht es daher Sonnenlicht und eine wolkenfreie Atmosphäre.

Aktive Fernerkundungssysteme senden eigene, künstlich erzeugte Strahlung aus. Dabei messen sie den reflektierten Anteil dieser Strahlung (Jensen 2007: 291). Bei der ausgesendeten Strahlung kann es sich sowohl um elektromagnetische Strahlung – zum Beispiel bei Radar- oder LiDAR-Systemen (Light Detection And Ranging) – als auch um Schallwellen handeln. Radarsysteme senden Mikrowellen aus, die Wel-

2

Strahlungsfluss der elektromagnetischen Strahlung mit aktiven und passiven Fernerkundungssensoren am Beispiel der reflektierten Sonnenstrahlung, Thermalstrahlung und reflektierten künstlichen Strahlung



E = Empfänger (Sensor), S = Sender

Quelle: Albertz 2008: 10

lenlängen befinden sich dabei im mm- bis m-Bereich. Diese Strahlen durchdringen Wolken, somit ist eine wetterunabhängige Messung möglich. Ein LiDAR-System besteht aus Sender, Empfänger und Verarbeitungseinheit und kann an verschiedenen Trägersystemen installiert werden.

Um das aufgenommene Material zu nutzen, müssen die Rohdaten vorher aufbereitet werden. Dies erfordert eine

geometrische (Orthorektifizierung) sowie eine radiometrische (atmosphärische, topografische) Korrektur. Rechnerische Auswertungsverfahren ermöglichen die Informationsreduktion und -selektion bis hin zur statistischen und/oder regelbasierten Klassifikation auf Pixel- oder Segmentebene (Honecker/Löffler 2018). Anwenderinnen und Anwender können zum Beispiel in den Daten Wolken entfernen oder Satellitenbildszenen zu einem Mosaik verknüpfen. Die Daten werden also zur direkten Verarbeitung vorverarbeitet.


Die Auswertung oder das Erstellen thematischer Karten (z. B. eine Klassifikation der Landbedeckung) auf Basis von Roh- oder bereits vorprozessierten Daten kann auch mittels verschiedener Verfahren der KI geschehen. Methoden der KI dienen dabei zur automatisierten Auswertung der Daten. Bei der Verarbeitung und Analyse dieser großen Datenmengen stehen Methoden des maschinellen Lernens und des Deep Learning (besonders der künstlichen neuronalen Netze) im Vordergrund (Bamler 2021).

Maschinelles Lernen gilt als ein Teilgebiet der Künstlichen Intelligenz, bei dem Programme aus den zur Verfügung stehenden Daten lernen und so Gesetzmäßigkeiten erkennen. Entsprechende Verfahren können beliebige Daten verknüpfen, um einerseits effiziente Zusammenhänge abzuleiten, zum anderen aber auch Rückschlüsse und Vorhersagen zu bestimmen (Segl et al. 2018: 19). Ein Teilbereich des maschinellen Lernens ist das Deep Learning, bei dem das zentrale Element künstliche neuronale Netzwerke (KNN) sind.

Die Grundidee bei der Entwicklung von einem KNN liegt darin, das (menschliche) Gehirn zu simulieren. Bei diesen

3

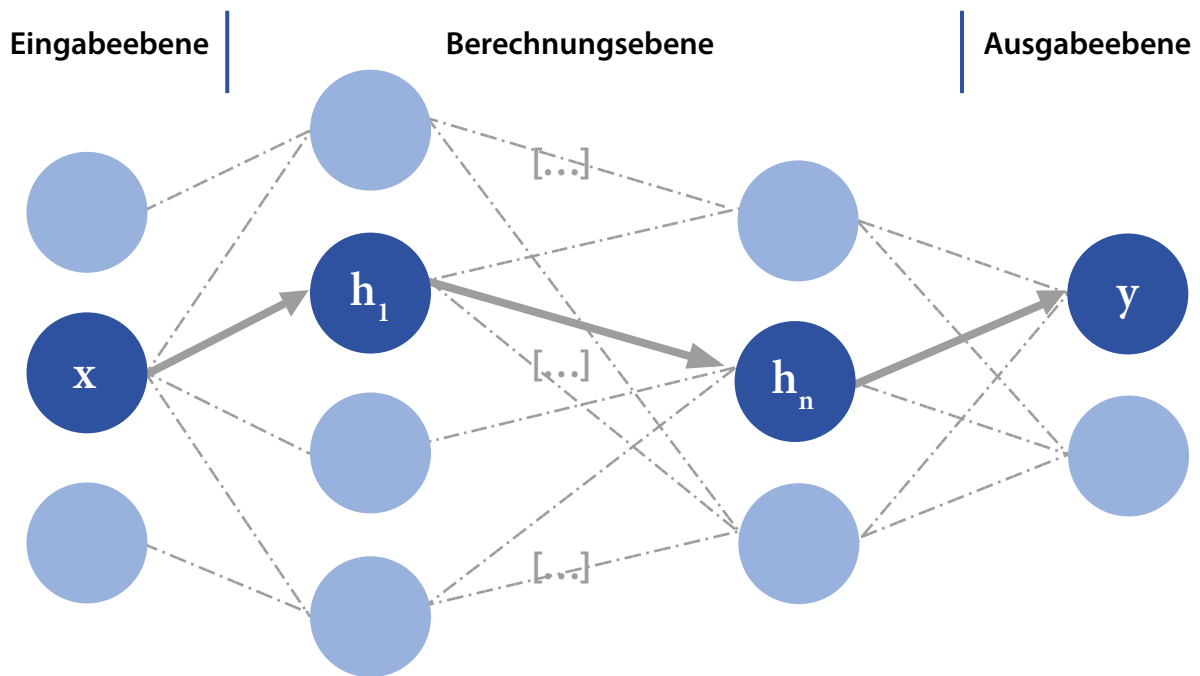
Unkorrigiertes Mosaik, atmosphärenkorrigiertes Mosaik und klassifiziertes Bild



