

KI-basierte Fernerkundungsdatenanalyse zur Aktualisierung des ATKIS® Basis-DLM

Using AI-based Remote Sensing Data Analysis for Updating the ATKIS® Basis-DLM

Jens Hollberg | Krister Kowalski | Abidur Rahman Khan | Judith Reinhardt | Lisa Schmitz

Zusammenfassung

Durch staatliche und private Erdbeobachtungsprogramme werden große Fernerkundungsdatensätze aufgenommen. Vor dem Hintergrund steigender Anforderungen an die Aktualität und Qualität des Digitalen Landschaftsmodells des Amtlichen Topographisch-Kartographischen Informationssystems (ATKIS® Basis-DLM) ist die Erschließung neuer Technologien notwendig, die eine automatisierte Auswertung von Fernerkundungsdatensätzen ermöglichen. Mit dem Aufbau einer leistungsstarken KI-Recheninfrastruktur wurde in der Hessischen Verwaltung für Bodenmanagement und Geoinformation (HVBG) die Grundlage geschaffen, Veränderungen der Landschaft auf Basis von Fernerkundungsdaten und KI automatisiert zu erkennen. Erste KI-basierte Pilotverfahren wurden entwickelt, die dazu beitragen, die Qualität und Aktualität des ATKIS® Basis-DLM weiter zu erhöhen.

Schlüsselwörter: ATKIS® Basis-DLM, Fernerkundungsdatenanalyse, Künstliche Intelligenz

Summary

Large remote sensing data sets are available through publicly and privately funded remote sensing programs. Given the increasing demands on the timeliness and quality of the digital landscape model of the Authoritative Topographic-Cartographic Information System (ATKIS® Basis-DLM), it is necessary to develop new processes that enable automated analysis of remote sensing data. By setting up a powerful AI computing infrastructure, the Hessian Administration for Land Management and Geoinformation (HVBG) has laid the foundations for automatically detecting changes in the landscape based on remote sensing data and AI. In order to increase the quality and timeliness of the ATKIS® Basis-DLM, first processes have been developed.

Keywords: ATKIS® Basis-DLM, remote sensing data analysis, artificial intelligence

1 Einleitung

Die Arbeitsgemeinschaft der Vermessungsverwaltungen der Länder der Bundesrepublik Deutschland (AdV) hat beschlossen, den Standard der Grundaktualität des Digitalen Basis-Landschaftsmodells des Amtlichen Topogra-

phisch-Kartographischen Informationssystems (ATKIS® Basis-DLM) von fünf auf drei Jahre zu erhöhen (vgl. AdV 2020: Beschluss P2018/8). Die Kombination aus knappen Finanzmitteln, dem Fachkräftemangel und steigenden Anforderungen an die Aktualität und Qualität der Datenbestände stellt die hessische Landesvermessung vor große Herausforderungen.

Fernerkundungsdaten bilden die Grundlage, um EDV-gestützt Veränderungen der Landschaft flächendeckend und präzise zu erfassen. Durch die Luftbild- und Laser-Scanbefliegungsprogramme der Hessischen Verwaltung für Bodenmanagement und Geoinformation (HVBG), das Copernicus-Programm der Europäischen Union und weitere Erdbeobachtungsprogramme liegen der hessischen Landesverwaltung immer mehr und immer umfassendere Fernerkundungsdatensätze vor. Die Auswertung der Vielzahl an Datensätzen in erhöhter zeitlicher Frequenz mit Hilfe der aktuell eingesetzten visuellen Interpretationstechniken von Einzelfällen am Bildschirmarbeitsplatz ist langfristig nicht mehr zu bewältigen. Daher werden neue Verfahren benötigt, die die automatisierte Auswertung von Geo- und Fernerkundungsdaten ermöglichen.

