

Schritthalende Baufallerkundung aus dem All mit frei verfügbaren Satellitenaufnahmen

Regular Investigation of Construction Activities from Space based on Open Satellite Imagery

Lea Schollerer | Andreas Schmitt | Anna Wendleder | Simone Rogginger

Zusammenfassung

In den letzten Jahren ist ein starker Aufschwung in der Baubranche, vor allem im Bereich des Wohnungsbaus, zu verzeichnen. Aufgrund der Einmessungspflicht von Veränderungen im Gebäudebestand in Bayern wird in diesem Artikel eine neue Methode zur Baufallerkundung mit Hilfe von Fernerkundung vorgestellt. Grundlage hierfür bilden Zeitreihen aus kostenlos zugänglichen Sentinel-1 (S1) und Sentinel-2 (S2) Satellitenaufnahmen des Europäischen Copernicus-Programms. Betrachtet wurden aktive und passive Aufnahmen im Zeitraum zwischen Anfang Oktober 2019 und Ende November 2020 über einem Testgebiet in der niederbayerischen Stadt Dingolfing. Nach Aufbereitung der multi-temporalen polarimetrischen und multispektralen Aufnahmen zu Analysis Ready Data (ARD) im Kennaugh-Framework und Anwendung des neu entwickelten LEAIIndex (LEAI) wurde ein Wavelet-basierter Ansatz zur Erkennung von Neubauten entwickelt. Der Abgleich sämtlicher Ergebnisse mit vor Ort gesammelten Eigentümerangaben zeigte, dass mit dem verwendeten Prototyp von 38 Neubauten 34 sicher erkannt worden sind. Die präsentierte Methodik ist darauf ausgerichtet, in naher Zukunft in einen flächendeckenden Baufallerkundungsservice umgesetzt zu werden.

Schlüsselwörter: Baufallerkundung, Änderungserkennung, Copernicus-Programm, Sentinel-1, Sentinel-2, Multi-SAR, Kennaugh-Framework, Zeitreihenanalyse

Summary

In recent years, there has been a strong upswing in the construction industry especially with respect to residential buildings. Due to the obligation to document changes in the building stock in Bavaria, this article presents a new method for the detection of construction activities from remote sensing data. The approach bases on time series from freely available multi-temporal active Sentinel-1 (S1) and passive Sentinel-2 (S2) satellite images from the European Copernicus programme. Data collected during the period between the beginning of October 2019 and the end of November 2020 over a study area in the town of Dingolfing (Lower Bavaria, Germany) were evaluated. After processing the multi-temporal polarimetric and optical images to Analysis Ready Data (ARD) in the Kennaugh framework and applying the novel LEAIIndex (LEAI), a simple, but robust, Wavelet-based approach for the detection of new buildings was developed. The validation of the results towards in-situ owner information gathered by the help of a questionnaire revealed that out of 38 new buildings 34 were reliably identified by the prototypic algorithm.

The described methodology is intended to be implemented in a steady detection service for construction activities.

Keywords: investigation of construction activities, change detection, Copernicus programme, Sentinel-1, Sentinel-2, Multi-SAR, Kennaugh framework, time series analysis

1 Einleitung

Seit einigen Jahren boomt die Baubranche in Deutschland, vor allem im Bereich des Wohnungsbaus. Dies wird mitunter durch die seit der Weltwirtschaftskrise im Jahr 2009 stetig steigende Auftragslage für Wohn- und nicht Wohngebäude deutlich (Statistisches Bundesamt (Destatis) 2020). Als Gründe sind die hohe Nachfrage auf dem Wohnungsmarkt, die gute wirtschaftliche Lage mit der aktuellen Niedrigzinspolitik und auch die steigenden Investitionen der Bundesregierung in die Infrastruktur zu nennen (Gornig et al. 2021, S. 5–6). Durch die starke Neubautätigkeit, die einen Genehmigungsüberhang mit sich bringt, werden in vielen Gemeinden deshalb immer wieder neue Baugebiete mit Wartelisten ausgewiesen. Dies ist vor allem in Ballungsgebieten mit guter technischer und sozialer Infrastruktur sowie einem hohen Bedarf an Arbeitskräften der Fall.

In Bayern zeigt sich die Zunahme auch in der Menge an Baugenehmigungen, die aufgrund der Einmessungspflicht von Veränderungen im Bestand der Gebäude (Art. 8 des Gesetzes über die Landesvermessung und das Liegenschaftskatasters (VermKatG)) von den zuständigen Stellen an die mit der Gebäudeeinmessung beauftragten Ämter für Digitalisierung, Breitband und Vermessung (ÄDBV) (nach Art. 12 Abs. 4 VermKatG) übermittelt werden. Daraus resultiert eine hohe Anzahl an einzumessenden Gebäuden. Die übermittelten Genehmigungen enthalten zwar den jeweiligen Bauantrag, jedoch noch nicht, wann und ob wirklich gebaut wird. Dies muss regelmäßig vor Ort durch die Baufallmesstrupps der ÄDBV überprüft werden, ebenso wie das Erfassen von nicht genehmigungspflichtigen Gebäuden bzw. Veränderungen. Um dabei den Überblick über die aktuelle Bautätigkeit zu behalten, reichen die bisher verwendeten Baufallerkundungsmethoden, wie beispielsweise das visuelle Durchgehen von neuen Luftbildern (in Bayern alle zwei Jahre) mit dem anschließenden

Abgleich der Digitalen Flurkarte (DFK), nicht mehr aus. Deshalb wird versucht, neue automatisierte Verfahren zu finden, die den Bau eines Gebäudes zeitnah detektieren und dadurch bereits eine Vorarbeit für die Gebäudemesstrupps leisten, damit diese nur noch vor Ort die Richtigkeit der digitalen Anwendungsergebnisse überprüfen müssen. Eine wichtige Rolle spielen hierbei Satellitenbilder, da diese einen kontinuierlichen »Überblick von oben« verschaffen und dadurch eine enorme Menge an Informationspotenzial bieten.

1.1 Literaturüberblick

Zur Extraktion von Siedlungen (»built-up areas«) und anderen Landbedeckungsklassen aus Fernerkundungsdaten wurden aufgrund der einfachen Implementierung im Laufe der Jahre verschiedene optische Indizes entwickelt. Angewandt auf Satellitenbilder der verschiedenen Landsat-Missionen der NASA (seit 1978) wurden zahlreiche Indizes abgeleitet und definiert, von denen hier folgende zu nennen sind: der *Normalized Difference Vegetation Index* (NDVI) (Masek et al. 2000, Tucker 1979); der *Normalized Difference Built-up Index* (NDBI) (Varshney 2013, Zha et al. 2003a, 2003b); der *Index-based Built-up Index* (IBI) basierend auf dem *Soil Adjusted Vegetation Index* (SAVI), dem *Modified Normalized Difference Water Index* (MNDWI) und dem NDBI (Xu 2008); die Methode von Jielj et al. (2010) basierend auf dem *New Built-up Index* (NBI), dem *Normalized Built-up Area Index* (NBAI) und der *Band Ratio for Built-up Area* (BRBA) (Waqar et al. 2012); der *Normalized Difference Impervious Surface Index* (NDISI) (Xu 2010); der *Enhanced Built-Up and Bareness Index* (EBBI) (As-syakur et al. 2012); ein *Biophysical Composition Index* (BCI)

(Deng und Wu 2012); die *Built-up Area Extraction Method* (BAEM) (Bhatti und Tripathi 2014); der *Ratio Normalized Difference Soil Index* (RNDSI) (Deng et al. 2015); ein multispektraler Index von Bouzekri et al. (2015); der *Modified Normalized Difference Soil Index* (MNDSI) und parallel dazu der *Normalized Ratio Urban Index* (NRUI) durch Modifizierung des BCI (Piyoosh und Ghosh 2017); der *Combinational Biophysical Composition Index* (CBCI) (Zhang et al. 2018); der *Built-up Land Features Extraction Index* (BLFEI) (Bouhennache et al. 2019) und der *Automated Built-up Extraction Index* (ABEI) (Firozjaei et al. 2019). Wie dieser Abschnitt eindrücklich zeigt, könnte man bei Landsat auf eine Vielzahl bereits erprobter Algorithmen zurückgreifen. Jedoch ist die räumliche Auflösung bei 30 m × 30 m-Pixeln am Boden nicht ausreichend.

Für die Klassifizierung von Straßenzügen wurde basierend auf WorldView-2-Daten eine objekt-orientierte Methode (Mhangara et al. 2011) und der *Road Extraction Index* (REI) (Shahi et al. 2015) veröffentlicht. Ebenfalls mit WorldView-2-Bildern wurde der *Morphological Building Index* (MBI) zusätzlich zum *Morphological Shadow Index* (MSI) (Huang und Zhang 2012) entwickelt. Angepasst auf Sentinel-2-Daten wurden verschiedene Indizes zur Klassifizierung der urbanen Ausbreitung von Valdiviezo-N et al. (2017) und Rahar und Pal (2019) auf ihre Wirksamkeit überprüft und deren Vorteile, Schwierigkeiten und auch Grenzen kritisch betrachtet. Morphologische Indizes erfordern eine sehr hohe räumliche Auflösung, da immer Kacheln statt Einzelpixeln betrachtet werden. Rein technisch ist die Aufnahme adäquater Daten mit heutiger Satellitentechnik auch flächendeckend möglich. Jedoch werden solche Aufnahmen nur auf Bestellung angefertigt und nur gegen Bezahlung ausgeliefert.

Nach den genannten optischen Ansätzen, die häufig aufgrund der großen Zeitspanne an vorhandenen Daten gewählt werden, wie auch in der Studie von Viana et al. (2019), in der auf 48 Landsat-Aufnahmen über sechs Jahre der NDVI, der NDBI, der *Normalized Difference Water Index* (NDWI, McFeeters 1996) und der *Normalized Difference Bareness Index* (NDBAI, Zhao und Chen 2005) angewandt und daraus die urbane Ausbreitung kartiert wurde, existieren auch einige Ansätze, welche auf Synthetic Aperture Radar (SAR)-Aufnahmen bzw. -Zeitreihen basieren. Wie in Abb. 1 zu erkennen ist, eignen sich diese Satellitenbilder ebenfalls zur Erkennung von Gebäuden bzw. von Bauvorgängen aufgrund der typischen Rückstreuemechanismen des Radarsignals. Deshalb wurde unter anderem versucht, die Ausdehnung von Städten bzw. allgemein die Kartierung

