

Die Identifikation klimaaktiver Grünflächen mit Hilfe künstlicher Intelligenz

Sascha Henninger, Pierre Müller

(Prof. Dr. Sascha Henninger, RPTU Kaiserslautern-Landau, Fachbereich Raum- und Umweltplanung, Pfaffenbergstraße 95, 67663 Kaiserslautern, sascha.henninger@ru.rptu.de)

(Pierre Müller, M.Sc., RPTU Kaiserslautern-Landau, Fachbereich Raum- und Umweltplanung, Pfaffenbergstraße 95, 67663 Kaiserslautern, pierre.mueller@rptu.de)

1 ABSTRACT

Der menschengemachte Klimawandel führt zu einer Erhöhung der durchschnittlichen Lufttemperaturen. Dies hat insbesondere Auswirkungen auf die dicht besiedelten und versiegelten urbanen Räume durch eine Intensivierung des städtischen Wärmeineffektes. Ein wichtiges Instrument zur Anpassung an den Klimawandel und die damit einhergehenden Temperaturveränderungen ist die Entwicklung, Erhaltung und Etablierung innerstädtischer Grünflächen. Zur Bestandsaufnahme und Weiterentwicklung der Grünflächen ist die Schaffung einer Grünflächenkartierung essenziell. Die Heterogenität und diffuse Verteilung von Grünflächen im räumlichen Kontext erschweren eine entsprechende Kartierung jedoch maßgeblich. Vorweg ist es notwendig, den Begriff der Grünflächen zu definieren. Anschließend kann bezugnehmend auf die Herausforderung einer vollständigen Kartierung aller Grünflächen vor Ort untersucht werden, inwiefern solche Flächen mithilfe des Einsatzes einer Künstlichen Intelligenz identifiziert, voneinander abgegrenzt und als lokal klimaaktiv bilanziert werden können.

Die initiale Definition der Grünflächen findet aufgrund der heterogenen Ausstattung und Eigenart der Flächen vorerst auf allgemeiner Ebene statt. Hierfür werden verschiedene fachwissenschaftliche/rechtliche Abgrenzungen hinzugezogen. Sie können darauf aufbauend in Gras- bzw. Strauchflächen, Wasserflächen, große Strauchflächen und vegetationslose Bodenflächen sowie vorhandener Baumbestand klassifiziert werden.

Die Analyse der definierten Grünflächen findet mithilfe eines vortrainierten Deep Learning Modells zur Identifikation der allgemeinen Landbedeckungen statt. Hierfür ist im Rahmen der Anwendung der Künstlichen Intelligenz die Nutzung/der Einsatz sehr hochauflöser Luftbilder Grundvoraussetzung für eine ausreichend gute Prognose der Lokalisation von Grünflächen und es sollte so eine Identifikation ebendieser Flächen möglich sein.

Die Anwendung dieses vortrainierten Deep-Learning-Algorithmus kann eine Identifikation der grünen Flächen, basierend auf den allgemeinen Landbedeckungen, leisten. Die besten Werte werden hierbei für innerstädtische Lagen erreicht. Die außerhalb der baulichen Strukturen befindlichen Grünflächen werden jedoch aufgrund ihrer Eigenart oftmals falsch abgegrenzt und als Wasserflächen ausgewiesen, sodass durch das vortrainierte Modell eine Gesamtgenauigkeit von lediglich 46 % erreicht wird. Nach Beurteilung der Ergebnisse soll zur potenziellen Verbesserung des Modells ein Nachtrainieren des Deep Learning Algorithmus stattfinden. Das Nachtrainieren des vortrainierten Deep Learning Modells mittels „Transfer Learning“ führt zu einer allgemeinen Verbesserung der Gesamtgenauigkeit auf 78 %. Dabei besitzt das nachtrainierte Modell einen höheren Detailgrad bei der Beurteilung außerstädtischer Grünflächen – innerstädtische Grünflächen hingegen werden im Vergleich zum vortrainierten Modell schlechter identifiziert. Eine sich daran anschließende Kombination aus der Modellierung des vor- und des nachtrainierten Deep Learning Algorithmus führt schließlich zu einer Gesamtgenauigkeit von 86 %.

Darauf aufbauend wird unter Zuhilfenahme der Kombinationsmodellierung die Klimaaktivität der Grünflächen bestimmt. Diese ist charakterisiert durch die potenzielle Kühlleistung der identifizierten Grünflächen mithilfe der Verschattungsanteile, der Bodenoberflächen sowie der absoluten Flächengröße. Hierbei sind die Grünflächen mit niedriger Klimaaktivität in den stark verdichteten und versiegelten innerstädtischen Lagen vorzufinden. Mit einer Zunahme an unversiegelter Fläche nimmt die absolute Flächengröße und damit einhergehend die Klimaaktivität von anfänglichen Kühlleistungen < 1 K in stark versiegelten Gebieten bis zu > 3 K im unversiegelten Bereich außerhalb der Siedlungsräume zu, welche aufgrund der hohen Kühlkraft zudem auch eine Transferwirkung über die eigentliche Grünfläche hinaus besitzen.

Keywords: Urbane Grünflächen, Stadtklima, Klimaanpassung, Künstliche Intelligenz, Blau-Grüne Infrastruktur

2 EINLEITUNG

Prognostizierte Temperaturveränderungen aufgrund des menschengemachten Klimawandels führen zu einer generellen Zunahme der Lufttemperatur. Urbane Räume sind hierbei durch vorhandene bauphysikalische und raumstrukturelle Eigenschaften besonders betroffen. Dies führt dazu, dass die städtische Überwärmung, überdurchschnittlich – ausgelöst durch den Klimawandel – zunimmt. Aufgrund dessen ist es wichtig, neben den Maßnahmen zur Mitigation des Klimawandels auch Maßnahmen zur Adaption an den Klimawandel vorzunehmen.

Eine zentrale Maßnahme zur Anpassung an den Klimawandel stellt die Etablierung, die Erhaltung und die Optimierung innerstädtischer Grünflächen dar. Grünflächen besitzen verschiedene Eigenschaften, welche dabei behilflich sind, das Stadtklima in stark versiegelten und besiedelten urbanen Räumen zu beeinflussen und zu verbessern (IPCC 2023).

Aufgrund der besonderen Stellung von Grünflächen als Bestandteil der Klimaanpassung in urbanen Räumen ist es essenziell, diese bestmöglich zu kartieren. Eine Kartierung fand in der Vergangenheit überwiegend in persona statt und setzte einen hohen zeitlichen und personellen Aufwand voraus. Für die Schaffung einer nachhaltigen Grünflächenkartierung gilt es deswegen zu untersuchen, inwieweit eine (teil-)automatisierte Identifikation von Grünflächen durch den Einsatz der Künstlichen Intelligenz möglich ist. Neben einer bloßen quantitativen Identifikation der Grünflächen (Wo? und Wieviel?) ist es auch Ziel der Forschungsarbeit zu eruieren, welche qualitativen klimaaktiven Effekte (Wie hoch ist die Kühlleistung der Grünflächen?) die jeweiligen (innerstädtischen) Grünflächen aufweisen und inwiefern diese bilanziert werden können.

3 STAND DER FORSCHUNG

Die Identifikation und anschließende Auswertung von Grünstrukturen als Teil der allgemeinen Landbedeckung findet oftmals durch die Auswertung von Fernerkundungs- und Multispektraldaten statt. Die jeweiligen Oberflächen werden bei diesen Verfahren mithilfe ihrer elektromagnetischen Strahlungseigenschaften identifiziert und klassifiziert. Für eine allgemeine Oberflächenklassifikation stehen hierbei verschiedene Klassifikationsmethoden zur Verfügung, welche grundlagentechnisch sowohl auf der Verwendung eines Trainingsgebietes zur Klassifikation der Oberflächen aufbauen (überwachte Klassifikationsverfahren) als auch solche, welche keine zusätzlichen Informationen zur Klassifikation voraussetzen (unüberwachte Klassifikationsverfahren).