Eine Reihe von Studien hat gezeigt, dass der Einsatz von Künstlicher Intelligenz (KI) bedeutende Potenziale für eine Steigerung des Automatisierungsgrads hinsichtlich der Auswertung von Fernerkundungsdatensätzen bietet (Reiter et al. 2023, Tetteh et al. 2023, Chetan et al. 2017, Hollberg und Schellberg 2017). Eine solche Anwendung von KI-Verfahren zur Analyse geografischer Daten (auch Geo-KI genannt) kann einen wesentlichen Beitrag dazu leisten, die steigenden Anforderungen an das ATKIS® Basis-DLM zu erfüllen.

2 Organisatorische und technische Grundlagen

Um Verfahren der automatisierten Analyse von Fernerkundungs- und Fachdaten in der HVBG zu implementieren, wurde im Jahr 2020 eine Entwicklungs- und Produktionsgruppe gegründet. Diese evaluierte zunächst mögliche Anwendungsfelder zum Einsatz von Geo-KI, inklusive der entsprechenden technischen Anforderungen. Die Ergebnisse zeigten, dass die benötigte Steigerung der Effizienz der Datenerfassung für das ATKIS® Basis-DLM nur durch den Einsatz umfassender KI-Rechenressourcen




Abb. 1:
Schematische Übersicht der
Architektur des KI-Rechen-
clusters

möglich ist. Anschließend wurden verschiedene Szenarien der Umsetzung wie die Nutzung von Cloudcomputing und der Aufbau eigener Systeme beleuchtet. Die Wahl fiel aus rechtlich-organisatorischen Gründen (insb. hinsichtlich der Systemintegration), aufgrund der Anforderungen an die IT-Sicherheit sowie aus fachlicher Sicht auf den Aufbau eines hausinternen Systems.

Im Rahmen von Workshops wurden die Anforderungen an ein solches System aufgestellt. Es folgte die Beantragung von Mitteln des Hessischen Ministeriums für Digitales und Innovation (HMD) für die Umsetzung der Maßnahme »Automation im Bereich der Geodatenanalyse hochaktueller Satellitendaten (Stufe 1)«. In den Jahren 2023 und 2024 erfolgten die Beschaffung, der Aufbau und die Installation des Systems, dessen Komponenten insgesamt sechs NVIDIA Hopper H-100-Grafikprozessoren beinhalten. Durch den Betrieb über eine Nutanix-Cloud-Infrastruktur ist die flexible Verwaltung der bereitstehenden Rechenressourcen möglich.

Clients können über Applikationsserver auf die Ressourcen des KI-Rechenclusters zugreifen (Abb. 1). Eine Anbindung an Datenbank- und Fileserverssysteme wurde

ebenfalls umgesetzt. Mit dem Betriebssystem Windows Server 2022 ist die Nutzung zentraler Werkzeuge, wie der Distribution Anaconda zur Entwicklung in den Programmiersprachen Python und R, der Entwicklungsumgebung Microsoft Visual Studio sowie weiterer GIS-spezifischer Softwarelösungen wie QGIS, FME und ERDAS Imagine realisiert.

3 Entwicklung und Einordnung der Pilotverfahren

Seit dem Jahr 2023 werden kontinuierlich Verfahren mit dem Ziel entwickelt, eine Erhöhung des Automatisierungsgrads bei der Aktualisierung des ATKIS® Basis-DLM zu erreichen. Die grundlegende Vorgehensweise der Datenverarbeitung ist in Abb. 2 dargestellt. Dabei werden zunächst verschiedene Eingangsdatensätze aufbereitet und kombiniert. Je nach Einsatzbereich des Prozesses kommen dabei rasterbasierte Daten wie Luft- und Satellitenbilder sowie vektorbasierte Geodaten zum Einsatz. Nach der Prozessierung der Eingangsdaten erfolgt die Entwicklung