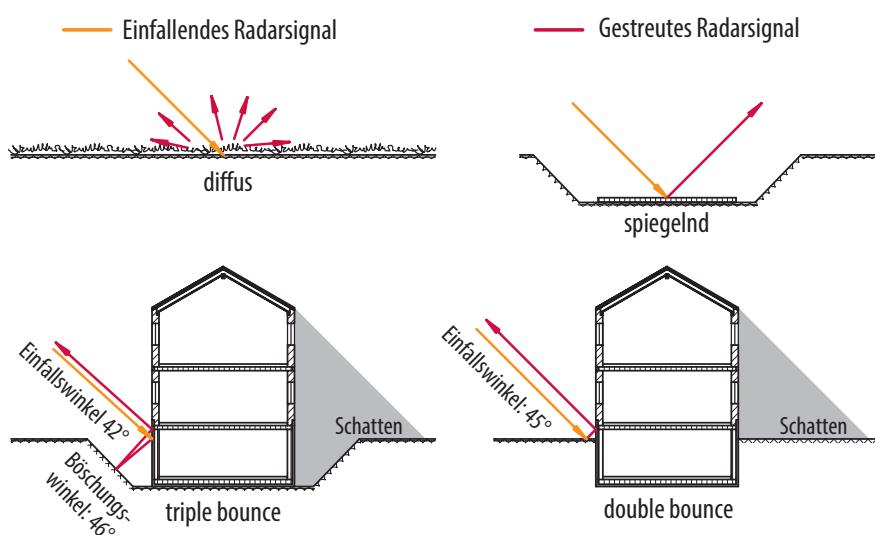


Abb. 1: Typische Rückstreuemechanismen eines Radarsignals: vor Baubeginn auf niedriger Vegetation (diffus), beim Einbau der Bodenplatte (spiegelnd), im Rohbau mit Keller (triple bounce) und im Rohbau ohne Keller bzw. bei bereits geschlossener Baugrube (double bounce). Der Radarsensor misst Amplitude und Phasenlage des in Richtung des einfallenden Strahls reflektierten Mikrowellensignals.

von urbanen Gebieten aus (multi-temporalen) SAR-Aufnahmen (Ban et al. 2015, Gamba et al. 2011, Herold und Gamba 2009, Li et al. 2015, Taubenböck et al. 2012) bzw. polarimetric interferometric SAR (POLinSAR) (Li et al. 2010) abzuleiten. In diesem Rahmen ist auch auf eine weitere Neuerung zur Abbildung aller menschlichen Siedlungen, den Global Urban Footprint (GUF), zu verweisen. Diese Karte stellt alle städtischen und ländlichen Siedlungen ab einer Pixelgröße von etwa 12 m weltweit abgeleitet aus TanDEM-X- und TerraSAR-X-Radarbildern dar (Esch et al. 2017). Ein ähnlicher Ansatz ist die von Miyazaki et al. (2013) entwickelte automatisierte Klassifikationsmethode aus optischen Satellitenbildern, aufgenommen mit dem Advanced Spaceborne Thermal Emission and Reflection Radiometer (ASTER/VNIR) und der Kombination dieser mit geografischen Informationssystem (GIS)-Daten bereits bestehender urbaner Kartierungen. Die aus diesen Daten mit einem iterativen maschinellen Klassifikationsverfahren abgeleiteten Karten weisen eine Pixelgröße von 15 m auf. Diese genannten weltweiten Siedlungskartierungen beziehen sich auf einen sehr engen Zeitraum, in dem die Aufnahmen gemacht wurden, und werden meist nur mit mehrjährigem zeitlichem Abstand wiederholt. In diesem Kontext ist zudem der World Settlement Footprint (WSF) 2019, eine der aktuellsten Neuerungen zur weltweiten Kartierung von urbanen Gebieten, zu nennen. Dieser wurde vom DLR (Deutsches Zentrum für Luft- und Raumfahrt), der ESA (European Space Agency) und dem Google Earth Engine Team generiert und resultiert aus S1- und S2-Aufnahmen mit einer Gitterweite von 10 m. Neben dem WSF 2019 ist als weiteres Produkt der WSF Evolution, basierend auf Landsat-Aufnahmen, mit einer Gitterweite von 30 m verfügbar, welcher die Entwicklung der Siedlungsgebiete im Zeitraum zwischen 1985 und 2015 in Jahresschritten aufzeigt (Marconcini et al. 2021). Innerstädtische Neu- oder Erweiterungsbauten werden darin nicht erfasst.

Speziell zur Baufallerkundung wurde eine neue Methode durch den Einsatz Künstlicher Intelligenz (KI) von Roschlaub et al. (2020a) publiziert. Diese stellt eine Alternative zu den beiden am Landesamt für Digitalisierung, Breitband und Vermessung (LDBV) eingesetzten Strategien, dem Filter- und Vergleichsklassenverfahren, dar, welche beide auf heuristischen Methoden basieren (Geßler et al. 2019, Roschlaub et al. 2020b). Für das Verfahren wird eine Kombination verschiedener Geodaten, unter anderem der Digitalen Flurkarte (DFK), dem True Digital Orthophoto (TrueDOP), dem normalisierten Digitalen Geländemodell (nDOM) und dem temporalen Digitalen Oberflächenmodell (tDOM) verwendet. Durch das Trainieren eines neuronalen Netzwerks können anschließend aus diesen Daten sowohl Neu- als auch Altbauten erkannt werden.

Dieses Verfahren nutzt die höchstauflösenden, im Zweijahres-Rhythmus akquirierten Luftbilder der Bayerischen Vermessungsverwaltung (BVV) und benötigt einen sehr großen Referenzdatensatz zum ausreichenden Training des KI-Algorithmus. Bei den Luftbildern läge zwar ebenfalls die Voraussetzung zur Anwendung der oben genannten

morphologischen Ansätze vor, jedoch könnte – unabhängig vom gewählten Algorithmus – nur alle zwei Jahre eine Aussage über Neubauten getroffen werden. Zudem beziehen sich die Luftbilder auf den sehr kurzen Zeitraum der Befliegung von wenigen Tagen und enthalten daher auch Baustelleneinrichtungen oder fliegende Bauten als vermeintliche Neubauten.

1.2 Zielsetzung

Im hier vorgestellten Baufallerkundungsservice sollen kostenlose, hochauflösende, multi-temporale Satellitendaten aus der Copernicus-Mission der ESA zum Einsatz kommen, um die oben genannten Defizite der bisher erprobten Verfahren auszumerzen. Durch die Verwendung von Kennaugh- bzw. Kennaugh-like-Elementen in dieser Arbeit ist als eine wichtige Vorarbeit das von Schmitt et al. (2015) vorgestellte Kennaugh-Framework zu nennen. Mit diesem können alle Arten von multi-skaligen, multi-temporalen, multi-polarisierten, multi-frequenten bzw. multi-sensoralen Daten und folglich alle verfügbaren Synthetic Aperture Radar (SAR) unabhängig von Sensor oder Aufnahmemodus verarbeitet werden. Zudem wird ein neues Rauschmodell entwickelt und zur adaptiven Rauschunterdrückung (»Multi-Scale Multi-Looking«) eingesetzt, welches in der Lage ist, die radiometrische Stabilität der Aufnahme zu erhöhen. Die Erweiterung der Kennaugh-Elemente auf multi-spektrale Daten wurde durch Schmitt und Wendleder (2018) als »SAR-Sharpening« im Kennaugh-Framework vorgestellt. Mittels der Kombination multi-modaler SAR und optischer Bilder ist in Kombination eine höhere geometrische sowie polarimetrische und damit radiometrische Auflösung zu erreichen. Basierend auf den beiden genannten Veröffentlichungen wurde von Schmitt et al. (2020) ein neuer konsistenter Rahmen für die gesamte Aufbereitung, Archivierung und Bereitstellung von Analysis Ready Data (ARD) aus multi-sensoralen und multi-temporalen Satellitenbildern mit einer integrierten, radiometrischen Datenfusion entwickelt. Die Fusion basiert auf einer orthogonalen Transformation der Reflektanzkanäle von optischen Sensoren auf hyperkomplexe Basen, die wiederum Kennaugh-like-Elemente liefert. Auf dieser Grundlage können optische und Radardaten fusioniert werden. Somit ist eine Kombination der Vorteile beider Datensätze möglich. Bis jetzt wurde das erweiterte Kennaugh-Framework für multi-spektrale Aufnahmen zwar als Ansatz publiziert, aber noch nicht in einem konkreten Anwendungsfall erprobt.

Für den neuen Ansatz zur Baufallerkundung wurde das oben genannte Kennaugh-Framework auf multi-temporale Aufnahmen angewandt, um eine Änderung im Gebäudebestand – in Form eines Gebäudenuebaus – zu erfassen. Auf den Einsatz selbstlernender Algorithmen wird ausdrücklich verzichtet, um den Verfahrensablauf so einfach wie möglich und damit nachvollziehbar und übertragbar zu halten. Hierfür wurden sowohl multi-spektrale Aufnahmen des passiven MultiSpectralImagers auf Sentinel-2 (S2)

als auch multi-polarisierte aktive Aufnahmen des SAR-Sensors auf Sentinel-1 (S1) als Zeitreihe über 14 Monate (Anfang Oktober 2019 bis Ende November 2020) betrachtet. Diese Datendienste eignen sich besonders gut, da sie für ganz Deutschland kostenlos und in regelmäßigen Abständen verfügbar sind. Dabei steht die fünftägige, aber aufgrund der starken Wetterabhängigkeit extrem löchrige Zeitreihe von S2 der 6-tägig durchgängig verfügbaren Zeitreihe von S1 gegenüber. Bei der neuen Baufallerkundungsmethode wurde vom Einsatz bereits bekannter Indizes aus den oben genannten Gründen abgesehen und komplett auf das Kennaugh-Framework (Schmitt et al. 2020) als konsistente und speicherplatzsparende Methode der Datenaufbereitung gesetzt. Als Testgebiet wurde aufgrund der hohen Bautätigkeit ein Neubaugebiet am nord-östlichen Rand der Stadt Dingolfing in Niederbayern gewählt, wo im Jahr 2020 über 30 neue Gebäude errichtet wurden. Das Untersuchungsgebiet umfasst mit einer Größe von $1,4 \text{ km} \times 1,4 \text{ km}$ sowohl eine Neubausiedlung als auch eine ältere, als unverändert angesehene Bestandssiedlung und zudem noch landwirtschaftlich genutzte Flächen.

Im folgenden Abschnitt wird nun näher auf die zugrundeliegende Methodik und die Vorgehensweise bei der Entwicklung des neuen prototypischen Algorithmus zur

automatischen Baufallerkundung eingegangen. Im Abschnitt 3 werden die Ergebnisse der Studie vorgestellt und diese im 4. Abschnitt mit den Angaben der Eigentümer aus der Umfrage validiert. Abschließend werden die Vor- und Nachteile bzw. wird die Verwendbarkeit der Datentypen diskutiert und ein für die Zukunft umsetzbarer Prozess aufgezeigt, der in der Lage ist, Neubauten anhand von S1- und S2-Daten vollautomatisch und trotzdem möglichst zuverlässig zu detektieren.

2 Methodik

Nachfolgend wird die Verarbeitung der Daten und die zugrundeliegende Methodik aufgezeigt. Die multi-temporalen Aufnahmen werden für S1 und S2 wegen Inkonsistenzen in der Zeitreihe jeweils getrennt im Kennaugh-Framework aufbereitet. Das Kennaugh-Framework ist eine Aufbereitungsmethode speziell für multi-modale Radaraufnahmen (Schmitt et al. 2015), die im Multi-SAR-Prozessor des Deutschen Zentrums für Luft- und Raumfahrt in den Jahren 2012 bis 2016 implementiert worden ist. Der Prozessor führt die Aufnahmen verschiedener satellitengetragener SAR-Sensoren mit unterschiedlicher Aufnahmegeometrie, räumlicher Auflösung und Polarisation über einem ausgewählten Gebiet vollautomatisch zu geokodierten Bildern zusammen. Durch die anschließende Bildverbesserung mit Hilfe des Multi-Scale Multi-Lookings bzw. der Schmittlets und der abschließenden Normierung auf Basis der TANH-Methode werden sogenannte Analysis Ready Daten (ARD) erzeugt. Die Übertragung des Kennaugh-Framework auf hyperkomplexe Basen schließt nun auch optische Satellitenaufnahmen sowie Zeitreihen mit ein (Schmitt et al. 2020). Eine prototypische Implementierung für die Copernicus-Missionen S1 und S2 wird derzeit an der Hochschule für Angewandte Wissenschaften München im Rahmen eines Forschungsprojekts realisiert.

