

Geographisches Institut  
Rheinische Friedrich-Wilhelms-Universität Bonn

# **Alles im grünen Bereich? Erreichbarkeit von Grünflächen in deutschen Großstädten:**

Eine räumliche Netzwerkanalyse von Supply-Demand-Beziehungen und  
Straßennetzwerken

## **Bachelorarbeit**

vorgelegt von:

Jan Hendrik Menke

betreut durch:

Prof. Dr. Christian Geiß  
Dr. Michael Wurm

Bonn, den 27.12.2024

## Danksagung

An dieser Stelle möchte ich mich herzlich bei all den Menschen bedanken, die mich während der Entstehung dieser Bachelorarbeit und meines gesamten Studiums unterstützt haben.

Mein besonderer Dank gilt meinen beiden Betreuern, Prof. Dr. Christian Geiß und Dr. Michael Wurm vom Deutschen Zentrum für Luft- und Raumfahrt. Ihre fachkundige Unterstützung, konstruktive Kritik und wertvollen Anregungen haben maßgeblich zum Gelingen dieser Arbeit beigetragen. Vielen Dank, dass Sie stets ein offenes Ohr für meine Fragen hatten und mich in jeder Phase mit Rat und Tat unterstützt haben.

Ebenso möchte ich meiner Familie und meinen Freunden danken, die mich während meines gesamten Studiums und insbesondere in den herausfordernden Momenten dieser Arbeit unterstützt haben. Euer Glaube an mich und eure Ermutigung haben mir stets Kraft gegeben, weiterzumachen.

Vielen Dank!

## Eidesstattliche Erklärung

Ich versichere, dass ich die Arbeit selbstständig verfasst habe, dass ich keine anderen Quellen und Hilfsmittel als die angegebenen benutzt und die Stellen der Arbeit, die anderen Werken dem Wortlaut oder dem Sinn nach entnommen sind, in jedem Fall als Entlehnung kenntlich gemacht habe. Das Gleiche gilt auch für beigegebene Zeichnungen, Kartenskizzen und Abbildungen. Der Textteil der Arbeit (inkl. Leerzeichen und Anmerkungen) umfasst 87.544 Zeichen.

Bonn, 27.12.2024

---

Ort, Datum

*J. Menke*

---

Unterschrift der\*des Studierenden

# Inhaltsverzeichnis

Abbildungsverzeichnis .....	II
Abkürzungsverzeichnis .....	III
Formelverzeichnis .....	IV
1. Einleitung .....	1
2. Theoretischer Hintergrund .....	4
2.1 Graphentheorie .....	4
2.2 Bedeutung von Grünflächen für den Menschen .....	6
2.3 Die Bewegung von Fußgängern in der Stadt .....	8
2.3.1 Walkability .....	8
2.3.2 Wie weit gehen Menschen? .....	10
2.4 Das Konzept der Accessibility .....	12
3. Das Untersuchungsgebiet .....	14
4. Daten und Methodik .....	17
4.1 Daten .....	18
4.1.1 Ausgangsdaten .....	18
4.1.2 Datenvorbereitung .....	21
4.2 Methodik .....	21
4.2.1 Disaggregation der Zensus-Daten .....	22
4.2.2 Two-step floating catchment area .....	23
4.2.3 Untersuchung der Accessibility als Netzwerk .....	26
4.2.3.1 Local Significance .....	26
4.2.3.2 Der Grad .....	26
4.2.3.3 Detour-Index .....	27
4.2.3.4 Community-Detection .....	27
5. Ergebnisse .....	31
6. Diskussion .....	38
6.1 Die Erreichbarkeit von Grünflächen in Bonn .....	38
6.2 Limitationen der Methodik .....	40
6.3 Potenziale von Netzwerkcharakteristika zur Untersuchung von Accessibility .....	41
7. Fazit .....	43
Quellenverzeichnis .....	44
Anhang .....	i

# Abbildungsverzeichnis

Abbildung 1: Zwei unterschiedliche Darstellungen desselben Graphen (eigene Darstellung) .....	4
Abbildung 2: Zwei topologische identische Graphen mit unterschiedlichen räumlichen Attributen (eigene Darstellung) .....	5
Abbildung 3: Entwicklungsmaßnahmen des Masterplans „Innere Stadt“ Bonn im Rahmen des Leitmotivs „Grüne Trittsteine“ .....	16
Abbildung 4: Gauß-Funktion zur Gewichtung in Abhängigkeit zur Netzwerkdistanz (eigene Darstellung).....	23
Abbildung 5: Schematische Darstellung der 2SFCA-Methode (LUO & WANG 2003).....	25
Abbildung 6: Ablauf des Leiden-Algorithmus (TRAAG et al. 2019) .....	29
Abbildung 7: Erreichbarkeit innerstädtischer Grünflächen in Bonn (eigene Darstellung) .....	31
Abbildung 8: Statistische Verteilung der Accessibility in den Ortsteilen Bonn-Zentrum, Nordstadt, Bonn-Castell und Südstadt (eigene Darstellung).....	32
Abbildung 9: Statistische Verteilung der Accessibility in den Ortsteilen Gronau, Kessenich und Dottendorf (eigene Darstellung).....	32
Abbildung 10: Statistische Verteilung der Accessibility in den Ortsteilen Brüser Berg und Ückesdorf (eigene Darstellung) .....	33
Abbildung 11: Statistische Verteilung der Accessibility in den Ortsteilen Duisdorf und Lengsdorf (eigene Darstellung) .....	33
Abbildung 12: Statistische Verteilung der Accessibility in den Ortsteilen Lannesdorf und Mehlem (eigene Darstellung) .....	34
Abbildung 13: Detour-Index in der Stadt Bonn: Dieser zeigt an, wie groß der Umweg ist, der durch das Straßennetzwerk auf dem Weg zur Grünfläche genommen werden muss. (eigene Darstellung).....	35
Abbildung 14: Darstellung des Angebots und der Nachfrage von Grünflächen als Netzwerk. Die Knoten repräsentieren die Grünflächen und sind an deren geometrischen Schwerpunkt positioniert. Die Kanten stellen die Beziehung eines Wohngebäudes mit einer Grünfläche dar. (eigene Darstellung) .....	36
Abbildung 15: Ergebnisse der Community-Detection: Während die Berechnung der Community Detection auf der linken Seite ohne Einbezug der local significance erfolgte, wurde auf der rechten Seite die local significance miteinbezogen. (eigene Darstellung).....	37

## Abkürzungsverzeichnis

2SFCA	Two-step floating catchment area
ATKIS	Amtliches Topographisch-Kartographisches Informationssystem
BMI	Body-Mass-Index
CSV	Comma sepreated Values
DI	Detour-Index
E2SFCA	Enhanced two-step floating catchment area
EU	Europäische Union
FAR	Floor Area Ratio
GIS	Geoinformationssystem
IWN	Individual Walkable Neighbourhood
LS	Local Significance
OSM	OpenStreetMap
VGI	Volunteered Geographic Information

## Formelverzeichnis

- (1) Disaggregation der Bevölkerungsdaten  $P_g = \sum_z \frac{A_{gz} \times P_z}{A_z}$  22
- (2) Distanzabhängige Gewichtungsfunktion  $G(d_{kj}, d_0) = \frac{e^{-0,5 \times \left(\frac{d_{kj}}{d_0}\right)^2} - e^{-0,5}}{1 - e^{-0,5}}, d_{kj} \leq d_0$  24
- (3) 1. Schritt 2SFCA (Populationsdruck)  $R_j = \frac{S_j}{\sum_{k \in \{d_{kj} \leq d_0\}} G(d_{kj}, d_0) \times P_k}$  24
- (4) 2. Schritt 2SFCA (Accessibility)  $A_i = \sum_{j \in \{d_{jk} \leq d_0\}} G(d_{kj}, d_0) \times R_j$  24
- (5) Local Significance  $LS = \frac{P_k \times S_j}{d_{kj}^2}$  26
- (6) Grad abhängig von Kantengewichten  $D_j = \sum_{k=1}^N a_{jk} w_{jk}$  27
- (7) Detour-Index  $DI = \frac{d_{kj}}{nd_{kj}}$  27

