

## Automatische Extraktion von Brachflächen aus Luftbildern mittels eines neuronalen Netzes

Dürrbeck, Konrad; Lippl-Seifert, Stefan

Veröffentlichungsversion / Published Version

Sammelwerksbeitrag / collection article

### Empfohlene Zitierung / Suggested Citation:

Dürrbeck, K., & Lippl-Seifert, S. (2022). Automatische Extraktion von Brachflächen aus Luftbildern mittels eines neuronalen Netzes. In *Flächennutzungsmonitoring XIV: Beiträge zu Flächenmanagement, Daten, Methoden und Analysen* (S. 305-314). Berlin: Rhombos-Verlag. <https://doi.org/10.26084/14dfns-p031>

### Nutzungsbedingungen:

Dieser Text wird unter einer CC BY Lizenz (Namensnennung) zur Verfügung gestellt. Nähere Auskünfte zu den CC-Lizenzen finden Sie hier: <https://creativecommons.org/licenses/by/4.0/deed.de>

### Terms of use:

This document is made available under a CC BY Licence (Attribution). For more information see: <https://creativecommons.org/licenses/by/4.0>



## Flächennutzungsmonitoring XIV

Beiträge zu Flächenmanagement,  
Daten, Methoden und Analysen

IÖR Schriften Band 80 · 2022

ISBN: 978-3-944101-80-4

## Automatische Extraktion von Brachflächen aus Luftbildern mittels eines neuronalen Netzes

*Konrad Dürrebeck, Stefan Lippl-Seifert*

Dürrebeck, K.; Lippl-Seifert, S. (2022): Automatische Extraktion von Brachflächen aus Luftbildern mittels eines neuronalen Netzes. In: Meinel, G.; Krüger, T.; Behnisch, M.; Ehrhardt, D. (Hrsg.): Flächennutzungsmonitoring XIV. Beiträge zu Flächenmanagement, Daten, Methoden und Analysen. Berlin: Rhombos, IÖR Schriften 80, S. 305-314.

DOI: <https://doi.org/10.26084/14dfns-p031>

# Automatische Extraktion von Brachflächen aus Luftbildern mittels eines neuronalen Netzes

Konrad Dürrbeck, Stefan Lippl-Seifert

## Zusammenfassung

Die Flächenknappheit in Ballungsräumen zwingt zu einer Reaktivierung nicht mehr genutzter Gewerbeflächen. Ziel der Machbarkeitsstudie des in der Arbeitsgruppe für Supply Chain Services des Fraunhofer-Instituts für Integrierte Schaltungen IIS angesiedelten Projektes ist die Evaluierung einer automatischen Extraktion von Brachflächen aus Luftbildern mittels eines neuronalen Netzes, wodurch im Vergleich zur manuellen Auswertung eine deutliche Zeit- und Kostenersparnis möglich ist. Die Genauigkeit wird durch einen Vergleich mit von der Firma Spacedatists GmbH zur Verfügung gestellten Brachflächen sowie einer manuellen Überprüfung für Untersuchungsgebiete in Nordrhein-Westfalen evaluiert. Die Ergebnisse zeigen hierbei Möglichkeiten einer automatischen Extraktion von Brachflächen auf und geben Hinweise auf den Nutzen der Integration weiterer Daten.

**Schlagerwörter:** Brachflächen, Flächennutzung, Fernerkundung, Künstliche Intelligenz

## 1 Einführung

Die Flächenneuversiegelung in Deutschland beträgt ca. 54 Hektar/Tag (Stand: 2020) und soll nach Plänen der Bundesregierung über 30 Hektar/Tag im Jahr 2030 auf 0 Hektar/Tag im Jahr 2050 reduziert werden (BMUV 2022). Eine Reduzierung der Flächenneuversiegelung ist deshalb ein wichtiger Baustein im Hinblick auf eine nachhaltige Entwicklung im kommunalen Flächenmanagement. Zusätzlich herrscht in Ballungsräumen bereits jetzt eine Flächenknappheit insbesondere für großflächige Gewerbeansiedlungen, sodass sowohl Marktentwicklung als auch politische Vorgabe zu einer Reaktivierung nicht mehr genutzter Flächen zwingen.