Aus den daraus gewonnenen optischen Kennaugh-like-Elementen wird über eine Linear-kombination ein optimierter Index definiert. Mit der Anwendung des zeitlichen Gradienten und der anschließenden Sensitivitätsanalyse werden die Ergebnisse in einer sogenannten »Post Classification Data Fusion« zusammengeführt. Der daraus resultierende Prozessablauf kann Abb. 2 entnommen werden.

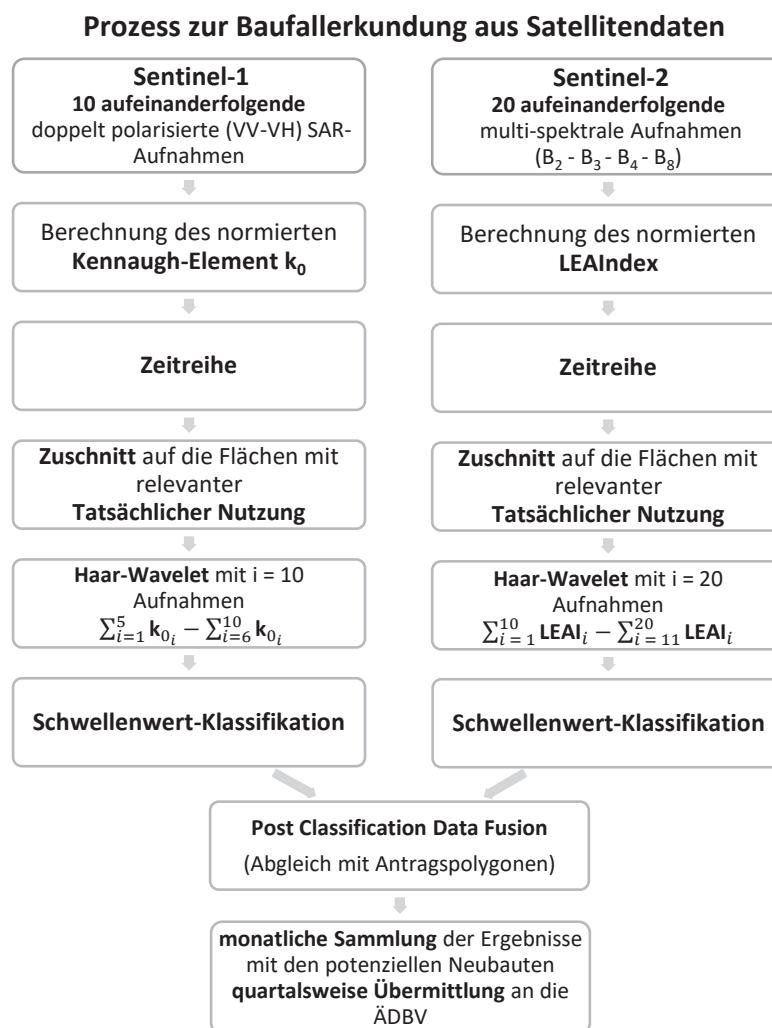


Abb. 2: Ablauf der automatischen Baufallerkundung

2.1 Aufbereitung der Satellitenbilder

Im ersten Schritt sind die Zeitreihen aus den Satellitendaten aufzubereiten. Hierfür wurden die ursprünglichen S1 Level-1 SLC, doppelt

polarisierten (VV-VH), mit dem Interferometric Wide Swath-Modus aufgenommenen Daten am Deutschen Zentrum für Luft- und Raumfahrt (DLR) durch das Multi-SAR-System vorprozessiert (Schmitt et al. 2015). Daraus resultieren geokodierte, kalibrierte und normalisierte Kennaugh-Elemente bzw. ein Level-2 SAR-Bild in einem konsistenten ARD-Datenformat (Bertram et al. 2016). Die für die Arbeit vorprozessierten Daten liegen somit für 67 Aufnahmemezeitpunkte als Multi-SAR-Stacks, jeweils in den Kennaugh-Elementen K_0 , K_1 , K_5 und K_8 vor. Die Pixelgröße der Aufnahmen beträgt $10 \text{ m} \times 10 \text{ m}$ im Koordinatensystem UTM Zone 33 Nord (EPSG:32633). Für die Bildung der multi-temporalen Aufnahmen werden die als Stack vorhandenen Multi-SAR-Bilder für jeden der 67 Aufnahmemezeitpunkte in die einzelnen Kennaugh-Elemente zerlegt. Im selben Schritt sind die Werte der Rasterdaten in Digital Numbers (DN) durch eine Tangens hyperbolicus (TANH)-Normierung zu skalieren und zur besseren Verwendbarkeit ist die Intensität um 5 dB zu verstärken. Ausgegeben werden die normierten Kennaugh-Elemente dann im platzsparenden Datenformat 8bit unsigned integer (UInt8) (Schmitt et al. 2015) als komprimiertes GeoTiff.

Als optische Daten werden atmosphärisch und bezüglich Zirruswolken korrigierte S2 Level 2A Mosaiken (MAJA-Daten) im Koordinatensystem UTM Zone 32 Nord (EPSG: 32632) verwendet (Hagolle et al. 2017). Die Rasterdaten liegen in Bottom-Of-Atmosphere (BOA) Reflektanzwerten vor, mit der höchsten Bodenauflösung mit 10 m-Pixeln, was den Bändern B_2 , B_3 , B_4 und B_8 (blau, rot, grün und Nahes Infrarot (NIR)) entspricht. Die 46 verwendbaren Satellitenbilder werden im nächsten Schritt – basierend auf dem Prinzip der hyperkomplexen Basen – in normierte Kennaugh-like-Elemente transformiert (Schmitt und Wendleder 2018, Schmitt et al. 2020), wodurch optische und Radardaten, vergleichbar als Ergebnis des Kennaugh-Frameworks, beide im Datenformat UInt8 vorliegen. Die Normierung erfolgt nach der TANH- bzw. Normalized Difference-Methode (bekannt von verschiedensten spektralen Indizes, siehe Kap. 1.1) und begrenzt den Wertebereich auf $[-1, +1]$, ohne jedoch einzelne Werte abzuschneiden. Die Abtastung im UInt8-Bild liegt in der Mitte bei 0,07 dB und steigt zum Rand hin auf 3 dB an, wobei ± 24 dB den größten unterscheidbaren Wert darstellt (Schmitt et al. 2015). Da immer nur Kanalrelationen abgelegt werden, ist dieser Wertebereich für die meisten Anwendungen völlig ausreichend. Für Spezialanwendungen ist auch eine zusätzliche Verstärkung problemlos möglich (siehe Vorverarbeitung der S1-Aufnahmen). Sowohl für die normierten polarimetrischen (k_0 , k_1 , k_5 , k_8) als auch die normierten optischen Kennaugh-Elemente (k_0 , k_1 , k_2 , k_3) wird jeweils ein multi-temporaler Stack mit 67 bzw. 46 Kanälen, welche den Aufnahmen zu den verwendeten Zeitpunkten entsprechen, gebildet. Außerdem findet ein Zuschnitt der Zeitreihen auf das Testgebiet statt. Die unterschiedlichen UTM-Zonen von S1 und S2 werden bei der Darstellung der Ergebnisse in QGIS wieder zusammengeführt.

2.2 Beschreibung der zeitlichen Signaturen

Mit dem Semi-Automatic Classification Plugin-Tool in QGIS (Congedo 2020) werden anschließend aus den vorher definierten Polygonen, den »Regions Of Interest« (ROIs), die Signaturen als Mittel der Pixelwerte für jeden Aufnahmemezeitpunkt der jeweiligen Zeitreihe berechnet. Für diese Arbeit werden für insgesamt drei verschiedene Klassen (Gebäude neu, Gebäude alt und Landwirtschaft) ROIs erstellt. Besonders wichtig sind hierbei die ROIs der im Testgebiet zwischen Anfang Oktober 2019 und Ende November 2020 neu entstandenen Wohnhäuser.

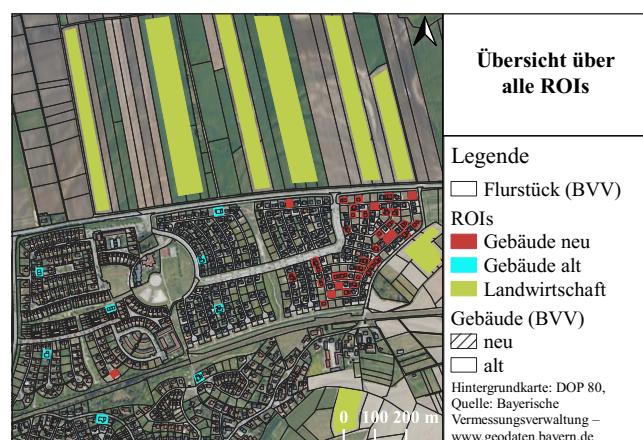


Abb. 3: Übersicht über alle generierten ROIs der Klassen »Gebäude neu«, »Gebäude alt« und »Landwirtschaft«

Um diese Häuser zu identifizieren, werden das Digitale Orthophoto (DOP) 80 der BVV, welches am 21.04.2020 über dem Gebiet erfasst wurde, und die DFK sowie die Erkundung vor Ort verwendet. Wie in Abb. 3 zu sehen ist, werden für den späteren Vergleich zudem ROIs über älteren Gebäuden sowie über landwirtschaftlichen Flächen im Testgebiet als eigene Klassen generiert. Für diese Polygone sind dann ebenfalls die Signaturen für alle Zeitreihen der normierten polarimetrischen und der optischen Kennaugh-Elemente zu berechnen. Gleicher gilt auch für die mit dem Haar-Wavelet (Kap. 2.4) modellierten multi-temporalen Aufnahmen, deren Signaturen der einzelnen ROIs ebenso berechnet werden.