Quelle: DLR; Copernicus

4

Skizze eines künstlichen neuronalen Netzes



Quelle: Buxmann/Schmidt 2019: 14, verändert

Netzen sind viele verschiedene Recheneinheiten beziehungsweise Neuronen miteinander verbunden und in vielen Ebenen organisiert. Dabei lassen sich drei Typen von Ebenen unterscheiden: Eingabe-, Berechnungs- und Ausgabeebene (vgl. Abb. 4). Durch Trainingsdaten „lernt“ das KNN, welche Gewichtung jede Berechnungsebene haben sollte, um eine

richtige Zuordnung (z. B. die Zuordnung eines Pixels der richtigen Landbedeckung) zu erzielen. Um diese Gewichtung zu „lernen“, geben Entwicklerinnen und Entwickler Daten mit bekannten Zusammenhängen ein. Der Algorithmus lernt diese Strukturen schließlich, um sie später auf unbekannte Zusammenhänge anzuwenden.

Flächenerhebung: Herausforderung für Fernerkundung und KI

Als einer von vielen Bausteinen für eine intelligente und zukunftsorientierte Stadt- und Raumplanung gilt die Flächenerhebung. Die einzelnen Flächen zu vermessen und in Datenbanken zu überführen, ist sehr zeit- und kostenintensiv. Es überrascht daher nicht, dass die amtliche Flächenstatistik die tatsächlichen Flächennutzungsdaten zum Beispiel mit einem Zeitversatz veröffentlicht (Destatis 2020) und sich auf aktuelle Themen nur zeitverzögert reagieren lässt. Zudem unterstehen erhobene Daten in der primären Quelle der Flächenstatistik ALKIS (Amtliches Liegenschaftskatasterinformationssystem) meist einer Mindest erfassungsgröße,

wobei Details wegfallen. Die Mindest erfassungsgröße beschreibt die Größe, die eine Fläche mindestens haben muss, um einer Landnutzung zugeordnet zu werden. Liegt die Größe der betrachteten Fläche unterhalb der Mindest erfassungsgröße, wird sie dem Nachbarobjekt zugeordnet (Dominanzprinzip).

Abbildung 5 vergleicht die ALKIS-Daten mit aus Fernerkundungsdaten abgeleiteten Landbedeckungsdaten. Sie verdeutlicht damit, worin sich die beiden Ansätze hauptsächlich unterscheiden.

Unterschiede zwischen Landnutzungsdaten der Flächenstatistik und Landbedeckungsdaten aus der Fernerkundung

Kriterium	Landnutzungsdaten der Flächenstatistik (ALKIS)	Fernerkundungsdaten
räumliche Genauigkeit	abhängig von Mindesterfassungsgröße und dem Dominanzprinzip, wird bei jeder Klasse unterschiedlich angegeben	abhängig von der Rasterzellengröße des Sensors, die Größe variiert von Zentimeter bis Kilometer
Aktualität	etwa 3 Jahre Zeitverzug	hochaktuell, jedoch abhängig von Verfügbarkeit brauchbarer Szenen
Informationsgehalt	Landnutzungsdaten mit hohem thematischen Informationsgehalt zur Nutzung des Objekts	Landbedeckungsdaten entsprechen der sichtbaren Landbedeckung, die durch den Sensor erfasst wird. Die Anzahl der Klassen wird vorher angegeben und leitet sich meist aus den Trainingsgebieten ab
Qualität	abhängig von der Auslegung der Datenerhebung, Unterschiede zwischen den Bundesländern, statistische Brüche nach Umstellungen der Datenbasis	abhängig unter anderem von Atmosphäre, Algorithmus, Trainingsgebieten
Aufwand	aufwendige Erhebung in den Bundesländern, viele Abstimmungsprozesse zwischen den Informationslieferanten	bei einer Automatisierung schnelle Ergebnisse
Gesamtbewertung	Informationsgehalt hoch, räumliche und zeitliche Auflösung im Vergleich zur Fernerkundung eher niedrig, hoher Aufwand	hohe räumliche und zeitliche Auflösung, schnell umsetzbar, fehleranfällig

Quelle: eigene Darstellung

KNN lassen sich auch dazu nutzen, die Landbedeckung abzuleiten. Für die Umsetzung braucht es große Mengen an frei verfügbaren Trainingsdaten (z. T. Open Data) und hohe Rechenkapazitäten, die mit diesen Datenmengen (Big Data) umgehen können. Die Trainingsdaten müssen teils händisch erhoben werden, was sehr zeit- und kostenintensiv sein kann. Sie sind aber essenziell, da sie das Rückgrat der KNN bilden. Eine Klassifizierung durch das KNN kann nur gelingen, wenn die Trainingsdaten stimmen.