Auswertung und Klassifikation finden grundsätzlich bereits mit Methoden des Maschinellen Lernens als Unterbereich der Künstlichen Intelligenz statt. Hier wird mit statistischen Verfahren wie dem Random Forest Algorithmus oder auch die mit der Häufigkeitsverteilung arbeitende Maximum Likelihood Methode in Verbindung mit Maschinellern Lernen gearbeitet (De Lange, 2020).

Als Unterbereich des Maschinellen Lernens bietet sich zudem die Verwendung des auf die Muster- und Bilderkennung spezialisierten Teilbereichs des „Tiefen Lernens“ (engl. Deep Learning) für die Identifikation und Klassifikation von Grünflächen an. Hierbei wird auf künstliche neuronale Netze zur Identifikation zurückgegriffen. Grundlagendaten für die Bestimmung der Grünflächen sind dabei oftmals Satellitenbilder mit relativ geringer Auflösung (Albert et al., 2017; Nguyen & Chidthaisong, 2022; Zhao, 2022). Neben der Untersuchung der Grünflächen mithilfe der neuronalen Netze findet eine kleinteiligere Untersuchung unter Hinzunahme von Straßenbildern und dem aus dem Nahinfrarot ableitbaren Normalized Difference Vegetation Index (NDVI) statt (Sun et al., 2021; Wang et al., 2021).

Hinsichtlich vorhandener Literatur bestehen dementsprechend bereits Ansätze zur Identifikation und Klassifikation von Grünflächen sowohl auf übergeordneter Ebene durch Satellitenbilder in Verbindung mit neuronalen Netzen als auch kleinräumigere Untersuchungen unter Zuhilfenahme von Multispektralbildern. Die Forschungsarbeit soll eine Kombination aus beiden Ansätzen untersuchen und eine kleinteiligere Identifikation der Grünflächen mithilfe künstlicher neuronaler Netze eruieren. Hierbei wird auf schon vorhandene Deep Learning Modelle zur allgemeinen Identifikation von Landbedeckungen zurückgegriffen (ESRI, 2024a).

4 UNTERSUCHUNGSgegenstand

Voraussetzung für die Identifikation von Grünflächen mittels neuronaler Netzwerke ist die Auswahl eines passenden Untersuchungsgebietes. Es bietet sich hier an, aufgrund der Voraussetzungen zur Ausführung des Deep-Learning-Modells, ein Gebiet auszuwählen, welches gute Datengrundlagen für eine anschließende Modellierung frei zur Verfügung stellt. Aufgrund der sehr guten Datenverfügbarkeit und der gesamtstädtischen Lokalisation wurde deswegen die Stadt Jena (Thüringen, Deutschland) als Untersuchungsgebiet ausgewählt.

Für eine erfolgreiche Identifikation von Grünflächen ist es zudem wichtig, diese hinreichend zu definieren. Es handelt sich bei den Grünflächen um Flächen, welche sowohl mit natürlicher als auch mit menschengemachter Vegetation ausgestattet sind (L. Li & Pussella, 2017). Sie decken zudem eine breite Anzahl an Ökosystemleistungen ab (Odini & Mhangara, 2012). Arabi et al. (2014) unterteilen Grünflächen in öffentliche, halböffentliche und private Grünflächen sowie in Straßen(begleit)grün (Arabi et al., 2014). Einen anderen Ansatz zur Definition von Grünflächen wählen Yang et al. (2017). Diese differenzieren Grünflächen in sog. angehängte, Straßen- und Parkgrünflächen, produktive Grün- sowie andere Grünflächen (Yang et al., 2017). Wie diese kurze Auswahl aus der Fachliteratur aufzeigt, werden die jeweiligen Arten von Grünflächen bereits differenziert definiert und unterschiedlich abgegrenzt. Allgemein handelt es sich bei diesen Flächen um sehr heterogene Räume ohne scharfe Abgrenzung. Jede fachwissenschaftliche Disziplin grenzt diese unterschiedlich ab (Harasimowicz, 2018).

Auch bei Betrachtung der Definition von Grünflächen im stadtklimatischen Kontext wird deutlich, dass keine allgemeingültige Definition der Grünfläche besteht. Allgemein werden die Ökosystemleistungen aufgegriffen und mit der Speicherung von Kohlenstoff, der Sicherung des Bodens durch das Verhindern der Versiegelung, das Verbessern der Luftqualität sowie der Speicherung von Wasser in Verbindung gebracht. Die stadtklimatische Definition der Grünfläche ist zudem von der Eigenschaft ebendieser geprägt, dass sie angrenzende sowie umliegende Strukturen durch die Prozesse der Evapotranspiration sowie durch eventuell vorhandene Verschattungseffekte abkühlt (klimaaktive Kühlleistung). Diese Eigenschaft haben sowohl großräumige Flächen als auch Einzelbepflanzungen in verschiedenem Maße inne (Bowler et al., 2010).

Weitergehende Attribute, welche die Klimaaktivität einer Grünfläche beeinflussen, sind die Größe und die Lage der Grünfläche, die Form und die Vitalität der Vegetation, die Verbindung mit Wasserflächen sowie exogene Ursachen (z. B. Straßenorientierung, angrenzende Bebauungsdichte) (Bao et al., 2016; Huang et al., 2008; Jaganmohan et al., 2016; Z. Li et al., 2024; Oliveira et al., 2011).

Aufgrund der Heterogenität der Grünflächen sowie deren unterschiedliche Ausstattung ist eine allgemeine Definitionsfindung schwer. Für die weitere Untersuchung werden daher Bestandteile der verschiedenen Definitionen dahingehend kombiniert, dass relativ klar abzugrenzende Grünstrukturen identifizierbar sind. Außerdem handelt es sich bei den Grünflächen zum Zwecke der Identifikation mit Deep Learning Modellen deshalb grundsätzlich um alle Flächen jeglicher Größe, welche den Klassen Gras- /kleine Strauchflächen, große Strauchflächen, unversiegelte Bodenflächen, Baumbestand sowie Wasserflächen zuzuordnen sind.

5 METHODIK

Die Grundlage der Identifikation der Grünflächen stellt ein vortrainiertes Deep Learning Modell mit ursprünglichen Trainingsdaten aus Nordamerika zur allgemeinen Identifikation von Landbedeckungen in Verbindung mit sehr hochauflösenden Luftbildern dar (ESRI, 2024a). Diese werden in ein geographisches Informationssystem (GIS) eingebunden. Mithilfe des Deep Learning Modells sowie der Datengrundlage kann eine Modellierung der Landbedeckungen des Untersuchungsgebietes stattfinden. Nach Entfernen der Landbedeckungen ohne Grünflächenbezug verbleiben die Grünflächenklassen des Modells, welche den entsprechenden Grünflächen zugewiesen werden können. Es kann daran anschließend eine subjektive sowie objektive Analyse und Abschätzung der Genauigkeit stattfinden. Anschließend wird das bereits vortrainierte Modell unter Anwendung von Transfer Learning im GIS mit zentraleuropäischen (deutschen) Landbedeckungen nachtrainiert. Unter dem Hinzuziehen der Modellierungen findet abschließend eine Untersuchung der Klimaaktivität auf Grundlage der durch das Deep Learning Modell identifizierten Grünflächen unter Rückgriff auf eine abgewandelte Methode von Zardo et al. (2017) statt. Hierbei wird die Kühlleistung der verschiedenen Grünflächen mithilfe sogenannter „coolingpoints“ klassifiziert und baut auf den jeweiligen klimaaktiven Eigenschaften der Grünflächen auf. Dabei behandelte Eigenschaften der

Grünflächen, welche die Kühlleistung beeinflussen, sind der Verschattungseffekt, die potentielle Verdunstungsleistung der Fläche, die Art der Bodenbedeckung sowie die absolute Flächengröße (Zardo et al., 2017).

6 MODELLIERUNG MITHILFE DES VORTRAINIERTEN DEEP LEARNING MODELLS

Die Modellierung der Grünflächen in Abbildung 1 mithilfe des vortrainierten Deep Learning Modells zeigt eine sehr heterogene Durchmischung der Grünflächen im Stadtgebiet Jenas auf. Die Analyse der Prognosen der Modellierung lässt sich schwerpunktmäßig sowohl in den stark versiegelten Siedlungsbereich Jenas als auch in den weniger bis gar nicht versiegelten Bereich außerhalb der Siedlungsräume aufteilen.