2.3 LEAIndex zur Erkennung von Neubauten

Gebäude sind im RadARBild von S1 laut Abb. 1 an der extrem starken Rückstreuung, d.h. einem hohen Wert im Kennaugh-Element k_0 (Gesamtintensität nach Schmitt et al. (2015)), zu erkennen. Im multispektralen Bild von S2 ist die Zuordnung nicht ganz so eindeutig und erfordert eine Linearkombination der Kennaugh-like-Elemente. Der in dieser Arbeit entwickelte LEAIndex bildet die anwendungsspezifisch interessanten spektralen Informationen eines optischen Vierkanalbilds (B_2 , B_3 , B_4 , B_8) in einem einzigen Kanal ab. Der Index basiert auf dem Verlauf der Signaturen der Kennaugh-like-Elemente, insbesondere

k_1 , k_2 und k_3 . Die Gesamtintensität K_0 der Rückstreuung in den sichtbaren Wellenlängen und im Nahen Infrarot (Schmitt et al. 2020) spielt hier lediglich als Normierungsfaktor (Gleichung 2) eine gewisse Rolle. Der Grundgedanke hinter dem LEAI ist es, aus den normierten optischen Kennaugh-Elementen durch geschickte Kombination einen stärkeren Kontrast zu generieren, da k_1 und k_2 einen ähnlichen und k_3 einen dazu entgegengesetzten Verlauf aufweisen bzw. die Elemente ähnliche Ausschläge zeigen (vgl. Abb. 5b, Verlauf Mai–Juli). Deshalb bildet die Gleichung 1 die Grundlage für den Index.

$$\text{LEAI} = k_{1_{DN}} + k_{2_{DN}} - k_{3_{DN}} \quad (1)$$

Zur Rückführung des LEAI auf die zugrundeliegenden Kanäle von S2 werden die Kennaugh-like-Elemente k_1 , k_2 und k_3 durch die ursprünglichen Gleichungen (Schmitt und Wendleder 2018) mit den spektralen Bändern des S2-Layerstacks (B_2 , B_3 , B_4 und B_8) ersetzt und weiter vereinfacht.

$$\text{LEAI} = \frac{\underbrace{B_2 + B_3 + B_4}_{K_0} - \underbrace{B_8 - B_8 - B_8}_{\text{NIR}}}{\underbrace{B_2 + B_3 + B_4 + B_8}_{K_0}} \cdot 127 + 128 \quad (2)$$

In Gleichung 2 ist erkennbar, dass die drei visuellen Kanäle (VIS) und der Nahinfrarot-Kanal (NIR) entsprechend in dreifacher Gewichtung eingehen. Außerdem kann eine Konvertierung in DN vorgenommen werden, da diese sich sehr speicherplatzsparend auswirkt und der Informationsverlust dennoch minimal ist (Schmitt et al. 2020). Dies eignet sich später mitunter zur Einbindung des LEAI als (pseudo-kolorierter) Hintergrundlayer in einem WebMappingService. Wenn der LEAI nun auf einen optischen Layerstack angewandt wird, resultiert daraus – im Vergleich zu den ursprünglichen Kennaugh-like-Elementen – ein verstärkter Verlauf der Signatur des S2 multi-temporalen Datenstacks, siehe Abb. 5b. Diese genannte Verstärkung wird auf den S2-Datensatz durch Berechnung der Grundgleichung 1 mit den bereits generierten Zeitreihen verwendet und für sämtliche Auswertungen als Vergleich zur S1-Gesamtintensität k_0 eingesetzt.

2.4 Zeitlicher Gradient aus dem Haar-Wavelet

Multi-temporale Aufnahmen können mit verschiedenen Modellen approximiert werden, um daraus Informationen beispielsweise in Form von lokalen Extrema bzw. allgemein Veränderungen zu extrahieren und zu visualisieren. In dieser Arbeit liegt der Fokus auf der Anwendung des zeitlichen Gradienten – implementiert als Haar-Wavelet (Haar 1910) – auf die multi-temporalen Datensätze der S1-Gesamtintensität k_0 und der verstärkenden Kombination der Kennaugh-like-Elemente im LEAI.

Bei dem mit dem Haar-Wavelet angewandten Filter handelt es sich um einen diskreten Moving-Window-Ansatz, wodurch nicht für die gesamte Zeitreihe, sondern nur für die Aufnahmen innerhalb eines lokalen Bereichs mit vordefinierter Ausdehnung die zeitlichen Änderungen erfasst werden (Percival und Walden 2000). Durch das Anwenden des Filters findet eine Faltung der Messungen statt. Dabei weist ein Minimum auf eine positive Änderung und ein Maximum auf eine negative Änderung im Signal (k_0 von S1 und LEAI von S2) hin. Bei einem Wert von 0 hat keine Änderung stattgefunden. Das Haar-Wavelet an sich entspricht einem Hochpassfilter, wird jedoch durch eine Skalierung kombiniert mit einem vorangehenden Tiefpassfilter zu einem Bandpass-Filter und vermindert somit kurzzeitiges Rauschen. Je nach Größe des Filterkernels findet eine stärkere oder schwächere Glättung der Zeitreihen statt (Cattani 2004). In dieser Studie werden für die pixelweise Auswertung drei verschiedene Kernelgrößen angewandt. Dabei werden für die Berechnung des lokalen Gradienten zuerst je 2 (H_4), dann je 5 (H_{10}) und zum Schluss je 10 (H_{20}) Aufnahmen vor und nach dem betrachteten Zeitpunkt herangezogen. Die Verwendung der Wavelet-Funktion garantiert, dass der Prozessor erstens jederzeit gestartet werden kann, weil er keine explizite Nullmessung benötigt, und zweitens mit einer überschaubaren Datenmenge von maximal 20 Aufnahmen auskommt.

2.5 Sensitivitätsanalyse

Nach der Anwendung der verschiedenen Skalen des Haar-Wavelets wird eine Sensitivitätsanalyse zur Ermittlung des optimalen Schwellenwerts durchgeführt, um dadurch später den Bau neuer Gebäude im Testgebiet, unabhängig von den Signaturen der ROIs, nur durch den Ausschlag in der jeweiligen Haar-Signatur bestimmen zu können. Interessant sind in diesem Fall Minima, da diese eine positive Änderung, also eine Zunahme in den Werten darstellen, was auf eine mögliche Bauaktivität zurückgeführt werden kann. Da es sich bei den Signaturen um gemittelte Pixelwerte aus den zuvor definierten Polygonen handelt, werden zur Schwellenwertbestimmung zunächst die Minima

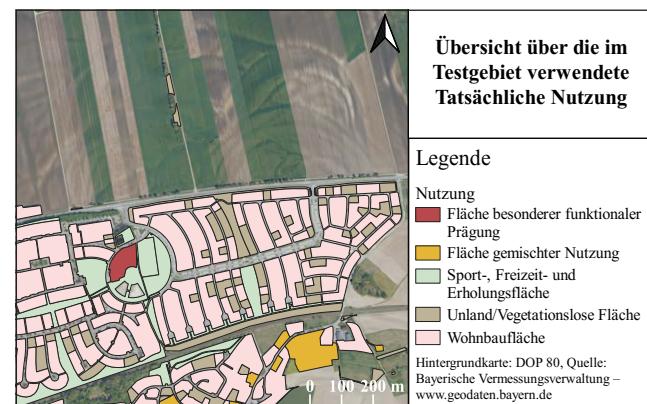


Abb. 4: Digitales Orthophoto und die für das Zuschneiden der Zeitreihen relevanten Polygone tatsächlicher Nutzung

der Pixel innerhalb der 38 ROIs der Neubauten über alle Aufnahmezeitpunkte berechnet. Zum Vergleich werden zudem die Minima der Pixelwerte der ROIs der alten Gebäude und der landwirtschaftlichen Flächen ausgegeben. Betrachtet werden hierfür die Werte der mit den drei verschiedenen Haar-Wavelets approximierten Zeitreihen von k_0 (S1) und LEAI (S2).

Der optimale Schwellenwert, bei dem möglichst viele neue Gebäude erkannt und möglichst wenige Fehlklassifikationen erfolgen, wird durch die Vollständigkeit oder »Producer's Accuracy« (PA) und die Richtigkeit oder »User's Accuracy« (UA) (Congalton 1991) ermittelt. Zur Ermittlung dieses Wertes wird ein ähnliches Validierungsverfahren wie in Schmitt et al. (2018) für die Genauigkeit der Detektion von Slums aus SAR-Daten angewandt. Dabei wird mit der PA ($PA \in [0,1]$) der Anteil an erkannten Neubauten in Bezug auf alle entstandenen Gebäude beschrieben. Die UA ($UA \in [0,1]$) beschreibt hingegen den Anteil an erkannten Neubauten in Bezug auf die als Neubau klassifizierten Pixel. Nicht erfasste neue Gebäude würden die PA und fälschlicherweise als neu erfasste Gebäude die UA verringern.

Da nur bestimmte Flächen als Bauplatz für ein neues Gebäude in Frage kommen, wird das Testgebiet zusätzlich mit den Daten über die tatsächliche Nutzung (TN) aus dem Amtlichen Liegenschaftskatasterinformationssystem

(ALKIS) auf die relevanten Bereiche (Abb. 4) zugeschnitten. Verwendet werden hierfür die Polygone mit folgenden Nutzungsarten als Attribut: Fläche besonderer funktionaler Prägung, Fläche gemischter Nutzung, Industrie- und Gewerbegebiete, Platz, Sport-, Freizeit- und Erholungsfläche, Unland/Vegetationslose Fläche und Wohnbaufläche.

Durch die anschließende Ausgabe der PA und UA in einem Diagramm kann durch den Schnittpunkt der beiden Graphen ein Schwellenwert ermittelt werden, bei dem beide Genauigkeiten denselben Wert aufweisen und somit möglichst viele Gebäude als Neubau erkannt und möglichst wenige Fehlklassifikationen verzeichnet werden.

3 Ergebnisse

Im Folgenden werden die durch die im vorherigen Kap. 2 beschriebene Methodik erzielten Ergebnisse dargelegt.

3.1 Zeitliche Signaturen

Ergebnis des ersten großen Bearbeitungsschrittes sind 76 Plots (S1 und S2) der berechneten temporalen Signaturen der 38 neu gebauten Wohnhäuser. Dabei werden für jedes Gebäude zwei Diagramme ausgegeben:

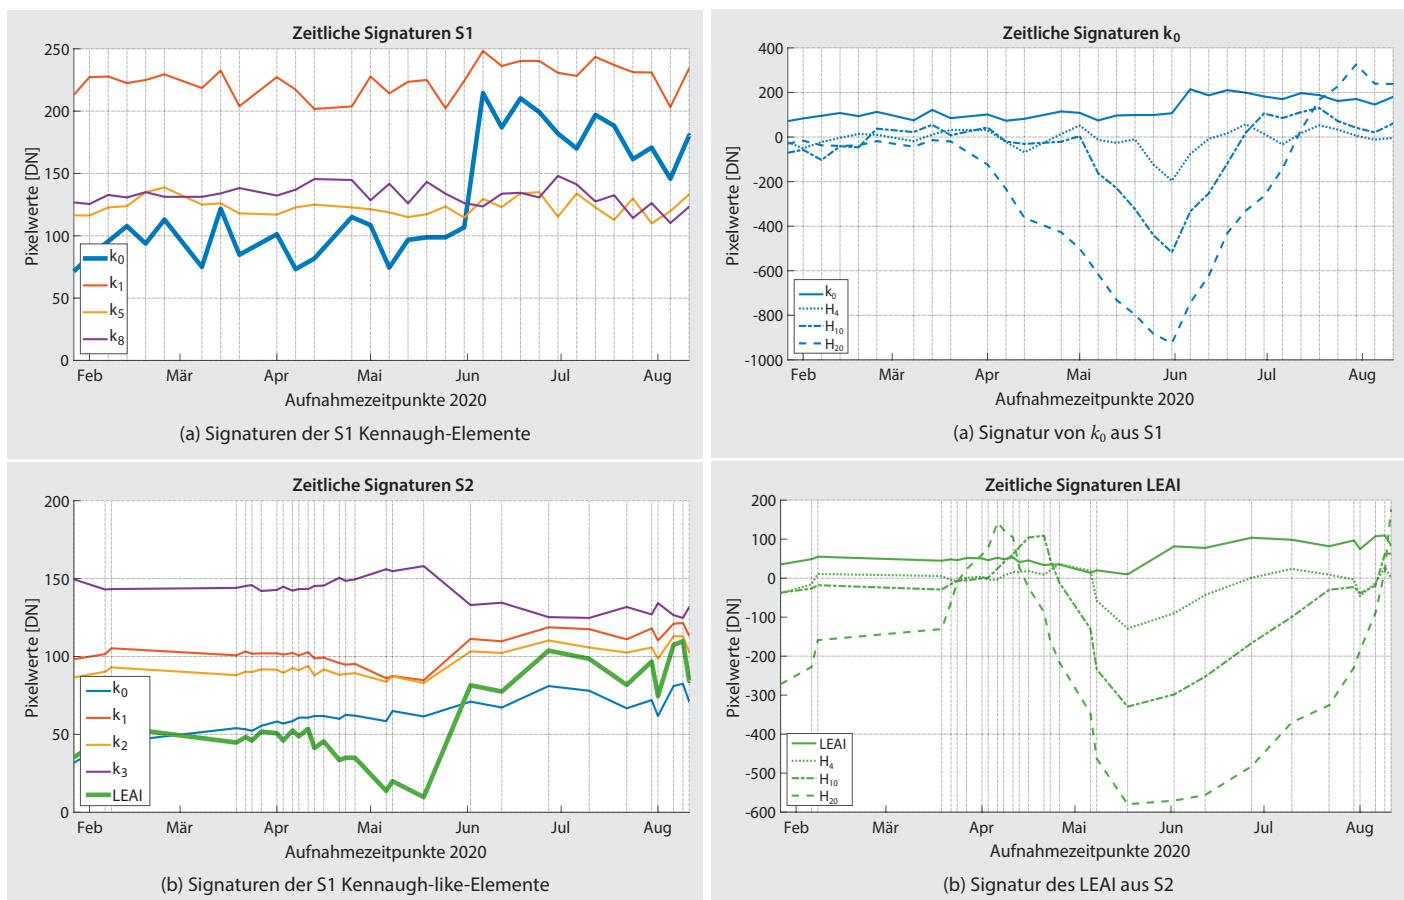


Abb. 5: Multi-temporelle Signaturen der S1 und S2 Kennaugh-(like-)Elemente und LEAI am Beispiel eines neu entstandenen Gebäudes (ROI 16)

Abb. 6: Zeitliche Signatur von k₀- und LEAI samt Wavelet-Filtrierungen mit den drei Skalen des Haar-Wavelets am Beispiel eines neu entstandenen Gebäudes (ROI 16)

Das erste enthält die Signaturen der Zeitreihen für die vier SAR (Abb. 5a) und das zweite die Signaturen für die vier Kennaugh-like-Elemente sowie die Signatur der Zeitreihe, auf die der LEAI (Abb. 5b) angewandt wurde.

Die mit den drei verschiedenen Skalen des Haar-Wavelets H_4 , H_{10} und H_{20} gefalteten k_0 -Signaturen (Abb. 6a) und LEAI-Signaturen (Abb. 6b) werden ebenfalls für jedes neu entstandene Gebäude jeweils in zwei Diagrammen ausgegeben. In den Plots ist zusätzlich zum Vergleich der zugehörige zeitliche Verlauf von k_0 und LEAI dargestellt.

3.2 Sensitivitätsanalyse

Aus der Schwellenwert-Klassifikation resultieren zwei Diagramme, die für die jeweiligen Schwellenwerte in Digital Numbers die UA und PA darstellen. Diese liegen getrennt jeweils für das Haar-Wavelet H_4 , H_{10} und H_{20} für die multi-temporalen Datensätze von k_0 (S1) (Abb. 7a) und LEAI (S2) (Abb. 7b) vor.

Der Abb. 8 ist als weiteres Ergebnis ein Ausschnitt der Schwellenwert-Klassifikation, angewandt auf den mit dem Haar-Wavelet H_{10} approximierten k_0 , zu entnehmen. Dabei werden die Pixel, welche dem originalen S1-Rasterbild entsprechen, basierend auf der Sensitivitätsanalyse in den drei Abstufungen mit hoher, mittlerer und geringer Wahrscheinlichkeit für einen Neubau eingefärbt.

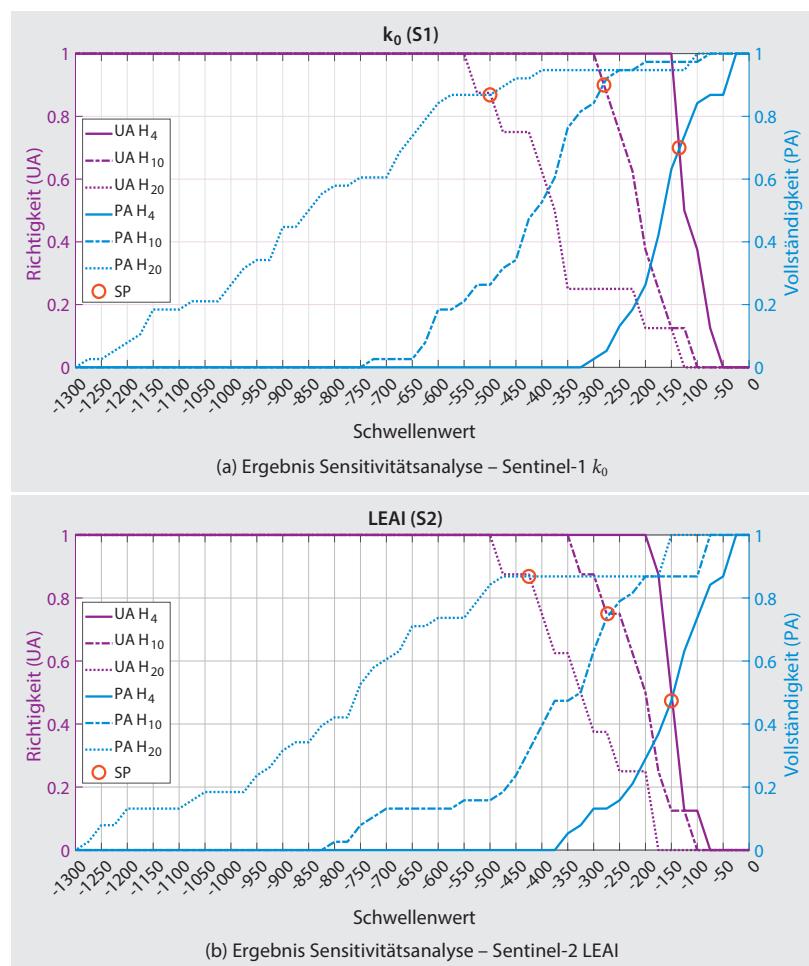


Abb. 7: Ergebnis der Sensitivitätsanalyse der mit den drei Skalen des Haar-Wavelets gefalteten k_0 - und LEAI-Zeitreihen – UA stellt die Fehlklassifikationen in der Klasse Gebäude neu (ohne Landwirtschaft und alte Gebäude) dar. PA zeigt den Anteil der erkannten Neubauten an der Summe aller 38 neu entstandenen Gebäude. Die Schnittpunkte (SP), an denen PA = UA gilt, sind markiert.



Abb. 8: Ausschnitt aus der Klassifikation der k_0 -Zeitreihe von S1 gefiltert mit dem H_{10} -Wavelet – zur Übersichtlichkeit sind die »Gebäude alt« nur in der Aufnahme vom 07.05.2020 eingeblendet. Die eingefärbten Pixelflächen der Wahrscheinlichkeitsangabe resultieren aus den originalen 10 m × 10 m-Pixel der vorprozessierten S1-Satellitendaten.

Wahrscheinlichkeit für Neubau	Flurstück
hoch	■
mittel	□
gering	▨
Gebäude/Bauwerk	▨
neu	▨
alt	□

Quelle: Bayerische Vermessungsverwaltung – www.geodaten.bayern.de

4 Validierung

Zur Validierung aller Ergebnisse (Tab. 1) wurde an zwei Tagen direkt im Untersuchungsgebiet eine Umfrage zum zeitlichen Verlauf des Baus der als ROI verwendeten Wohnhäuser durchgeführt. Von insgesamt 37 Befragten (ROI 38 wurde ausgelassen, da es sich hierbei um ein Mietshaus handelte) nahmen 25 an der Umfrage teil, fünf Eigentümer wollten keine Auskunft geben und die restlichen sieben wurden nicht persönlich angetroffen bzw. haben sich nicht auf das hinterlassene Anschreiben gemeldet.

Tab. 1: Übersicht zu den Ergebnissen der beiden Zeitreihen in Kombination mit der darauf angewandten Methodik. Zum einen aus der visuellen Auswertung der Signaturen und zum anderen als Ergebnis der Sensitivitätsanalyse. S1 steht immer für die Zeitreihe der Gesamtintensität k_0 und S2 für die des LEAI.

Methodik	Daten	Ergebnis
Visuell erkannte Neubauten aus zeitlicher Signatur	S1	58 %
	S2	68 %
Visuell erkannte Neubauten aus zeitlichem Gradienten	S1	89 %
	S2	86 %
Mit Schwellenwert aus der Sensitivitätsanalyse	H_4	70 %
	S1 H_{10}	90 %
	H_{20}	87 %
automatisch erkannte Neubauten	H_4	48 %
	S2 H_{10}	75 %
	H_{20}	87 %

Bei der Befragung wird zwischen drei verschiedenen Gebäudetypen unterschieden: dem Fertighaus, dem gemauerten Haus und einem Gebäude aus Holzständerbauweise, wobei Letzteres aufgrund der ähnlichen Erscheinung in der Satellitenbildzeitreihe mit Ersterem zusammengefasst werden kann. Zudem wird dokumentiert, ob das Wohnhaus über einen Keller verfügt. Die weiteren Fragen fokussieren sich dann auf den zeitlichen Verlauf, beginnend mit dem Aushub der Baugrube am Anfang, dem anschließenden Guss der Bodenplatte, dem Start des Rohbaus als nächsten zeitlichen Eckpunkt, über das Aufrichten des Dachstuhls bis hin zur Vollendung des Dachs mit der Eindeckung. Bei den neuen Gebäuden ohne Angaben der Eigentümer zum Bau werden die Zeitpunkte der Minima mit dem DOP 80 abgeglichen. Mit der Validierung anhand der Eigentümerdaten können in Form eines klar erkennbaren Sprungs in der zeitlichen Signatur 58 % (22 Gebäude) der Neubauten im Verlauf des S1 Kennaugh-Elements k_0 und 68 % (26 Gebäude) im Verlauf der Signatur des LEAI erkannt werden.