Eine bundesweite Ausweisung von Brachflächen gibt es in Deutschland nicht. Gemäß Umweltbundesamt liegen keine zuverlässigen und aktuellen bundesweiten Daten zum innerörtlichen Brachflächenbestand vor. Schätzungen gehen von circa 150 000 bis 176 000 Hektar ungenutzten Flächen aus (UBA 2020). Durch die hohe Relevanz sind „*Flächenrecycling und verstärkte Innenentwicklung [...] in der nationalen Nachhaltigkeitsstrategie als Kernelemente zur Reduzierung der Flächeninanspruchnahme ausgewiesen. [...] Weiter werden die Planungsträger im BauGB verpflichtet, die Möglichkeiten zur Innenentwicklung (Innenentwicklungspotenziale) zu ermitteln*

*bevor landwirtschaftliche oder als Wald genutzte Flächen umgewandelt werden.*" (UBA 2020).

Für das Landesamt für Natur, Umwelt und Verbraucherschutz Nordrhein-Westfalen (LANUV) ist die Ermittlung der Brachflächenpotenziale und eine entsprechende Aufbereitung zur Nutzung für alle Beteiligten für eine effektive kommunale Planung äußerst wichtig (LANUV 2015: 3). Die Ergebnisse eines Pilotprojektes haben hierbei gezeigt, dass Luftbildauswertungen ein wesentliches Instrument für die Identifizierung von Brachflächen sind und die Anzahl der erfassten Flächen deutlich über dem bekannten Umfang lag (LANUV 2015: 9).

Eine manuelle Luftbildinterpretation ist allerdings mit einem großen Personal- bzw. Zeitaufwand verbunden. Ziel der vorliegenden Machbarkeitsstudie ist deshalb die Evaluierung einer automatischen Extraktion von Brachflächen aus hochaufgelösten Luftbildern (DOP20 des Bundesamts für Kartographie und Geodäsie) mittels eines neuronalen Netzes.

## **2 Definition von Brachflächen, Datenquellen und Erarbeitung der Untersuchungsdaten**

### **2.1 Definition von Brachflächen**

Grundsätzlich muss eine Industrie-, Gewerbe- oder Wohnbrache von einer landwirtschaftlichen Brache unterschieden werden. Eine Brache in der Landwirtschaft ist eine temporär aus der wirtschaftlichen Nutzung entnommene Fläche, bei der es sich u. a. um eine temporäre Nichtnutzung zur Regeneration des Bodens oder auch um längerfristig angelegte Brachen mit wichtiger ökologischer Funktion handeln kann (Landwirtschaftskammer Nordrhein-Westfalen 2021). In einem Vorschlag der Bund/Länder-Arbeitsgemeinschaft Bodenschutz wird eine Brachfläche als eine nach Aufgabe einer gewerblich-industriellen oder sonstigen baulichen Nutzung über einen längeren Zeitraum ungenutzte und funktionslos gewordene Fläche mit Potenzial für Neunutzungen beschrieben. Das LANUV unterscheidet hierbei ob Flächen über einen längeren Zeitraum „ungenutzt“, „mindergenutzt“ bzw. „temporär zwischengenutzt“ werden oder ob eine Aufgabe der Nutzung absehbar ist (LANUV 2015: 11). Da die vorliegenden hochaufgelösten Luftbilder immer nur einen bestimmten Zeitpunkt darstellen können, muss der Fokus dieser Machbarkeitsstudie auf der Erkennung von „ungenutzten“ bzw. „mindergenutzten“ Brachflächen liegen.

Weiterhin beschränkt sich diese Studie auf industrielle oder gewerbliche Brachen, weshalb das untersuchte Gebiet auf Flächen mit gewerblicher Nutzung, wie im folgenden Abschnitt beschrieben, eingeschränkt wird.