## 1. Einleitung

Mehr als 50 % der Weltbevölkerung leben inzwischen in Städten, und ein weiterer Anstieg dieses Anteils wird prognostiziert (KONDO et al. 2018). Auch in Deutschland lässt sich ein absolutes oder zumindest relatives Wachstum der städtischen Bevölkerung im Vergleich zum Umland beobachten (MILBERT 2018). Aufgrund einer Veränderung der Demografie und der Beschäftigungsformen haben gut ausgestattete Wohnungen in lebendigen Innenstädten im Vergleich zu Einfamilienhäusern im Umland an Beliebtheit gewonnen. Dementsprechend hat sich die menschliche Umwelt, die in engem Zusammenhang mit der menschlichen Gesundheit steht, stark verändert (JACKSON 2003; ZHANG et al. 2017). So kann die Gestaltung der Umwelt einen relevanten Einfluss auf die physische Aktivität von Menschen haben (JACKSON 2003). In Hinblick auf die öffentliche Gesundheit hat sich gezeigt, dass der Zugang zu Grün- und Freiflächen sowie ausreichende Exposition gegenüber Sonnenlicht von großer Bedeutung ist. Insbesondere Grünflächen in der Stadt können durch verschiedene Mechanismen vielfältige positive Effekte auf die menschliche Gesundheit haben (THOMPSON et al. 2016). So gibt es Hinweise darauf, dass städtische Grünflächen positive Auswirkungen auf Aufmerksamkeit, Stimmung, körperliche Aktivität und auf das Herz-Kreislauf-System haben, während sie gleichzeitig mit geringerer Sterblichkeit und weniger Gewalt verbunden sind (KONDO et al. 2018). Auch DADVAND et al. (2014) stellen für Kinder fest, dass Parks und Wälder in der Umgebung mit einem geringeren Body-Mass-Index (BMI) und weniger passiven Lebensstil verknüpft sind. Außerdem wurde beobachtet, dass Grünflächen auch unabhängig des reduzierten Stress‘ zu einer gesünderen Schlafdauer beitragen (ASTELL-BURT et al. 2013). Daher sollte die Planung in urbanen Räumen den Zugang zu Frei- und Grünflächen berücksichtigen (JACKSON 2003).

Es wurde deutlich, dass sowohl die Verfügbarkeit als auch die Gleichmäßigkeit der Verteilung von Grünflächen erheblich zwischen verschiedenen Städten und Regionen variiert (WEIGAND et al. 2023). Eine Reihe von Studien untersucht die Erreichbarkeit von Grünflächen in einzelnen Städten (XING et al. 2018; WEN et al. 2020; ZHANG et al. 2022; SUN et al. 2023). Diese Arbeit reiht sich in die bestehende Forschung ein, untersucht die Erreichbarkeit von Grünflächen in deutschen Großstädten am Beispiel der Stadt Bonn und erprobt dabei neue methodische Ansätze. Der erste Teil der Arbeit fokussiert sich auf die Untersuchung der Erreichbarkeit von Grünflächen in Bonn. Bonn ist für sein grünes Stadtbild bekannt. So wurde Bonn in der Vergangenheit als grünste Hauptstadt Europas bezeichnet (SCHÄFFER & ERDMANN 2015).



Zudem wurden verschiedene Projekte, wie das „Grüne C“ im Rahmen der Regionale 2010 und die „Grünen Trittsteine“ des Masterplans „Innere Stadt“ initiiert, welche die Versorgung mit Grünflächen in Bonn weiter verbessern sollten (REGIONALE 2010-AGENTUR 2012; WACHTEN et al. 2012). Die zentrale Methode, die zur Untersuchung der Erreichbarkeit von Grünflächen dienen soll, ist die *Two-step floating catchment area* (2SFCA)-Methode, welche bereits in zahlreichen Studien zur Bewertung der Erreichbarkeit von Grünflächen genutzt wurde (XING et al. 2018; ZHANG et al. 2022; SUN et al. 2023). Im Rahmen dieser Arbeit sollen die folgenden Fragen hinsichtlich der Erreichbarkeit von Grünflächen in Bonn beantwortet werden:

- 1) Erreichbarkeit von Grünflächen in Bonn
  - a) Wie stellt sich die Erreichbarkeit von Grünflächen in Bonn dar und wie ist diese räumlich differenziert?
  - b) Wodurch zeichnet sich das räumliche Netzwerk von Grünflächenangebot und -nachfrage in Bonn aus?
  - c) Wie sind die Projekte der Stadt Bonn vor dem Hintergrund der Ergebnisse dieser Untersuchung zu bewerten?

Für die Quantifizierung der Versorgung mit Grünflächen findet man in der Literatur zahlreiche Methoden (EKKEKEL & VRIES 2017). Verschiedene Studien beschäftigen sich mit den Vorteilen der unterschiedlichen Methoden und arbeiten an deren Verbesserung (WANG 2012; CHEN & JIA 2019; WANG et al. 2021). Diese Arbeit soll dazu beitragen, die methodische Analyse der Erreichbarkeit von Grünflächen weiterzuentwickeln. Dazu soll die von WOLFF (2021) entwickelte Methodik angewendet und getestet werden. Hier wird die Erreichbarkeit von Grünflächen als Netzwerk aus Angebot und Nachfrage verstanden, welches visualisiert und mittels graphentheoretischer Maße analysiert werden kann. Zudem wurde, wie bei SALGADO et al. (2022), ein Community-Detection-Algorithmus eingesetzt, der die Identifikation von Subnetzwerken ermöglicht. Hinsichtlich der eingesetzten Methodik sollen die folgenden Fragen beantwortet werden:

- 2) Untersuchung der Erreichbarkeit von Grünflächen als Netzwerk
  - a) Welche Aussagekraft und welche Potenziale haben die von WOLFF (2021) vorgeschlagenen Indikatoren?
  - b) Eignet sich ein Community-Detection-Algorithmus für die weitere Untersuchung der Erreichbarkeit von Grünflächen im Rahmen einer Netzwerkanalyse?

Im ersten Teil dieser Arbeit werden zunächst grundlegende Konzepte wie Walkability und Accessibility eingeführt, welche im Kontext der Untersuchung der Erreichbarkeit von Grünflächen in urbanen Räumen eine Rolle spielen. Es wird erörtert, warum Grünflächen in Großstädten für den Menschen von Bedeutung sind und eine Einführung in die Graphentheorie, welche als Grundlage für die Netzwerkanalyse dient, gegeben. Anschließend wird das Untersuchungsgebiet Bonn vorgestellt, wobei besonders auf die Verfügbarkeit von Grünflächen und Projekte zur Entwicklung von Grünflächen in Bonn eingegangen wird. Danach werden die verwendeten Daten und Methoden detailliert vorgestellt. Im Mittelpunkt stehen dabei die 2SFCA-Analyse und die Netzwerkanalyse, die einen Community-Detection-Algorithmus umfasst. Zum Abschluss der Arbeit werden die Ergebnisse für die Stadt Bonn präsentiert und diskutiert, um die gestellten Untersuchungsfragen zu beantworten.

## 2. Theoretischer Hintergrund

### 2.1 Graphentheorie

Die Graphentheorie ist ein etablierter Teilbereich der Mathematik und hat in den Raumwissenschaften zunehmend an Bedeutung gewonnen, da viele Systeme aus den Raumwissenschaften als Netzwerk dargestellt werden können (PHILLIPS et al. 2015). Die Graphentheorie eignet sich insbesondere für den Umgang mit komplexen Sachverhalten und große Datensätze. PHILLIPS et al. (2015) behaupten, dass die Graphentheorie zum methodischen Standardrepertoire der Raumwissenschaften zählen sollte.

Ein Graph besteht aus Knoten und Kanten, die die Knoten miteinander verbinden und deren Beziehung zueinander darstellen (SAOUB 2021). Graphen können auf unterschiedliche Weise dargestellt werden, solange die Knoten und deren Verbindungen korrekt abgebildet bleiben. Entscheidend ist dabei die Topologie, also die Struktur der Verbindungen, während die räumliche Anordnung der Knoten keine Rolle spielt. Abbildung 1 zeigt verschiedene Darstellungsweisen desselben Graphen. In beiden Varianten bleibt die Struktur unverändert: Knoten a ist nur mit den Knoten b und c verbunden, während Knoten d ausschließlich Verbindungen zu den Knoten c und b aufweist. Ebenso stimmen die Verbindungen aller weiteren Knoten in den beiden Darstellungen überein.