Für die mit den drei verschiedenen Skalen des Haar-Wavelets gefilterten Zeitreihen können durch konkrete Minima, welche eine Veränderung in Form einer Zunahme darstellen, 89 % (34 Gebäude) an Neubauten aus dem S1 und 86 % (33 Gebäude) aus dem S2 multi-temporalen

Datensatz nach Validierung des Zeitpunktes mit den vorhandenen Eigentümerdaten erfasst werden. Die Minima der Pixelwerte der ROIs und somit die Schwellenwerte der einzelnen neu entstandenen Gebäude werden jeweils mit den aus der Umfrage bekannten Angaben überprüft und dadurch validiert. Durch die Validierung können die UA und PA und die daraus resultierenden Schnittpunkte in den Diagrammen (Abb. 7) der Schwellenwert-Klassifikation ermittelt werden. Somit wird bei der k_0 -Zeitreihe (Abb. 7a), welche mit dem H_4 -Wavelet modelliert wird, eine Genauigkeit von etwa 70 % erreicht. Wohingegen bei der Faltung mit dem H_{20} -Wavelet schon 87 % und mit dem H_{10} -Wavelet sogar 90 % zu verzeichnen sind.

Ähnliches ist auch für den multi-temporalen LEAI aus S2 zu erkennen (Abb. 7b). Hier weist die mit dem H_4 -Wavelet modellierte Zeitreihe die geringste Genauigkeit von 48 % auf. Mit der Anwendung des H_{10} -Wavelets auf die Zeitreihe wird bereits eine höhere Genauigkeit von 75 % und die höchste in Form von 87 % durch die Faltung mit dem H_{20} -Filterkernel erreicht.

5 Diskussion

In diesem Kapitel werden abschließend die erzielten Ergebnisse genauer betrachtet. Ein Augenmerk liegt dabei auf der Güte der verschiedenen Datensätze von S1 und S2.

5.1 Datenlage

Bei der Datenlage stellten vor allem bei den S2 L2A-Bildern trotz Vorprozessierung mit dem MAJA-Prozessor die starke Bewölkung und Dunst ein Problem dar, wodurch von ungefähr 80 möglichen Aufnahmen nur 46 verwendet werden konnten und teilweise Lücken von bis zu einem Monat entstanden. Diesem Problem kann eine dichtere Aufnahmerekord Abhilfe schaffen. Eine Möglichkeit wäre hier der Einsatz von Planet-Scope-Daten der Firma Planet, welche durch tägliche Aufnahmen eine höhere Datendichte und somit potenziell mehr wolkenfreie Bilder bieten könnten. Der Zugang zu diesem Satellitensystem ist jedoch kostenpflichtig. Die S1-Aufnahmen hingegen sind aufgrund der Wetterunabhängigkeit des aktiven SAR-Systems bis auf drei Zeitpunkte im März und April konstant im Abstand von sechs Tagen vorhanden (Abb. 5a). Durch Wartungsarbeiten kann es durchaus vorkommen, dass von Zeit zu Zeit eine Aufnahme ausfällt, was sich aber wie gesehen auf lediglich 5 % der Zeitreihe anhäuft. Trotz der Klaffungen in der Sentinel-2-Zeitreihe ist die Aktualität und die Verfügbarkeit der Daten, zum Beispiel im Vergleich zum DOP der BVV, welches nur im zwei Jahres-Zyklus neu erfasst wird, um einiges höher. Somit bietet die neue Methode eine bessere zeitliche Abdeckung.

Mit Validierung der Eigentümerangaben zeigt sich, dass für den S1-Datensatz die Gesamtintensität k_0 die

meisten Informationen zum Bau eines neuen Gebäudes enthält (Abb. 5a). Für den S2-Datensatz hat sich der neu entwickelte LEAIndex, aufgrund des verstärkten Verlaufs im Vergleich zu den Kennaugh-like-Elementen, als äußerst gute Möglichkeit zur besseren Auswertung der S2-Zeitreihen herausgestellt. Zudem kombiniert er alle notwendigen Informationen in einem Kanal, wodurch lediglich die Analyse eines einzelnen optischen Datensatzes notwendig ist. Der LEAI wird zusätzlich zur Erkennung von Neubauten dadurch gestützt, dass das Band 8, welches dem Nahen Infrarot (NIR) entspricht, stärker gewichtet ist. Infolgedessen wird die Versiegelung (geringe Rückstreuung im NIR) von gesunder Vegetation (hohe Rückstreuung im NIR) besser abgegrenzt. Ein weiterer großer Vorteil des LEAI und generell des Kennaugh-Frameworks ist die verwendete TANH-Normierung, durch welche die Bit-Tiefe und somit der benötigte Speicherplatz reduziert wird, ohne dass dadurch ein nennenswerter Informationsverlust entsteht (Schmitt et al. 2020). Der geschlossene Wertebereich erleichtert zudem die Auswertung und vor allem die Visualisierung der Daten.

5.2 Signaturen

Trotz des radiometrischen Rauschens – ganz besonders im Verlauf der Signaturen der S1-Daten – kann ohne Vorwissen zum Bau der insgesamt 38 neuen Gebäude bereits bei 22 (S1) bzw. 26 (S2) die Bautätigkeit auf einen konkreten Sprung in den Signaturen bezogen werden. Die zeitlichen Verläufe der Signaturen werden durch die Anwendung des Haar-Wavelets deutlich geglättet und durch klar erkennbare Extrema leichter auswertbar (Abb. 6). Dadurch können, im Gegensatz zu den ungefilterten Kennaugh-Elementen, auch visuell mehr Bauaktivitäten anhand der auftretenden Minima erkannt werden, weshalb die Wavelet-gefilterten Daten zu bevorzugen sind.

Durch den Abgleich der Signaturen mit den Eigentümerangaben wird der Zusammenhang des Verlaufs der Bautätigkeit und dem zeitlichen Auftreten der Sprünge in den zwei verschiedenen Datensätzen deutlich. Die Signaturen der S2-Zeitreihe weisen bereits eine klare Änderung beim Aushub der Baugrube bzw. dem Guss der Bodenplatte auf. Dies ist auf die starke Veränderung der erfassten spektralen Reflektanzen zurückzuführen, da die Versiegelung einer gesunden Vegetationsfläche vor allem im Nahen Infrarot eine starke Änderung bewirkt (Kuechly et al. 2020). Im Gegensatz dazu wird mit einem Sprung in den S1-Daten vor allem der Beginn des Rohbaus angezeigt. Dies ist auf die Reflexionsmechanismen bezüglich der ausgesendeten Radarwellen in den verschiedenen Stadien des Hausbaus zurückzuführen (Abb. 1). Bei einer noch unbebauten Vegetationsfläche findet eine diffuse Reflexion statt und bei dem Bau der Bodenplatte wird das einfallende Radarsignal spiegelnd abgelenkt. Erst bei Beginn des Rohbaus kann durch einen »double bounce« an der Gebäudefassade bzw. wenn ein Keller vorhanden ist durch einen »triple bounce«

zwischen Fassade und der Böschung der Baugrube eine deutliche Zunahme in der zurückkommenden Intensität des SAR-Signals registriert werden.

5.3 Sensitivitätsanalyse

Ein Vorteil des bereits genannten Multi-SAR-Systems ist es, aufgrund der Reduktion von stochastischen Variationen, mit einer einfachen Schwellenwert-Klassifikation – statt rechenintensiver KI – bereits zeitliche Änderungen zuverlässig erkennen zu können (Schmitt et al. 2020). Die Auswertungen der Vollständigkeit (PA) und Richtigkeit (UA) (Kap. 3.2) zeigen ebenso wie die Signaturen selber, dass für die S1-Zeitreihe mit dem Haar-Wavelet H_{10} , welches 10 Aufnahmen in die Filterung mit einbezieht, mit 90 % die höchste Genauigkeit erreicht werden kann. Im Vergleich dazu liefern die S2-Daten eine ähnliche Genauigkeit von 87 %, aber erst durch die Erweiterung des Haar-Wavelets um weitere 10 Aufnahmen auf H_{20} . Die etwas besseren Ergebnisse des Radarsystems trotz halbiertem Beobachtungszeitraum sind auf die höhere Aufnahmedichte zurückzuführen. Mit der Klassifikation bzw. auch den oben genannten, durch das Haar-Wavelet gefalteten Signaturen konnten bereits viele Neubauten detektiert werden, bei manchen sind jedoch Unregelmäßigkeiten aufgetreten, auf die im Folgenden näher eingegangen wird.

Der Neubau zweier Gebäude konnte mit der S1-Zeitreihe nicht erkannt werden. Als Grund hierfür ist die geringe Gebäudegröße von etwa 10 m × 10 m, was der Pixelgröße der Zeitreihen entspricht, zu nennen. Bei Gebäuden in dieser Größenordnung kann es sein, dass das vom Neubau erzeugte Signal in dem Radar-inhärenten Speckle-Rauschen z.B. über angrenzenden naturbelassenen Flächen untergeht und die Bautätigkeit somit nur unzuverlässig erkannt wird. Die verwendeten 10 m × 10 m-Pixel für S1 haben sich mittlerweile etabliert, weil sie einen guten Kompromiss zwischen räumlicher Auflösung und radiometrischer Stabilität darstellen und die Kompatibilität mit S2 gewährleisten. Ein erster Versuch wäre hier die feinere Abtastung der S1-Daten, die in Aufnahmegeometrie eine Pixelgröße von 2,3 m × 14,1 m aufweisen, auf 5 m × 5 m-Pixel im Zuge der Geokodierung.

Ein weiterer Lösungsansatz wäre die Kombination mit den S2-Daten, in denen der Bau – in den betrachteten zwei Beispielen – durchaus erkannt wird oder allgemein die Einbeziehung von höher auflösenden Satellitensystemen. Ein Beispiel für optische Daten sind die bereits erwähnten Planet-Scope-Aufnahmen, die mit einer Pixelkantenlänge am Boden von 3,7 m bereitgestellt werden, oder SAR-Daten mit einer Abtastung von 3,5 m × 3,5 m im Original, welche der S1-StripMap-Mode liefern würde bzw. auch das zukünftige High Resolution Wide Swath (HRWS)-Radarsatelliten-Projekt generieren wird. Des Weiteren kann es bei einer Bauaktivität auf dem benachbarten Grundstück, durch Interferenzen und Abbildungseffekte zu einem Fehlauschlag in den Signaturen bzw. bei der

S1-Schwellenwert-Klassifikation kommen. Dieser Einfluss könnte durch den Einsatz höher auflösender Daten jedoch ebenfalls reduziert werden. In der Regel verringert sich aber derzeit noch mit höherer Auflösung die räumliche Abdeckung der Satellitenszene, was eine flächendeckende Anwendung erschwert.

Durch die bereits vorhandene hohe zeitliche Auflösung der Daten ist im Vergleich zum Verfahren von Roschlau et al. (2020a) kein Problem durch temporär vorhandene Bauwerke, wie fliegende Bauten oder Baustelleneinrichtungen, gegeben. Die dadurch verursachten kurzzeitigen Ausschläge in den Daten werden durch die Anwendung des Haar-Wavelets geglättet. Noch robuster könnte das Verfahren durch die Verwendung hyperkomplexer Basen in zeitlicher Dimension (Schmitt et al. 2020), statt der Haar-Wavelets, gestaltet werden, da kurzzeitige Variationen dadurch ebenso erfasst und somit bei der Klassifikation explizit ausgeschlossen werden können.

