

Landbedeckungsklassifikation mit neuronalen Netzen – das Projekt DatKI4BKG

**MICHAEL HOVENBITZER¹, EVA-CHRISTINA KATZ¹, PATRICK MERITA¹, MICHAEL WURM²,
HENDRIK ZWENZNER², KONSTANZE LECHNER² & MONIKA GÄHLER²**

Zusammenfassung: Das Bundesamt für Kartographie und Geodäsie (BKG) arbeitet im Projekt „KI-basierte Analyse in der Fernerkundung“ an der Überführung von Anwendungen der Künstlichen Intelligenz (KI) im Bereich Fernerkundung von der Forschung in die angewandte Praxis. Dies unterstützt die Rolle des BKG als Geodatenbroker und Berater für Geodaten sowie -methoden und soll z.B. zu einer schnelleren und genaueren Klassifizierung der Landbedeckung im Rahmen des Projekts DatKI4BKG führen, welches mit dem Deutschen Zentrum für Luft- und Raumfahrt e.V. (DLR) im Auftrag des Bundesministerium des Innern bearbeitet wird.

Konkret wird im Projekt vor allem an zwei Themen gearbeitet: Erstens an der Konzeption und dem Aufbau eines Datenmanagementsystems (DMS) für Fernerkundungsdaten in Form von z.B. DataCubes. Zweitens an der Entwicklung und Anwendung KI-basierter Methoden mit Fokus auf Unterstützung der Erstellung des Landbedeckungsmodells (LBM-DE). Beide Themenblöcke werden so koordiniert und bearbeitet, dass Schnittstellen vorgesehen werden um ein optimales Ineinandergreifen der Komponenten zu ermöglichen. Dies beinhaltet jeweils auch Maßnahmen um den Wissenstransfer an das BKG sicherzustellen.

1 Einleitung

Fernerkundung ermöglicht eine berührungslose und kostengünstige Erfassung vorhandener Objekte auf der Erdoberfläche, wie z.B. Infrastruktur, Gebäude, Vegetation und Wasserflächen. Auch ein Monitoring von Veränderungen in zeitlich und räumlich immer enger werdenden Abständen ist möglich. In den letzten Jahren konnte die Analyse aus Fernerkundungsdaten für viele Zwecke eingesetzt werden, wie beispielsweise das Landmonitoring für den Umweltbereich oder Lagebilder bei Naturkatastrophen.

Für viele Analysefragen der Fernerkundung eignen sich Methoden der künstlichen Intelligenz um bestimmte Entscheidungsstrukturen des Menschen nachzubilden, indem z.B. ein Modell so angelehrt wird, dass es relativ eigenständig konkrete Problemstellungen bearbeiten kann. Künstliche Intelligenz (KI bzw. engl. AI) meint hierbei ein Teilgebiet der Informatik, das sich mit der Automatisierung intelligenten Verhaltens und dem maschinellen Lernen befasst. Die Analyse der Fernerkundungsdaten mit Hilfe dieser Methoden wird immer wichtiger, da Fernerkundungsdaten als Big Data anzusehen sind und mit Hilfe dieser Methoden effizienter analysiert werden können. Big Data meint in diesem Zusammenhang massenhafte Geodaten, die zu groß und zu komplex sind, um sie mit herkömmlichen Methoden der Geodatenverarbeitung analysieren zu können. Im Zuge der technologischen Entwicklung der Sensoren und immens

¹ Bundesamt für Kartographie und Geodäsie, Richard-Strauss-Allee 11, D-60598 Frankfurt am Main, E-Mail: [michael.hovenbitzer, eva-christina.katz, patrick.merita]@bkg.bund.de

² Deutsches Zentrum für Luft- und Raumfahrt, Deutsches Fernerkundungsdatenzentrum (DFD), D-82234 Weßling, E-Mail: [michael.wurm, hendrik.zwenzner, konstanze.lechner, monika.gaehler]@dlr.de

steigenden verfügbaren Datenmengen der Fernerkundung bieten Methoden der KI neue Potenziale, auch Aufgaben und Prozesse in der Bundesverwaltung durch die Auswertung von Erdbeobachtungsinformationen zu unterstützen bzw. ermöglichen erst eine automatisierte Bearbeitung einzelner Aufgaben.

Im Rahmen des Hauptprojekts „KI-basierte Analyse in der Fernerkundung“ wird das Projekt „DatKI4BKG“ durchgeführt, welches über den Rahmenvertrag „IF-Bund“ zwischen dem Bundesministerium des Inneren und für Heimat und dem DLR gefördert wird. Hierbei wird das BKG vom DLR unterstützt. Ziel ist es, das BKG bei der Anwendung von Methoden der KI im Bereich Fernerkundung zu unterstützen und zu befähigen, eigene Fernerkundungsdatensysteme aufzubauen und darauf basierend KI-Analysen durchzuführen. Die entwickelten KI-Methoden sollen dabei auf dynamische Bedarfe, Datenstrukturen und Datentypen übertragbar sein. Die Erdbeobachtungsinformationen sind dabei intelligent zu speichern, zu verarbeiten, bzw. analysieren und mit bestehenden Geodaten zu verknüpfen. Das Projekt zielt darauf ab, die Methoden der künstlichen Intelligenz von der Forschung in die angewandte Praxis zu überführen, so dass diese methodisch neuartige Herangehensweise bei konkreten Verwaltungsaufgaben eingesetzt werden kann. Dies unterstützt die Rolle des BKG als Geodatenbroker und Berater für Geodaten sowie -methoden und soll zu einer schnelleren und genaueren Klassifizierung der Landbedeckungsobjekte führen.

Konkret bearbeitet das DLR vor allem zwei Themen: Erstens die Konzeption und den Aufbau eines Datenmanagementsystems (DMS) für Fernerkundungsdaten in Form von DataCubes und zweitens die Entwicklung und Anwendung KI-basierter Methoden mit Fokus auf Unterstützung der Erstellung des LBM-DE. Beide Themenblöcke werden innerhalb des DLR so koordiniert, dass Schnittstellen und letztlich ein Ineinandergreifen der Komponenten möglich ist. Im letzten Schritt sollen das DMS sowie die KI-Methoden übergeben und das BKG befähigt werden, eigene Kapazitäten in diesen Bereichen aufzubauen.

2 Daten

2.1 LBM-DE

Das Digitale Landbedeckungsmodell beschreibt die topographischen Objekte der Landschaft im Vektorformat. Dabei werden die Aspekte der Landbedeckung (LB) und Landnutzung (LN) betrachtet. Das LBM-DE soll es ermöglichen, den Zustand der Umwelt zu einem bestimmten Zeitpunkt darzustellen. Das LBM-DE wird seit 2009 in einem 3-jährigen Intervall u.a. anhand von Satellitenbildern aktualisiert. Für die Jahre 2015 und 2018 sind sowohl RapidEye-Daten als auch Sentinel-2-Daten und digitale Orthophotos zum Einsatz gekommen, für das Jahr 2021 sind SPOT-Daten und Sentinel-2-Daten genutzt worden. Das LBM-DE beinhaltet 31 Landbedeckungsklassen, welche in Tabelle 1 abgebildet sind (BKG 2020).

2.2 Rapid-Eye

Für die Ableitung des LBM-DE 2015 sowie 2018 mittels KI-Methoden sind Rapid-Eye Daten mit Aufnahmezeitpunkten in der Vegetationsperiode genutzt worden. Die Satellitenbilder liegen in 5 Kanälen (Rot, Grün, Blau, Red Edge und Nahes Infrarot) vor und sind radiometrisch korrigiert sowie orthorektifiziert. Sie besitzen eine räumliche Auflösung von 5m und eine Lagegenauigkeit von 7,5m (BKG 2021).

Tabelle 1: LBM-DE Klassen

Nr.	LBM-DE Klasse	Nr.	LBM-DE Klasse	Nr.	LBM-DE Klasse
1	Bebauung	12	Zwergsträucher (Heide)	22	Sumpf
2	Anlagen	13	Büsche, Sträucher	23	Moor
3	Versiegelte gebäudelose Flächen	14	Aufforstung	24	Sumpf mit Büschen/ Bäumen (< 50%)
4	Mischflächen (regelmäßige Struktur)	15	Laubbäume	25	Moor mit Büschen/ Bäumen (<50%)
5	Ackerland	16	Nadelbäume	26	Watt
6	Weinbau	17	Nadel- und Laubbäume	27	Wasserlauf
7	Obst- und Beerenobst	18	Sand, Steine, Erde	28	Wasserfläche
8	Hopfen	19	Fels	29	Lagune
9	Homogenes Grünland	20	Brandfläche	30	Mündungstrichter
10	Inhomogenes Grünland	21	Schnee (permanent) und Eis	31	Offenes Meer
11	Grasland mit Bäumen (< 50%)				

2.3 SPOT

Für die Ableitung des LBM-DE 2021 sind SPOT6 und SPOT7 Daten eingesetzt worden. Sie liefern hochauflösende natürliche Farb- und Nahinfrarot-Informationen in 12 Bit. Die originale Auflösung beträgt 2m (PAN) und 8m (MS) und wurde durch den Post-Processing- auf 1,5m (PAN) und 6m (MS) verbessert (AIRBUS 2021).