Abbildung 1: Zwei unterschiedliche Darstellungen desselben Graphen (eigene Darstellung)

Es gibt außerdem zahlreiche spezielle Varianten von Graphen. Ungerichtete Graphen stellen symmetrische Beziehungen zwischen den Knoten dar, während gerichtete Graphen asymmetrische Beziehungen abbilden (SAOUB 2021). Bei gerichteten Graphen wird den Kanten eine Richtung zugewiesen, die die Wirkungsrichtung der Beziehung angibt. Gewichtete Graphen erweitern diese Darstellung, indem sie den Kanten Gewichte zuordnen, welche die Stärke der Beziehung beschreiben.

Eine besondere Form von Graphen sind bipartite Graphen, die dazu dienen, verschiedene Arten von Objekten darzustellen (SAOUB 2021). Die Knoten unterscheiden sich in ihrer Art und lassen sich in zwei unterschiedliche Mengen einteilen. Verbindungen sind hierbei nur zwischen Knoten verschiedener Mengen möglich, nicht jedoch zwischen Knoten derselben Art.

Eine besondere Rolle nehmen in dieser Arbeit räumliche Graphen ein. Während bei gewöhnlichen Graphen räumliche Daten vernachlässigt werden und in einem abstrakten Raum vorliegen, enthalten räumliche Graphen auch die Koordinaten der Knoten (BARTHÉLEMY 2022). Diese Graphen enthalten demnach Informationen, die über die reine Topologie hinausgehen. Solche Graphen sind häufig sehr groß und müssen mittels statistischer Verfahren untersucht werden, um Informationen aus ihnen zu gewinnen. Abbildung 2 zeigt zwei Graphen, die dieselben topologischen Eigenschaften aufweisen, sich jedoch in ihren zugrunde liegenden räumlichen Daten unterscheiden. So ist Knoten a mit den Knoten b und c verbunden, während Knoten e nur mit Knoten d verbunden ist. Auch alle anderen Verbindungen stimmen in beiden Graphen überein. Wären diese beiden Graphen nicht-räumliche Graphen, wären sie identisch. Bei räumlichen Graphen hingegen wird die Anordnung der Knoten und Kanten durch die zugrunde liegenden Geodaten bestimmt, wodurch sie sich klar voneinander unterscheiden. Hier spielt die räumliche Anordnung eine entscheidende Rolle.




Abbildung 2: Zwei topologische identische Graphen mit unterschiedlichen räumlichen Attributen (eigene Darstellung)

Straßennetzwerke können auch als räumliche Graphen dargestellt werden (BARTHÉLEMY 2022). Straßennetzwerken wird dabei häufig noch eine zusätzliche Eigenschaft zugeschrieben – die Planarität. Ein Graph ist dann planar, wenn es keine Darstellung des Netzwerks gibt bei dem sich die Kanten nicht kreuzen (DIESTEL 2017). Brücken und Unterführungen können dazu führen, dass ein räumlicher Graph nicht planar ist. In der Praxis lässt sich dies jedoch oft vernachlässigen, da in solchen Fällen meist eine Verbindung zur entsprechenden Straße besteht und der Umweg, um diese zu erreichen, im Verhältnis zur Gesamtgröße des Netzwerks relativ gering ist.

Für die Untersuchung von Graphen gibt es zahlreiche Indikatoren und statistische Verfahren (BARTHÉLEMY 2022). Ein einfacher Indikator ist der Grad eines Knotens, der die Anzahl der von einem Knoten ausgehenden Kanten angibt (TITTMANN 2021). In Abbildung 2 ist Knoten e lediglich mit Knoten d verbunden und hat daher den Grad 1. Knoten a hingegen hat den Grad 2, während Knoten b den Grad 3 aufweist. Ein weiteres bekanntes Maß, welches zur Untersuchung der Zentralität eines Knotens dient, ist die *betweenness centrality* (BARTHÉLEMY 2022). Sie zeigt an, welche Knoten und Kanten im Netzwerk besonders wichtig sind. Die *betweenness centrality* eines Knotens wird berechnet, indem gezählt wird, wie viele der kürzesten Wege im gesamten Netzwerk durch diesen Knoten verlaufen. Darüber hinaus gibt es eine Vielzahl weiterer Maße und Methoden, die zur Analyse von Graphen verwendet werden und ganz andere Charakteristika versuchen zu beschreiben.

## 2.2 Bedeutung von Grünflächen für den Menschen

Grünflächen in der Stadt sind aufgrund einer Vielzahl von Gründen positiv zu bewerten und können durch ganz unterschiedliche Mechanismen einen positiven Einfluss auf die menschliche Gesundheit haben (THOMPSON et al. 2016). Diese Mechanismen wirken jedoch nicht isoliert, sondern sind miteinander verbunden und beeinflussen sich gegenseitig.

MAAS et al. (2009) bestätigt, dass die Rolle von Grünflächen sehr wichtig für die Gesundheit ist. Es hat sich gezeigt, dass die Befunde über den wahrgenommenen physischen und mentalen Gesundheitszustand durch untersuchte Gesundheitsparameter, wie Blutdruck, Rücken- oder Nackenschmerzen, Depressionen, Migräne und andere Symptome, bestätigt werden konnten. Besondere Unterschiede im Gesundheitszustand in Abhängigkeit von Grünflächen wurden bei Gruppen festgestellt, die Kinder, Menschen mit niedrigem sozioökonomischem Status und Menschen zwischen 45 und 65 Jahren umfassten. Außerdem wurde festgestellt, dass physische Aktivität in natürlichen Umgebungen, insbesondere in Wäldern und Parks, einen positiven Effekt auf die psychische Gesundheit hat (MITCHELL 2013). MITCHELL & POPHAM (2007) konnten feststellen, dass Gesundheit und Grünflächenanteil miteinander korrelieren. Allerdings zeigte sich, dass dieser Zusammenhang in Gebieten mit hohem Einkommen weniger ausgeprägt ist. Es wird vermutet, dass diese Menschen bereits eigene Möglichkeiten zur Naturerfahrung besitzen, etwa durch Gärten. In einigen Gegenden mit niedrigem Einkommen und hohem Grünflächenanteil wurde sogar eine negative Assoziation mit der Gesundheit festgestellt. Es wird vermutet, dass auch die Qualität der Grünflächen dafür eine wichtige Rolle spielt.

Für ältere Menschen in Tokyo konnte festgestellt werden, dass der Zugang zu Grünflächen, unabhängig von Geschlecht oder sozioökonomischem Status, einen positiven Einfluss auf die Überlebensrate hat (TAKANO et al. 2002). TAKANO et al. (2002) kommen daher zu dem Schluss, dass insbesondere in sehr dicht besiedelten urbanen Räumen Parks und Grünflächen von hoher Bedeutung sind. In ihrer Untersuchung konnten VILLENEUVE et al. (2012) ebenfalls feststellen, dass eine höhere Anzahl an Grünflächen zu einer geringeren Sterblichkeit führt.

Außerdem führt physische Aktivität in Grünflächen zur Verbesserung der Fitness und zur Reduktion von Übergewicht. So wurde beobachtet, dass sich Kinder in grüneren Stadtteilen mehr bewegen, wobei andere Faktoren wie die Sicherheit möglicherweise ebenfalls eine Rolle spielen (ALMANZA et al. 2012). Auch DADVAND et al. (2014) stellen für Kinder fest, dass Parks und Wälder in der Umgebung mit einem geringeren BMI und weniger passiven Lebensstil verknüpft sind. Außerdem konnte festgestellt werden, dass Grünflächen unabhängig von sozioökonomischen Faktoren das Risiko für Typ-2 Diabetes reduzieren (ASTELL-BURT et al. 2014). Interessant ist, dass in dieser Studie nicht ein aktiverer Lebensstil und ein niedrigerer BMI als Ursache identifiziert werden konnten.