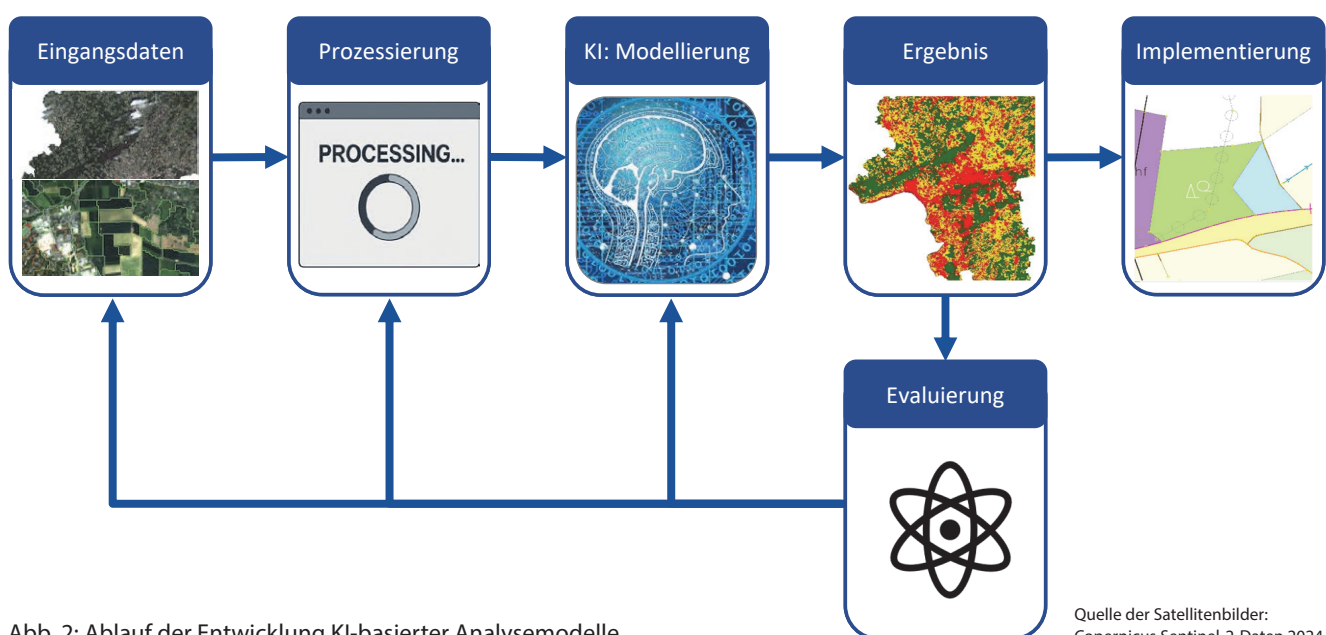


Abb. 2: Ablauf der Entwicklung KI-basierter Analysemodelle

Quelle der Satellitenbilder:
Copernicus Sentinel-2-Daten 2024

eines KI-basierten Modells, welches auf die Daten angewendet wird, sodass ein Verfahrensergebnis entsteht. Anschließend werden die Ergebnisse evaluiert. Wenn die Ergebnisse des Prozesses zufriedenstellend sind, wird das Verfahren in den Gesamtprozess der Datenerhebung des ATKIS® Basis-DLM implementiert. Andernfalls wird die Eingangsdatengrundlage modifiziert, die Datenverarbeitung optimiert oder das KI-Modell angepasst.

Die erzeugten Ergebnisse bestehen dabei entweder aus rasterbasierten Informationen oder werden in ein vektorbasiertes Format konvertiert. Die Praxis besteht darin, in das Erhebungssystem automatisiert generierte Informationen zu Änderungen von Objekten der Landschaft zu importieren (sog. Änderungshinweise). Diese helfen den Bearbeiterinnen und Bearbeitern des ATKIS® Basis-DLM in Hessen, gezielt Änderungen von Objektgeometrien, Attributen oder Werten einzupflegen. Damit wird der Erhebungsprozess bedeutend unterstützt.

4 Darstellung der Pilotverfahren

Bereits während der Schaffung der technischen Voraussetzungen für einen Einsatz komplexer KI-Modelle wurde mit der Bearbeitung von Pilotverfahren begonnen. Da während des Aufbaus des KI-Rechenclusters 2023 und 2024 nur eingeschränkte KI-Rechenressourcen zur Verfügung standen, wurden sog. Ensemble Methoden eingesetzt (vgl. Saini und Ghosh 2017, Zhang et al. 2022). Diese können auch ohne den Einsatz umfassender Rechencluster-Ressourcen trainiert und angewandt werden. Seit Fertigstellung der gesamten Infrastruktur zum 31.12.2024 werden verstärkt Künstliche Neuronale Netze verwendet. Drei der ersten KI-basierten Verfahren, die in der HVBG zum Einsatz kommen, sind in Tab. 1 aufgeführt.