3 Aufbau des Datenmanagementsystems

Im Rahmen des Projekts “DatKI4BKG” soll ein Prototyp eines Datenmanagementsystems entwickelt werden. Das System soll dabei optimal an den Anforderungen eines KI-basierten Klassifikationsansatzes des LBM-DE orientiert sein. Die Anforderungen sind im Wesentlichen die Integration von Fernerkundungsdaten und abgeleiteten Informationsprodukten. Die Ermöglichung eines effizienten Datenzugriffs für KI-Analysen in Form von DataCubes. Eine effiziente Datensuche durch die Bereitstellung von Produktmetadaten sowie eine effiziente Datenspeicherung durch verteilte Datenhaltung. Wichtig ist ebenfalls eine Bereitstellung von Visualisierungs- und Download-Diensten.

Um einen effizienten Datenaustausch zwischen dem DMS und den KI-Analysesystem (AIDE – Artificial Intelligence Development Environment) zu gewährleisten, müssen beide Komponenten gut integriert sein und über standardisierte Schnittstellen miteinander kommunizieren können. Abbildung 1 zeigt schematisch, wie DMS und AIDE in ein Gesamtsystem eingebettet sind. Beide Komponenten werden idealerweise in einem Datenzentrum betrieben, dessen Hardwareressourcen mittels Kubernetes abstrahiert sind und eine Container-basierte Installation ermöglichen. Diese Schicht wird vom IT-Provider des Datenzentrums bereitgestellt und administriert. Das DMS und AIDE kommunizieren über verschiedene Schnittstellen (S3, STAC und HTTP). Im AIDE werden die KI-Methoden und die zugehörige Software von einem Data Scientist entwickelt, installiert und administriert. Die Software und Geodatendienste des DMS werden vom Service Provider entwickelt, installiert und administriert. Das DMS stellt zudem Datenworkflowdienste bereit, die der Data Integrator nutzt um automatisierte Arbeitsabläufe zu entwickeln um die Eingangsdaten entsprechend den Anforderungen des AIDE und mit Hilfe des Data Scientist aufzubereiten.

Die Validierung und der Zugriff auf die Eingangsdaten sowie der abgeleiteten Ergebnisdaten erfolgt über eine Service API, die mittels Geodatendiensten den Operatoren zur Validierung, Optimierung und Weiterverarbeitung sowie externen Systemen (Data User / Validator, External Systems) den Zugriff ermöglichen.

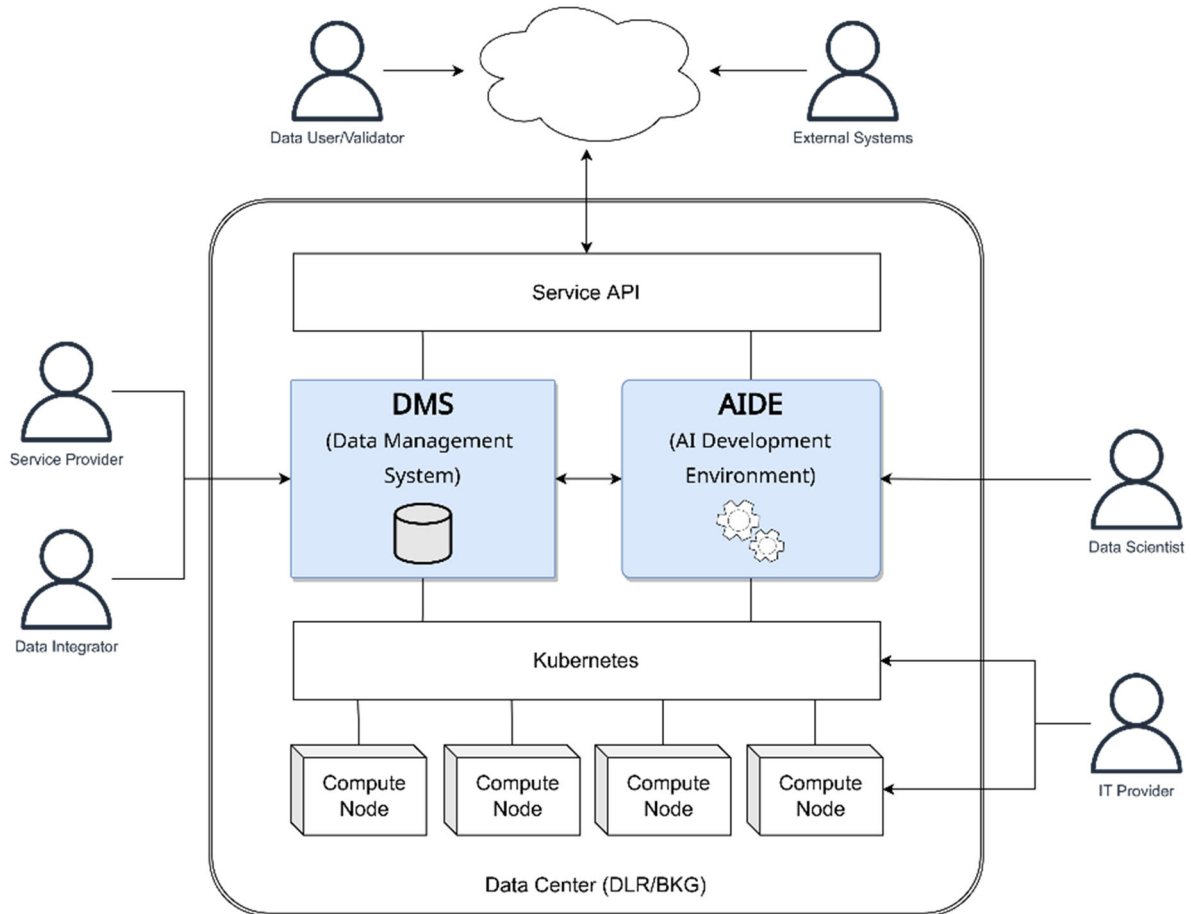


Abb. 1: Interaktion und Einbettung der beiden zu entwickelnden Komponenten DMS (Data Management System) und AIDE (Artificial Intelligence Development Environment) mit den zu erwartenden interagierenden Rollen

Das Design des DMS ermöglicht den Nutzern und insbesondere dem AIDE den Zugriff auf bereitgestellten Daten über Standardschnittstellen, sowie dem AIDE zusätzlich eine Möglichkeit optimierte und prozessierte Daten wieder ins DMS zu registrieren. Das Design ist in Abb. 2 dargestellt und besteht aus fünf Komponenten, die im Folgenden näher beschrieben werden.