Es ist schwierig herauszufinden, über welche Mechanismen Grünflächen die Gesundheit von Menschen verbessern (MITCHELL & POPHAM 2008). Eine Studie aus den Niederlanden hat als wichtige Mediatoren, die die Auswirkungen grüner Umgebungen auf die Gesundheit betreffen, soziale Kohäsion und Stressreduktion identifiziert. (VRIES et al. 2013). Die physische Aktivität wurde als weniger wichtig erachtet. Stattdessen wird vermutet, dass die gesundheitlichen Vorteile hauptsächlich durch Stressreduktion oder soziale Interaktion anstatt durch körperliche Anstrengung bedingt sind. ULRICH et al. (1991) konnten feststellen, dass die Exposition gegenüber naturnahen Umgebungen im Vergleich zu urbanen Umgebungen erheblichen Einfluss auf Stress haben kann. Gerade die Erholung von Stress kann durch das Erleben von Natur stark verbessert werden. Außerdem wurde beobachtet, dass Grünflächen unabhängig von reduziertem Stress zu einer gesünderen Schlafdauer beitragen (ASTELL-BURT et al. 2013).

Bäume im urbanen Umfeld können einen positiven Einfluss auf die Gesundheit haben, indem sie dazu beitragen, die Luftqualität zu verbessern (NOWAK et al. 2006). So werden Schadstoffe, wie Ozon oder Kohlenstoffmonoxid, aus der Luft gefiltert. Steigende Temperaturen und das Risiko von Hitzewellen sind eine große Gefahr für die öffentliche Gesundheit (BOWLER et al. 2010). In Studien wurde gezeigt, dass ein Park durchschnittlich 1 Grad Celsius kühler ist als andere Flächen (BOWLER et al. 2010). Große Parks und Bäume, die Schatten spenden, haben einen positiven Einfluss auf die Temperaturen.

In einigen Studien konnte auch festgestellt werden, dass Parks über ihre unmittelbaren Grenzen hinaus einen kühlenden Effekt haben. TAYLOR et al. (2015) haben festgestellt, dass städtische Wärmeinseln Einfluss auf die räumliche Variation der Todesfälle während Hitzewellen haben. Angesichts der steigenden Urbanisierung und steigenden Temperaturen kann davon ausgegangen werden, dass der Effekt von Wärmeinseln hinsichtlich Mortalität noch wichtiger wird.

MAAS et al. (2009) konnten feststellen, dass nahegelegene Grünflächen in weniger als 1 km Entfernung wichtiger sind, als weiter entfernte Grünflächen. Außerdem haben SUGIYAMA et al. (2010) festgestellt, dass weniger die Anzahl der verfügbaren Grünflächen eine Rolle spielt, sondern vielmehr die Qualität der Grünflächen – wie Größe, Attraktivität und Begrünung.

## 2.3 Die Bewegung von Fußgängern in der Stadt

### 2.3.1 Walkability

Walkability ist ein interdisziplinäres Forschungsfeld, das weitere Untersuchungen erfordert und von besonderer Bedeutung ist, um die Mobilität in urbanen Räumen zu verstehen (LO 2009). Attribute, die in der Literatur mit Walkability in Zusammenhang gebracht werden, sind zusammenhängende und qualitativ hochwertige Fußgängerwege, geringe Umwege im Straßennetzwerk, die Trennung von Fußwegen und Straßen, Begrünung sowie funktionale Mischung und einige weitere Aspekte.

EWING & HANDY (2009) betonen, dass Walkability stark durch die eigene Wahrnehmung bestimmt wird. Diese vermittelt zwischen der physischen Umwelt, der urbanen Gestaltung und dem Gehverhalten. Die urbane Gestaltung beschreibt das Design der physischen Umwelt in Form von Größe, Proportion und Anordnung. EWING & HANDY (2009) behaupten, dass diese Maße über funktionale Mischung und Dichte hinausgehen und somit zusätzliche Erkenntnisse liefern können.

DOVEY & PAFKA (2020) definieren Walkability als die Qualität eines Stadtteils, die durch drei Dimensionen bestimmt wird: die Dichte von Personen und Gebäuden, funktionale Mischung und Netzwerke, die Zugang zu diesen Funktionen ermöglichen. Sie gehen davon aus, dass diese drei Faktoren miteinander verbunden sind und nicht isoliert betrachtet werden können.

Sie verstehen Walkability als mehr als die Summe seiner Teile, was die Messung in Form von Indizes erschwert. Sie betonen, dass Walkability eine Eigenschaft der Stadt ist und nicht direkt aus der Bewegung von Fußgängern abgeleitet werden sollte, da Gehen nicht direkt aus der Walkability resultiert, sondern sie lediglich ermöglicht oder erleichtert.

Da Dichte ein zentrales Merkmal von Walkability ist, existieren zahlreiche Indizes, die versuchen, Dichte zu quantifizieren (DROIN et al. 2023). Um den Zusammenhang zwischen gemessener und wahrgenommener Dichte zu verbessern, haben DROIN et al. (2023) das Konzept der *individual walkable neighbourhood* (IWN) eingeführt. Die IWN wird ausgehend von einem zentralen Ausgangspunkt definiert und basiert auf der Netzwerkdistanz. Sie umfasst alle Straßenabschnitte, deren Netzwerkdistanz vom Ausgangspunkt einen festgelegten Schwellenwert nicht überschreitet. Auf Grundlage dieser individuell definierten Fläche lassen sich städtebauliche Kennzahlen wie die *floor area ratio* (FAR) berechnen. Dieser Ansatz orientiert sich an der individuellen Umgebung des Punktes, anstatt auf willkürlich festgelegte administrative Grenzen zurückzugreifen. Dadurch können starke Dichteunterschiede, die häufig bereits in unmittelbarer Nähe vorliegen können, präzise berücksichtigt werden.

DROIN et al. (2024) nutzen das Konzept der IWN außerdem, um die Durchlässigkeit der Umgebung für Fußgänger zu quantifizieren. Dazu setzen sie die Fläche der IWN ins Verhältnis zu einem Puffer mit demselben Schwellenwert. Die Ergebnisse zeigen, dass die fußläufige Durchquerbarkeit in Stadtkernen tendenziell höher ist als in den Randgebieten. Physische Barrieren wie Eisenbahnstrecken, Autobahnen oder steiles Gelände können die Permeabilität zudem erheblich einschränken.



### 2.3.2 Wie weit gehen Menschen?

Welche Schwellenwerte für die Distanz zu Grünflächen angenommen werden, haben großen Einfluss auf die Ergebnisse (DAI 2010; SHI et al. 2012). Trotzdem gibt es in der Literatur keine eindeutig festgelegten und fundierten Schwellenwerte für die Distanz, die zu Fuß gegangen wird (AHMED et al. 2023). Es werden verschiedene Schwellenwerte zwischen 300m und 1000m verwendet.

Die Distanz, die Menschen bereit sind zu Fuß zu gehen, wird durch verschiedene Faktoren beeinflusst und variiert je nach Situation (SCHINDLER et al. 2022; HOOK 2024). Eine Studie aus den Niederlanden hat untersucht, wie Menschen verschiedene Verkehrsmittel nutzen – zu Fuß oder mit dem Fahrrad – für verschiedene Ziele und Aktivitäten und wie sich dabei die zurückgelegten Entfernungen zwischen unterschiedlichen Zielorten und -aktivitäten unterscheiden (SCHNEIDER et al. 2018). Es wurde festgestellt, dass die meisten Strecken, die zu Fuß zurückgelegt wurden, für Einkäufe, Besuche oder Erholung genutzt werden. Die zurückgelegte Distanz variierte nur geringfügig zwischen den unterschiedlichen Zielen.

HOOK (2024) konnte Faktoren identifizieren, die das Gehen von langen Distanzen beeinflussen. So können zum Beispiel externe Einflüsse wie spezifische Wetterbedingungen, Sorgen um Verkehrssicherheit oder Kriminalität die Bereitschaft dazu verringern, lange Strecken zu Fuß zurückzulegen. Auch die Bedingungen der Route selbst, wie zum Beispiel Zeitdruck, das Reiseziel oder Transportgüter spielen eine Rolle. Persönliche Faktoren, wie der Gesundheitszustand, können ebenfalls einen Einfluss haben. Auch AHMED et al. (2023) weist darauf hin, dass individuelle Unterschiede in der Bereitschaft und Fähigkeit bestehen, lange Distanzen zurückzulegen. SCHINDLER et al. (2022) konnten außerdem noch weitere Merkmale identifizieren, die Einfluss auf die zurückgelegte Distanz haben. Ein höherer Bildungsgrad war mit kürzeren zurückgelegten Strecken verbunden. Auch das Alter hatte Einfluss auf die zurückgelegten Distanzen – dabei wurden längere Strecken vor allem von Personen im Alter zwischen 25 und 55 Jahren zurückgelegt (SCHINDLER et al. 2022).