## 2.2 Datenquellen und Erarbeitung der Untersuchungsdaten

Als erster Schritt erfolgte eine Recherche zu bereits bestehenden Brachflächen-Datensätzen. Mittels des Dienstes OverpassTurbo wurde auf die frei zugänglichen Daten von OpenStreetMap (OSM) mit dem Tag „landuse=brownfield“ (Stand 03.11.2021) zugegriffen. Hierdurch konnten über ganz Deutschland verteilt 6 435 von OSM-Benutzern als Brachfläche erfasste Polygone ermittelt werden. Durch die Firma Spacedatists GmbH konnten zusätzlich Daten in Nordrhein-Westfalen zur Verfügung gestellt werden, für die im Vergleich zu den „Community-based“ Daten von OSM eine zusätzliche Kontrolle auf Richtigkeit sichergestellt ist. Ohne die Massendaten aus OSM würde der Datensatz allerdings hinsichtlich der Anzahl und Variation den Anforderungen an einen Trainingsdatensatz für ein neuronales Netzwerk nicht gerecht.

Für die Erarbeitung der Untersuchungsdaten wurde auf die flächendeckend für Deutschland über das Bundesamt für Kartographie und Geodäsie (BKG) beziehbaren Datensätze zur Bodennutzung (Digitales Landbedeckungsmodell für Deutschland, LBM-DE2018; Digitales Basis-Landschaftsmodell, Basis-DLM) zurückgegriffen. Hierfür wurden Flächen mit gewerblicher/industrieller Nutzung im LBM-DE2018 (Landnutzungs-kategorie N120: „Produktion“) für die Landbedeckungsklassen B110: „Bebauung“ sowie B121: „Anlagen“ extrahiert, welche ca. 75 % der möglichen Landbedeckungsklassen innerhalb von Flächen der Landnutzungs-kategorie N120 abdecken.

Als zusätzliche Datenquellen fließen im weiteren Verlauf Einträge der Datenbanken von Gelbe Seiten bzw. den Handelsregistern der Amtsgerichte für die Überprüfung einer „aktiven“ Gewerbenutzung sowie die digitalen Orthophotos (DOP20) des BKG als Bilddaten in die Prozessierungskette ein. Deren weitere Verarbeitung bei der Erzeugung der Lerndaten wird im nächsten Abschnitt genauer erläutert. Sämtliche Datensätze wurden für eine Übernahme in ein Geographisches Informationssystem (GIS) aufbereitet, wenn notwendig in ein einheitliches Koordinatensystem projiziert und für die Möglichkeit zur effizienten Verschneidung der großen Datensätze in eine Geodatenbank (PostgreSQL mit PostGIS-Erweiterung) übernommen. Durch die Verschneidung der georeferenzierten Daten im GIS können die Lerndaten zum Trainieren des Modells generiert und die Untersuchungsdaten für die anschließende Anwendung des neuronalen Netzes gewonnen werden. Je nach gewünschtem Klassifikationstyp kann durch eine Extraktion der betreffenden Gegenklassen für aktive Gewerbeflächen das neuronale Netz auf bestimmte Parameter bzw. Landbedeckungsklassen trainiert werden. Bei der anschließenden Anwendung zur Vorhersage muss allerdings darauf geachtet werden, dass derselbe Extraktionsschritt auch auf die zu untersuchenden Daten angewendet wird.

### 3 Methodik – Extraktion potenzieller Brachflächen

#### 3.1 Erzeugen der Lerndaten

Die Datensätze für ein Trainieren und Testen des neuronalen Netzes können durch eine Verschneidung und automatisierte Extraktion der Digitalen Orthophotos des BKG erstellt werden. Hierfür wurde für jede Brachfläche eine Bilddatei mit 1 000 x 1 000 Pixel mit einem Maßstab von 1:1 000 erstellt, welche 200 m x 200 m Bodenfläche abdeckt und dadurch der maximalen räumlichen Auflösung von 20 cm des DOP20 entspricht. Abbildung 1 veranschaulicht schematisch den gesamten Lernprozess.