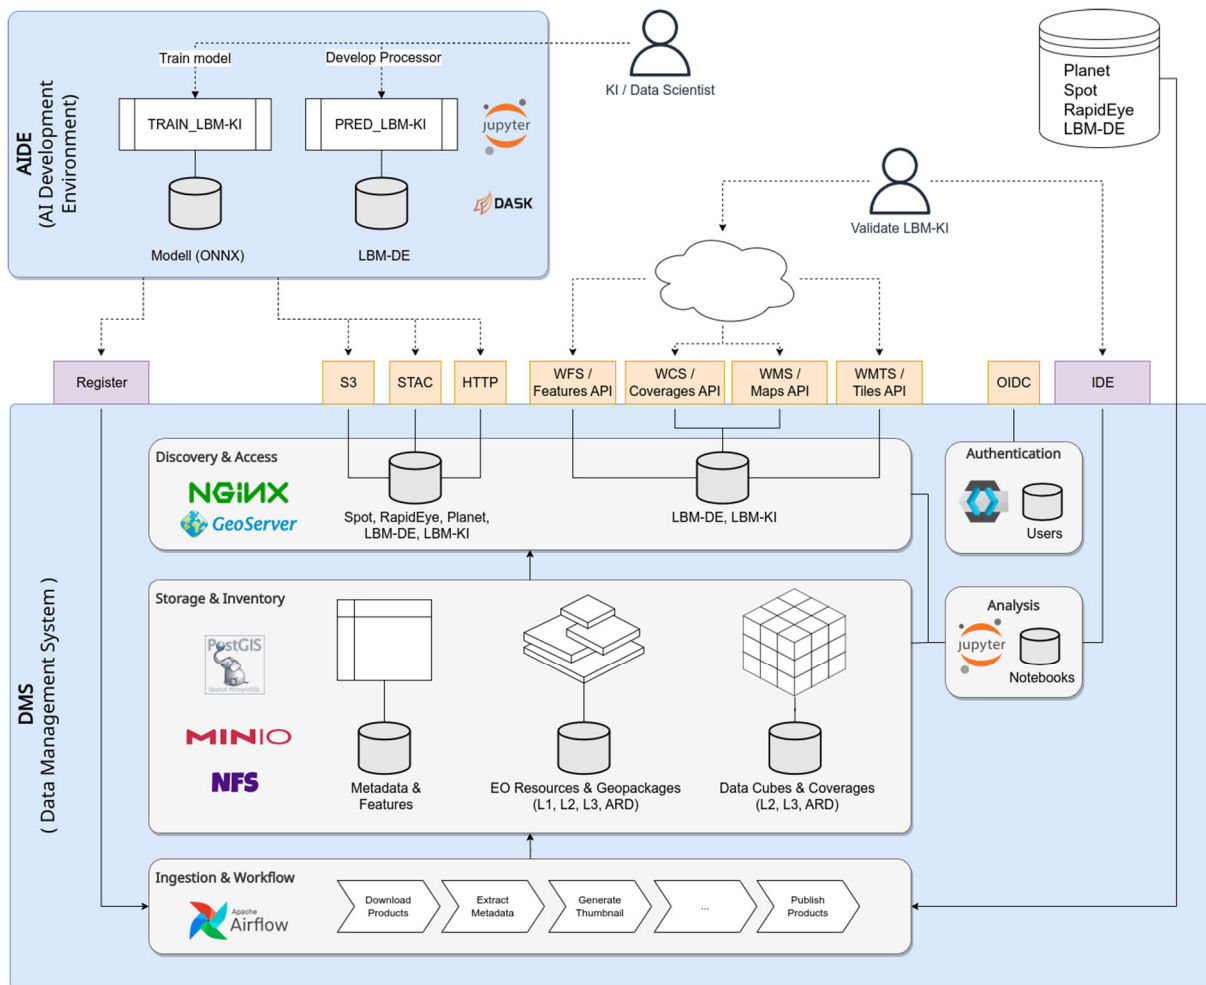


Abb. 2: Design des DMS mit den einzelnen funktionalen Komponenten sowie Schnittstellen zum AIDE und zu den Nutzern

3.1 Ingestion & Workflow

Die erste Komponente "Ingestion & Workflow" ist verantwortlich für die systematischen Abläufe, die im Wesentlichen das Laden und Aufbereiten der Daten ins DMS implementieren. Der Ablauf ist dabei in der Regel gleich. Allerdings gilt es dabei Datensatz-spezifische Eigenheiten zu berücksichtigen. Z.B. sind beschreibenden Metadaten innerhalb der Datensätze unterschiedlich und müssen daher mit speziellen Verfahren ausgelesen werden, um sie dann in dem DMS für Nutzer einheitlich such- und darstellbar zu machen. Gleiches gilt auch für die Datensätze, die mittels der Abläufe in ein Standardformat gebracht werden und die optimiert für den Zugriff in der nachfolgenden Komponente abgelegt werden. Generell werden folgende Schritte pro Datensatz systematisch durchlaufen, wobei es natürlich zu Abweichungen durch die Eigenheiten des speziellen Datensatzes kommen kann:

1. Kopieren der Dateien eines Datensatzes von einer externen Quelle in den internen Bereich des DMS
2. Entpacken und strukturiertes Ablegen der Eingangsdaten in den Speicherbereich des DMS, der für die Auslieferung und Bereitstellung über HTTP bzw. S3 freigegeben ist.
3. Für die dynamische Visualisierung über Standarddienste (WMS/WMTS, WFS, WCS) findet zusätzlich eine Konvertierung der raster-basierten Datensätze in zugriffsoptimierte Formate mit auflösungsreduzierten Bildpyramiden statt; vektorbasierte Datensätze werden zur

performanten Filterung und Darstellung in raumzeitlichen Datenbanken (PostgreSQL/PostGIS) eingefügt und ggf. für kleinskalige Darstellung simplifiziert.

4. Extraktion und Vereinheitlichung der Metadaten in ein Standardformat (STAC)
5. Generierung eines visuellen Bildes des Datensatzes ("Quicklook") zur Darstellung in einem Katalog
6. Raumzeitliche Indizierung und Publizierung des Datensatzes in einem DataCube.

Die "Workflow & Ingestion" Komponente ist mit Airflow und GDAL implementiert. Neben dem statischen (einmaligem) Laden von Daten sind auch regelmäßige Abläufe (z.B. 1-mal am Tag) und extern gesteuerte Ausführungen möglich, um z.B. durch AIDE generierte Daten zu registrieren.

3.2 Storage & Inventory

Die zweite Komponente "Storage & Inventory" ist verantwortlich für die Speicherung der Originaldaten, sowie der aufbereiteten Datensätze. Die optimierten und harmonisierten Datensätze werden dabei in Dateispeichersysteme wie NFS (Network File Storage) und dem objektbasierte S3 (Simple Storage Service) gespeichert. Jeder Datensatz wird raum-zeitlich indiziert und mit Metadaten und Quicklooks in einer PostGIS-basierten Datenbank abgelegt. Zusätzlich zu den Metadata werden auch Vektordaten (Features) wie das LBM-DE und das KI-optimierte „LBM-KI“ für die effiziente Filterung, Analyse und Darstellung in PostGIS gespeichert.

3.3 Discovery & Download

Die dritte Komponente "Discovery & Access" stellt die Datendienste und standardisierten Schnittstellen bereit, um auf die im DMS gespeicherten Datensätze zuzugreifen. Diese sind in Abb. 3 dargestellt:

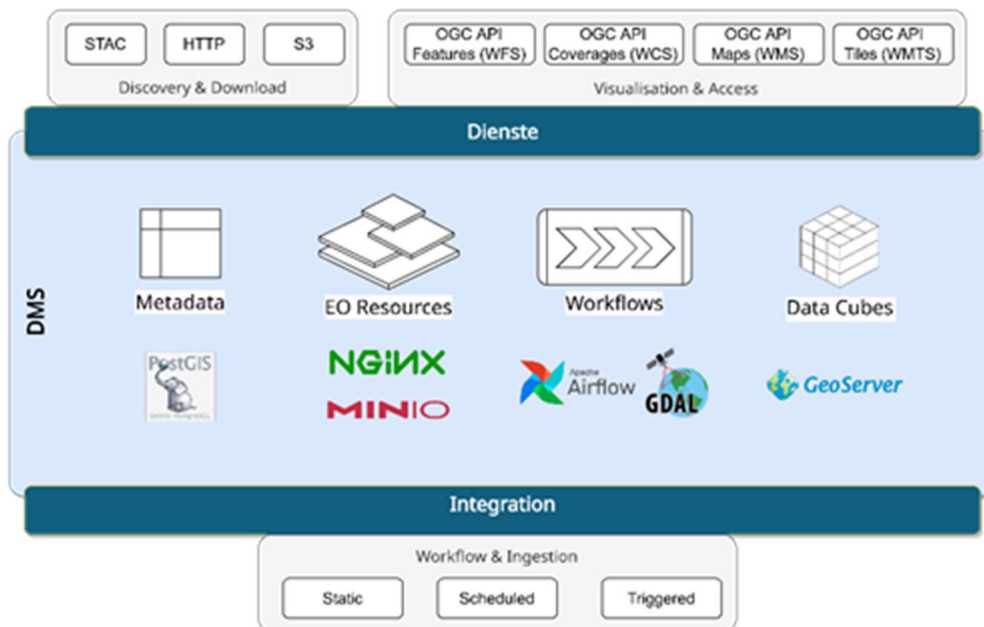


Abb. 3: Standardisierte Schnittstellen und verwendete Softwarekomponenten des DMS

1. Visualisierung: Die Darstellung der Daten wird über Web Map Service (WMS), Web Map Tile Service (WMTS) sowie experimentell über die OGC Map / Tile API ermöglicht. Hierbei handelt es sich nur um eine visuelle Repräsentation der Daten in Bildformaten (jpeg, png), nicht um die originalen Raster- oder Vektordaten.

2. Zugriff: Die Extraktion der originalen Raster- oder Vektordaten wird entsprechend über Web Coverage Service (WCS) und Web Feature Service (WFS) Schnittstellen ermöglicht. Damit lassen sich raumzeitlich Ausschnitte der Daten extrahieren und nahtlos in bestehende GIS-Systeme (QGIS, ArcGIS) einbetten.
3. Suche: Die effiziente Suche nach Datensätzen und deren einzelnen Szenen bzw. Kacheln ist über die Spatio-temporal Asset Catalog (STAC) Schnittstelle umgesetzt. Damit können geeignete Datensätze nach spezifischen Eigenschaften gefiltert werden und in externe Systeme (wie dem AIDE) für die Weiterverarbeitung heruntergeladen werden.
4. Download / Streaming: Der Zugriff auf die Daten erfolgt innerhalb des DMS über lokale Dateisysteme. Für externe Systeme stellt das DMS die Daten über HTTP (oder S3) zum Download bereit.