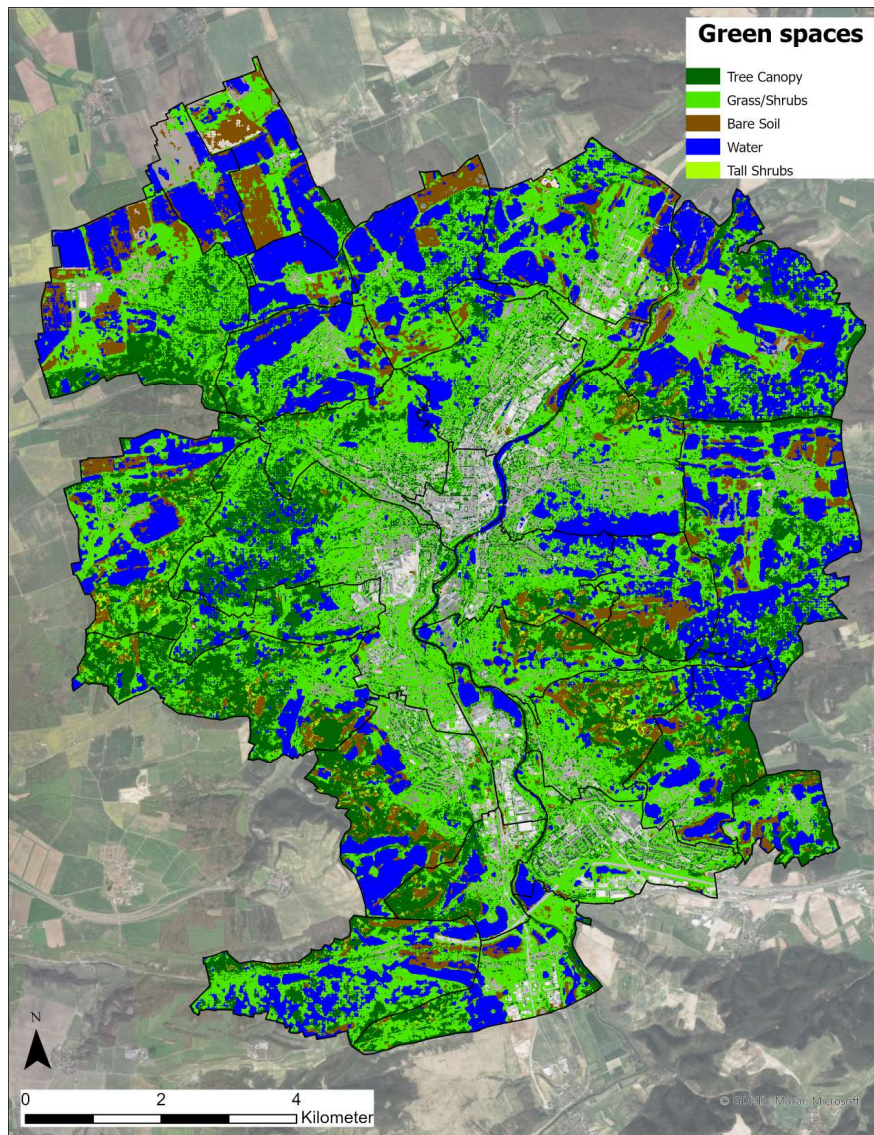


Abb. 1: Modellierung der Grünflächen des Stadtgebietes von Jena mithilfe des vortrainierten Deep Learning Modells (Eigene Darstellung in ArcGIS Pro in Verbindung mit den Deep Learning Libraries (Version 3.3), Datengrundlage: © GDI-Th, Esri, EarthstarGeographics, Maxar, Microsoft und Layer Grünflächen)

Die Untersuchung der peripher gelegenen Bereiche Jenas zeigt eine durchmischte Modellierung von Grünflächen auf. Hervorzuheben ist ein sehr hoher Anteil an (fälschlicherweise) ausgewiesenen Wasserflächen in den Bereichen, bei denen es sich um großflächige heterogene Flächen handelt (z. B. Wälder und Wiesen). Diese werden durch die Modellierung aufgrund ihrer Struktur, ihrer Heterogenität sowie der geringeren Auflösung der verwendeten DOPs als Wasserflächen ausgewiesen.

Bei Betrachtung der Modellierung des innerstädtischen Bereiches wird deutlich, dass es hier im Großen und Ganzen zu einer Ausweisung von Gras- und Strauchflächen sowie von Baumflächen kommt. Wasserflächen werden auch in innerstädtischem Kontext vereinzelt (fälschlicherweise) ausgewiesen, aber es zeigt sich, dass

eine deutlich verbesserte Identifikation der Grünflächen in innerstädtischer Lage im Vergleich zu außerhalb der Siedlungsstrukturen zu verortenden Grünflächen stattfindet.

Insgesamt kommt es bei der Modellierung des vortrainierten Deep Learning Modells zur Identifikation der Grünflächen unter dem Hinzuziehen einer Konfusionsmatrix mithilfe des Vergleiches von Referenzwerten (Ground Truth Werten) zu einer Gesamtgenauigkeit von ca. 46 %.

Zur Verbesserung der Genauigkeit bei der Identifikation und Klassifikation kann das vortrainierte Deep Learning Modell mittels Transfer Learning im GIS mit verhältnismäßig wenig Aufwand nachtrainiert werden (Wallace, 2023). Hierbei wird das vortrainierte Deep Learning Modell mithilfe ausgewählter Trainingsdaten dahingehend nachtrainiert, dass es mit den zur Verfügung stehenden Grundlegendaten (20 x 20 cm Bodenauflösung, zentraleuropäische Vegetation) eine erhöhte Genauigkeit im Vergleich zum ursprünglichen Modell aufweist.

7 MODELLIERUNG MITHILFE DES NACHTRAINIERTEN DEEP LEARNING MODELLS

Die Modellierung des mit Transfer Learning nachtrainierten Deep Learning Modells in Abbildung 2 weist insbesondere bei den außerhalb der Siedlungsräume liegenden Strukturen eine subjektiv deutlich akkuratere Ausweisung von Grünflächen auf.