Ein weiterer Aspekt ist das Einschätzen von Gehzeiten. RALPH et al (2020) haben beobachtet, dass diese häufig zu hoch eingeschätzt werden und Menschen dadurch weniger zu Fuß gehen. Entfernungen werden oft größer eingeschätzt, wenn die Strecke durch Barrieren oder zahlreiche Richtungsänderungen unterbrochen wird.

Zahlreiche Studien haben untersucht, welche Entfernungen Menschen bereit sind zu Fuß zurückzulegen (SCHINDLER et al. 2022; HOOK 2024). HOOK (2024) nimmt an, dass Reisezeit eine besser geeignete Metrik ist, um die Entfernung einer Reise zu messen. Auf Grundlage von Twitter-Daten wurde untersucht, ob eine Gehzeit von 23 Minuten als akzeptabel angesehen wird. Die Ergebnisse zeigten, dass die Mehrheit diese Dauer als angemessen empfindet. Allerdings wurde auch deutlich, dass dies eher das obere Limit der akzeptierten Gehzeit darstellt. Zudem beeinflusst eine Vielzahl von Faktoren, ob Menschen bereit sind, diese Strecke tatsächlich zurückzulegen. Im Zusammenhang mit Grünflächen wurde untersucht, welche Entfernungen Menschen in vier europäischen Städten zurücklegen, um Grünflächen zu erreichen (SCHINDLER et al. 2022). Die Ergebnisse zeigen, dass Menschen bereit sind zwischen 1400 und 1900 Metern zurückzulegen. Dabei wurde jedoch nicht berücksichtigt, welches Transportmittel genutzt wurde. Für einen Park in Bukarest wurde außerdem untersucht, wie viele Besucher aus welchem Umkreis des Parks kommen (STOIA et al. 2022). Nur wenige Besucher des untersuchten Parks stammten aus der unmittelbaren 5-Minuten-Umgebung. Die Mehrheit kam aus Gebieten, die 10 bis 15 Minuten entfernt lagen. Im Kontext des Schulwegs wurde untersucht, wie weit Kinder bereit sind, zu Fuß zur Schule zu gehen. Die Ergebnisse zeigten, dass Jugendliche bereit sind, längere Strecken zurückzulegen als jüngere Kinder. Während Kinder Distanzen von bis zu 875 Metern bewältigen, sind Jugendliche bereit, Strecken von bis zu 1350 Metern zu gehen (RODRÍGUEZ-LÓPEZ et al. 2017).

Außerdem wurden Untersuchungen durchgeführt, um herauszufinden welche Schwellenwerte gute Ergebnisse im Zusammenhang mit gesundheitlichen Effekten von Grünflächen liefern. CARDINALI et al. (2024) liefern sehr differenzierte Ergebnisse bezüglich der Nutzung bestimmter Schwellenwerte und Indikatoren. Während zur Einschätzung der physischen Aktivität eher Accessibility-Indikatoren geeignet sein sollen, sollen für die Einschätzung direkter Gesundheitsvorteile andere Indikatoren genutzt werden. CARDINALI et al. (2024) empfehlen für die Nutzung von Accessibility-Indikatoren im Kontext physischer Aktivität einen Schwellenwert von 800 m. Für Puffer-Analysen haben BROWNING & LEE (2017) festgestellt, dass sich Puffergrößen zwischen 500 m und 999 m eignen, wenn Hausadressen als Mittelpunkte genutzt werden.

Basierend auf diesen Ergebnissen wurde in dieser Arbeit ein Schwellenwert von 1000 m ausgewählt. Dieser befindet sich am oberen Ende der Schwellenwerte, die in anderen Arbeiten eingesetzt wurden (AHMED et al. 2023). Dies deckt sich mit zahlreichen anderen Arbeiten, die belegen, dass ein höherer Schwellenwert geeignet ist.

## 2.4 Das Konzept der Accessibility

In dieser Arbeit wird unter Erreichbarkeit der weit verbreitete Begriff Accessibility aus der englischsprachigen Literatur verstanden. Dieser Begriff hat in den Bereichen der Geographie, Planung und des Gesundheitswesens eine hohe Relevanz erlangt (INGRAM 1971; BATTY 2009). Der Begriff Accessibility wird jedoch häufig auch synonym mit Access oder Availability verwendet und konnte lange nicht klar gefasst werden (FRENK 1992).

BATTY (2009) weist darauf hin, dass bei der Definition von Accessibility der Maßstab und der Untersuchungsgegenstand eine große Rolle spielt und unterscheidet daher zwischen drei verschiedenen Perspektiven auf Accessibility. Der erste Typ beschreibt, wie nah ein Individuum an einer Ressource ist und legt den Fokus auf das Verhalten der Bevölkerung. In diesem Ansatz werden die physischen Strukturen eher nebensächlich betrachtet und nur implizit miteinbezogen. Dieser Ansatz ähnelt der Definition in einer der ersten grundlegenden Arbeiten, die den Begriff Accessibility geprägt haben, in welcher HANSEN (1959) den Begriff im Zusammenhang mit der räumlichen Entwicklung von Städten nutzt. So soll das Entwicklungspotenzial einer Region von seiner Accessibility mitbestimmt werden. HANSEN (1959) definiert Accessibility als die Intensität der potenziellen Interaktion mit einer Ressource. Accessibility soll unter Einbezug des Verhaltens der Nachfrager beschreiben, wie gut eine Ressource von einem bestimmten Ort aus erreichbar ist. Demnach ist die Accessibility an einem Ort die Summe der Accessibility zu jedem einzelnen Angebotspunkt. Die Accessibility zu einem bestimmten Nachfrageort hängt vom Angebot am jeweiligen Standort ab und ist negativ verknüpft mit der Distanz zu diesem Ort.

Die zweite Perspektive auf Accessibility nimmt mehr die physische Nähe von Infrastrukturen in den Fokus (BATTY 2009). Das Verhalten von Personen spielt eher eine untergeordnete Rolle. Es wird angenommen, dass die Ressourcen überall gleich verteilt sind. Nach einer ähnlichen Definition arbeitet auch INGRAM (1971). Er bezeichnet die relative Accessibility als die Erreichbarkeit zwischen zwei Orten und die integrierte Accessibility als die Erreichbarkeit von einem Ort zu allen Angebotsorten. INGRAM (1971) versteht die Accessibility als eine Eigenschaft des Raums und verzichtet daher darauf die Angebotsverteilung miteinzubeziehen. Dieser Ansatz kann direkt auf einer Repräsentation des Straßennetzwerks als Graph umgesetzt werden, wobei Punkte Kreuzungen repräsentieren und die Straßen durch Kanten dargestellt werden. Die dritte Perspektive auf Accessibility, die BATTY (2009) definiert, fokussiert sich wie Typ 2 auf die physische Struktur des Netzwerks.

Im Unterschied werden jedoch die Straßen als Knoten definiert und die Kreuzungen, also Verbindungen zwischen den Straßen, als Kanten. Dieser Ansatz ist auch unter dem Namen *space syntax* bekannt.

FRENK (1992) definiert Accessibility als die Beziehung zwischen Angebot und Nachfrage und wie stark diese durch andere Faktoren beeinträchtigt wird. FRENK (1992) stellt fest, dass Autoren bei Accessibility unterschiedlich weite Domänen untersuchen. So fassen manche Autoren auch das Erkennen eines Bedürfnisses unter Accessibility. Je mehr solcher Faktoren in die Analyse einbezogen werden, desto näher komme das Konzept der Accessibility der tatsächlichen Nutzung. Der Begriff Access würde dabei oft eine weiter gefasste Domäne widerspiegeln. So bezeichnen LEVESQUE et al. (2013) Access als die Möglichkeit, auf eine Ressource zuzugreifen, wenn ein wahrgenommener persönlicher Bedarf besteht. In dieser Definition werden neben persönlichen Merkmalen auch die physische und soziale Umgebung sowie die Eigenschaften des Angebots berücksichtigt.