3.4 Authentication

Die Authentifizierungskomponente im DMS basiert auf der Open-Source Software Keycloak. Diese ermöglicht das Verwalten der Nutzer und bietet mit der OpenID Connect (OIDC) eine Schnittstelle für die Integration in die anderen DMS Komponenten. In der aktuellen Implementierung wird sie zur Absicherung der Analyse Komponente eingesetzt.

3.5 Analysis

Authentisierte Nutzer können über die Analysekomponente des DMS direkt innerhalb des DMS Daten suchen, visualisieren, weiterverarbeiten und analysieren. Dafür steht ihnen eine Python-basierte Integrierte Entwicklungsumgebung (IDE) auf Basis von JupyterLab zu Verfügung. Die Implementierung dieser Dienste erfolgt im DMS Prototypen durch die Open-Source Software GeoServer (Visualisierung, Zugriffs, Suche), Nginx (Download / Streaming), Keycloak (Authentifizierung) und JupyterLab (Analysis).

3.6 Datenintegration

Für die Datenintegration wird jeder Datensatz einzeln betrachtet, da es sich um heterogene Datensätze handelt. Wichtige Aspekte sind die Metadaten, Datentypen, Datenformate und in welchen Zieldiensten die Daten später bereitgestellt werden sollen. Die nötigen Bearbeitungsschritte werden in einem Workflow, ein versionierter, datensatzspezifischer Arbeitsablauf, zusammengefasst und können statisch, zeitlich planmäßig oder getriggert ausgeführt werden. Die Konfigurierung findet im Text-format (YAML) und die Versionierung über Git statt.

Im Fall der DatKI4BKG-Rasterdaten ist eine Transformation der Daten in das Cloud Optimized GeoTIFF (COG)-Format nötig, die Anreicherung und Extraktion der Metadaten, das Erstellen von Thumbnails und Quicklooks, die Erstellung der STAC-Metadaten und im letzten Schritt die Veröffentlichung über die verschiedenen Dienste. Diese STAC-Metadaten werden über einen STAC-Catalog, in Verbindung mit einem Downloaddienst und Geoserver bereitgestellt.

4 Ableitung des LBM-DE mittels KI-Methoden

Unter dem Überbegriff KI fallen eine Vielzahl an Verfahren zur Datenverarbeitung. Unter aktuellen KI-Verfahren werden vor allem jene Methoden aus dem Themenfeld sogenannter Convolutional Neural Networks (CNN) (LECUN et al. 1999) verstanden, welche auch unter dem

Begriff "Deep Learning" bekannt sind. CNNs finden etwa seit 2015 in der Wissenschaftscommunity breiten Anklang und werden seither kontinuierlich weiterentwickelt (HOESER & KUENZER 2020). Diese Verfahren des Deep Learnings haben in kürzester Zeit tradierte Bildanalyseverfahren und Konzepte abgelöst und werden in einer Vielzahl an unterschiedlichen Anwendungen genutzt, wie beispielsweise zur Detektion von Gebäuden (WURM et al. 2021) oder Erkennung von informellen Siedlungen (Wurm et al. 2019). So ist es auch zu erklären, dass heute z.B. pixelbasierte Verfahren der semantischen Segmentierung objektbasierten Bildanalyseverfahren in der Landbedeckungsklassifikation als überlegen zu bezeichnen sind (HAO et al. 2020).

Im Rahmen des Projekts DatKI4BKG bestehen aufgrund verschiedener Faktoren extrem hohe Anforderungen an das KI-Modell, da das Modell in der Lage sein muss, auf sehr große räumliche Gebiete (Bundesrepublik Deutschland) angewendet zu werden und Daten einer hohen Pixelauflösung verarbeiten muss. Zusätzlich existieren im LBM-DE eine sehr große Vielfalt semantischer Klassen, welche teilweise nur sehr schwer alleine durch ihre spektrale Signatur in optischen Satellitenbilddaten belastbar erkannt werden können. Üblicherweise werden automatisierte KI-Verfahren in der fernerkundungsgestützten Bildanalyse für wesentlich kleinräumigere Gebiete oder einer deutlich geringeren Klassenanzahl entwickelt. Die Entwicklung eines belastbaren und generalisierbaren KI-Verfahrens im aktuellen Projektkontext stellt daher eine intensive wissenschaftliche Herausforderung dar, da es keine vorgefertigten "Out-of-the-box"-Verfahren gibt, welche die projektspezifischen Herausforderungen adressieren können. Insgesamt wurde eine große Anzahl an KI-Verfahren bzw. Einstellungen sowie deren Parameter empirisch getestet und eine erste Vorauswahl getroffen.

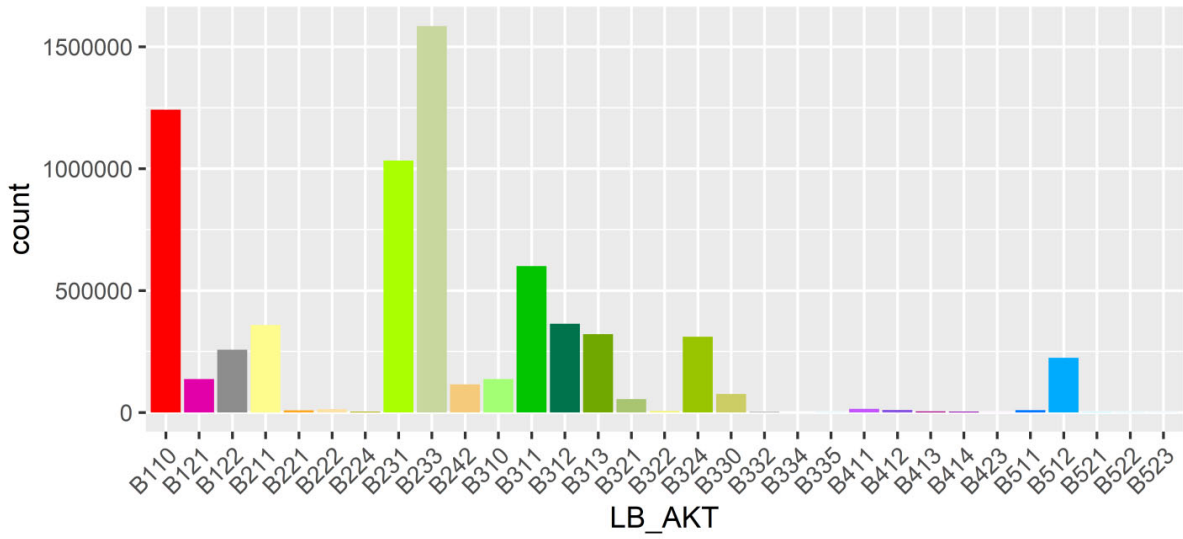
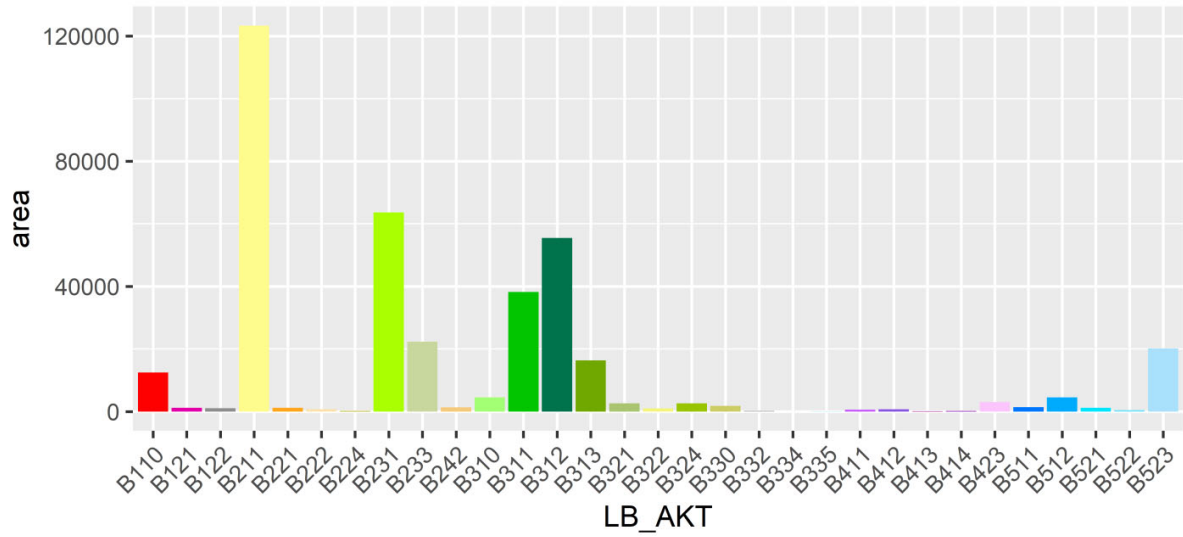
4.1 Aufbereitung der Referenzdatensätze

Zu Beginn ist es erforderlich, die existierenden Datenbestände (Fernerkundungsdaten & LBM-DE) des BKG zu erfassen und strukturiert aufzuarbeiten, um sie für Training, Validierung und Test der KI-Methoden verwendbar zu machen. Ein besonderes Augenmerk liegt hierbei auf der Konsistenz der Daten bezüglich räumlicher und semantischer Genauigkeit zwischen Satellitenbildern und Vektordaten des existierenden LBM-DE.