Abb. 1: Schematische Darstellung der im Rahmen der Machbarkeitsstudie erarbeiteten Prozessierungskette (Quelle: Fraunhofer IIS, Geobasisdaten: © GeoBasis-DE/BKG 2022)

Durch die aus OSM extrahierten Polygone können somit Bilder von Brachflächen vollständig automatisch generiert werden. Bei Flächen mit industrieller oder gewerblicher Nutzung wurde für die Generierung der entsprechenden Gegenklasse („sich in Nutzung befindende Gewerbefläche“) zusätzlich zur Kategorisierung im LBM-DE2018 auf

verortbare Einträge in der Datenbank von Gelbe Seiten bzw. den Handelsregistern der Amtsgerichte zurückgegriffen. Durch eine Analyse der Einträge innerhalb eines Polygons einer bestimmten Landbedeckungs- und Landnutzungsklasse kann die Wahrscheinlichkeit für das Auftreten einer nicht erfassten Brachfläche innerhalb des Polygons minimiert werden, indem nur die Polygone mit einer hohen Dichte (definiert als die Anzahl von bekannten Unternehmen geteilt durch die Polygonfläche) berücksichtigt werden. Durch die hohe Anzahl an Polygonen je Nutzungsklasse im LBM-DE2018, die die Anzahl an Beispielen für Brachflächen weit übersteigt, ist es hiermit möglich, durch Auswahl von über Deutschland zufällig verteilten Polygonen einen adäquat großen Lerndatensatz zu generieren.

Einen wichtigen Punkt im Lernprozess stellt die Auswahl der Eingangsdaten dar. Neuronale Netze benötigen hierbei eine gleichbleibende, rechteckige Bildgröße. Durch die starke Schwankung der räumlichen Ausdehnung der Brachflächen würde dies zu einer unterschiedlichen räumlichen Auflösung oder zu einer hohen Anzahl an Pixeln der Klasse „Nicht-Brachfläche“ auch in den Lerndatensätzen für Brachflächen führen. Aus diesem Grund werden bei der Generierung der Bilddaten im GIS-System alle Flächen außerhalb der betreffenden Polygone ausmaskiert. Hierdurch wird ein Resampling zu einer einheitlichen Rastergröße vermieden und eine konstante Auflösung kann später auch bei den Untersuchungsdaten angewendet werden. Weiterhin erhält das neuronale Netz im Lernprozess nur Bilddaten, die der jeweiligen Klasse angehören.

### 3.2 Training des Neuronalen Netzes

Die Zuordnung von Landbedeckungen mittels Klassifizierung ist ein im Bereich Fernerkundung häufig angewendetes Verfahren, bei dem in vielen Fällen „gefaltete neuronale Netze“ angewendet werden (Ma et al. 2019). Für die beiden Landbedeckungs-/Landnutzungskombinationen B110/N120 sowie B121/N120 wurde jeweils ein eigenes neuronales Netz für eine binäre Bildklassifikation in die Klassen „Brachfläche“ und „aktive Gewerbefläche“ bestehend aus sieben „Convolutional Layern“ (LeCun et al. 2015) mit steigender Anzahl an Filtern (32 bis 1024) trainiert. Hierdurch können durch das neuronale Netz mit steigender Tiefe immer feinere Bildstrukturen gelernt werden, während in einem abschließenden „Dense Layer“ nach einem Dropout mit Faktor 0,5 die Wahrscheinlichkeit für eine Zugehörigkeit des Bildes zu den jeweiligen beiden Klassen ausgegeben wird. Die neuronalen Netze wurden für jeweils 10 Epochen trainiert, bis die Genauigkeit der Validationsdaten einen stabilen Wert angenommen hat. In den besten Durchläufen konnten hierbei Genauigkeiten von ~90 % (B110/N120) bzw. ~88 % (B121/N120) erreicht werden, welche in einer sich an das Training anschließenden Überprüfung mit für das neuronale Netz unbekanntem Testdaten knapp niedriger ausfielen (~85 % für B110/N120 und ~80 % für B121/N120).