Die Klassifikation von Rohdaten in Geoinformationen mithilfe von KI

Fernerkundungsdaten lassen sich visuell unterschiedlich interpretieren. Zunächst werden die verschiedenen Elemente des Bildes zusammengefasst und Grenzen zwischen den zu unterscheidenden Elementen der Landbedeckung gezogen. Dabei erfolgt die Unterscheidung der Bildinhalte unter Berücksichtigung visueller und gedanklicher Grenzen und den Merkmalen Form, Größe, Grau- oder Farbton, Textur, Lage, Umfeld, Beziehung und Auflösung (Jensen 2007: 25; Lillesand et al. 2004: 550).

Bei der (semi-)automatischen Klassifizierung von Fernerkundungsdaten werden den Pixeln des Bildes auf Basis der spektralen Werte Klassen zugeordnet (Lillesand et al. 2004: 551). Es gilt, zwei grundlegende Ansätze zu unterscheiden: Zum einen die überwachte Klassifikation, zum anderen die

unüberwachte Klassifikation (ebd.). Die überwachte Klassifikation basiert nicht nur auf den vorliegenden Messwerten, sondern hängt auch von zusätzlichen Informationen ab. Dabei müssen den Werten, denen die Unterteilung des Merkmalsraums zugrunde liegt, Objektklassen zugeordnet werden. Als Referenzflächen dienen dazu Trainingsgebiete. Um jede Klasse voneinander unterscheiden zu können, ist ihnen jeweils mindestens ein Trainingsgebiet zuzuordnen (Albertz 2008: 163). Der Klassifikator (Algorithmus) wird mit den Trainingsgebieten trainiert und weist allen Pixeln mit einer vergleichbaren Wellensignatur („spektraler Fingerabdruck“) dieselbe Klasse zu.

Die unüberwachte Klassifikation erfolgt wiederum ohne Trainingsgebiete. Ein vollautomatisches System klassifiziert die Pixel mittels Angabe der zu erwartenden Klassen. Das hat den Vorteil, dass es keine zeitaufwendige Aufnahme/Aufbereitung von Referenzdaten braucht. Die Ergebnisse solch einer Methode lassen sich schwer bewerten, da es keinerlei Referenz zur Überprüfung gibt (Richards 2013: 94).

Je nach Art der Klassifikation existieren verschiedene Ansätze. Einfachere Klassifikationsansätze sind beispielsweise Maximum Likelihood, wobei jedes Pixel der Klasse zugeordnet wird, für die es die größte Wahrscheinlichkeit aufweist, und Minimum Distance, bei dem jedes Pixel der Klasse zugeordnet wird, deren Mittelpunkt am nächsten liegt (Albertz 2008: 165). Neben der pixelbasierten Klassifikation ist ein weiterer

Ansatz die objektbasierte Bildanalyse (OBIA), die dem maschinellen Lernen zugeordnet wird. Dieser Ansatz wurde wegen der immer höher aufgelösten Satellitenbilder entwickelt. Vorbild der OBIA ist die menschliche Perzeption. Sie beruht nicht allein auf den spektralen Farbinformationen; es geht auch um Lage, Formcharakteristiken, Nachbarschaftsbeziehungen, charakteristische Muster und strukturelle Merkmale (Blaschke 2000: 30 ff.). Die Objektinformationen leiten sich nicht nur aus einzelnen Pixeln ab, sondern aus mehreren gruppierten Pixeln, die sich zu einzelnen Segmenten zusammenfassen lassen. Jeder objektbasierten Klassifikation ist eine Segmentation vorangestellt, wobei das Ergebnis von der Genauigkeit dieser Segmentierung abhängt (Blaschke et al. 2014: 186). Der ausschlaggebende Punkt für eine objektorientierte Bildanalyse ist daher die Nutzung von Wissen über einzelne Objekte (Weidner/Lemp 2005: 107).