Im Projekt DatKI4BKG stehen von BKG Seite verschiedene Satellitenbilddatensätze im Original und flächendeckend sowie Referenzdatensätze für Deutschland zur Verfügung. Die Referenzdaten sind dabei die Landbedeckungsmodelle von Deutschland aus den Jahren 2015, 2018 und 2021.

Die Datenstruktur der LBM-DE Zeitstände ist weitgehend vergleichbar und sie weisen jeweils 11 Merkmale auf (IDs, thematische Klassen, geometrische Merkmale). Die LBM-DE Datensätze werden in weiterer Folge für die Modellbildung und die Validierung der Klassifikationsergebnisse der maschinellen Lernverfahren (KI-Modelle) genutzt. In diesem Zusammenhang ist es vorteilhaft, die a priori Häufigkeitsverteilung ('count') bzw. Flächenanteile ('area') der einzelnen Landbedeckungsarten zu kennen.

Nachfolgend sind in Abb. 4 die a priori Häufigkeitsverteilung ('count') und Flächenanteile ('area') für die einzelnen Landschaftsklassen der LBM-DE 2015 und 2018 dargestellt. Es wird beispielsweise deutlich, dass die Klasse B110 „Bebauung“ sehr häufig in Deutschland vorkommt, aber nur einen geringen Flächenanteil ausmacht. Die Klasse B211 „Ackerland“ dagegen kommt nicht so häufig vor, bedeckt aber von allen LBM-DE Klassen deutschlandweit die meiste Fläche.






Abb. 4: A priori Häufigkeitsverteilung ('count') und Flächenanteile ('area') für LBM-DE 2015 und 2018

4.2 Aufbereitung der Satellitendaten für Training, Test und Validierung von KI-Methoden

Für die Entwicklung des KI-Modells wurde zunächst ein initiales Basismodell für das Referenzjahr 2015 erstellt. Für diesen Zeitschnitt liegen Satellitendaten von RapidEye und das Landbedeckungsmodell im Vektorformat vor. Für die Nutzung der Vektordaten als Referenzdaten für die pixelbasierte Klassifikation wurde eine rasterisierte Version des Landbedeckungsmodells in der geometrischen Auflösung des RapidEye Datensatzes erstellt. Dieser Datensatz dient als Grundlage für Training, Test und Validierung des trainierten KI-Modells.

Die RapidEye-Satellitendaten liegen als > 800 einzelne Bildszenen mit einer Größe von 25x25 km vor. Für die Erstellung eines generalisierbaren sowie räumlich und zeitlich übertragbaren KI-Modells, wird die Grundgesamtheit an verfügbaren Szenen in drei Teilmengen für Trainings-, Test- und Validierungsdaten aufgeteilt (Abb. 5). Nachdem Mehrfachbelegungen einzelner Szenen und unvollständige Szenen gefiltert wurden, blieben 753 Szenen übrig, die wie folgt aufgeteilt wurden:

- 527 Training (70%)
- 113 Validation (15%)
- 113 Test (15%)

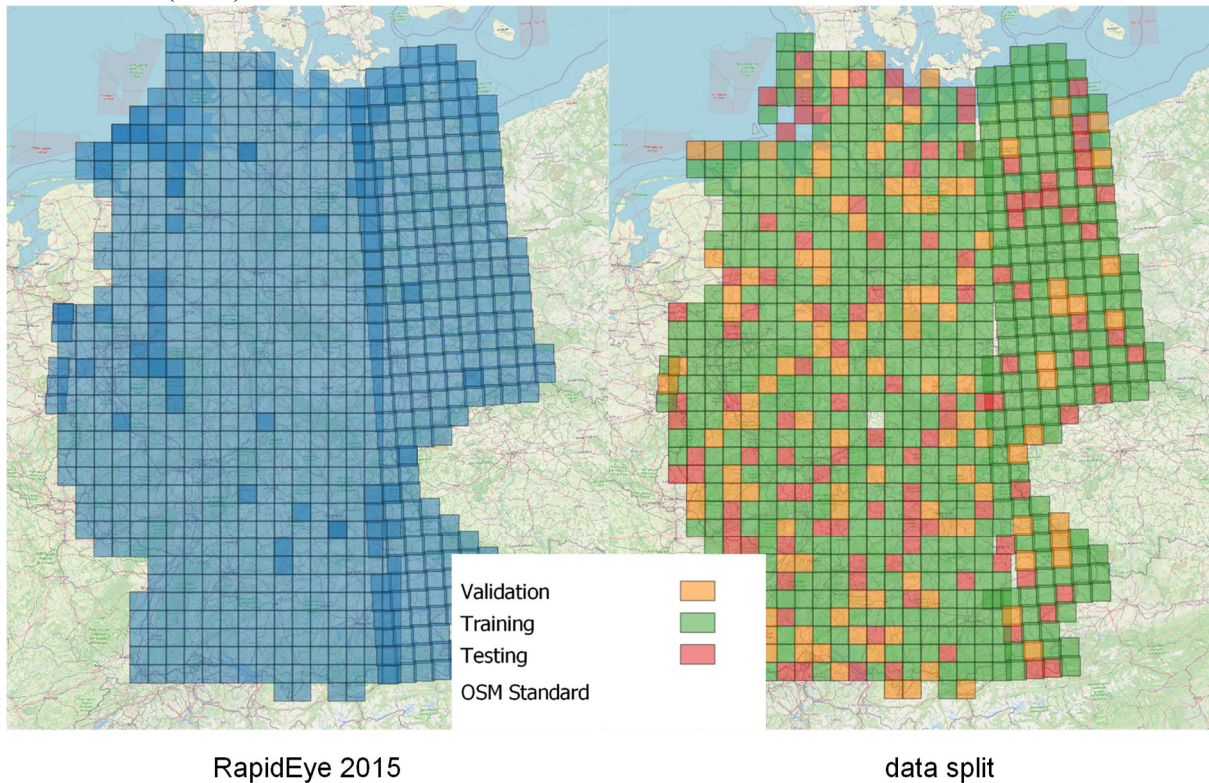


Abb. 5: Aufteilung der RapidEye Szenen für das Jahr 2015 in Trainings-, Test- und Validierungsdaten

Die Aufteilung kann dabei durch eine Zufallsstichprobe erfolgen, oder durch die gezielte Auswahl von bestimmten Szenen. Insbesondere im Falle des LBM-DE ist dabei zu berücksichtigen, dass bestimmte Landbedeckungsklassen nicht räumlich gleich über das gesamte Gebiet verteilt sind und auch eine sehr unterschiedliche Häufigkeitsverteilung zwischen den LBM-DE Klassen besteht (Abb. 6 und Abb. 7).




Abb. 6: Häufigkeitsverteilung der einzelnen LBM-DE Klassen nach Aufteilung der Szenen in Trainings-, Test- und Validierungsdaten. N.B.: Die Ordinate ist logarithmisch skaliert.

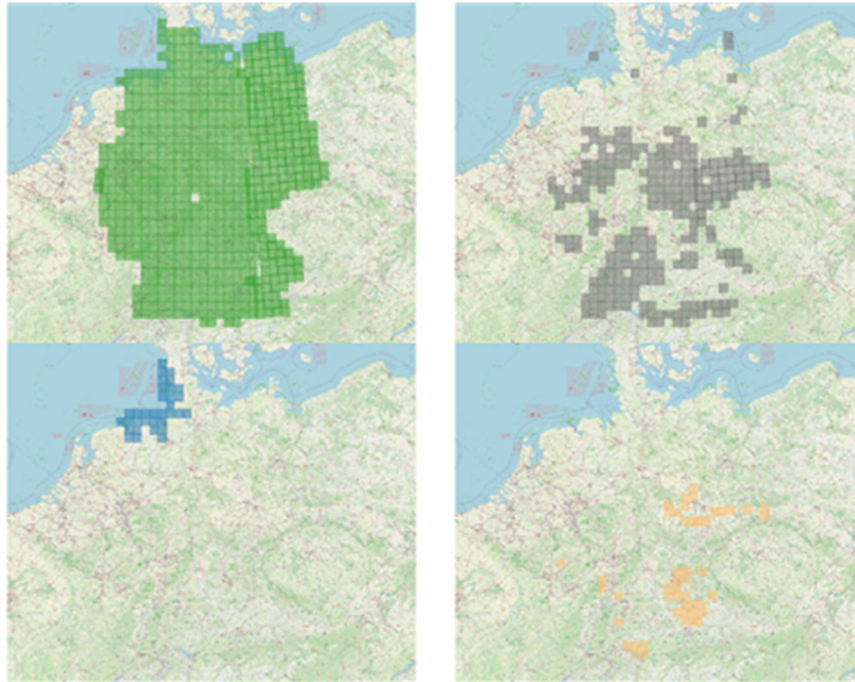


Abb. 7: Vorkommen ausgewählter LBM-DE Klassen in RapidEye Szenen: links oben: Laubbäume, rechts oben: Fels, links unten: Watt, rechts unten: Hopfen