Die Einbindung der Verfahren in den Gesamterhebungsprozess des ATKIS® Basis-DLM erfolgt, je nach Zweck des Verfahrens, dem genutzten Datenmaterial und der zeitlichen Auflösung der Verfahrensergebnisse einzelfallbezogen. Dies hängt auch mit den verschiedenen Anlässen der Verfahrensnutzung, bspw. im Rahmen regelmäßiger Überarbeitungen (Grundaktualisierung), einmaliger Überarbeitungen (i. d. R. Projektbezogene Aktualisierung)

oder im Rahmen hochaktuell benötigter Aktualisierungen (Spitzenaktualisierung), zusammen.

4.1 Erstellung von Änderungshinweisen zu flächenhaften Objekten des ATKIS® Basis-DLM aus Sentinel-2-Satellitendaten

Im Jahr 2023 wurde ein erstes Pilotverfahren zur Erstellung von Änderungshinweisen zu flächenhaften Objekten der Landbedeckung des ATKIS® Basis-DLM aus Sentinel-2-Satellitendaten fertiggestellt (vgl. Tab. 1). Die Durchführung des Verfahrens setzt die Verfügbarkeit wolkenfreien Bildmaterials voraus. Dazu werden offen verfügbare Daten der ESA etwa vierteljährlich zu einem Sentinel-2-Mosaik Hessens aufbereitet (vgl. ESA 2025).

Da ein pixelbasierter Ansatz sich als unpraktikabel erwiesen hat, erfolgt eine objektbasierte Bildanalyse (OBIA) (vgl. Blaschke 2010). Dazu werden zunächst auf Grundlage des Full-Lambda-Algorithmus Segmente, also zusammenhängende und homogene Regionen eines Satellitenbilds, erzeugt (Govedarica et al. 2015).

Anschließend erfolgt die Zuordnung der Segmente zu einer Landbedeckungsklasse anhand ihrer spektralen Eigenschaften unter Anwendung des Verfahrens Random Forest (Breiman 2001). Werden signifikante Abweichungen zwischen dem Klassifikationsergebnis und dem aktuellen Datenbestand des ATKIS® Basis-DLM identifiziert, werden Änderungshinweise generiert und in die entsprechende Datenbank importiert. Der hohe Automatisierungsgrad des Verfahrens erlaubt dabei die Analyse der Sentinel-2-Daten auf Knopfdruck.

Die Bearbeiterinnen und Bearbeiter des ATKIS® Basis-DLM werden mit Hilfe der Änderungshinweise direkt zu Bereichen mit Landschaftsveränderungen geführt. Gegenstand des Modells sind die Klassen Ackerland, Bebauung, vegetationslos, Wald/Gehölz, Wasser, Weinreben und Grünland. Die räumliche Auflösung des Sentinel-2-Sensors von 10 m oder weniger bedingt die besondere Eignung der Satellitenbilder für die Identifikation großflächiger und topographisch signifikanter Objekte.

Im finalen Schritt erfolgt die Validierung der identifizierten Änderungen mittels visueller Analyse der Satellitenbilder oder Digitaler Orthophotos (vgl. Abb. 3).