### 3.3 Extraktion realer Untersuchungsdaten und Vorhersage

Bei der Anwendung des neuronalen Netzes in der Praxis muss im Vergleich zu einer Anwendung der Testdaten allerdings bedacht werden, dass es sich bei den übermittelten Bilddaten um keine Polygone mit festen Grenzen handelt, welche in ihren Eigenschaften einem zusammenhängenden Grundstück bzw. einer fest definierten Brachfläche entsprechen. Aus diesem Grund wird auf die Erstellung eines regelmäßigen 200 x 200 m Gitters zurückgegriffen, welches auf die Fläche der jeweiligen Nutzungsklasse zugeschnitten wird. Pro einzelner Gitterzelle über 4 000 m<sup>2</sup> wird der Bildinhalt an das neuronale Netz übergeben, welches anschließend eine Wahrscheinlichkeit für das Auftreten einer Brachfläche innerhalb dieses Ausschnitts ausgibt.

## 4 Ergebnisse und Genauigkeit

Das im Abschnitt Methodik beschriebene Verfahren zur Extraktion potenzieller Brachflächen wurde im Anschluss an das Training des neuronalen Netzes und der Extraktion realer Untersuchungsdaten in Form von 200 x 200 m Gitterzellen für die beiden Landbedeckungs-/Landnutzungskombinationen B110/N120 und B121/N120 auf sämtliche Bundesländer Deutschlands angewendet. Hierbei ergibt sich folgende Häufigkeitsverteilung der Vorhersagewerte je zugeschnittener Gitterzelle/Polygon (Abb. 2).




Abb. 2: Häufigkeitsverteilung der Vorhersagewerte je Polygon für die untersuchten Gewerbeflächen in Deutschland (Quelle: eigene Bearbeitung)

Ein Großteil der Fläche wird hierbei mit einer niedrigen Wahrscheinlichkeit für eine Brachfläche klassifiziert, nur ca. 10 % der Fläche erhalten Werte über 0,8. Berücksichtigt man die Fläche des jeweiligen Polygons, so erhält man für die in 10 %-Schritten



aufgeteilten Vorhersageklassen die in Tabelle 1 dargestellten Werte. Abbildung 3 zeigt eine Visualisierung der Ergebnisse in einem Geoinformationssystem.

Tab. 1: Summierte Flächen und prozentualer Anteil nach Vorhersageklassen für die untersuchten Gewerbeflächen in Deutschland (Quelle: eigene Bearbeitung)

Vorhersagewerte	Flächensumme (km <sup>2</sup> )	Anteil (%)
0,0-0,1	1 662	40,70
0,1-0,2	444	10,87
0,2-0,3	326	7,97
0,3-0,4	277	6,77
0,4-0,5	256	6,27
0,5-0,6	248	6,08
0,6-0,7	243	5,94
0,7-0,8	239	5,86
0,8-0,9	195	4,77
0,9-1,0	195	4,78