Herausforderungen

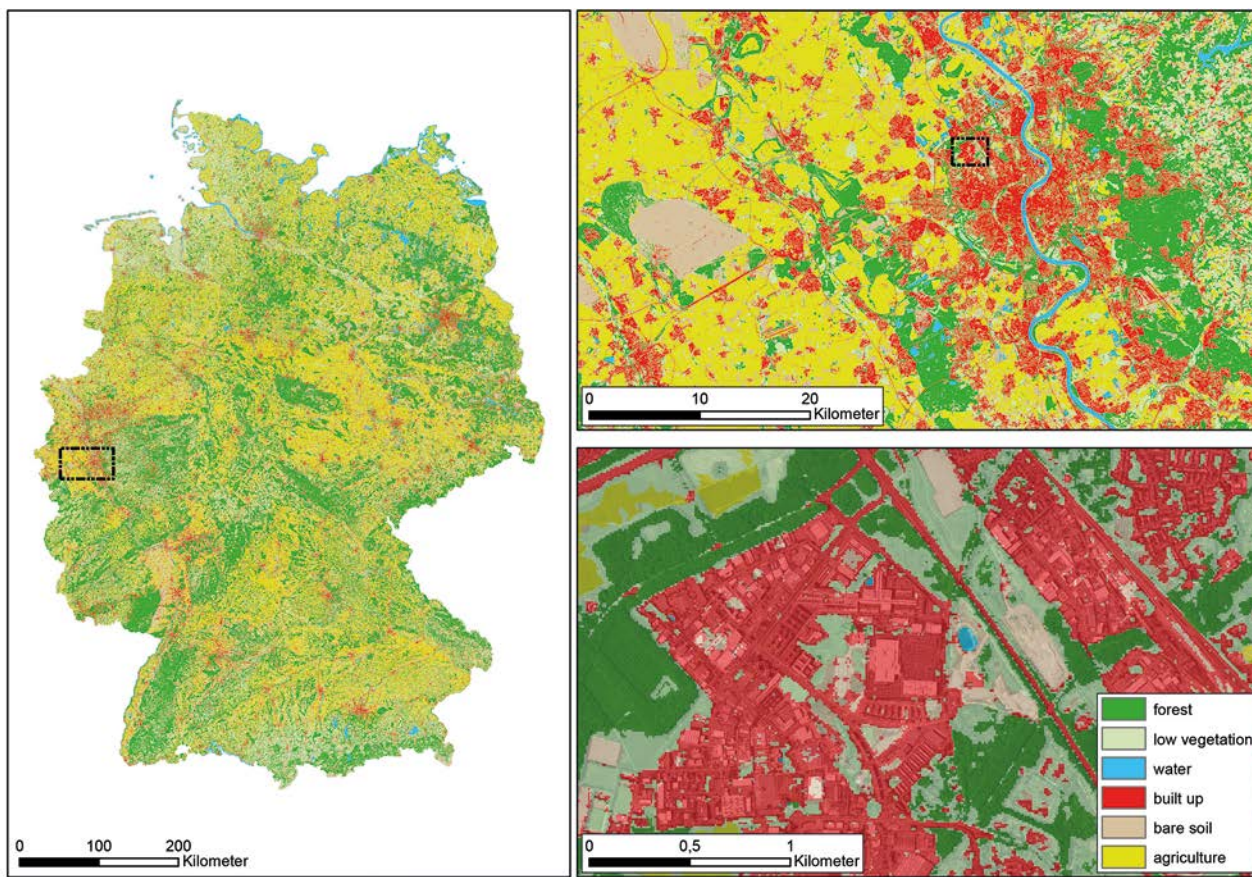
Eine Klassifikation ist nur so gut, wie die Trainingsdaten es vorgeben. Sie reichen teils nicht aus, um einen ausreichenden Trainingsdatensatz abzubilden. Dabei ist das Erstellen zum einen sehr kostenintensiv, zum anderen ist es auch fehleranfällig, da der Mensch teilweise einzelne Landbedeckungen schlecht unterscheiden kann. Helfen kann hier eine (semi-)automatische Ableitung von Trainingsdaten.

So nutzt das Projekt incora (vgl. Beispiel 1, nächstes Unterkapitel) OpenStreetMap (OSM) und High Resolution Layer Imperviousness (HRL), um Trainingsdaten automatisiert abzuleiten (Riembauer et al. 2021a).

Als Quelle für einen offiziellen regelmäßig erhobenen Datensatz gelten die LUCAS-Referenzpunkte (2006–2018 in

6

Deutschlandweite Landbedeckungsklassifikation 2019, Zwischenprodukt aus dem incora-Projekt; Ausschnitt Großraum Bonn-Köln; Detailausschnitt Köln-Ossendorf



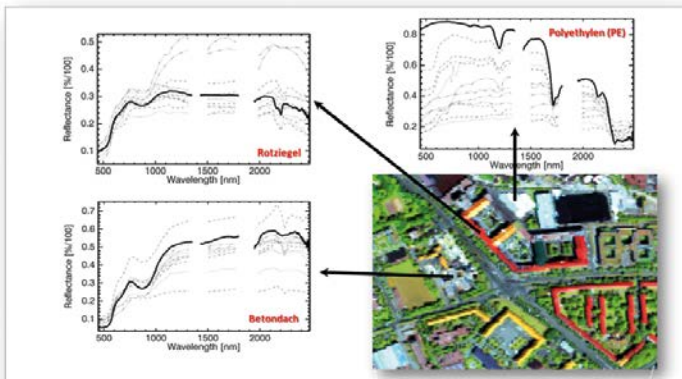
Quelle: Sentinel-2-Landbedeckungsklassifikation 2019 des Projekts incora

3-Jahres-Intervallen) (Eurostat 2015) als valide Trainingsdaten (LUCAS: Land Use and Coverage Area frame Survey). Das Forschungsprojekt Monitoring des Stadtgrüns (vgl. Beispiel 3, nächstes Unterkapitel) nutzte sie beispielsweise erfolgreich als Trainingsdatensatz (Weigand et al. 2020).

Beide beschriebenen Ansätze erzielen ein deutschlandweit gutes Klassifikationsergebnis.