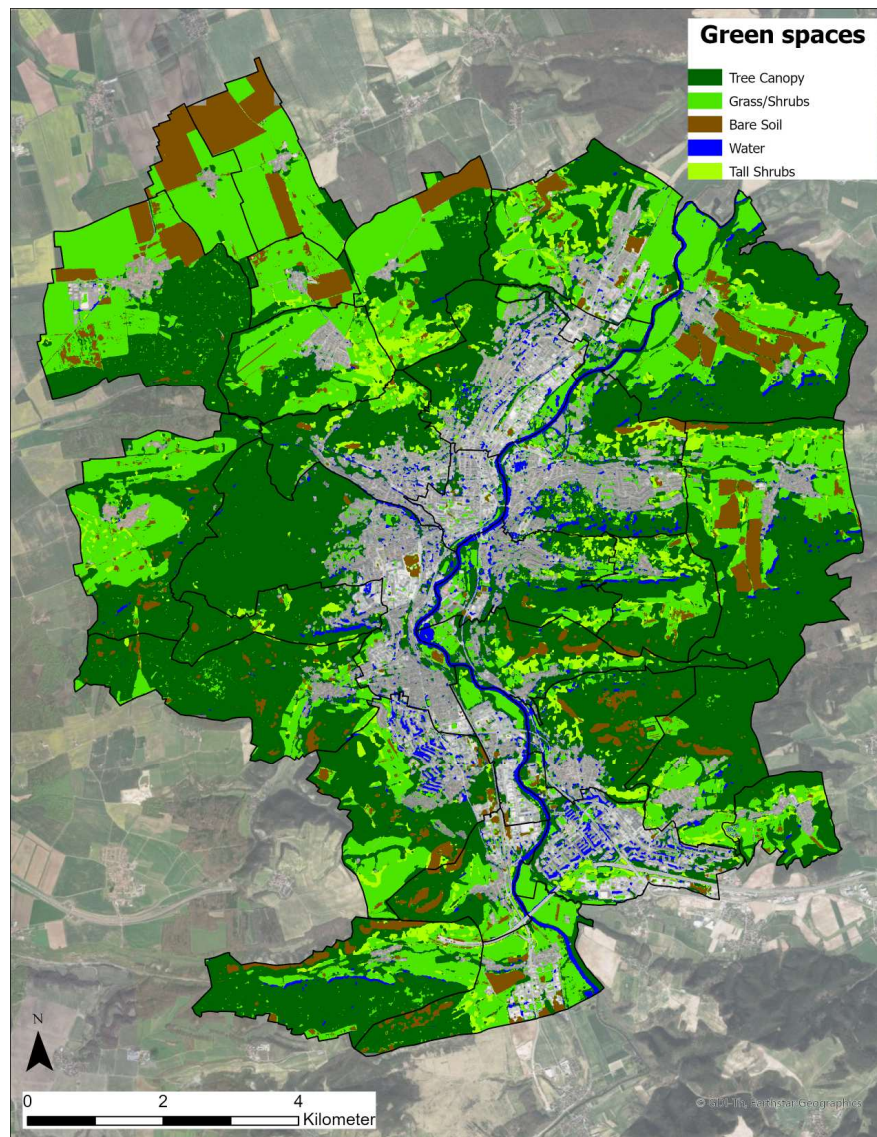


Abb. 2: Modellierung der Grünflächen des Stadtgebietes von Jena mithilfe des nachtrainierten Deep Learning Modells (Eigene Darstellung in ArcGIS Pro in Verbindung mit den Deep Learning Libraries (Version 3.3), Datengrundlage: © GDI-Th, Esri, EarthstarGeographics, Maxar, Microsoft und Layer Grünflächen nachtrainiertes Modell)

Es kommt im Vergleich zu der Modellierung des vortrainierten Modells in den periphereren Gebieten zu einer hauptsächlichen Ausweisung von Gras- und Strauchflächen, Baumflächen sowie Flächen mit großen

Sträuchern. Leider zeigt sich in der nachtrainierten Version aber auch, dass, wenn die Genauigkeit der Identifikation von Grünflächen in den äußeren Gebieten Jenas in subjektiver Betrachtung zugenommen hat, deutlich weniger Grünflächen in innerstädtischer Lage identifiziert werden. Dies ist vermutlich darauf zurückzuführen, dass die Auswahl der Trainingsdaten – insbesondere in innerstädtischer Siedlungsstruktur – aus sehr diversen und heterogenen Strukturen besteht. Dies führt dazu, dass keine eindeutig abzugrenzenden Strukturen entstehen. Infolgedessen wird von dem nachtrainierten Modell ein Großteil der innerstädtischen Grünflächen einer grünflächenfremden Landbedeckung (i. d. R. baulichen Strukturen) zugeordnet.

Allerdings zeigt sich alles in allem, dass die differenzierte Ausweisung von Grünflächen im Vergleich zur vorherigen Untersuchung der vortrainierten Deep Learning Modellierung zu einer Gesamtgenauigkeit des nachtrainierten Modells von ca. 78 % führt. Somit besitzt das nachtrainierte Modell eine deutlich höhere Gesamtgenauigkeit im Vergleich zum vortrainierten Modell – systematische Schwächen bestehen jedoch in der Ausweisung von Grünflächen in innerstädtischer Lage.

8 HYBRIDMODELLIERUNG

Für eine optimierte Ausweisung der Grünflächen sowohl in innerstädtischer als auch in peripherer Lage bietet es sich an, die Grünflächenmodellierung des vortrainierten Modells in innerstädtischer Lage und die Modellierung der Grünflächen des nachtrainierten Modells außerhalb der dicht besiedelten Bereiche zu verschneiden und eine Hybridmodellierung durchzuführen, die die Stärken beider zuvor eingesetzten Modellierungen vereint.

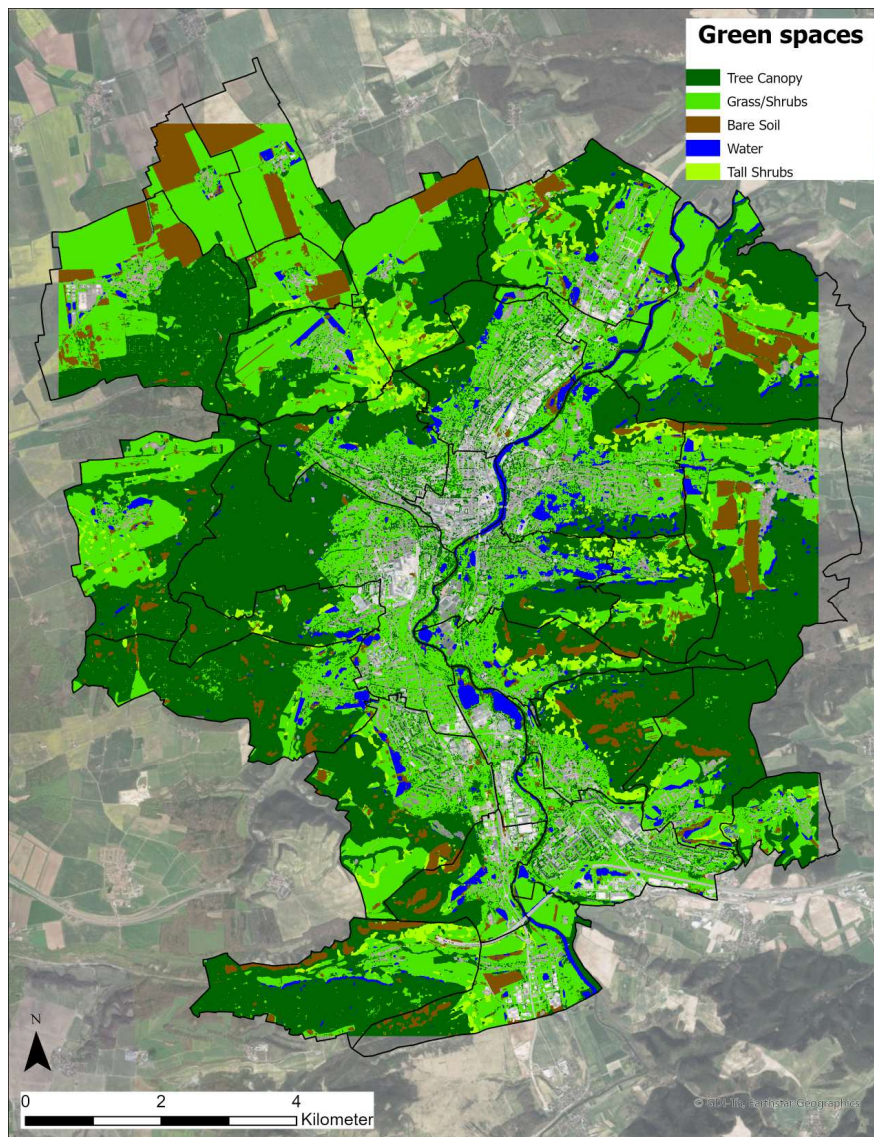


Abb. 3: Hybridmodellierung der Grünflächen des Stadtgebietes von Jena mithilfe der Kombination des vortrainierten sowie des nachtrainierten Deep Learning Modells (Eigene Darstellung in ArcGIS Pro in Verbindung mit den Deep Learning Libraries (Version 3.3), Datengrundlage: © GDI-Th, Esri, EarthstarGeographics, Maxar, Microsoft und Layer Hybridmodellierung Grünflächen)

Die Hybridmodellierung in Abbildung 3 zeigt insgesamt ein deutlich einheitlicheres Bild bei der Identifikation der Grünflächen im gesamten Stadtgebiet auf. Die Grünflächen werden subjektiv sowohl innerhalb als auch außerhalb der Siedlungsräume überwiegend identifiziert und korrekt klassifiziert. Mithilfe der Kombination der beiden ursprünglichen Modellierungen kann mit der Hybridmodellierung eine Gesamtgenauigkeit von ca. 86 Prozent erreicht werden, was als ein mehr als ausreichendes Ergebnis für die initiale Identifikation von Grünflächen bezeichnet werden kann. Auf Grundlage der durch die Hybridmodellierung identifizierten Grünflächen muss anschließend eine grundlegende Bestimmung der Klimaaktivität der zu differenzierenden Flächen erfolgen.