4.3 Initiales Trainiertes KI-Modell für ausgewählte LBM-DE Klassen

Auf Basis der Trainings-, Test- und Validierungsdaten wurden verschiedene Einstellungen und Parameter für das KI-Modell empirisch getestet. Um möglichst große Vergleichbarkeit der einzelnen Experimente zu gewährleisten, wurde stets die gleiche Datengrundlage für das Modelltraining und die Validierung genutzt. Die Daten zur Validierung und zum Test gingen nicht in das Modelltraining ein, damit die Bewertung der Prädiktion des Modells auf unabhängigen Daten durchgeführt werden kann. Bei den einzelnen Experimenten wurden unterschiedliche Datensamples (Stichproben für die Aufteilung in Training, Test und Validierungsdaten), sowie unterschiedliche Hyperparameter für das Modell getestet: z.B. Lernraten (engl. learning rates), epochs drop, Anzahl der Epochen, die Lossfunktion und die Datenaugmentierung. In Tabelle 2 sind die Parameter für das initiale KI-Modell angegeben.

Tabelle 2: Parameter für das initiale KI-Modell

Da- tensampling	Datensplit	Klassen	Learning rate	Epochs drop	Encoder/ decoder	Epochen	Loss Funk- tion
Random D (fil- tered overlaps 60%)	527, 113, 113	31+1	0.001 warm up training 1e-8	20	ResNet FPN	67	CE (label smoothing)

Das KI-Modell besteht aus zwei Hauptelementen, dem Encoder und dem Decoder, für beide existieren in der aktuellen Forschungslandschaft eine große Auswahl an unterschiedlichen Möglichkeiten die miteinander kombiniert werden können (HOESER & KUENZER 2020). Aufgrund bestehender Erfahrungswerte bezüglich der Performanz aber auch hinsichtlich der Zeit, die für das Modelltraining benötigt wird, wurde eine Kombination aus Resnet50 (Encoder) (HE

et al. 2015) und Feature Pyramid Network (FPN) (Decoder) (LIN et al. 2017) gewählt. Resnet50 besteht aus 50 Faltungslayern und hat sich in der Praxis als Encoder etabliert aufgrund der sehr guten Performance als Feature extractor. Sogenannte Residual Connections (Verbindungen zwischen den Faltungslayern) propagieren Signale an tiefere Layer, hierdurch kann eine größere Anzahl an Layern trainiert werden. FPN verarbeitet die Feature Maps verschiedener Auflösungen des Resnets (blau, grün, rot, gelb) durch stufenweises Upsampling (Verdoppelung) auf die nächstgrößere Auflösung und Verrechnung mit den Feature Maps der entsprechenden Auflösungsstufe. Hierdurch wird eine Balance zwischen der höheren semantischen Genauigkeit der schwächer aufgelösten Feature Maps und der höheren geometrischen Genauigkeit der höher aufgelösten Feature Maps erzielt. Vor allem für die großflächige Anwendung von Landbedeckungsklassifikationen kommt der Automatisierung ein erheblicher Stellenwert zu, da die vor-trainierten Modelle sehr rasch für die Prädiktion auf neuen Daten verwendet werden können. Die Schnelligkeit des Verfahrens wird dabei vor allem von der verwendeten IT-Infrastruktur beeinflusst. Maßgeblich ist dabei die verwendete Grafikkarte. Auf einer in performanten Desktop-PCs benutzten Grafikkarte benötigt das Modelltraining etwa 60-75 Stunden und die Prädiktion weniger als eine Stunde. Es kann daher davon ausgegangen werden, dass bei performanteren Grafikkarten auch die Geschwindigkeit für die Trainingsprozesse beschleunigt werden kann.

4.4 Ergebnisse

In einem exemplarischen Ausschnitt in Abb. 8 werden Satellitenbild, Referenz (LBM-DE) und KI-Modell basierte Vorhersage gegenübergestellt. Das Modell weist für die große Klassenanzahl und die oben bereits beschriebenen Herausforderungen (Pixelgröße, spektrale Differenzierung einzelner Landbedeckungsklassen in den Satellitenbilddaten etc.) bereits hohe Genauigkeiten auf. Es muss an dieser Stelle jedoch ausdrücklich darauf hingewiesen werden, dass diese Genauigkeitsabschätzung nur für das initiale KI-Modell steht und lediglich als Richtschnur für die weiteren Entwicklungen dient. So ist beispielsweise bereits weiterhin angedacht, dass bestimmte, spektral sehr ähnliche Landbedeckungsklassen aggregiert werden, bzw. dass für Landbedeckungsklassen mit besonders geringen Häufigkeiten (z.B. Brandflächen) keine ausreichende Anzahl an Trainingspixel zur Verfügung steht und eine Vorhersage dieser Klassen mittels KI-Verfahren nicht als sinnvoll erachtet wird.




Abb. 8: Exemplarischer Ausschnitt des RapidEye Satellitenbildes 2015 [rechts], des BKG LBM-DE 2015 (Referenz) [Mitte] und der von KI-Modell berechneten LBM-DE Klassen [rechts]

4.4.1 Initiale klassenbasierte Genauigkeitsabschätzung eingesetzter Verfahren zur Klassifikation von LBM-DE

Für die Genauigkeitsabschätzung von Klassifikationsergebnissen hat sich in der fernerkundungsgestützten Bildverarbeitung und im Gebiet des maschinellen Lernens die Herstellung einer Konfusions- oder Errormatrix etabliert (TERVEN et al. 2023). Dabei wird für jedes Ausgabepixel der Klassifikation der Klassenwert mit dem Klassenwert des Pixels der Referenzdaten abgeglichen. Die Referenzdaten sind in diesem Fall das existierende LBM-DE mit seinen Objektklassen. Damit die Objektklassen und die pixelbasierte KI-Klassifikation verglichen werden können, wurden die Objekte des LBM-DE auf Pixel heruntergebrochen, d.h. jedem Pixel wurde ein entsprechender Wert des LBM-DE zugewiesen.

Übereinstimmungen zwischen Ergebnis der Modellprädiktion (KI-Verfahren) und Referenz (LBM-DE) werden dabei in der Diagonalen der Matrix (rot umrandet) dargestellt. Abweichungen werden in den anderen Zellen dargestellt. Auf Basis dieser Konfusionsmatrix können weitere Genauigkeitswerte bestimmt werden, die dabei helfen, Über- sowie Unterklassifikationen einzelnen Klassen zu bestimmen. Abb.9 zeigt die Errormatrix des initialen KI-Modells und die daraus resultierenden klassenbasierten Genauigkeiten. Man sieht beispielsweise, dass Klasse 1 „Bebauung“ zu 87,3% mit dem Referenz-LBM-DE übereinstimmt, während Klasse 22 „Sumpf“ nur zu 26,8% übereinstimmen. Insgesamt wurden die Klassen wie Bebauung (1), Ackerland (5) und Watt (26) sehr gut klassifiziert, während Klassen wie „Büsche und Sträucher“ (13), „Nadel- und Laubbäume“ (17) und „Moor mit Büschen/Bäumen (<50%)“ (25) eher schlecht oder gar nicht aufgrund ihrer spektralen Signatur in den Satellitenbilddaten erkannt wurden.




Abb. 9: Konfusionsmatrix des initialen KI-Modells

4.4.2 Postprocessing

Die Gesamtgenauigkeit des Modells kann zusätzlich erheblich gesteigert werden durch signifikante Verbesserungen im Postprocessing des KI-Modells. Dafür wurde einerseits ein Workflow entwickelt, welcher die Datenbereiche, welche ohne Bildinhalt oder Referenz vorliegen ("no data") sowohl aus Modelltraining, als auch -validierung und -test exkludiert. In diesem Kontext wurde auch die Mehrfachüberlappung der einzelnen Kacheln bei Schritt der Klassifikation implementiert. Durch die Mehrfachüberlappung im Sinne eines "Moving Window Ansatzes" können vor allem Randbereiche der Bildkacheln, in denen naturgemäß weniger Kontextinformation vorhanden ist, stabiler klassifiziert werden, da somit jedes Pixel bis zu 9 mal und mehrheitlich mit mehr Kontextinformation klassifiziert wird. Die finale Klassifikation wird durch die am häufigsten vorkommende Klasse gebildet. Hierdurch konnte die Gesamt-klassifikationsgenauigkeit erhöht und ein stabileres Klassifikationsergebnis erzielt werden.