Das Datenmanagement von Rohdaten gilt je nach Auflösung, Erfassungsgebiet und Informationsgehalt als Herausforderung. Cloud-Computing-Plattformen wie CODE-DE (ESA) oder Google Earth Engine erleichtern die Handhabbarkeit der teils großen Datenmengen. Sie stellen die passenden Rechenkapazitäten zur Verfügung. Zudem finden sich

7 Falschfarbendarstellung eines HyMap-Hyperspektralbildes von München (Ostbahnhof) und Kartierung von Oberflächenmaterialien mittels spektraler Entmischung



Quelle: DLR-DFD (https://www.dlr.de/eoc/desktopdefault.aspx/tabid-5278/8856_read-15911)

auf der Plattform CODE-DE vorprozessierte Daten aus den Copernicus- und Landsat-Programmen.

Nutzung von Fernerkundungsdaten im BBSR

Nutzung der Fernerkundung für ein verbessertes Monitoring von Siedlungsflächen (Beispiel 1): Das ILS (Institut für Landes- und Stadtentwicklungsforschung), das BBSR und die Firma Mundialis führen gemeinsam das Verbundprojekt incora (Inwertsetzung von Copernicus-Daten für die Raumbewachung) durch. Es liefert eine zeitlich und räumlich hochauflösende Datenbasis, mit der sich Indikatoren für ein verbessertes Monitoring von Siedlungsflächen berechnen lassen. Werte für die Jahre 2016, 2019 und 2020 (Mundialis 2020; Mundialis 2021) zeigen eine aus Sentinel-2 abgeleitete deutschlandweite Landbedeckungsklassifikation mit guter Qualität. Zur Berechnung verwendete das Projektteam das maschinelle Lernverfahren Random Forest in einem automatisierten Workflow der Firma Mundialis (Riembauer et al. 2021a; Riembauer et al. 2021b). Random Forest beschreibt einen mehrstufigen Klassifikationsansatz, der als Entscheidungsbaum organisiert wird. Jedes Pixel durchläuft bei der Klassifikation den Entscheidungsbaum, wobei jeder Baum eine Klassenzuordnung liefert. Die Auswertung der Bäume liefert am Ende das Klassifikationsergebnis.

Informationen zu Gebäuden aus Fernerkundungsdaten (Beispiel 2): Im Bereich der Gebäude liegen mit Bau, Betrieb und Rückbau fundamentale Hebel für die Transformation hin zu einem nachhaltigen Wirtschaften. Das Wissen über den Gebäudebestand in Deutschland ist jedoch unzureichend, vor allem im Bereich der Nichtwohngebäude.

Das Team Smart Cities und Raumentwicklung des DLR-DFD erstellte im Auftrag des BBSR eine Übersichtstudie zu möglichen Verfahren der Informationsgewinnung zu Einzelgebäuden aus Fernerkundungsdaten. Im Projekt halfen die Katasterdaten bei der Anwendung KI-gestützter Analyseverfahren. So lässt sich die Identifizierung von Gebäuden durch den Vergleich mit Hausumringen sowohl vereinfachen als auch kontrollieren. Für ausgewählte Verfahren berechnete das Projektteam Beispielauswertungen für verschiedene Regionen in Deutschland. Der entwickelte Methodenkatalog soll die Entscheidungsfindung zum deutschlandweiten Einsatz und die Weiterentwicklung der Fernerkundungsmissionen unterstützen.

KI im Anwendungsbeispiel Monitoring des Stadtgrüns (Beispiel 3): Das Team im Projekt Monitoring des Stadtgrüns erarbeitete eine Methodik zur bundesweit flächendeckend-

den fernerkundlichen Erfassung und stadträumlich-funktionalen Differenzierung der Grünausstattung von Städten in Deutschland (BBSR 2021).