9 KLIMAAKTIVITÄTSBESTIMMUNG

Die Klimaaktivität der Grünflächen kann je nach unmittelbarer Kühlleistung in verschiedene Klassen eingeteilt werden. Es handelt sich hierbei um Grünflächen mit sehr geringer Kühlleistung ($< 1 \text{ K}$), Grünflächen mit geringer Kühlleistung ($> 1 \text{ K} < 2 \text{ K}$), Grünflächen mit einer hohen Kühlleistung ($> 2 \text{ K} < 3 \text{ K}$) sowie Grünflächen mit einer sehr hohen Kühlleistung ($> 3 \text{ K}$) (Zardo et al., 2017).

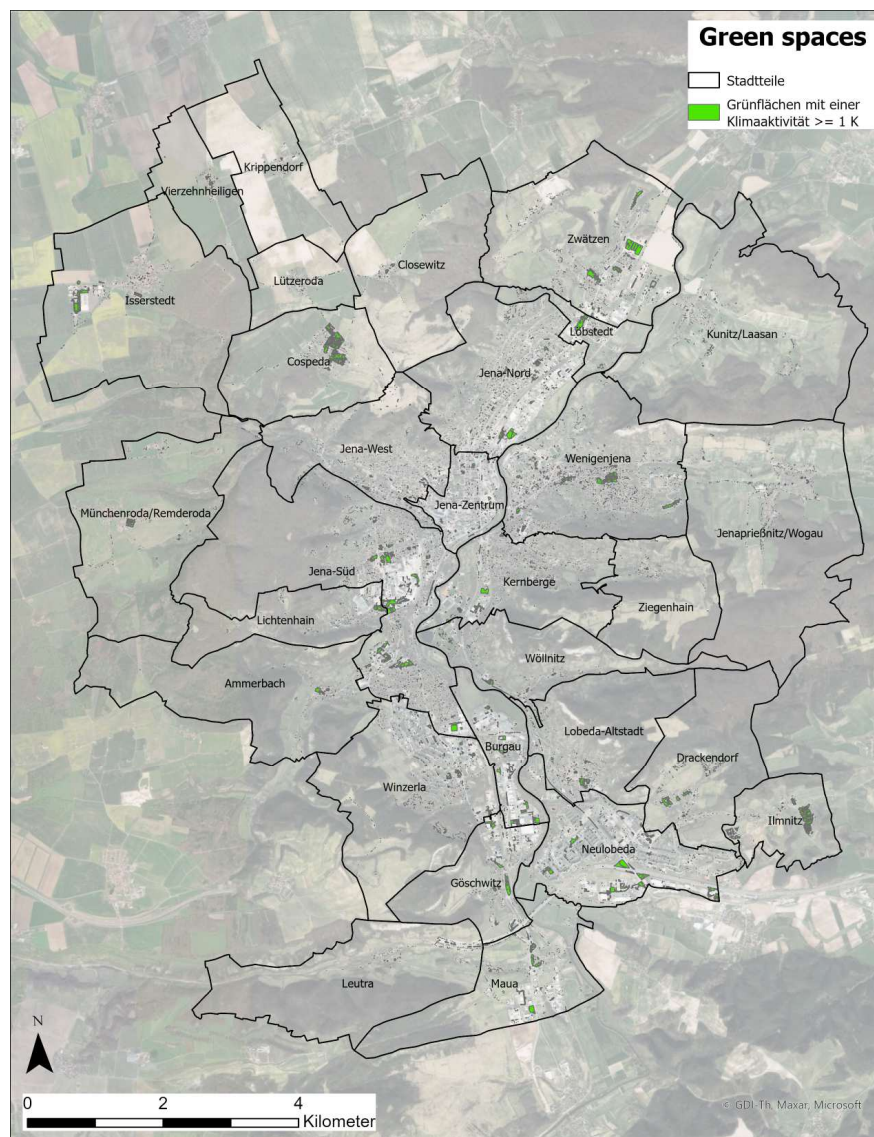


Abb. 4: Klimaaktive Grünflächen mit einer sehr geringen Kühlleistung $< 1 \text{ K}$ innerhalb des Untersuchungsgebietes von Jena (Eigene Darstellung in ArcGIS Pro in Verbindung mit den Deep Learning Libraries (Version 3.3), Datengrundlage: © GDI-Th, Esri, EarthstarGeographics, Maxar, Microsoft, Stadt Jena, dl-de/by-2-0 (<http://www.govdata.de/dl-de/by-2-0>), URL: <https://opendata.jena.de/dataset/ortsteile> und Layer Grünflächen mit einer Klimaaktivität $\geq 1 \text{ K}$, Stadtteile)

Bei der Betrachtung der klimaaktiven Grünflächen mit einer sehr geringen Kühlleistung in Abbildung 4 wird ersichtlich, dass diese insbesondere in den dicht versiegelten Bereichen im Stadtgebiet von Jena vorzufinden sind. Es handelt sich bei diesen Flächen mit sehr geringer Klimaaktivität um Bereiche mit einer absoluten Flächengröße $< 2 \text{ ha}$ sowie einem anteilweise geringen Baumbestand. Flächen, welche dieser

Klimaaktivitätsklasse zugeordnet werden können, sind kleine zusammenhängende Gartenstrukturen, kleinere Abschnitte von Straßenbegleitgrün sowie einzelne Grasflächen.

Die darauffolgende Klasse hinsichtlich der Klimaaktivität aufgrund ihrer abrufbaren Kühlleistung definiert sich durch eine absolute Flächengröße < 2 ha, allerdings mit einem deutlich höheren prozentualen Baumbestand innerhalb der Fläche im Vergleich zur vorherigen mit sehr geringer Klimaaktivität.