5.4 Aufzeigen eines automatisierten Prozesses

Die Bewertung und Diskussion der Ergebnisse aus den beiden Datenquellen bestätigt den Verfahrensablauf aus Abb. 2, mit dem aus Satellitendaten die Detektion von Neubauten realisiert werden kann. Es wäre ein Prozess realisierbar, der beide – sowohl optische als auch Radar-Aufnahmen – getrennt auswertet und dann die Ergebnisse im Rahmen einer Post Classification Data Fusion kombiniert. Wenn dann zuerst ein Ausschlag in der optischen Zeitreihe beim Einbau der Bodenplatte und kurz darauf ein weiterer Ausschlag in der SAR-Zeitreihe beim Errichten vertikaler Strukturen des Rohbaus zu verzeichnen ist, kann mit an Sicherheit grenzender Wahrscheinlichkeit davon ausgegangen werden, dass an dieser Stelle wirklich ein neues Gebäude entstanden ist. Dadurch könnte die Detektion eines Neubaus mit einer zusätzlichen Kontrolle noch zuverlässiger festgestellt werden. Weiterhin würden sich die beiden Datensätze auch dahingehend ergänzen, dass die diskutierten Vor- und Nachteile der jeweiligen Systeme kombiniert und dadurch ausgeglichen werden.

6 Fazit

Neben der Anwendung des Kennaugh-Frameworks auf Radardaten aus Sentinel-1 wurden mit der Studie zum ersten Mal auch die neuartigen optischen Kennaugh-like-Elemente aus Sentinel-2 überaus erfolgreich im praktischen Einsatz getestet. Es kann abschließend festgestellt werden, dass sich sowohl der neu entwickelte LEAI als auch die neue Baufallerkundungsmethode – trotz der lückenhaften Sentinel-2-Zeitreihe und der Pixelgröße von immerhin $10\text{ m} \times 10\text{ m}$ – mit Genauigkeiten bis zu 90 % als sehr wirksam und gut anwendbar herausgestellt haben. Außerdem weist das Verfahren eine um den Faktor 100 höhere zeitliche Auflösung als derzeit verwendete Methoden

auf Basis der Luftbildbefliegungen auf. Die Satellitenaufnahmen stehen zudem komplett kostenlos zur Verfügung. Das durchweg deterministische Verfahren braucht keinerlei Trainingsdaten und liefert klar beleg- und nachvollziehbare Aussagen. Bei den weiterhin zu erwartenden Wachstumsraten in der Baubranche (Gornig et al. 2021) würde das Verfahren eine Effizienzsteigerung und Erleichterung der Arbeit an den ÄDBV mit sich bringen und könnte durch zusätzliche Optimierungen wie beispielsweise die Verwendung hyperkomplexer Basen in zeitlicher Dimension als Erweiterung des Wavelet-Ansatzes bzw. die Einbeziehung weiterer Datensätze zukünftig noch fortentwickelt und großflächig erprobt werden.

Danksagung

Ein Dank gilt der European Space Agency (ESA) für die kostenlose Bereitstellung der Satellitendaten, im Detail der Satellitenbilder von Sentinel-1 und Sentinel-2 (©ESA data 2019 & 2020). Des Weiteren ist hier dem Deutschen Zentrum für Luft- und Raumfahrt (DLR) zum einen für die Aufbereitung der Sentinel-1-Aufnahmen im Multi-SAR-System und zum anderen für die Bereitstellung der Sentinel-2 L2A MAJA-Daten zu danken. Für die kostenlose Bereitstellung des Digitalen Orthophotos (DOP 80) und der ALKIS-Daten möchten sich die Autoren bei der Bayerischen Vermessungsverwaltung, insbesondere dem ADBV Landau a. d. Isar bedanken. Abschließend ist noch den Bewohnern des Testgebiets in Dingolfing, die bereit waren, an der Umfrage zur Validierung der Ergebnisse teilzunehmen, besonderer Dank und Anerkennung entgegenzubringen.

Literatur

- As-syakur, A. R., Adnyana, I. W. S., Arthana, I. W., Nuarsa, I. W. (2012): Enhanced Built-Up and Bareness Index (EBBI) for Mapping Built-Up and Bare Land in an Urban Area. In: Remote Sensing 4 (2012), oct, Nr. 10, 2957–2970. www.mdpi.com/2072-4292/4/10/2957, letzter Zugriff 2021-02-26.
- Ban, Y., Jacob, A., Gamba, P. (2015): Spaceborne SAR data for global urban mapping at 30 m resolution using a robust urban extractor. In: ISPRS Journal of Photogrammetry and Remote Sensing 103 (2015), may, 28–37. www.sciencedirect.com/science/article/pii/S0924421614002032?via=ihub, letzter Zugriff 2021-02-27.
- Bertram, A., Wendleder, A., Schmitt, A., Huber, M. (2016): Long-term Monitoring of water dynamics in the Sahel region using the Multi-SAR-System. In: The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences (2016), 1–8. https://elib.dlr.de/107607/1/Bertram-Long-term_monitoring_of_water_dynamics_in_the_Sahel_region_using_the_Multi-SAR-System-1146_a.pdf, letzter Zugriff 2020-11-15.
- Bhatti, S. S., Tripathi, N. K. (2014): Built-up area extraction using Landsat 8 OLI imagery. In: GIScience & Remote Sensing 51 (2014), Nr. 4, 445–467. DOI: 10.1080/15481603.2014.939539, letzter Zugriff 2021-10-17.
- Bouhennache, R., Boudin, T., Taleb-Ahmed, A., Cheddad, A. (2019): A new spectral index for the extraction of built-up land features from Landsat 8 satellite imagery. In: Geocarto International 34 (2019), Nr. 14, 1531–1551. DOI: 10.1080/10106049.2018.1497094, letzter Zugriff 2021-10-17.

- Bouzekri, S., Lasbet, A. A., Lachehab, A. (2015): A New Spectral Index for Extraction of Built-Up Area Using Landsat-8 Data. In: Journal of the Indian Society of Remote Sensing 43 (2015), jul, Nr. 4, 867–873. <https://link.springer.com/article/10.1007/s12524-015-0460-6>, letzter Zugriff 2021-02-26.
- Cattani, C. (2004): Haar wavelet-based technique for sharp jumps classification. In: Mathematical and Computer Modelling: An International Journal 39 (2004), Nr. 2-3, 255–278.
- Congalton, R. G. (1991): A review of assessing the accuracy of classifications of remotely sensed data. In: Remote Sensing of Environment 37 (1991), jul, Nr. 1, 35–46. www.sciencedirect.com/science/article/pii/003442579190048B, letzter Zugriff 2021-03-03.
- Congedo, L. (2020): Semi-Automatic Classification Plugin Documentation Release 7.0.0.1 Luca Congedo.
- Deng, C., Wu, C. (2012): BCI: A biophysical composition index for remote sensing of urban environments. In: Remote Sensing of Environment 127 (2012), dec, 247–259. www.sciencedirect.com/science/article/pii/S003442571200363X?via=ihub, letzter Zugriff 2021-02-26.
- Deng, Y., Wu, C., Li, M., Chen, R. (2015): RNDSI: A ratio normalized difference soil index for remote sensing of urban/suburban environments. In: International Journal of Applied Earth Observation and Geoinformation 39 (2015), jul, 40–48. www.sciencedirect.com/science/article/pii/S0303243415000422?via=ihub, letzter Zugriff 2021-02-26.
- Esch, T., Heldens, W., Hirner, A., Keil, M., Marconcini, M., Roth, A., Zeidler, J., Dech, S., Strano, E. (2017): Breaking new ground in mapping human settlements from space – The Global Urban Footprint. In: ISPRS Journal of Photogrammetry and Remote Sensing 134 (2017), 30–42. ISSN 0924-2716. www.sciencedirect.com/science/article/pii/S0924271617301880.
- Firozjaei, Sedighi, Kiavarz, Qureshi, Haase, Alavipanah (2019): Automated Built-Up Extraction Index: A New Technique for Mapping Surface Built-Up Areas Using LANDSAT 8 OLI Imagery. 11 (2019), August, Nr. 17, 1966. www.mdpi.com/2072-4292/11/17/1966/htm, letzter Zugriff 2021-10-17.
- Gamba, P., Aldrighi, M., Stasolla, M. (2011): Robust extraction of urban area extents in HR and VHR SAR images. In: Selected Topics in Applied Earth Observations and Remote Sensing, IEEE Journal of 4 (2011), 04, 27–34. www.researchgate.net/publication/224156455_Robust_extraction_of_urban_area_extents_in_HR_and_VHR_SAR_images, letzter Zugriff 2021-02-27.
- Gefßler, S., Krey, T., Möst, K., Roschlau, R. (2019): Mit Datenfusionierung Mehrwerte schaffen – Ein Expertensystem zur Baufallerkundung. In: Mitteilungen des DVW Bayern e.V., Heft 2 (2019), 159–187. ISSN 1613-3064. https://bayern.dvw.de/images/lv/bayern/datei/Datenfusion-Baufallerkundung_DVW2019-2.pdf.
- Gornig, M., Michelsen, C., Pagenhardt, L. (2021): Bauwirtschaft trotz der Corona-Krise – dennoch ruhigeres Geschäft im Jahr 2021. In: DIW Wochenbericht (2021), Nr. 1+2/2021, 3–14. ISSN 1860-8787. www.diw.de/documents/publikationen/73/diw_01.c.808414.de/21-1.pdf, letzter Zugriff 2021-02-21.
- Haar, A. (1910): Zur Theorie der orthogonalen Funktionensysteme. In: Mathematische Annalen 69 (1910), sep, Nr. 3, 331–371. <https://link.springer.com/article/10.1007/BF01456326>, letzter Zugriff 2021-03-08.
- Hagolle, O., Huc, M., Desjardins, C., Auer, S., Richter, R. (2017): MAJA ATBD – Algorithm Theoretical Basis Document. Dezember 2017. www.theia-land.fr/wp-content/uploads/2018/12/atbd_maja_071_217.pdf, letzter Zugriff 2021-01-31.
- Herold, M., Gamba, P. (2009): Global Mapping of Human Settlement: Experiences, Datasets, and Prospects. 01 2009. – ISBN 1420083392.
- Huang, X., Zhang, L. (2012): Morphological Building/Shadow Index for Building Extraction From High-Resolution Imagery Over Urban Areas. In: IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing 5 (2012), Nr. 1, 161–172. <https://ieeexplore.ieee.org/document/6056582>, letzter Zugriff 2021-03-14.
- Jieli, C., Manchun, L., Yongxue, L., Chenglei, S., Wei, H. (2010): Extract residential areas automatically by New Built-up Index. In: 2010 18th International Conference on Geoinformatics, IEEE, 2010, 1–5. <https://ieeexplore.ieee.org/document/5567823>, letzter Zugriff 2021-02-26.
- Kuechly, H., Cozaci, A., Kodl, G., Nicolai, C., Vallentin, C. (2020): Grundlagen der Fernerkundung. In: Inforeihe SAPIENS: Satelliten-daten für Planung Industrie (2020), S. Energiewirtschaft und Natur-schutz.
- Li, X., Guo, H., Yang, H., Sun, Z., Zhang, L., Yan, S., Shen, G., Wu, W., Liang, L., Wang, M. (2015): Monitoring Recent Urban Expansion and Urban Subsidence of Beijing Using ENVISAT/ASAR Time Series Datasets. In: Remote Sensing Time Series. Springer Internatio-nal Publishing, 2015, 401–426.
- Li, X., Pottier, E., Guo, H., Ferro-Famil, L. (2010): Urban land cover classification with high-resolution polarimetric SAR interferometric data. In: Canadian Journal of Remote Sensing 36 (2010), Nr. 3, 236–247. DOI: 10.5589/m10-046, letzter Zugriff 2021-02-27.
- Marconcini, M., Metz-Marconcini, A., Esch, T., Gorelick, N. (2021): Understanding Current Trends in Global Urbanisation – The World Settlement Footprint Suite. 1. (2021), 33–38. https://austriaca.at/0xc1aa5576_0x003c9b4c.pdf, letzter Zugriff 2022-02-09.
- Masek, J. G., Lindsay, F. E., Goward, S. N. (2000): Dynamics of urban growth in the Washington DC metropolitan area, 1973–1996, from Landsat observations. In: International Journal of Remote Sensing 21 (2000), jan, Nr. 18, 3473–3486. www.tandfonline.com/doi/abs/10.1080/014311600750037507, letzter Zugriff 2021-03-14.
- McFeeters, S. (1996): The use of normalized difference water index (NDWI) in the delineation of open water features. In: International Journal of Remote Sensing 17 (1996), 1425–1432.
- Mhangara, P., Odindi, J., Kleyn, L., Remas, H. (2011): Road extrac-tion using object oriented classification. In: Visualisation Technical (2011), 45–50. <https://pdfs.semanticscholar.org/d96e/08aebed9547d/cf4b36447cb478cc18506956.pdf>, letzter Zugriff 2021-02-26.
- Miyazaki, H., Shao, X., Iwao, K., Shibasaki, R. (2013): An Automated Method for Global Urban Area Mapping by Integrating ASTER Satellite Images and GIS Data. In: Selected Topics in Applied Earth Observations and Remote Sensing, IEEE Journal of 6 (2013), 04, 1004–1019. <https://ieeexplore.ieee.org/document/6365772>, letzter Zugriff 2021-03-13.
- Percival, D. B., Walden, A. T. (2000): Wavelet methods for time series analysis. Bd. 4. Cambridge university press, 2000.
- Pivoosh, A. K., Ghosh, S. K. (2017): Development of a modified bare soil and urban index for Landsat 8 satellite data. In: Geocarto Internatio-nal 33 (2017), jan, Nr. 4, 423–442. www.tandfonline.com/doi/full/10.1080/10106049.2016.1273401?scroll=top&needAccess=true, letzter Zugriff 2021-02-26.
- Rahar, P. S., Pal, M. (2019): Comparison of Various Indices to Dif-ferentiate Built-up and Bare Soil with Sentinel 2 Data. In: Lecture Notes in Civil Engineering. Springer Singapore, jun 2019, 501–509. https://link.springer.com/chapter/10.1007/978-981-13-7067-0_39, letzter Zugriff 2021-02-26.
- Roschlau, R., Li, Q., Auer, S., Möst, K., Glock, C., Schmitt, M., Shi, Y., Zhu, X. (2020a): KI-basierte Detektion von Gebäuden mittels Deep Learning und amtlichen Geodaten zur Baufallerkundung. In: zfv – Zeitschrift für Geodäsie, Geoinformation und Landmanage-ment (2020), Heft 3/2020, 145. Jg., 180–189. ISSN 1618-8950. DOI: 10.12902/zfv-0299-2020.
- Roschlau, R., Möst, K., Krey, T. (2020b): Automated Classification of Building Roofs for the Updating of 3D Building Models Using Heu-ristic Methods. In: PFG – Journal of Photogrammetry, Remote Sen-sing and Geoinformation Science 88 (2020), Februar, Nr. 1, 85–97.
- Schmitt, A., Wendeler, A. (2018): SAR-SHARPENING IN THE KEN-NAUGH FRAMEWORK APPLIED TO THE FUSION OF MULTI-MODAL SAR AND OPTICAL IMAGES. In: ISPRS Annals of Photogrammetry, Remote Sensing and Spatial Information Sciences IV-1 (2018), 133–140. <https://elib.dlr.de/122537/1/isprs-annals-IV-1-133-2018.pdf>, letzter Zugriff 2020-09-26.