4.4.3 Übertragung zwischen den Zeitschnitten

Ein wichtiger Schritt um die Generalisierungsfähigkeiten der KI-Modelle zu quantifizieren, ist eine Bewertung der Güte der Modelle, welche lediglich mit Daten eines Zeitschnitts trainiert wurden, bei der Klassifikation von Satellitendaten eines anderen Zeitschnitts. Bei der Auswertung mit Daten aus 2017, konnte sowohl für die Modelle, welche mit Daten von 2015 trainiert wurden, sowie jenen welche mit Daten aus 2017 trainiert wurden sehr gute Ergebnisse erzielt

werden. Die Ergebnisse unterscheiden sich in ihrer Güte nur minimal voneinander. Somit konnte verifiziert werden, dass die generierten KI-Modelle unabhängig vom Zeitschnitt der RapidEye Daten zuverlässig LBM-DE Klassen ableiten können. Dies lässt sich als erster notwendiger Schritt für die mögliche Übertragung und Anwendbarkeit der generierten Modelle auf andere Sensordaten einordnen. Durch die bereits erwähnten Weiterentwicklungen in Post-processing und den, im folgenden Abschnitt beschriebenen, methodischen Weiterentwicklungen konnten die Modellgüten erheblich verbessert werden (siehe Tabelle 4).

Tabelle 4: Güte der neuen KI-Modelle im Vergleich zum Frühjahr (Originaldaten)

Auswertung	Training data	Test data	Stand Frühjahr	Neuer Stand
Pixel OA [%]	2015	2015	80,24 %	85,13 %
Pixel OA [%]	2017	2017	77,70 %	84,65 %
Pixel OA [%]	2015	2017	75,51 %	83,92 %

4.4.4 Klassifikation auf Polygonebene

Ein weiterer wesentlicher Schritt bei der Analyse der Klassifizierungsergebnisse der KI-Methoden, welche reine Pixelvorhersagen generiert, ist eine Aggregation der generierten Klassifikation auf die Polygonebene um eine bessere Vergleichbarkeit mit dem LBM-DE Datensatz zu schaffen, welcher ebenfalls ein generalisierter Polygondatensatz ist. Für die Aggregation werden die Geometrien aus dem LBM-DE herangezogen und klassifiziert, indem alle in einem Polygon liegenden klassifizierten Pixel betrachtet werden und der am häufigsten vorkommende Klassenwert dem Polygon zugeordnet wird. Beim Vergleich der aggregierten Flächen mit den Flächen des LBM-DE, zeichnet sich eine noch stärkere Übereinstimmung ab, welche in einer signifikant verbesserten Genauigkeit resultiert (siehe Tabelle 5).

Tabelle 5: Auswertung der Klassifikation auf Polygonebene

Auswertung	Training data	Test data	Overall Accuracy
Pixel	Train 2015	Test 2015	85,13 %
Polygone	Train 2015	Test 2015	89,15 %

In Abb. 10 sind einige beispielhaften Abbildungen prädizierter Szenen dargestellt.

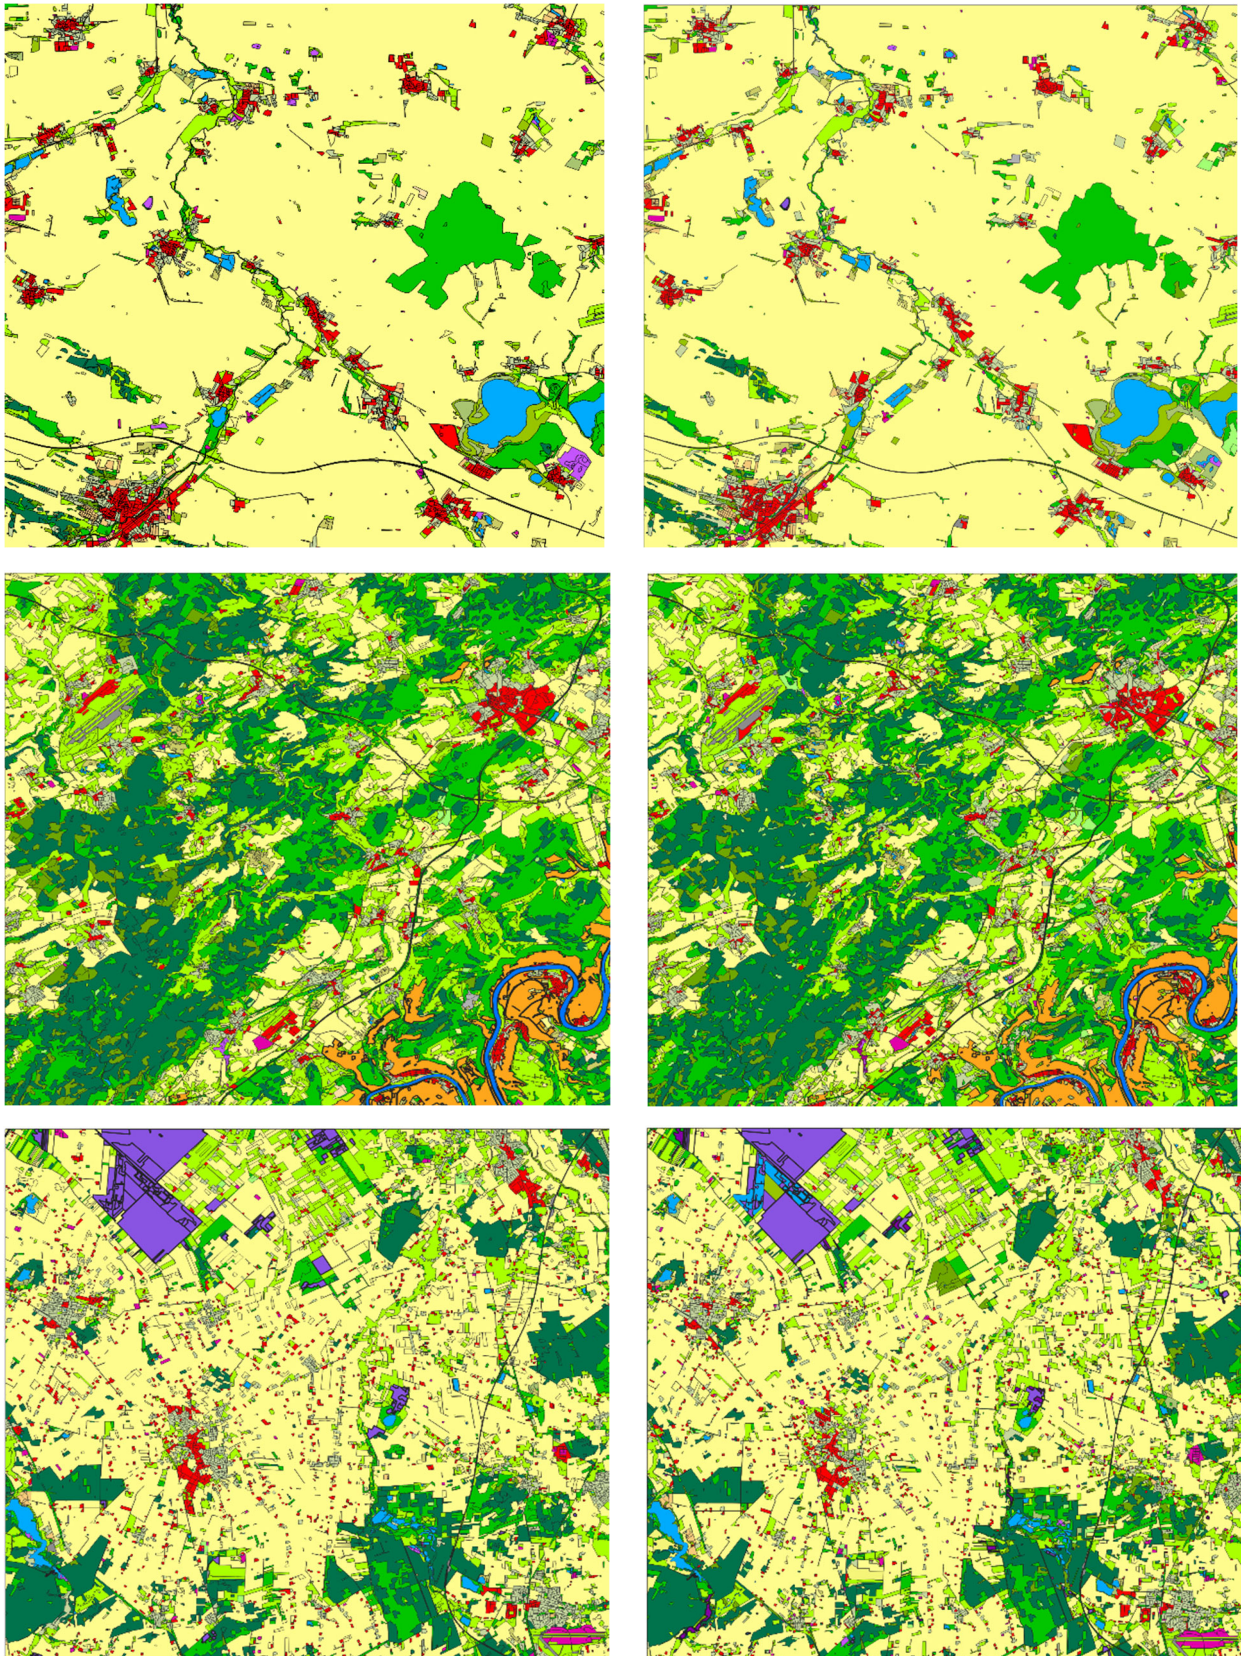


Abb.10: Klassifizierte RapidEye Szenen (links LBM-DE Referenz, rechts aggregierte Klassifikation)