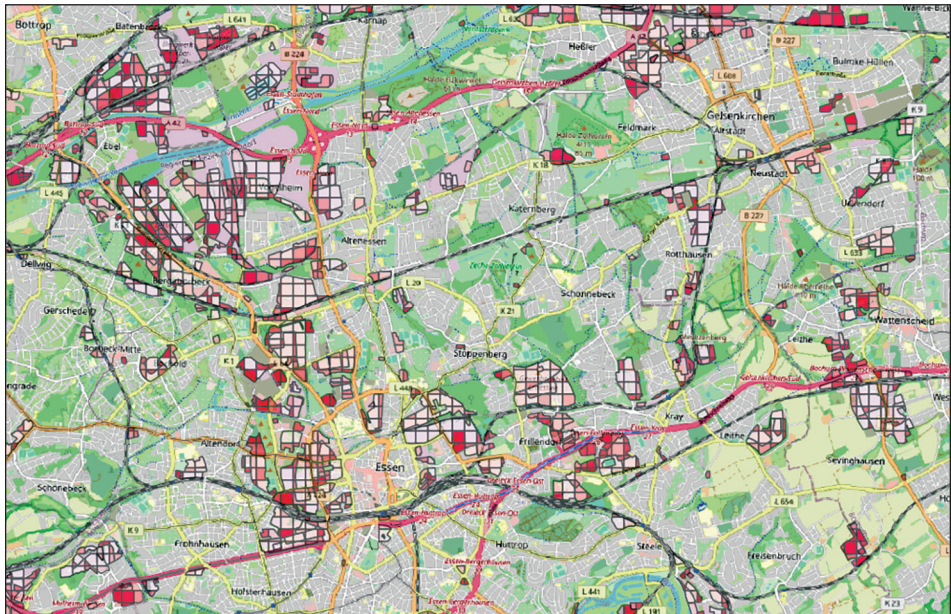


Abb. 3: Beispielhafte Darstellung der durch die KI ermittelten Wahrscheinlichkeiten für Brachflächen im Raum Essen-Gelsenkirchen (Quelle: Fraunhofer IIS, Hintergrundkarte: © OpenStreet-Map-Mitwirkende)

Auch hinsichtlich der Flächenverteilung entscheidet sich das neuronale Netz also in der überwiegenden Mehrheit für eine geringe Wahrscheinlichkeit für eine Brachfläche

(~72 % liegen unter dem Grenzwert 0,5). Insgesamt wurden über 4 000 km<sup>2</sup> untersucht, von denen etwas über 1 000 km<sup>2</sup> eine erhöhte Wahrscheinlichkeit (über Grenzwert 0,5) für das Vorliegen einer Brachfläche haben. Knapp 400 km<sup>2</sup> treten hierbei durch einen besonders hohen Wert (über Grenzwert 0,8) hervor.

Da es im Bereich Brachen kein flächendeckendes Kataster und somit nur eingeschränkte Möglichkeiten zur Überprüfung der Ergebnisse gibt, wurden für die Berechnung der Genauigkeit der Ergebnisse von der Firma Spacedatists GmbH im Bundesland Nordrhein-Westfalen eigens manuell überprüfte Datensätzen verwendet. Hierbei wurde zusätzlich zum Expertenwissen der in Nordrhein-Westfalen bereits langjährig im Bereich Brachflächenerkennung tätigen Firma auf Zeitreihenaufnahmen historischer Luftbilder zurückgegriffen. Für die Berechnung der entsprechenden Kennzahlen wurde auf eine prozentuale Gewichtung der Vorhersageklassen gemäß der in der Realität vorkommenden Klassen geachtet, sodass für die folgenden Abbildungen 4 und 5 die summierte Anzahl an Polygonen mit niedrigen Vorhersagewerten deutlich höher ist als diejenige mit hohen Vorhersagewerten. Dies bewirkt ebenfalls eine niedrigere Anzahl an durch die Spacedatists GmbH als (Teil-) Brachfläche eingestuftem Datensätzen im Vergleich zur Anzahl an aktiven Gewerbeflächen.




Abb. 4: Anzahl der Polygone nach Vorhersagewerten für (Teil-)Brachflächen für die untersuchten Gewerbeflächen (Quelle: eigene Bearbeitung)




Abb. 5: Anzahl der Polygone nach Vorhersagewerten für aktive Gewerbeflächen für die untersuchten Gewerbeflächen (Quelle: eigene Bearbeitung)

Bei der Berechnung der entsprechenden Kennzahlen muss also bedacht werden, dass sich eine prozentual kleine Anzahl an fälschlicherweise als Brachfläche eingestuftes aktiven Gewerbeflächen in großem Maße auf die „Precision“ (d. h. auf den Anteil an korrekt klassifizierten Brachflächen unter allen Brachflächenklassifikationen) auswirkt. Tabelle 2 veranschaulicht dies. Ähnlich wie bei anderen Klassifikationsverfahren für sehr ungleichverteilte Daten (z. B. Tests für die Erkennung seltener Krankheiten) muss hierbei zwischen einem hohen Anteil an positiven Vorhersagewerten oder einer hohen Sensitivität abgewogen werden (Neumann 2003).