- Schmitt, A., Sieg, T., Wurm, M., Taubenböck, H. (2018): Investigation on the separability of slums by multi-aspect TerraSAR-X dual-polarized high resolution spotlight images based on the multi-scale evaluation of local distributions. In: International Journal of Applied Earth Observation and Geoinformation 64 (2018), feb, 181–198.
- Schmitt, A., Wendleder, A., Hinz, S. (2015): The Kennaugh element framework for multi-scale, multi-polarized, multi-temporal and multi-frequency SAR image preparation. In: ISPRS Journal of Photogrammetry and Remote Sensing 102 (2015), 122–139. ISSN 0924-2716. www.sciencedirect.com/science/article/pii/S0924271615000246, letzter Zugriff 2020-09-26.
- Schmitt, A., Wendleder, A., Kleynmans, R., Hell, M., Roth, A., Hinz, S. (2020): Multi-Source and Multi-Temporal Image Fusion on Hypercomplex Bases. In: Remote Sensing 12 (2020), Nr. 6. ISSN 2072-4292. www.mdpi.com/2072-4292/12/6/943, letzter Zugriff 2020-09-26.
- Shahi, K., Shafri, H. Z., Taherzadeh, E., Mansor, S., Muniandy, R. (2015): A novel spectral index to automatically extract road networks from WorldView-2 satellite imagery. In: The Egyptian Journal of Remote Sensing and Space Science 18 (2015), Nr. 1, 27–33. ISSN 1110-9823. www.sciencedirect.com/science/article/pii/S111098231400043X, letzter Zugriff 2020-12-03.
- Statistisches Bundesamt (Destatis) (2020): Bautätigkeit und Wohnungen – Fachserie 5 Reihe 1 – 2019. Juli 2020. www.destatis.de/DE/Themen/Branchen-Unternehmen/Bauen/Publikationen/Downloads-Bautaetigkeit/bautaetigkeit-2050100197004.pdf?__blob=publicationFile, letzter Zugriff 2021-02-21.
- Taubenböck, H., Esch, T., Felsbier, A., Wiesner, M., Roth, A., Dech, S. (2012): Monitoring urbanization in mega cities from space. In: Remote Sensing of Environment 117 (2012), feb, 162–176. www.sciencedirect.com/science/article/pii/S0034425711003427, letzter Zugriff 2021-02-27.
- Tucker, C. J. (1979): Red and photographic infrared linear combinations for monitoring vegetation. In: Remote Sensing of Environment 8 (1979), 127–150.
- Valdiviezo-N, J. C., Téllez-Quiñones, A., Salazar-Garibay, A., López-Caloca, A. A. (2017): Built-up index methods and their applications for urban extraction from Sentinel 2A satellite data: discussion. In: Journal of the Optical Society of America A 35 (2017), dec, Nr. 1, 35–44. www.osapublishing.org/josaa/abstract.cfm?URI=josaa-35-1-35, letzter Zugriff 2021-02-26.
- Varshney, A. (2013): Improved NDBI differencing algorithm for built-up regions change detection from remote-sensing data: an automated approach. In: Remote Sensing Letters 4 (2013), may, Nr. 5, 504–512. www.tandfonline.com/doi/abs/10.1080/2150704X.2013.763297, letzter Zugriff 2021-02-26.
- Viana, C. M., Oliveira, S., Oliveira, S. C., Rocha, J. (2019): 29 – Land Use/Land Cover Change Detection and Urban Sprawl Analysis. In: Pourghasemi, H. R., Gokceoglu, C. (Hrsg.): Spatial Modeling in GIS and R for Earth and Environmental Sciences. Elsevier, 2019, 621–651. ISBN 978-0-12-815226-3. www.sciencedirect.com/science/article/pii/B9780128152263000296.
- Waqr, M. M., Mirza, J. F., Mumtaz, R., Hussain, E., et al. (2012): Development of new indices for extraction of built-up area & bare soil from landsat data. In: Open Access Sci. Rep 1 (2012), Nr. 1, 4. www.omicsonline.org/scientific-reports/srep136.php, letzter Zugriff 2021-01-23.
- Xu, H. (2008): A new index for delineating built-up land features in satellite imagery. In: International Journal of Remote Sensing 29 (2008), Nr. 14, 4269–4276. www.tandfonline.com/doi/abs/10.1080/01431160802039957?journalCode=tres20, letzter Zugriff 2021-02-26.
- Xu, H. (2010): Analysis of Impervious Surface and its Impact on Urban Heat Environment using the Normalized Difference Impervious Surface Index (NDISI). In: Photogrammetric Engineering & Remote Sensing 76 (2010), may, Nr. 5, 557–565. www.ingentaconnect.com/content/asprs/pers/2010/00000076/00000005/art00002;jsessionid=4e9c1jashcs64.x-ic-live-03, letzter Zugriff 2021-03-14.
- Zha, Y., Gao, J., Ni, S. (2003a): Use of normalized difference built-up index in automatically mapping urban areas from TM imagery. In: International Journal of Remote Sensing 24 (2003), Januar, Nr. 3, 583–594. www.scopus.com/record/display.uri?eid=2-s2.0-0037429468&origin=inward&txGid=0c59a729f08e4e5fbcae9c74e56d211.
- Zha, Y., Ni, S., Yang, S. (2003b): An effective approach to automatically extract urban land-use from TM imagery. In: JOURNAL OF REMOTE SENSING-BEIJING 7 (2003), Nr. 1, 37–40. [https://en.cnki.com.cn/Article_en/CJFDTotal-YGXB200301006.htm](http://en.cnki.com.cn/Article_en/CJFDTotal-YGXB200301006.htm), letzter Zugriff 2021-02-23.
- Zhang, S., Yang, K., Li, M., Ma, Y., Sun, M. (2018): Combinational Biophysical Composition Index (CBCI) for Effective Mapping Biophysical Composition in Urban Areas. In: IEEE Access 6 (2018), 41224–41237. [https://ieeexplore.ieee.org/document/8412481](http://ieeexplore.ieee.org/document/8412481), letzter Zugriff 2021-10-17.
- Zhao, H.-M., Chen, X. (2005): Use of normalized difference bareness index in quickly mapping bare areas from TM/ETM+. In: International Geoscience and Remote Sensing Symposium (IGARSS) Bd. 3, 08 2005, 1666–1668. ISBN 0-7803-9050-4.

Kontakt

Lea Schollerer

Hochschule München, Fakultät für Geoinformation
Karlstraße 6, 80333 München
scholler@hm.edu

Andreas Schmitt

Institut für Anwendungen des maschinellen Lernens und intelligenter Systeme (IAMLIS)
Karlstraße 6, 80333 München
schmitt@hm.edu

Anna Wendleder

Deutsches Zentrum für Luft- und Raumfahrt (DLR),
Earth Observation Center (EOC)
Oberpfaffenhofen, 82234 Weßling
anna.wendleder@dlr.de

Simone Rogginger

Amt für Digitalisierung, Breitband und Vermessung Pfarrkirchen,
Außenstelle Simbach a. Inn
Münchner Straße 2, 84359 Simbach a. Inn
simone.rogginger@adbv-pan.bayern.de

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