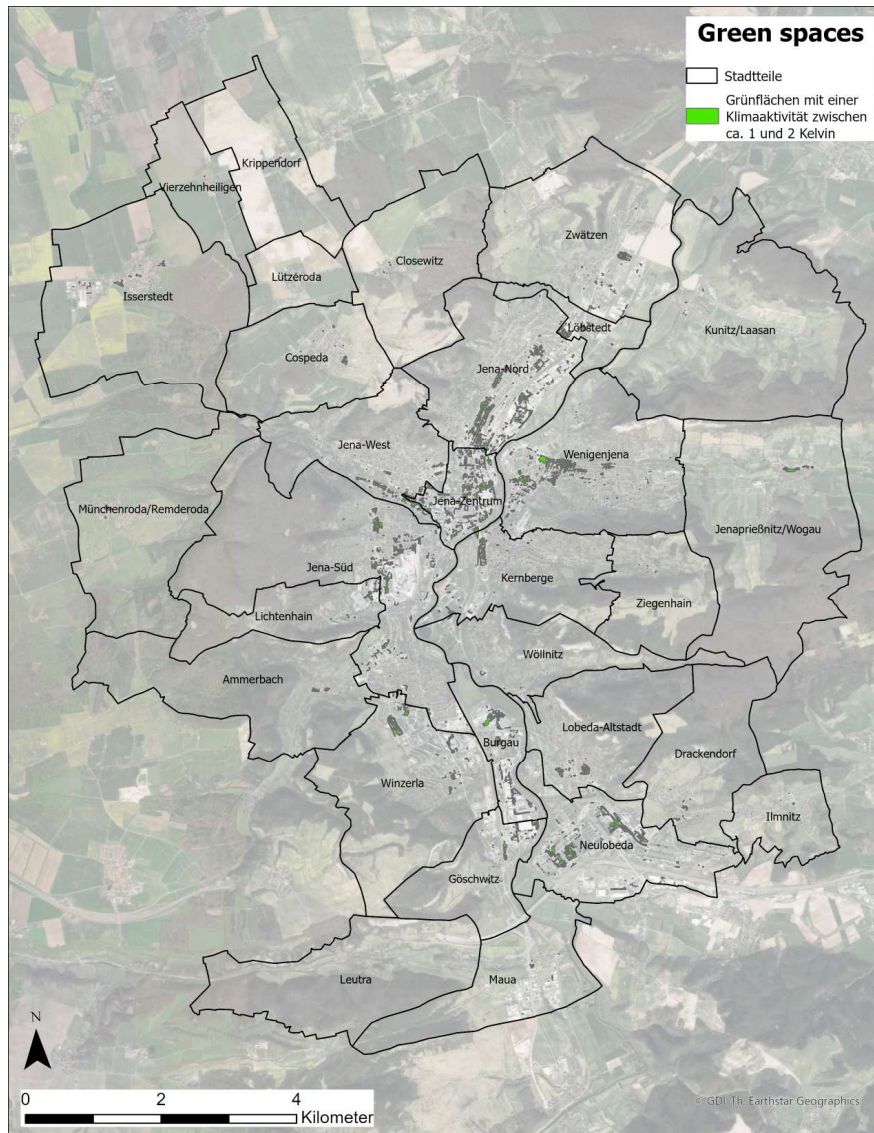


Abb. 5: Klimaaktive Grünflächen mit einer geringen Kühlleistung ($> 1 \text{ K} < 2 \text{ K}$) innerhalb des Untersuchungsgebietes von Jena (Eigene Darstellung in ArcGIS Pro in Verbindung mit den Deep Learning Libraries (Version 3.3), Datengrundlage: © GDI-Th, Esri, EarthstarGeographics, Maxar, Microsoft, Stadt Jena, dl-de/by-2-0 (<http://www.govdata.de/dl-de/by-2-0>), URL: <https://opendata.jena.de/dataset/ortsteile> und Layer Grünflächen mit einer Klimaaktivität zwischen ca. 1 und 2 Kelvin, Stadtteile)

In Abbildung 5 wird deutlich, dass Grünflächen mit einer geringen Klimaaktivität subjektiv aufgrund ihres höheren Baumanteils an der absoluten Flächengröße tendenziell größere Bereiche einnehmen, als dies bei den Grünflächen mit einer sehr geringen Klimaaktivität der Fall war. Sie sind noch immer in den dicht besiedelten und versiegelten Räumen vorzufinden, haben sich jedoch hinsichtlich ihrer räumlichen Verteilung in Richtung der Kernstadt (insbesondere Jena-Zentrum sowie Jena-Nord) verschoben. Aufgrund ihrer Standorte und ihren zuordenbaren Eigenschaften handelt es sich bei diesen Flächen beispielhaft um bepflanzte Innenhöfe von Blockbauten, Straßenalleen sowie kleineren Stadtparks. Daher lässt sich insgesamt festhalten, dass die Grünflächen mit sehr geringer und geringer Klimaaktivität überwiegend in den Siedlungsräumen vorzufinden sind. Sie tragen zur Kühlung der unmittelbaren Umgebung nur in geringem Maße bei und stellen einen untergeordneten Teil des Siedlungsraumes dar.

Die Flächen mit einer hohen und sehr hohen Klimaaktivität mit Kühlleistungen von > 3 K werden mithilfe des Deep Learning Algorithmus grundsätzlich den außerhalb der Siedlungsräume liegenden Grünflächen zugewiesen (Gesamtstadt Jena exkl. Jena-Zentrum, Jena-Nord, Jena-Süd sowie Wenigenjena).

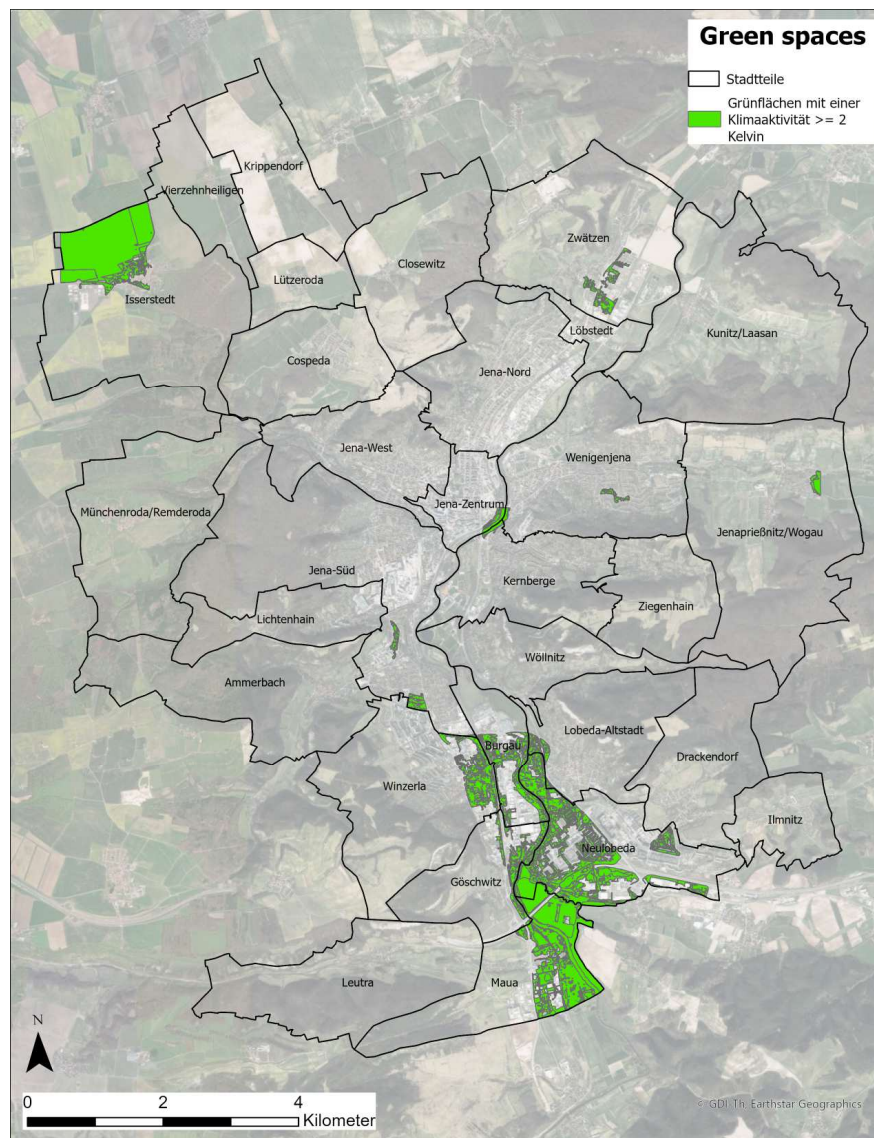


Abb. 6: Klimaaktive Grünflächen mit einer hohen Kühlleistung > 2 K < 3 K innerhalb des Untersuchungsgebietes von Jena (Eigene Darstellung in ArcGIS Pro in Verbindung mit den Deep Learning Libraries (Version 3.3), Datengrundlage: © GDI-Th, Esri, Maxar, Earthstar Geographics, Microsoft, Stadt Jena, dl-de/by-2-0 (<http://www.govdata.de/dl-de/by-2-0>), URL: <https://opendata.jena.de/dataset/ortsteile> und Layer Grünflächen mit einer Klimaaktivität ≥ 2 Kelvin, Stadtteile)

So ist in den Abbildungen 6 und 7 erkennbar, dass die Grünflächen mit einer hohen sowie sehr hohen Klimaaktivität größtenteils außerhalb der Siedlungsbereiche liegen. Diese sind in ihrer absoluten Fläche größer als zwei Hektar und besitzen einen anteiligen Baumbestand zwischen 0 und 40 % (Flächen mit einer hohen Kühlleistung) respektive über 40 % an der Gesamtfläche (Flächen mit einer sehr hohen Kühlleistung).