4.4.5 Übertragung auf SPOT

Im Rahmen des Projekts wird zusätzlich die Modellübertragbarkeit auf Daten eines anderen Sensortyps evaluiert. Speziell getestet wurde in diesem Zusammenhang die Übertragbarkeit

der RapidEye-Modelle auf SPOT-Daten. Da der bisher erarbeitete Workflow gezielt auf die Kompatibilität der RapidEye-Daten ausgerichtet war, mussten zusätzlich einige Faktoren in Vorbereitung des Übertrags der Deep Learning Routine auf die SPOT-Daten berücksichtigt und dementsprechende Anpassungen durchgeführt werden. Es fanden Anpassungen hinsichtlich der Szenengröße und Szenenüberlappung statt. Berücksichtigt wurden auch die unterschiedlichen Grauwerte der jeweiligen Datensätze. Ebenfalls wurden Wolken maskiert.

Anschließend an die Vorbereitung der Daten und der Trainings-Umgebung für Modelltransfer wurden mehrere Experimente durchgeführt, um die Machbarkeit des Transfers überprüfen zu können. Alle Experimente wurden für die Sicherstellung der Vergleichbarkeit mit denselben Parametereinstellungen trainiert wie das RapidEye-Basismodell. Außerdem wurde für den Test der Modelle konsistent derselbe Datensatz verwendet. Getestet wurde u.a. ein Übertrag eines vortrainierten RapidEye Modells (Zeitabschnitt 2015) auf die SPOT Daten. In einem zweiten Test wurden zusätzliche Referenzdaten aus dem Jahr 2021 für das Modelltuning genutzt. Experiment 3 sollte überprüfen, ob das Modelltuning aus Experiment 2 bessere Ergebnisse liefert als ein Modell, das nur auf SPOT trainiert wurde. Die bisher für den Übertrag der Modelle gewonnenen Erkenntnisse sollen im weiteren Projektverlauf in folgenden Aspekten vertieft werden:

Die initialen Tuning-Experimente wurden bisher auf der vollen verfügbaren Datensatzgröße durchgeführt. Ziel des Modelltunings soll es zukünftig sein, den zusätzlich benötigten Dateninput zu minimieren. Dazu sollen weitere Experimente mit reduziertem Dateninput durchgeführt werden, die den minimalen Dateninput ermitteln. Weitere Untersuchungen sind hinsichtlich bundesländerspezifischer Unterschiede (phänologische Unterschiede der Vegetation, inhomogene Klassenverteilung) geplant.

5 Fazit & Ausblick

Das Projekt "DatKI4BKG" läuft noch bis April 2024. Im Rahmen des Projekts konnte ein leistungsfähiges, zukunftsgerichtetes und übertragbares DMS aufgebaut werden, auf das die entwickelten KI-Methoden zugreifen können. Mit den entwickelten KI-Modellen ist es möglich die Klassen des LBM-DE deutschlandweit abzuleiten und dies für unterschiedliche Zeitpunkte und Satellitendaten. Im letzten Jahr wurde die Methodik und der gesamte Workflow nochmals weiterentwickelt, somit konnte die Güte und auch die Stabilität des KI-Modells im Vergleich zum Vorjahr nochmals deutlich gesteigert werden. Zusätzlich konnten viele wichtige Erkenntnisse über die Eigenschaften der generierten Klassifikation gewonnen werden. Im weiteren Projektverlauf liegt das Hauptaugenmerk auf der bestmöglichen Integration der KI-Methoden und den davon abgeleiteten Datenprodukten in den Erstellungsprozess des LBM-DE. In Abstimmung zwischen DLR und BKG wird hierfür auf die eigens entwickelten Datenprodukte der Entropie sowie der Top-3 Klassen, inklusive Klassenwahrscheinlichkeiten, fokussiert. Ein wichtiger Punkt sind weitere Optimierungen des KI-Verfahrens für die Übertragung der vortrainierten Modelle auf die neuen Sensordaten.

Im Rahmen eines Folgeprojektes (DatKI-Operational) mit Laufzeit bis Ende 2024 sollen die in DatKI4BKG entwickelten KI-basierten Methoden zur Ableitung von LBM-DE Klassen in die bestehenden LBM-DE Prozessketten integriert und somit die exemplarisch erarbeiteten KI-Modelle auf ein operationelles Level gehoben werden. Nach Abschluss des Projekts DatKI-Operational wird die Ableitung des LBM-DE 2024 durch die gewonnenen Erkenntnisse deutlich erleichtert werden.

6 Literaturverzeichnis

- AIRBUS, 2021: SPOT Imagery User Guide. https://storage.googleapis.com/p-oaf-ibe-back-00e-strap-uploads/SPOT_User_Guide_2021_09_low2_d145a2a31b/SPOT_User_Guide_-_2021_09_low2_d145a2a31b.pdf, letzter Zugriff 25.01.2024.
- BUNDESAMT FÜR KARTOGRAPHIE UND GEODÄSIE (BKG), 2020: Dokumentation Digitales Landbedeckungsmodell für Deutschland (LBM-DE2018). https://sg.geodatenzentrum.de/web_public/gdz/dokumentation/deu/lbm-de2018.pdf, letzter Zugriff 23.01.2024.
- BUNDESAMT FÜR KARTOGRAPHIE UND GEODÄSIE (BKG), 2021: Dokumentation RapidEye Satellitenbilder. https://sg.geodatenzentrum.de/web_public/gdz/dokumentation/deu/rapideye_2017.pdf, letzter Zugriff 23.01.2024.
- HAO, S., ZHOU, Y. & GUO, Y., 2020: A brief survey on semantic segmentation with deep learning. *Neurocomputing*, **406**, 302-321, <https://doi.org/10.1016/j.neucom.2019.11.118>.
- 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*, 770-778, <https://doi.org/10.1109/CVPR.2016.90>.
- HOESER, T. & KUENZER, C., 2020: Object detection and image segmentation with deep learning on earth observation data: A review-part i: Evolution and recent trends. *Remote Sensing*, **12**(10), 1667, <https://doi.org/10.3390/rs12101667>.
- LECUN, Y., BOTTOU, L., BENGIO, Y. & HAFFNER, P., 1999: Gradient-based learning applied to document recognition. *Proceedings of the IEEE*, **86**(11), 2278-2324.
- LIN, T. Y., DOLLÁR, P., GIRSHICK, R., HE, K., HARIHARAN, B. & BELONGIE, S., 2017: Feature pyramid networks for object detection. *Proceedings of the IEEE conference on computer vision and pattern recognition*, 2117-2125, <https://doi.org/10.48550/arXiv.1612.03144>.
- TERVEN, J., CORDOVA-ESPARZA, D. M., RAMIREZ-PEDRAZA, A., & CHAVEZ-URBIOLA, E. A., 2023: Loss functions and metrics in deep learning. A review. *arXiv preprint arXiv:2307.02694*, <https://doi.org/10.48550/arXiv.2307.02694>.
- WURM, M., DROIN, A., STARK, T., GEIß, C., SULZER, W. & TAUBENBÖCK, H., 2021: Deep Learning-Based Generation of Building Stock Data from Remote Sensing for Urban Heat Demand Modeling. *ISPRS International Journal of Geo-Information*, **10**(1), 23, <https://doi.org/10.3390/ijgi10010023>.
- WURM, M., STARK, T., ZHU, X., WEIGAND, M. & TAUBENBÖCK, H., 2019: Semantic segmentation of slums in satellite images using transfer learning on fully convolutional neural networks. *ISPRS Journal of Photogrammetry and Remote Sensing*, **150**, 59-69, <https://doi.org/10.1016/j.isprsjprs.2019.02.006>.