FRENK (1992) definiert Accessibility mit einer enger gefassten Domäne. Accessibility soll also nur das Aufsuchen von einer Ressource umfassen. Dafür schlägt er folgende Terminologie vor: Availability beschreibt das physische Angebot. Da jedoch nicht immer alle Ressourcen genutzt werden, beschreibt der zusätzliche Faktor Resistance den Widerstand, der überwunden werden muss, um eine Ressource zu erreichen. Aus der Kombination von Resistance und Availability ergibt sich dann Effective-Availability. Diese Konzepte beziehen sich auf die Ressourcen. Die Utilization-Power beschreibt nun die Nachfrageseite und deren Fähigkeit, den Widerstand zu überwinden. Laut FRENK (1992) ist die Accessibility der Grad der Anpassung zwischen Angebot und Nachfrage. Demnach kann Accessibility als die Beziehung zwischen Utilization-Power und Resistance verstanden werden, da die zu überwindenden Widerstände stets im Kontext der Eigenschaften der Bevölkerung betrachtet werden müssen. Auch WEIGAND et al. (2023) heben den Unterschied zwischen Availability und Accessibility hervor. Sie argumentieren, dass die bloße Verfügbarkeit von Grünflächen (Availability) nicht automatisch bedeutet, dass diese auch für alle zugänglich (Accessibility) sind. Der Schwerpunkt liegt hierbei jedoch auf der Unterscheidung zwischen verschiedenen Arten von Grünflächen und ihrer Zugänglichkeit, ob sie privat oder öffentlich sind.

Die Untersuchungen dieser Arbeit fügen sich nahtlos in die zugrunde liegenden theoretischen Konzepte ein, da sie sich eingehend mit der Beziehung zwischen Angebot und Nachfrage auseinandersetzen. Wenn die Distanz als Widerstand betrachtet wird, so wird die Utilization-Power durch den Schwellenwert von 1000 m und die Gauß-Funktion abgebildet.

Zudem werden in die Untersuchung ausschließlich Grünflächen einbezogen, die öffentlich zugänglich sind, wie zum Beispiel Parks, Wälder oder Spielplätze. Die Definition, wie sie FRENK (1992) vorschlägt, bietet außerdem ein gutes Fundament zur Weiterentwicklung der Methodik bezüglich der Bevölkerungscharakteristika und deren Utilization-Power.

### 3. Das Untersuchungsgebiet

Die Bundesstadt Bonn befindet sich im südlichen Teil der niederrheinischen Tieflandbucht und wird rechtsrheinisch vom Siebengebirge und linksrheinisch von den Nieder- und Mittelterrassen sowie der Hauptterrasse des Rheins begrenzt (SCHÄFFER & ERDMANN 2013). Im Jahr 2022 ist die Bevölkerung Bonns um 2.421 Personen auf insgesamt 338.396 Personen gestiegen (BUNDESTADT BONN 2023). Von diesen haben 107.723 Personen einen Zuwanderungshintergrund, was einem Bevölkerungsanteil von 31,8 Prozent entspricht. Seit dem Vorjahr stieg der Anteil der Personen mit Zuwanderungshintergrund um 1,2 Prozentpunkte.

SCHÄFFER & ERDMANN (2015) zu Folge wurde Bonn zu Hauptstadtzeiten als grünste Hauptstadt Europas bezeichnet. Das Bonner Stadtgebiet umfasst insgesamt 141,22 km<sup>2</sup>, von denen 77,7 km<sup>2</sup>, also ca. 55 %, Freiflächen sind. Dabei sind der Rhein und die Sieg mit ihren zugehörigen Bachsystemen die größten Wasserflächen in Bonn (SCHÄFFER & ERDMANN 2013). Wichtige landwirtschaftlich genutzte Freiräume befinden sich in den Außenbereichen des Stadtgebiets (BUNDESTADT BONN 2018). Im Süden Bonns prägen Obstkulturen das Landschaftsbild, darunter auch der Anbau von Tafeltrauben. Im Norden und am östlichen Rand der Stadt dominieren landwirtschaftliche Flächen, auf denen vorwiegend Marktfrüchte angebaut werden. Das Meßdorfer Feld ist eine der wenigen erhaltenen landwirtschaftlichen Flächen innerhalb des Stadtgebiets und spielt eine bedeutende Rolle als Erholungsraum für die Bevölkerung. Etwa 50 % des Stadtgebiets stehen seit 2015 unverändert unter Schutz, wobei die Schutzgebiete nahezu gleichmäßig auf Naturschutzgebiete und Landschaftsschutzgebiete verteilt sind. In den Wäldern hat der Laubbaumbestand zwischen 2006 und 2017 um 3,7 % zugenommen. Dabei sind die Bonner Waldflächen überwiegend von Eichen-, Buchen- und Winterlindenwäldern geprägt (SCHÄFFER & ERDMANN 2013). Rechnerisch lagen 2018 die Erholungsflächen pro Einwohner bei 155,3 m<sup>2</sup> außerhalb von Siedlungsgebieten und, 24,9 m<sup>2</sup> innerhalb von Siedlungsflächen (BUNDESTADT BONN 2020).

Die Stadt Bonn ist gekennzeichnet durch ihre lange Geschichte (ROCH et al. 2010). Insbesondere die Funktion als Residenzstadt und die Lage am Rhein prägen das Stadtbild und die Erreichbarkeit von Grünflächen. Aber auch der weitläufige Rheinauenpark spielt eine große Rolle für die Grünflächenversorgung in der Stadt. Diese abwechslungsreiche Gestalt der Umwelt ist kennzeichnend für die Bonner Freiraumqualität. Die Bonner Südstadt ist durchgrünt durch ihre Lage zum Alten Zoll, zum Hofgarten, der Poppelsdorfer Allee und zum Baumschulwäldchen (ROCH et al. 2010). Durch PTOCK (2016) wurde die Bedeutung der innerstädtischen Grünflächen in Bonn umfassend untersucht. Alle analysierten Standorte – der Hofgarten, die Poppelsdorfer Allee, das Poppelsdorfer Schloss und der Botanische Garten – zeichnen sich durch eine hohe Qualität aus. Besonders hervorgehoben wird der Botanische Garten. Darüber hinaus hat sich gezeigt, dass die Grünflächen im Stadtbezirk Bonn gut miteinander vernetzt sind (PTOCK 2016). Die Erreichbarkeit dieser Grünflächen erstreckt sich bis in die Innenstadt (ROCH et al. 2010). Die Ortsteile Ippendorf und Tannenbusch sind gut begrünt (ROCH et al. 2010). In Tannenbusch stehen öffentliche Grünflächen für den sozialen Austausch in ausreichendem Maße zur Verfügung, während es in Ippendorf an solchen Flächen mangelt. Ippendorf zeichnet sich jedoch durch seine besondere Lagequalität am Naturpark Kottenforst aus, der erhöht über dem Stadtzentrum liegt.

Bei der Entwicklung neuer Baugebiete werden durch die Stadt Bonn regelmäßig Grün- und Erholungsflächen mitgeplant (BUNDESTADT BONN 2020). Verschiedene Projekte wie zum Beispiel das „Grüne C“, welches im Rahmen der „Regionalen 2010“ entwickelt wurde, sollen die Qualität und die Konnektivität der Freiräume in Bonn und dem Umland verbessern (REGIONALE 2010-AGENTUR 2012; WACHTEN et al. 2012). Das „Grüne C“ soll das empfindliche Freiraumnetz am Nordrand von Bonn, das durch die Ausweitung von Siedlungsflächen gefährdet ist, schützen (REGIONALE 2010-AGENTUR 2012). Dieser grüne Korridor verbindet über den Rhein hinweg den Kottenforst, Waldville, die Rheinaue, die Siegmündung, das Siebengebirge sowie das Pleiser Hügelland. Zusätzlich werden auch im angrenzenden Königswinter durch andere Projekte Attraktionen, wie die Klosterlandschaft Heisterbach oder der Drachenfels noch attraktiver gestaltet.