Tab. 1: Auszug erster Pilotverfahren im Bereich KI in der HVBG

| Kapitel | Verfahrenstitel | KI-Verfahren | Fertigstellung | Referenzliteratur |
|---------|--|--|----------------|---|
| 4.1 | Erstellung von Änderungshinweisen zu flächenhaften Objekten des Basis-DLM aus Sentinel-2-Satellitendaten | Ensemble-Methode: Random Forest | 2023 | Blaschke 2010, Breiman 2001 |
| 4.2 | Erfassung von Änderungen an Tagebauen, Gruben und Steinbrüchen | Künstliches Neuronales Netz; Bagging; Objektbasierte Bildanalyse | 2024 | Blaschke 2010, Breiman 1996, Paszke et al. 2019 |
| 4.3 | Automatisierte Detektion von Biogasanlagen | Ensemble-Methode: Haar-Kaskade | 2024 | Viola und Jones 2001 |




Abb. 3: Exemplarisches Ergebnis des Verfahrens: (a) Sentinel-2-Bild, August 2024; (b) Sentinel-2-Bild, Januar 2024; (c) Ergebnis der Klassifikation; (d) Änderungshinweise als Punkte (rot) mit hinterlegtem Digitalem Orthophoto.

Schließlich werden die Änderungen in das ATKIS® Basis-DLM übertragen.

4.2 Erfassung von Änderungen an Tagebauen, Gruben und Steinbrüchen

Die automatische Erfassung von Änderungen an Tagebauen, Gruben und Steinbrüchen adressiert die bereits im ATKIS® Basis-DLM geführten Objekte. Durch ein solches Monitoring der Ausdehnung der Objektflächen werden die Bearbeiterinnen und Bearbeiter des ATKIS® Basis-DLM gezielt durch Änderungshinweise bspw. über signifikante Erweiterungen, Renaturierungen oder sonstige Modifikationen der Flächen informiert.

Im Verfahren werden zunächst Ausschnitte rund um die relevanten Objekte aus Sentinel-2-Satellitenbildern (Image Chips) extrahiert. Anschließend werden mit Hilfe des ATKIS® Basis-DLM Potenzialflächen identifiziert, sodass die Untersuchungsfläche weiter eingegrenzt wird. Durch diese Schritte können die benötigten Rechenkapazitäten zur Anwendung des Verfahrens bedeutend reduziert werden.

Zur besseren Detektion von offen liegenden Sedimenten werden dann aus den Sentinel-2 Image Chips der Covermanagement Factor (C-Factor; Panagos et al. 2015) und der Barren Soil Index (Nguyen et al. 2021) berechnet. Anschließend werden die erzeugten Ausschnitte mittels Quickshift Clustering segmentiert (Vedaldi et al. 2008, Blaschke 2010). Um die erzeugten Segmente einer Klasse




Abb. 4: Exemplarisches Ergebnis des Verfahrens: (a) Sentinel-2-Bildausschnitt mit aktueller Abgrenzung des Objekts im ATKIS® Basis-DLM (rot); (b) Sentinel-2-Bildausschnitt mit Ergebnis der Bildsegmentierung (grün); (c) DOP-Bildausschnitt mit Ergebnis der Klassifikation (blau).




Abb. 5: Im TrueDOP erfasste Biogasanlagen-Fermenter innerhalb der quadratischen Markierungen

zuzuordnen, wird eine Klassifikation mit Hilfe eines Neuronalen Netzes durchgeführt (Paszke et al. 2019, Breiman 1996). Dieses klassifiziert die Bildpixel innerhalb der Segmente anhand ihrer optischen Eigenschaften in zwei Klassen: Tagebau/Grube/Steinbruch (True) und »nicht-Tagebau« (False). Das vorherrschende Klassifikationsergebnis unter allen Pixeln bestimmt die Klasse eines gesamten Segmentes. Die detektierten Tagebauflächen werden nun als Polygone vektorisiert. Anschließend erfolgt ein Abgleich mit den Tagebauflächen im Datenbestand des ATKIS® Basis-DLM mittels Intersection over Union. Werden deutliche Änderungen detektiert, wird ein Änderungshinweis erzeugt, in die entsprechende Datenbank importiert und den Bearbeiterinnen und Bearbeitern zur Verfügung gestellt. Diese prüfen den Sachverhalt und modifizieren ggf. die Objekte.

4.3 Automatisierte Detektion von Biogasanlagen

Stichprobenartige Qualitätskontrollen des hessischen ATKIS® Basis-DLM haben gezeigt, dass Biogasanlagen aktuell nicht vollständig erfasst sind. Dies gab den Ausschlag zur Entwicklung eines Verfahrens zu deren automatisierter Detektion auf Grundlage von True Digital Orthophotos (TrueDOP) der HVBG mit 1 m Auflösung.