Tab. 2: Kennzahlen der Klassifizierungsgenauigkeit (Quelle: eigene Bearbeitung)

Kennzahl	Brachflächen	Gegenklasse
Präzision (Precision)	0,37	0,96
Sensitivität (Recall)	0,77	0,80
F1-Score	0,50	0,87
F2-Score	0,63	0,83
Korrektklassifikationsrate (Accuracy)	0,80	

## 5 Fazit

Durch die beschriebene Machbarkeitsstudie konnten Wege zu einer flächendeckenden und automatisierten Erstellung eines Brachflächenkatasters aufgezeigt werden. Da sich die Erstellung eigener neuronaler Netze je Bedeckungstyp für die Gegenklasse aktiver Gewerbeflächen als zu präferieren herausgestellt hat, empfiehlt sich die Erzeugung weiterer Lerndatensätze für die restlichen 25 % der Gewerbefläche umfassenden Landbedeckungsklassen des LBM-DE2018. Weiterhin gilt es, die Genauigkeit des Klassifizierungsansatzes über die Verwendung weiterer Eingangsdaten (Luftbilder mit höherer räumlicher Auflösung, Zeitreihen) bzw. über methodische Weiterentwicklung (z. B. die Extraktion realistischer Polygongrenzen anstatt der „willkürlichen“ Gitterzellen zur Vermeidung gemischter Klassen je Eingangsbild an das neuronale Netz) zu erhöhen.

## 6 Literatur

- BMUV – Bundesministerium für Umwelt, Naturschutz, nukleare Sicherheit und Verbraucherschutz (2022): Flächenverbrauch – Worum geht es?  
<https://www.bmuv.de/themen/nachhaltigkeit-digitalisierung/nachhaltigkeit/strategie-und-umsetzung/flaechenverbrauch-worum-geht-es> (Zugriff: 07.07.2022).
- BKG – Bundesamt für Kartographie und Geodäsie (2022): Digitale Orthophotos Bodenauflösung 20 cm.  
<https://gdz.bkg.bund.de/index.php/default/webdienste/digitale-orthophotos.html> (Zugriff: 03.03.2022).

- BKG – Bundesamt für Kartographie und Geodäsie (2022): Digitales Landbedeckungsmodell für Deutschland, Stand 2018 (LBM-DE2018 <https://gdz.bkg.bund.de/index.php/default/digitales-landbedeckungsmodell-fur-deutschland-stand-2018-lbm-de2018.html>) (Zugriff: 03.03.2022).
- Gelbe Seiten (2002): DTM Deutsche Tele Medien GmbH. <https://www.gelbeseiten.de> (Zugriff: 07.04.2022).
- LANUV – Landesamt für Natur, Umwelt und Verbraucherschutz Nordrhein-Westfalen (2015): Leitfaden zur Erfassung von Brachflächen in Nordrhein-Westfalen. LANUV-Arbeitsblatt 26.
- LeCun, Y.; Bengio, Y.; Hinton, G. (2015): Deep learning. *Nature* 521 (7553): 436-444.
- Ma, L.; Liu, Y.; Zhang, X.; Ye, Y.; Yin, G.; Johnson, B. A. (2019): Deep learning in remote sensing applications: A meta-analysis and review. *ISPRS Journal of Photogrammetry and Remote Sensing*. Volume 152: 166-177.
- Neumann, A. (2003): Korrekturverfahren für Stichproben von Verkehrsverhaltenserhebungen des Personenfernreiseverkehrs. Dissertationsarbeit zur Erlangung des Doktorgrads an der Universität für Bodenkultur Wien.
- UBA – Umweltbundesamt (2020): Flächenrecycling und Innenentwicklung. <https://www.umweltbundesamt.de/themen/boden-landwirtschaft/flaechensparen-boeden-landschaften-erhalten/flaechenrecycling-innenentwicklung#brachennutzen-grune-wiesen-schonen> (Zugriff: 07.07.2022).