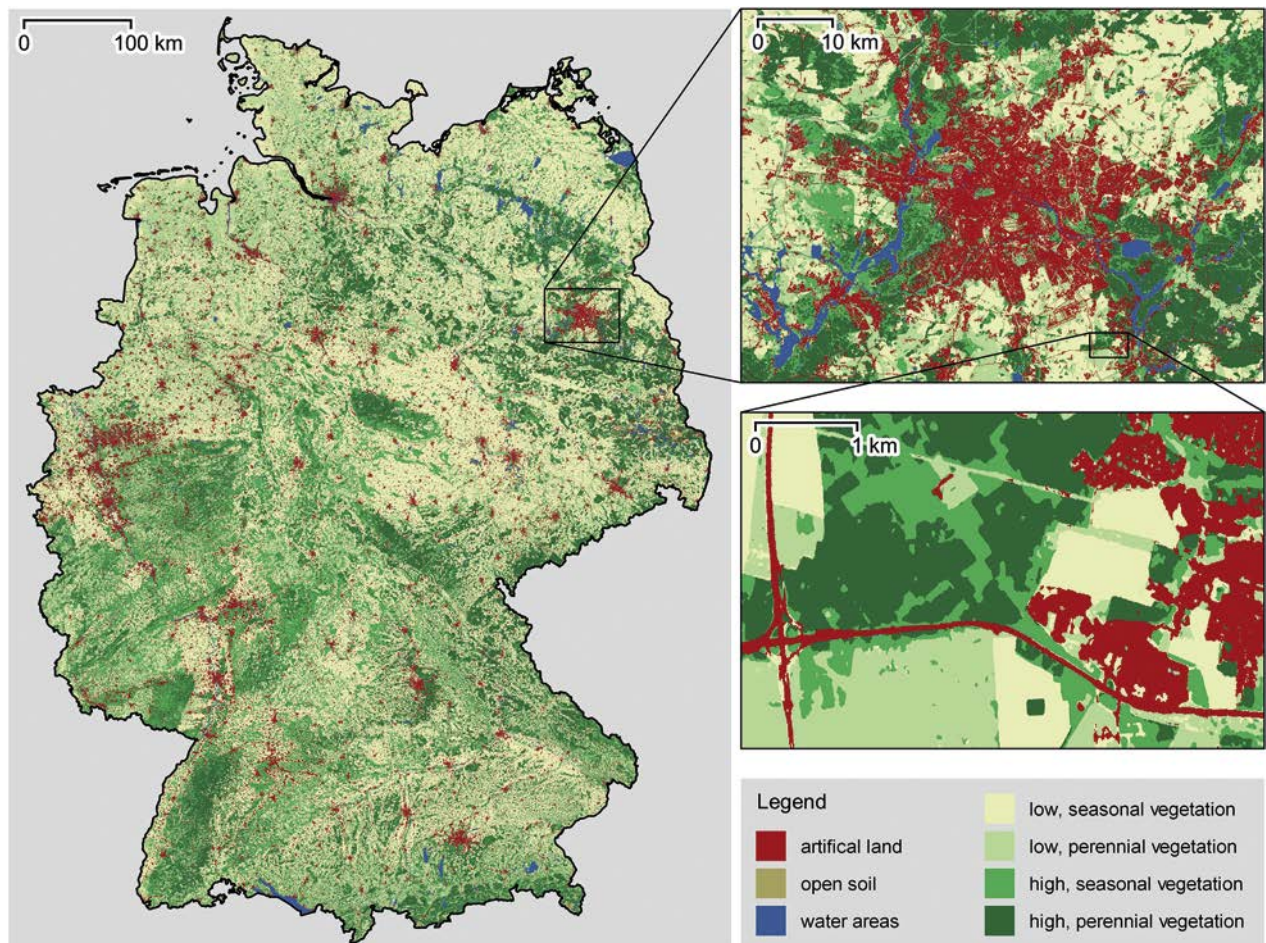
Datenbasis bilden die kostenfreien Sentinel-2A- und -2B-Satellitendaten des europäischen Programms Copernicus. Vor der thematischen Bildanalyse werden die Satellitenbilddaten durch eine Wolkenmaske vorprozessiert und ein Medianmosaik erstellt (Eichler et al. 2020). Verschiedene Indizes wie NDVI (Normalized Difference Vegetation Index), NDWI (Normalized Difference Water Index), NDBI (Normalized Difference Built-up Index) und fokale Texturmerkmale verbessern die Bilddaten-Layer.

Als Trainings- und Validierungsdaten nutzte das Projektteam Messpunkte der LUCAS-Erhebung von 2015 und 2018, die für ein INSPIRE-Raster von 2 km² vorliegen. Datengrundlage für diese Trainingsgebiete sind 80 % der LUCAS-Referenzpunkte. Die restlichen 20 % der Punkte dienten dazu, die Klassifikationsergebnisse in weiteren Schritten zu validieren.

Die darauffolgende Klassifikation wurde mit dem maschinellen Lernverfahren Random Forest Layer gebildet (Breiman 2001). Im Ergebnis unterscheiden die Klassifikationen für 2016 und 2018 sieben Landbedeckungsklassen: bebaut/versiegelt, offener Boden, Laubholz, Nadelholz, Ackerland, Wiese und Wasser. Insbesondere die Klassen Laubholz, Na-

8

Deutschlandweite Landbedeckungsklassifikation des Projekts Monitoring des Stadtgrüns; Ausschnitt Großraum Berlin; Detailausschnitt A10 Schönefelder Kreuz und Wildau (Landkreis Dahme-Spreewald)



Quelle: Weigand et al. 2020, CC BY-SA 4.0 (<https://creativecommons.org/licenses/by-sa/4.0>)

delholz und Wiese spiegeln das städtische Grün wider. Die ermittelte Gesamtgenauigkeit weist für alle sieben Klassen hohe Werte von über 90 % auf (Weigand et al. 2020). Die fertiggestellten Klassifikationen der Landbedeckung bilden die Basis für die indikatorgestützte Erfassung des Stadtgrüns. Ein erstes Klassifikationsprodukt ist für Deutschland 2016

unter dem Namen LandCover-DE als Datensatz frei verfügbar. Aus den Klassifikationen wurden inzwischen einige flächenstatistische Auswertungen abgeleitet (BBSR 2021), um die Datengrundlagen für das städtische Grün kleinräumig zu verbessern (Taubenböck et al. 2021).

Fazit und Ausblick

Die unter dem Begriff Künstliche Intelligenz zusammengefassten Methoden sind die wichtigsten Werkzeuge, um in der Fernerkundung großräumig und schnell hochwertige Daten und Klassifikationen zur Raum- und Stadtentwicklung zu ermitteln. Eine intelligente und nachhaltige Planung hängt mehr und mehr von Daten ab, die sich neben den amtlichen Planungsgrundlagen als zeitlich aktuelle Grundlage nutzen lassen.