Zur Erfassung der Objekte wird ein Kaskaden-Klassifikator genutzt, der durch die Suche nach diversen Übereinstimmungen einfacher Merkmale der gesuchten Objekte (sogenannter Haar-Merkmale) trainiert wird (Viola und Jones 2001). Dazu werden Bildausschnitte, in denen Biogasanlagen identifiziert wurden, sowie solche, in denen keine Biogasanlagen liegen, in hoher Anzahl als Trainingsdaten benötigt. Grundlage für den Trainingsdatensatz waren die bereits in Hessen und anderen Bundesländern im ATKIS® Basis-DLM erfassten Biogasanlagen sowie zusätzliche manuell identifizierte Objekte. Die Größe des Trainingsdatensatzes wurde zudem synthetisch (bspw. durch Drehung, Spiegelung) der TrueDOPs erhöht. Durch eine Anwendung des erzeugten Modells können schließlich auch unbekannte Biogasanlagen identifiziert werden. Insgesamt wurden so 200 Objekte in Hessen detektiert, von denen 67 bislang nicht im ATKIS® Basis-DLM erfasst wa-

ren. Schließlich werden Änderungshinweise erzeugt, die durch die Bearbeiterinnen und Bearbeiter geprüft und ggf. eingepflegt werden (Abb. 5).

5 Fazit und Ausblick

Die drei vorgestellten Pilotverfahren belegen, dass die KI-basierte Fernerkundungsdatenanalyse einen bedeutenden Beitrag leisten kann, um die steigenden Anforderungen an die Qualität und Aktualität des ATKIS® Basis-DLM zu erfüllen. Zur Nutzung der Potenziale komplexer KI-Modelle ist der Zugang zu leistungsstarken Recheninfrastrukturen notwendig.

In den kommenden Jahren werden die Entwicklungsaktivitäten zur Integration von KI in den Prozess der Aktualisierung des ATKIS® Basis-DLM vorangetrieben. Dazu werden zunächst das Portfolio KI-basierter Prozesse weiter ausgebaut und bestehende Verfahren optimiert. Die HVBG setzt dabei auch auf die Kooperation mit wissenschaftlichen Einrichtungen, Unternehmen und Behörden.

Literatur

- AdV (2020): Produkt- und Qualitätsstandard für das Digitale Basis-Landschaftsmodell (Basis-DLM). AdV-Arbeitskreis Geotopographie, Umlaufbeschluss GT 2020/07. <https://www.adv-online.de/Veroeffentlichungen/Broschueren-und-Faltblaetter/Geotopographie/binarywriterservlet?imgUid=25419114-249e-4711-1fea-f5203b36c4c2&uBasVariant=11111111-1111-1111-1111-111111111111>, letzter Zugriff 04/2025.
- Blaschke, T. (2010): Object based image analysis for remote sensing. In: ISPRS Journal of Photogrammetry and Remote Sensing, Issue 1/2010, 65. Jg., 2–16. DOI: 10.1016/j.isprsjprs.2009.06.004.
- Breiman, L. (1996): Bagging Predictors. In: Machine Learning, 1996, 24. Jg., 123–140. DOI: 10.1007/BF00058655.
- Breiman, L. (2001): Random Forests. In: Machine Learning, 2001, 45. Jg., 5–32. DOI: 10.1023/A:1010933404324.
- Chetan, M., Dornik, A., Urdea, P. (2017): Comparison of Object and Pixel-based Land Cover Classification through three Supervised Methods. In: zfv – Zeitschrift für Geodäsie, Geoinformation und Landmanagement, Heft 5/2017, 142. Jg., 265–270. DOI: 10.12902/zfv-0165-2017.
- ESA (European Space Agency) (2025): <https://dataspace.copernicus.eu/explore-data/data-collections/sentinel-data/sentinel-2>, letzter Zugriff 06/2025.