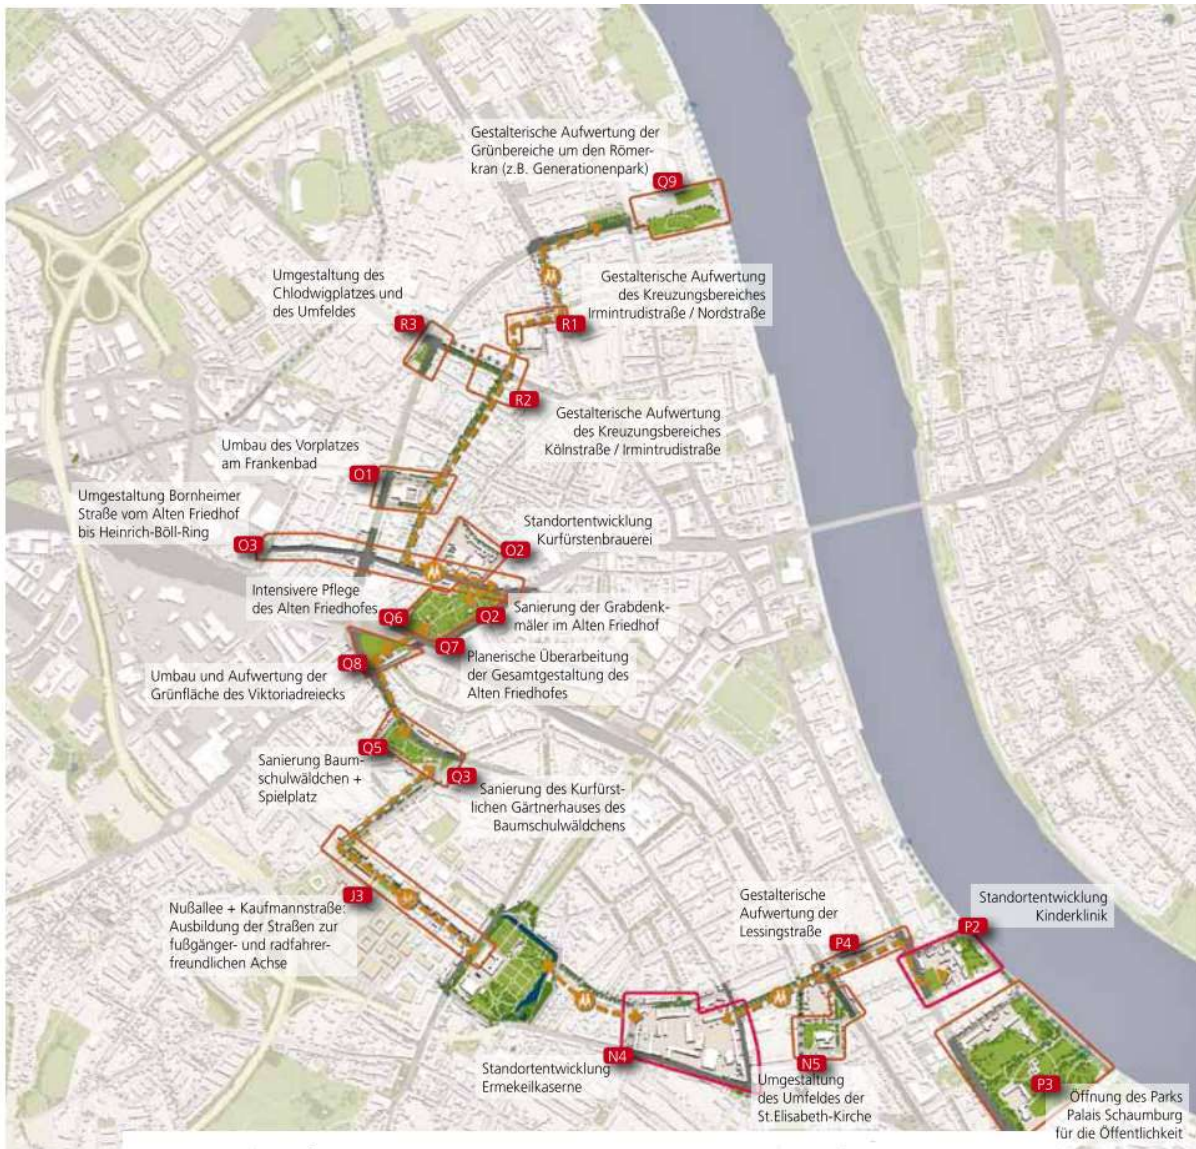


Abbildung 3: Entwicklungsmaßnahmen des Masterplans „Innere Stadt“ Bonn im Rahmen des Leitmotivs „Grüne Trittsteine“

Ein weiteres Mittel, welches die Entwicklung des Grünflächenangebots in der Stadt Bonn beeinflusst, ist der Masterplan „Innere Stadt“ Bonn. Um die Wettbewerbsfähigkeit der Stadt Bonn zu erhalten und der wachsenden Bedeutung innerstädtischer Räume gerecht zu werden, soll die Innenstadt Bonns gestärkt werden. Der Masterplan „Innere Stadt“ ist durch drei Leitmotive geprägt: das „Urbane C“, die „Bonner Promenaden“ und die „Grünen Trittsteine“. Das „Urbane C“ soll wichtige öffentliche Räume miteinander verbinden, während die „Bonner Promenaden“ das Motiv der Poppelsdorfer Allee aufgreifen und weiterführen sollen. Durch die „Bonner Promenaden“ soll „ein Promenaden-Geviert, das den Rhein innerstädtisch erschließt“ entstehen (WACHTEN et al. 2012, S. 7).

Das letzte Motiv, „Grüne Trittsteine“, soll Grün- und Freiräume miteinander verknüpfen, indem auch weniger beachtete und kleinere Grünflächen miteinbezogen werden. Abbildung 3 zeigt die Entwicklungsmaßnahmen, die im Rahmen des Leitmotivs „Grüne Trittsteine“ des Masterplans „Innere Stadt“ ergriffen werden sollen. Die bereits bestehenden Grünflächen, die von hoher Relevanz für die Versorgung der Innenstadt sind, wie der Hofgarten, die Poppelsdorfer Allee und der Alte Zoll, werden zunächst außen vorgelassen. Stattdessen sollen weniger beachtete umliegende Grünflächen miteinbezogen werden. Dazu gehören beispielsweise die Umgestaltung des Chlodwigplatzes in der Nordstadt, des Alten Friedhofs und des Baumschulwäldchens sowie das Umfeld der St. Elisabeth Kirche in der Südstadt und des Parks Palais Schaumburg. Damit werden vorwiegend die Ortsteile Bonn-Castell, die Nordstadt, Weststadt, Südstadt und Gronau in den Fokus der Entwicklung gezogen.

## 4. Daten und Methodik

Im ersten Teil dieser Arbeit wird die Erreichbarkeit von innerstädtischen Grünflächen in deutschen Großstädten am Beispiel Bonn untersucht. Die Berechnung der Erreichbarkeit erfolgt mittels einer etablierten Methode. Die 2SFCA-Analyse wird in vielen aktuellen Studien zur Abschätzung der Erreichbarkeit innerstädtischer Grünflächen genutzt (XING et al. 2018; XING et al. 2020; ZHANG et al. 2022). Grundlage für die Berechnung der Distanzen ist dabei die Netzwerkdistanz, da diese die Distanz zwischen zwei Punkten besser abbildet (XING et al. 2020; ZHANG et al. 2022). Für die Berechnung der Distanzen werden Start- und Zielpunkte benötigt. Gebäude werden dabei durch ihre geometrischen Schwerpunkte repräsentiert, während für Grünflächen die Zugänge als Zielpunkte herangezogen werden. Die Repräsentation der Grünflächen durch ihre Zugänge wird in der Arbeit von WANG et al. (2021) vorgeschlagen. Auf Grundlage der Ergebnisse aus Kapitel 3.4 wurde der Schwellenwert von 1000 m festgelegt.

Der zweite Teil der Arbeit widmet sich der Erprobung des Verfahrens nach WOLFF et al. (2021). Dabei werden Grünflächen und Wohngebäude als Netzwerk aus Angebot und Nachfrage verstanden. Dieses Netzwerk kann als Graph dargestellt werden und mittels unterschiedlicher Indikatoren untersucht werden. Dieses Verfahren soll zusätzliche Einblicke in die Beziehung zwischen dem Angebot und der Nachfrage von Grünflächen ermöglichen. SALGADO et al. (2022) nutzen die Graphentheorie, um innerstädtische Grünflächen und deren Nutzung zu untersuchen. Ein Community-Detection-Algorithmus soll dabei Gruppen von Parks und Nutzern identifizieren, die eine Tendenz aufweisen, dieselben Orte zu besuchen. Diese Methode soll die von WOLFF (2021) vorgeschlagenen Indikatoren ergänzen.