Anwenderinnen und Anwender können mit den Ergebnissen je nach Automatisierungsgrad innerhalb kürzester Zeit unterschiedliche Fragen beantworten. Dabei beruht die Nutzbarkeit auf den beschriebenen Faktoren. In vielen Fällen gibt es nur ein begrenztes Verständnis dafür, was die Ergebnisse bedeuten. Zudem bleibt die Frage offen, ob maschinelles Lernen künftig zentraler Bestandteil von Anwendungen der Fernerkundung sein oder aufgrund seiner Black-Box-Eigenschaften mit Vorsicht eingesetzt werden sollte (Zhu et al. 2019). Fehlendes Know-how der Nutzerinnen und Nutzer sowie personelle und wirtschaftliche Einschränkungen sind dabei oft limitierend und hemmen den Einsatz dieser Systeme in der Praxis. Hier gilt es mittels zugeschnittenen, zum Thema passenden Daten und Fallbeispielen, die Nutzerinnen und Nutzer zu sensibilisieren und die Daten als Unterstützung zu den amtlichen Daten anzubieten. Das BBSR bietet dafür Produkte aus aktuellen Projekten zum verbesserten

Monitoring von Siedlungsflächen (incora) und dem Stadtgrün (Monitoring des Stadtgrüns) an. Die Entwicklungen der Fernerkundung der vergangenen Jahre, die Fortschritte der Technik der Satelliten- und anderer Befliegungssysteme, der Ausbau der Rechenkapazitäten zur Verarbeitung immer größerer Datenmengen, aber auch die Fortschritte im Bereich der KI zeigen uns in etwa, wohin die Entwicklungen auch zukünftig gehen können. Insbesondere die grenzüberschreitende Raumbesichtigung, aber auch die Beobachtung von Veränderungen der Erdoberfläche in entlegenen Teilen unserer Welt wird die Wissenschaft zunehmend berücksichtigen können.

Frei verfügbare und kommerzielle vorprozessierte Daten, fertige Produkte und einfach zu bedienende Plattformen beschleunigen zudem die Entwicklung von Anwendungen auch außerhalb der wissenschaftlichen Gemeinschaft. Dabei bleibt festzuhalten, dass der alleinige Einsatz der aus den Fernerkundungsdaten mit KI abgeleiteten Produkte eines von vielen Mitteln zum Ziel ist. Um komplexe Fragen zu beantworten, lassen sich zusätzliche Daten nutzen. Ein Datensatz, der sich aus mehreren Quellen speist, gilt dabei als multidimensional und kann eine Frage oft genauer beantworten. Die Verbindung verschiedenster Schnittstellen begünstigt Entwicklungen in diese Richtung.