Die außerhalb der Siedlungsräume liegenden Grünflächen ziehen sich durch Grünverbindungen bis in den Siedlungskern hinein. So ist es möglich, dass Flächen, welche ursprünglich keine bzw. eine deutlich geringere Kühlleistung aufweisen, durch die Verbindung mit anderen Grünflächen, in Summe eine höhere Kühlleistung abrufen können.

Bei den Flächen mit sehr hoher Klimaaktivität, welche in Abbildung 7 zu erkennen sind, handelt es sich um sehr große, außerhalb der Siedlungsräume zu lokalisierende Grünräume in Form von Wiesen, Feldern und Wäldern – aber auch große innerstädtische Grünräume wie Stadtparks.

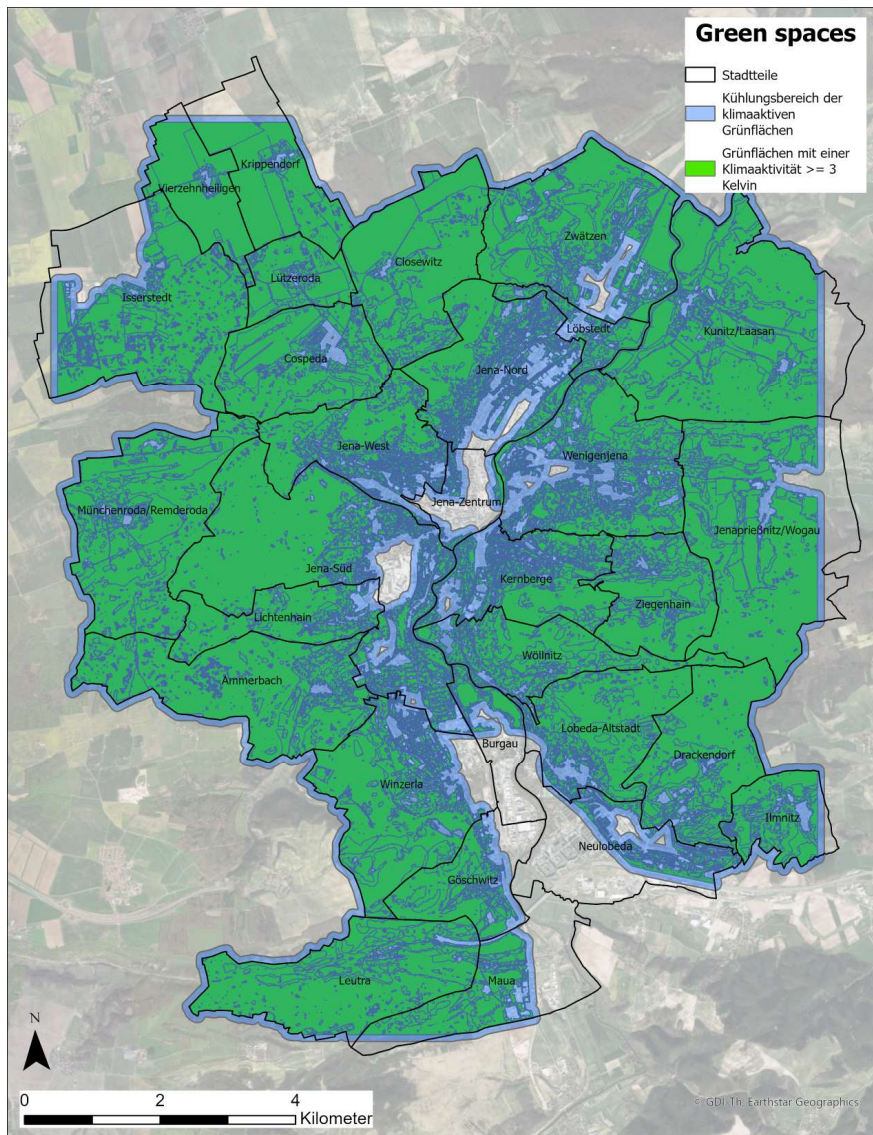


Abb. 7: Klimaaktive Grünflächen mit einer sehr hohen Kühlleistung > 3 K sowie einer Transferkühlleistung von 100 Metern über die eigentliche Grünfläche hinweg, innerhalb des Untersuchungsgebietes von Jena (Eigene Darstellung in ArcGIS Pro in Verbindung mit den Deep Learning Libraries (Version 3.3), Datengrundlage: © GDI-Th, Esri, EarthstarGeographics, Maxar, Microsoft, Stadt Jena, dl-de/by-2-0 (<http://www.govdata.de/dl-de/by-2-0>), URL: <https://opendata.jena.de/dataset/ortsteile> und Layer Kühlbereich der klimaaktiven Grünflächen, Grünflächen mit einer Klimaaktivität ≥ 3 Kelvin, Stadtteile)

Es handelt sich bei den Flächen mit sehr hoher Klimaaktivität um Bereiche, die eine unmittelbare Kühlleistung auf ihre nähere Umgebung aufweisen, aber auch Transferkühlleistungen erbringen. So kommt es zu Transferkühlleistungen von ca. 110 Metern um großangelegte Parks. Die unmittelbaren Kühlleistungen von Grünräumen mit einem hohen Anteil an Bäumen, wie beispielsweise Wälder, weisen Transferkühlleistungen von ca. 190 Metern auf. Unter Berücksichtigung der siedlungsstrukturellen Besonderheiten wie beispielsweise der Blockade der unmittelbaren Kaltluft wird hier mit einer Kühltransferleistung von 100 Metern in Form eines Puffers um die klimaaktiven Grünflächen gearbeitet (Jaganmohan et al., 2016; Syrbe et al., 2024).

10 AUSBLICK UND HERAUSFORDERUNGEN

Insgesamt kommt es zu einigen Herausforderungen bei der Modellierung von Grünflächen sowie deren Klimaaktivität. Sie liegen in der Schwierigkeit bei der Definition einer allgemeinen Abgrenzung für eine solche Fläche, in der generellen Arbeit mit Künstlicher Intelligenz im Allgemeinen und Deep Learning Modellen im Speziellen sowie den damit verbundenen Grundlegenden für die Berechnung der Modellierung bzw. deren Verfügbarkeit.

Wie bereits erwähnt, handelt es sich bei der Begrifflichkeit der Grünfläche keinesfalls um eine allgemeingültige sowie universal anerkannte. Je nach Situation, Ziel sowie anderen Rahmenbedingungen

wird diese subjektiv definiert. Dies macht es schwierig, die „eine“ Grünflächendefinition zu finden. Für die Identifikation dieser Räume mithilfe des Instrumentes der Künstlichen Intelligenz wird mittels einer Kombination aus verschiedenen Abgrenzungen für Grünflächen eine subjektiv definierte Begrifflichkeit für die weiteren Untersuchungen formuliert.

Eine weitergehende Herausforderung besteht in der Abhängigkeit bei der Auswahl des Deep Learning Modells und den damit verbundenen ursprünglichen Trainingsdaten bzw. dem ursprünglichen Trainingsgebiet. Im konkreten Fall handelt es sich um einen Algorithmus, der mithilfe sehr hochauflösender (10 x 10 cm Bodenauflösung) Luftbilder aus dem nordamerikanischen Raum initial trainiert wurde. Er funktioniert dementsprechend mit diesen Inputdaten am besten. Wird nun ein mitteleuropäischer Raum mit den frei zur Verfügung stehenden Luftbildern mit einer sehr hohen Auflösung (20 x 20 cm Bodenauflösung) durch den Algorithmus modelliert, kommt es aufgrund verschiedener geometrischer Auflösung, Landbedeckungsarten bzw. unterschiedlicher Vegetation auch zu differenzierten Prognosen, mit – im Endeffekt – einer Verschlechterung der Ergebnisse.

Für die bestmögliche Modellierung der Grünflächen ist es demnach nötig, so nah wie möglich an die für das ursprüngliche Training verwendete Daten hinsichtlich ihrer Eigenschaften (z. B. Auflösung, Landbedeckungs-/Grünflächenarten, etc.) zu gelangen. Es besteht dementsprechend eine Abhängigkeit in Bezug auf die Grundlagendaten.