- Govedarica, M., Ristić, A., Jovanović, D., Herbei, M., Sala, F. (2015): Object Oriented Image Analysis in Remote Sensing of Forest and Vineyard Areas. In: Bulletin of University of Agricultural Sciences and Veterinary Medicine Cluj-Napoca. Horticulture, Heft 2/2015, 72. Jg., 362–370. DOI: 10.15835/buasvmcn-hort:11409.
- Hollberg, J., Schellberg, J. (2017): Distinguishing Intensity Levels of Grassland Fertilization Using Vegetation Indices. In: Remote Sensing, Issue1(81)/2017, 9. Jg., 1–20. DOI: 10.3390/rs9010081.
- Nguyen, C. T., Chidthaisong, A., Diem, P. K., Huo, L.-Z. (2021): A Modified Bare Soil Index to Identify Bare Land Features during Agricultural Fallow-Period in Southeast Asia Using Landsat 8. In: Land Heft 3(231)/2021, 10. Jg., 1–17. DOI: 10.3390/land10030231.
- Paszke, A., Gross, S., Massa, F., Lerer, A., Bradbury, J., Chanan, G., Killeen, T., Lin, Z., Gimelshein, N., Antiga, L., Desmaison, A., Köpf, A., Yang, E., DeVito, Z., Raison, M., Tejani, A., Chilamkurthy, S., Steiner, B., Fang, L., Bai, J., Chintala, S. (2019): PyTorch: An Imperative Style, High-Performance Deep Learning Library. In: 33rd Conference on Neural Information Processing Systems. Vancouver, Canada, 2019. DOI: 10.48550/arXiv.1912.01703.
- Reiter, D., Meinel, G., Forkel, M. (2023): Evaluierung der Tatsächlichen Nutzung im ATKIS Basis-DLM mittels Digitaler Orthophotos und Deep Learning. In: zfv – Zeitschrift für Geodäsie, Geoinformation und Landmanagement, Heft 3/2023, 148. Jg., 126–136. DOI: 10.12902/zfv-0422-2023.
- Saini, R., Ghosh, S. (2017): Ensemble classifiers in remote sensing: A review. In: Proceedings of the 2017 International Conference on Computing, Communication and Automation (ICCCA), Greater Noida, India, 2017, 1148–1152.
- Tetteh, G. O., Schwieder, M., Erasmi, S., Conrad, C., Gocht, A. (2023): Comparison of an Optimised Multiresolution Segmentation Approach with Deep Neural Networks for Delineating Agricultural Fields from Sentinel 2 Images. In: PFG – Journal of Photogrammetry, Remote Sensing and Geoinformation Science 2023, 91. Jg., 295–312. DOI: 10.1007/s41064-023-00247-x.
- Vedaldi, A., Soatto, S. (2008): Quick Shift and Kernel Methods for Mode Seeking. In: Forsyth, D., Torr, P., Zisserman, A. (Hrsg.) (2008): Computer Vision – ECCV 2008, 10th European Conference on Computer Vision, Marseille, France, 2008, 705–718. DOI: 10.1007/978-3-540-88693-8_52.
- Viola, P., Jones, M. (2001): Rapid object detection using a boosted cascade of simple features. In: Proceedings of the 2001 IEEE computer society conference on computer vision and pattern recognition 2001, Kauai, HI, USA. DOI: 10.1109/CVPR.2001.990517.
- Zhang, Y., Liu, J., Shen, W. A. (2022): Review of Ensemble Learning Algorithms Used in Remote Sensing Applications. Applied Sciences 17(8654)/2022, 12. Jg. DOI: 10.3390/app12178654.

Kontakt

Dr. Jens Hollberg | Krister Kowalski | Abidur Rahman Khan |
 Judith Reinhardt | Lisa Schmitz
 Hessisches Landesamt für Bodenmanagement und Geoinformation
 Schaperstraße 16, 65195 Wiesbaden
 jens.hollberg@hvbh.hessen.de
 kristerandreas.kowalski@hvbh.hessen.de
 abidurrahman.khan@hvbh.hessen.de
 judith.reinhardt@hvbh.hessen.de
 lisa.schmitz@hvbh.hessen.de

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