Literatur

- Albertz, J.**, 2008: Einführung in die Fernerkundung. Grundlagen der Interpretation von Luft- und Satellitenbildern. WBS, Darmstadt.
- Bamler, R.** 2021: KI in der Erdbeobachtung: Daten – Algorithmen – Initiativen. Zugriff: www.d-copernicus.de/fileadmin/Content/pdf/Forum_2021/Nationales_Forum_Copernicus_-_KI_EO_-_Bamler.pdf [abgerufen am 14.05.2021].
- BBSR – Bundesinstitut für Bau-, Stadt- und Raumforschung**, 2021: Wie grün sind bundesdeutsche Städte? Fernerkundliche Erfassung und stadträumlich-funktionale Differenzierung der Grünausstattung von Städten in Deutschland. Zugriff: www.bbsr.bund.de/BBSR/DE/forschung/programme/refo/staedtebau/2019/gruenmonitoring/01-start.html [abgerufen am 14.05.2021].
- Blaschke, T.**; Hay, J. H.; Kelly, M.; Lang, S., 2014: Geographic Object-Based Image Analysis – Towards a new paradigm, *ISPRS Journal of Photogrammetry and Remote Sensing* 87(100): 180–191.
- Blaschke, T.**; Lang, S.; Lorup, E.; Strobl, J.; Zeil, P., 2000: Object-oriented Image Processing in an Integrated GIS/Remote Sensing Environment and Perspectives for Environmental Applications. In: Cremers, A. B. & Greve, K. (Hrsg.), *Umwelthinformatik '00* Umwelthinformatik für Planung, Politik und Öffentlichkeit. Marburg: Metropolis.
- Breiman, L.**, 2001: Random Forests. *Machine Learning*, 45(1): 5–32. Zugriff: <https://link.springer.com/content/pdf/10.1023/A:1010933404324.pdf> [abgerufen am 14.05.2021].
- Buxmann, P.**; Schmidt, H., 2019: Künstliche Intelligenz – Mit Algorithmen zum wirtschaftlichen Erfolg. Springer Berlin Heidelberg.
- Copernicus Programme**, o. J.: CORINE Land Cover. Zugriff: <https://land.copernicus.eu/pan-european/corine-land-cover> [abgerufen am 14.05.2021].
- Destatis – Statistisches Bundesamt**, 2020: Bodenfläche nach Art der tatsächlichen Nutzung – Fachserie 3 Reihe 5.1 – 2019.
- DLR – Deutsches Zentrum für Luft- und Raumfahrt e. V.**; EOC – Earth Observation Center, 2021: Aktuelle Themen aus der Wissenschaft: Big Data und Künstliche Intelligenz für die Erdbeobachtung. Forum B.3 des Nationalen Copernicus Forum 2021.
- Ehlert, I.**; Schweitzer, C. (Hrsg.), 2018: Copernicus für das Umweltmonitoring. Eine Einführung. Hamburg, Dessau-Roßlau.
- Eichler, L.**; Krüger, T.; Meinel, G.; Tenikl, J.; Wurm, M., 2020: Wie grün sind deutsche Städte? Indikatorgestützte fernerkundliche Erfassung des Stadtgrüns. *AGIT – Journal für Angewandte Geoinformatik*, 6-2020: 306–315.
- Eurostat**, 2015: LUCAS Data 2015. Zugriff: <https://ec.europa.eu/eurostat/web/lucas/data/primary-data/2015> [abgerufen am 14.05.2021].
- Honecker, U.**; Löffler, E.-W., 2018: Fernerkundung. In: *ARL – Akademie für Raumforschung und Landesplanung* (Hrsg.): *Handwörterbuch der Stadt- und Raumentwicklung*. Hannover: 655–660.
- Jensen, J. R.**, 2007: *Remote Sensing of the Environment. An Earth Resource Perspective*. Pearson, New York.
- Khorram, S.**; Koch, F.; Wiele, C.; Nelson, S., 2012: *Remote Sensing. Springer Briefs in Space Development*. Springer, New York, Heidelberg.
- Lillesand, T.**; Kiefer, R.; Chipman, J., 2004: *Remote Sensing an Image Interpretation*. Wiley, Hoboken.
- Mundialis**, 2020: Deutschland 2019 – Landbedeckung auf Basis von Sentinel-2 Daten. Zugriff: <https://www.mundialis.de/de/deutschland-2019-landbedeckung-auf-basis-von-sentinel-2-daten> [abgerufen am 14.05.2021].
- Mundialis**, 2021: Deutschland 2020 – Landbedeckung auf Basis von Sentinel-2 Daten. Zugriff: <https://www.mundialis.de/de/deutschland-2020-landbedeckung-auf-basis-von-sentinel-2-daten> [abgerufen am 14.05.2021].
- Richards, J. A.**, 2013: *Remote sensing digital image analysis. An introduction*. Springer, Berlin, New York.
- Riebmayer, G.**; Weinmann, A.; Xu, S.; Eichfuss, S.; Eberz, C.; Neteler, M., 2021a: Germany-wide Sentinel-2 based Land Cover Classification and Change Detection for Settlement and Infrastructure Monitoring. 2021 conference on Big Data from Space (BiDS'2021).
- Riebmayer, G.**; Weinmann, A.; Tawalika, C.; Andreo, V.; Delucchi, L.; Fagandini, R.; Neteler, M., 2021b: Sentinel processing in GRASS GIS: A growing toolset for downloading, preprocessing and multitemporal analysis of Copernicus Sentinel data. Submitted to FOSS4G 2021, Buenos Aires, Argentina.
- Segl, K.**; Bohn, N.; Chabrillat, S.; Neumann, C.; Roessner, S.; Ward, K.; Wolanin, A., 2018: Maschinelles Lernen bei der Auswertung von Fernerkundungsdaten. *System Erde*, 8, 1: 18–25.
- Taubenböck, H.**; Reiter, M.; Dosch, F.; Leichtle, T.; Weigand, M.; Wurm, M., 2021: Which city is the greenest? A multi-dimensional deconstruction of city rankings. *J. Computers, Environment and Urban Systems*, unter Begutachtung.
- UBA – Umweltbundesamt**, 2017: Welchen Beitrag können Satellitenfernerkundung und insbesondere Copernicus-Daten und -Dienste für die Ermittlung ausgewählter Indikatoren des Indikatoren-Sets der Deutschen Anpassungsstrategie an den Klimawandel (DAS) leisten? – Endbericht. *Climate Change* 07/2017.
- UBA – Umweltbundesamt**, 2020: CORINE Land Cover – CLC. Zugriff: <https://www.umweltbundesamt.de/themen/boden-landwirtschaft/flaechensparen-boeden-landschaften-erhalten/corine-land-cover-clc> [abgerufen am 14.05.2021].
- Weigand M.**; Staab J.; Wurm M.; Taubenböck H., 2020: Spatial and Semantic Effects of LUCAS Samples on Fully Automated Land Use/Land Cover Classification in High-resolution Sentinel-2 Data. *International Journal of Applied Earth Observations and Geoinformation*.
- Weidner, U.**; Lemp, D., 2005: Objektorientierte Klassifizierung. In: Bähr, H.-P.; Vögtle, T. (Hrsg.): *Digitale Bildverarbeitung – Anwendung in Photogrammetrie, Fernerkundung und GIS*. Herbert Wichmann Verlag, Heidelberg: 106–122.
- Zhu, Z.**; Zhou, Y.; Seto, K.; Stokes, E.; Deng, C.; Pickett, S. T. A.; Taubenböck, H., 2019: Understanding an Urbanizing Planet: Strategic Directions for Remote Sensing. *Remote Sensing of Environment*. 228, 2019: 164–182.