Ebenso ist die korrekte Identifikation bodennaher Grünflächen mit Fernerkundungsdaten in Verbindung mit der Identifikation von ebendieser mithilfe Künstlicher Intelligenz eine weitere Herausforderung. Dies wird insbesondere dann zum Problem, wenn Landbedeckungen verschiedener vertikaler Ausdehnung übereinanderliegen und hierdurch durch das Luftbild nicht ausreichend dargestellt werden. Eine korrekte Bilanzierung der Grünflächen wird somit deutlich erschwert. Abhilfe geschaffen werden kann hier mit der Anwendung von Interpolation.

Insgesamt lässt sich feststellen, dass eine grundsätzliche Identifikation von Grünflächen mithilfe Künstlicher Intelligenz möglich ist. Differenziert werden muss dahingehend – aufgrund der unterschiedlichen Eigenschaften – zwischen dem Siedlungsraum und dem unbesiedelten bzw. weniger dicht besiedelten (oftmals periphereren) Raum. Aufbauend auf der Identifikation der Grünflächen ist es zudem initial möglich, eine Bestimmung der Klimaaktivität, definiert durch die abrufbaren Kühlleistungen der Grünflächen, vorzunehmen. Die Identifikation (klimaaktiver) Grünflächen unter der Zuhilfenahme von Künstlicher Intelligenz stellt dahingehend ein Instrument mit sehr hohem Potenzial dar, welches für eine Kartierung sowie Optimierung der Grünflächen innerhalb des Bestandes genutzt werden kann.

11 REFERENCES

- ALBERT, A., Kaur, J., & Gonzalez, M. C. (2017). Using Convolutional Networks and Satellite Imagery to Identify Patterns in Urban Environments at a Large Scale. In: Proceedings of the 23rd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining, 1357–1366.
- ARABI, Z., Hatami, D., & Mahdi, J. (2014). Analysis of the pattern of spatial-local distribution of green space (case study of mehr city in iran). In: Indian Journal of Scientific Research, 8(1), 197–202.
- BAO, T., Li, X., Zhang, J., Zhang, Y., & Tian, S. (2016). Assessing the Distribution of Urban Green Spaces and its Anisotropic Cooling Distance on Urban Heat Island Pattern in Baotou, China. In: ISPRS International Journal of Geo-Information, 5(2), 12.
- BOWLER, D. E., Buyung-Ali, L., Knight, T. M., & Pullin, A. S. (2010). Urban greening to cool towns and cities: A systematic review of the empirical evidence. In: Landscape and Urban Planning, 97(3), 147–155.
- DE LANGE, N. (2020). Geoinformatik in Theorie und Praxis: Grundlagen von Geoinformationssystemen, Fernerkundung und digitaler Bildverarbeitung. Springer Berlin Heidelberg.
- EARTHSTAR GEOGRAPHICS (2025): TerraColor Next Gen. <https://www.terracolor.net/> (letzter Abruf: 03.02.2025)
- ESRI. (2024a). Land Cover Classification (Aerial Imagery) – Übersicht. <https://www.arcgis.com/home/item.html?id=c1bca075efb145d9a26394b866cd05eb> (letzter Abruf: 03.02.2025)
- ESRI (2025). ArcGIS Pro 3.3 [Software]. ESRI. <https://www.esri.com/de-de/arcgis/products/arcgis-pro/overview>
- FREISTAAT THÜRINGEN (2024): Download Luftbilder und Orthophotos, dl-de/by-2-0 (www.govdata.de/dl-de/by-2-0). URL: <https://geoportal.thueringen.de/gdi-th/download-offene-geodaten/download-luftbilder-und-orthophotos>
- HARASIMOWICZ, A. (2018). Green Spaces as a part of the city structure. In: Ekonomia i Środowisko, 2(65), 45–62.
- HUANG L., Li, J., Zhao, D., & Zhu, J. (2008). A fieldwork study on the diurnal changes of urban microclimate in four types of ground cover and urban heat island of Nanjing, China. In: Building and Environment, 43(1), 7–17.
- IPCC (2023): Climate Change 2023: Synthesis Report. Contribution of Working Groups I, II and III to the Sixth Assessment Report of the Intergovernmental Panel on Climate Change, Geneva, Switzerland
- JAGANMOHAN, M., Knapp, S., Buchmann, C. M., & Schwarz, N. (2016). The Bigger, the Better? The Influence of Urban Green Space Design on Cooling Effects for Residential Areas. In: Journal of Environmental Quality, 45(1), 134–145.

- LI, L., & Pussella, P. G. R. N. I. (2017). Is Colombo city, Sri Lanka secured for urban green space standards? In: *Applied Ecology and Environmental Research*, 15(3), 1789–1799.
- LI, Z., Bai, X., Tan, Q., Zhao, C., Li, Y., Luo, G., Chen, F., Li, C., Ran, C., Zhang, S., Xiong, L., Song, F., Du, C., Xiao, B., Xue, Y., & Long, M. (2024). Dryness stress weakens the sustainability of global vegetation cooling. In: *Science of The Total Environment*, 909, 168474.
- MAXAR (2025): Satellite imagery and multi-int Collection, <https://www.maxar.com/maxar-intelligence/products/satellite-imagery> (letzter Abruf: 06.02.2025)
- MICROSOFT IRELAND OPERATIONS LIMITED (2025): Microsoft Bing Maps, <https://www.bing.com/maps> (letzter Abruf: 06.02.2025)
- NGUYEN, T. C., & Chidthaisong, A. (2022). Urban green space inventory using different spatial resolution satellite images: Practical notes in Bangkok.
- ODINI, J., & Mhangara, P. (2012). Green Spaces Trends in the City of Port Elizabeth from 1990 to 2000 using Remote Sensing. In: *International Journal of Environmental Research*, 653–662.
- OLIVEIRA, S., Andrade, H., & Vaz, T. (2011). The cooling effect of green spaces as a contribution to the mitigation of urban heat: A case study in Lisbon. In: *Building and Environment*, 46(11), 2186–2194.
- SUN, Y., Wang, X., Zhu, J., Chen, L., Jia, Y., Lawrence, J. M., Jiang, L., Xie, X., & Wu, J. (2021). Using machine learning to examine street green space types at a high spatial resolution: Application in Los Angeles County on socioeconomic disparities in exposure. In: *Science of The Total Environment*, 787, 147653.
- STADT JENA (2024): Ortsteile, dl-de/by-2-0 (<http://www.govdata.de/dl-de/by-2-0>), URL: <https://opendata.jena.de/dataset/ortsteile>
- SYRBE, R.-U., Meier, S., Moyzes, M., Dworczyk, C., & Grunewald, K. (2024). Assessment and Monitoring of Local Climate Regulation in Cities by Green Infrastructure – A National Ecosystem Service Indicator for Germany. In: *Land*, 13(5), 689.
- WALLACE, S. (2023). Ein Deep-Learning-Modell mit Transfer Learning verbessern | Learn ArcGIS. <https://learn.arcgis.com/de/projects/improve-a-deep-learning-model-with-transfer-learning/>
- WANG, R., Feng, Z., Pearce, J., Yao, Y., Li, X., & Liu, Y. (2021). The distribution of greenspace quantity and quality and their association with neighbourhood socioeconomic conditions in Guangzhou, China: A new approach using deep learning method and street view images. In: *Sustainable Cities and Society*, 66, 102664.
- YANG, C., He, X., Wang, R., Yan, F., Yu, L., Bu, K., Yang, J., Chang, L., & Zhang, S. (2017). The Effect of Urban Green Spaces on the Urban Thermal Environment and Its Seasonal Variations. In: *Forests*, 8(5), 153.
- ZARDO, L., Geneletti, D., Pérez-Soba, M., & Van Eupen, M. (2017). Estimating the cooling capacity of green infrastructures to support urban planning. In: *Ecosystem Services*, 26, 225–235.
- ZHAO, J. (2022). Automatically Mapping Urban Green Space Using Sentinel-2 Imagery and Deep Learning Methods in Multiple Cities Worldwide: A Convolutional Network Approach.