Die folgenden Kapitel stellen die Datengrundlage und deren Aufbereitung sowie die verwendeten Methoden und deren Implementierung im Detail vor.

## 4.1 Daten

Als Datengrundlage dienten frei verfügbare Geodaten, darunter „OpenStreetMap“ (OSM)-Daten, die über „Geofabrik“ ([www.geofabrik.de](http://www.geofabrik.de)) heruntergeladen wurden. Aus diesen Daten wurden das Straßennetzwerk sowie die Gebäudegrundrisse extrahiert. Informationen zu Grünflächen stammten aus den „Urban Atlas“ Landbedeckungs-Daten ([land.copernicus.eu/en/products/urban-atlas](http://land.copernicus.eu/en/products/urban-atlas)), während Bevölkerungsdaten aus dem Zensus 2022 ([www.zensus2022.de](http://www.zensus2022.de)) genutzt wurden. Ergänzend wurden Daten zu den administrativen Grenzen des Stadtgebiets von Bonn über das Datenportal der Stadt ([opendata.bonn.de](http://opendata.bonn.de)) bezogen. Die Datenaufbereitung erfolgte in QGIS, wobei vorwiegend native Methoden zum Einsatz kamen, ergänzt durch einige spezifische Plug-Ins.

### 4.1.1 Ausgangsdaten

Bei „OpenStreetMap“ handelt es sich um ein partizipatives Geoinformationssystem (GIS) (CURRAN et al. 2012). Internetnutzer können hier räumliche Daten hinzufügen, bearbeiten und einsehen. GOODCHILD (2007) prägte für diese Form von GIS den Begriff *volunteered geographic information* (VGI). Bei OSM handelt es sich um das bekannteste dieser VGI mit den meisten Nutzern und Daten (MOONEY & MINGHINI 2017). 2016 gab es über 2,7 Millionen registrierte Nutzer. Laut GOODCHILD (2007) handelt es sich hierbei um eine Innovation, die großen Einfluss auf die Geographie und GIS haben wird. Auch NEIS & ZIELSTRA (2014) kommen zu dem Schluss, dass das Interesse an VGI sowohl in der Öffentlichkeit als auch in der Wissenschaft hoch ist. Wichtige Forschungsfelder umfassen dabei die Qualität der Daten und die Nutzercommunity. Zudem hat sich gezeigt, dass OSM-Daten ein breites Anwendungsfeld besitzen.

Die Qualität der OSM-Daten ist für die Nutzung dieser Daten von hoher Bedeutung. Es ist jedoch schwierig die Datenqualität zu quantifizieren und zu bewerten, weshalb je nach Anwendungsfall entschieden werden muss, ob sich OSM-Daten eignen (MOONEY & MINGHINI 2017). Grundsätzlich konnte festgestellt werden, dass die Datenqualität sehr heterogen ist (NEIS & ZIELSTRA 2014; DORN et al. 2015). So gibt es große Unterschiede zwischen unterschiedlichen Ländern sowie ländlichen und urbanen Räumen. Außerdem unterscheidet sich die Qualität der OSM-Daten auch zwischen den verschiedenen Klassen der Landbedeckungs-/Landnutzungs-klassifikation.

Dorn et al. (2015) haben die OSM-Daten mit Daten des Amtlich Topographisch-Kartographischen Informationssystems (ATKIS) verglichen und festgestellt, dass im Untersuchungsgebiet nur eine von 15 Klassen eine Vollständigkeit über 90 % aufwies und sechs von 15 Klassen eine Korrektheit über 90 %.

Demnach war OSM zu diesem Zeitpunkt nicht als Datengrundlage geeignet, wenn eine hohe Vollständigkeit und Korrektheit erforderlich waren. ZIELSTRA & ZIPF (2010) haben in Deutschland die relative Vollständigkeit sowie die Positionsgenauigkeit der Daten untersucht. Hier hat sich für urbane Räume eine hohe Positionsgenauigkeit ergeben. Auch HELBICH et al. (2012) bewerten die Positionsgenauigkeit bei „OpenStreetMap“ positiv. Besonders bei kleinen Straßen und Wegen, die für Fußgänger relevant sind, waren die Daten relativ vollständig (ZIELSTRA & ZIPF 2010). Während diese Studien überwiegend die räumlichen Qualitätsmerkmale untersuchten, wurde bei BILJECKI et al (2023) die Qualität der semantischen Gebäudeattribute überprüft. Für die meisten Gebäude sind nur Grundrisse und keine weiteren Daten verfügbar. Mit ca. 20 % der klassifizierten Gebäude ist der Gebäudetyp das am häufigsten genutzte Attribut. Auch hier wurde eine räumlich stark ungleichmäßige Verteilung festgestellt, wodurch in urbanen Gebieten eine ausreichende Abdeckung erzielt werden kann. Obwohl es keine festen Vorgaben für die Benennung gibt, konnte eine konstante und zuverlässige Benennung in OSM festgestellt werden.

„Urban Atlas“ ist ein Dienst der im Rahmen des Copernicus Programms der Europäischen Union (EU) zur Verfügung gestellt wird. Es handelt sich um eine Landbedeckungsklassifikation, die Städte in der EU, der Europäischen Freihandelsassoziation, im westlichen Balkan, Großbritannien und der Türkei mit mehr als 50.000 Einwohnern abdeckt (EUROPEAN COMMISSION 2020). Dabei werden nicht nur die administrativen Grenzen einer Stadt berücksichtigt, sondern auch das funktional verbundene Umland. Es werden alle angrenzenden Gemeinden miteinbezogen, in denen mindestens 15 % der erwerbstätigen Bevölkerung in der betreffenden Stadt arbeiten (DIJKSTRA & POELMAN 2012). Grundlage für die „Urban Atlas“-Daten sind hochauflösende Satellitendaten (EUROPEAN COMMISSION 2020). In urbanen Räumen wird eine Mindestgröße von 0,25 ha für Flächen vorgegeben, während in ländlichen oder suburbanen Bereichen eine Mindestgröße von 1 ha erforderlich ist. Die angegebene Klassifikationsgenauigkeit beträgt 85 % im urbanen Raum und 80 % im suburbanen Raum. Der Validierungsbericht zeigt, dass diese Anforderungen im Plausibilitätscheck mit 93,61 % im urbanen Raum und 86,64 % erfüllt wurden (WEGSCHEIDER et al. 2021).

Die Klassifikation basiert auf „CORINE Land Cover“, einem weiteren Dienst der EU (EUROPEAN COMMISSION 2020). Es werden die folgenden Gruppen unterschieden: Künstliche Oberflächen, Landwirtschaftliche Flächen, Natürliche Flächen, Feuchtgebiete und Gewässer. Diese Kategorien werden in weitere Untergruppen unterteilt. Die für die Arbeit relevanten Klassen sind urbane Grünflächen und Wälder. Urbane Grünflächen umfassen Spielplätze, Parks oder Zoos. Auch Wälder werden als urbane Grünflächen kartiert, wenn sie mindestens an zwei Seiten an städtisches Gebiet grenzen. Gebäude innerhalb von Parks oder private Gärten werden jedoch nicht als urbane Grünflächen eingestuft. Der Kategorie Wald werden Gebiete zugeordnet, bei denen mehr als 30 % der Bodenfläche mit Baumkronen über 5 m Höhe bedeckt werden. Auch Baumschulen und Kahlschlagflächen fallen in diese Kategorie.

Beim „Zensus 2022“ handelt es sich um die aktuellste Erhebung der Bevölkerungszahl in Deutschland. Alle Personen, die mit alleinigem Wohnsitz oder Hauptwohnsitz meldepflichtig sind, sowie Angehörige der Bundeswehr, der Polizeibehörden oder des Auswärtigen Diensts und deren Familien (BRETSCHI et al. 2024) werden gezählt. Datengrundlage sind die Personendatensätze der Melderegister, die zunächst von Mehrfachfällen bereinigt werden müssen. Zur Korrektur der Daten werden zudem Vollerhebungen in Wohnheimen und Gemeinschaftsunterkünften durchgeführt. Für die restlichen Haushalte werden Stichprobenuntersuchungen eingesetzt. Ein systematisches Qualitätsmanagement, das den gesamten statistischen Produktionsprozess umfasst, soll sicherstellen, dass die Ergebnisse des „Zensus 2022“ höchsten Qualitätsansprüchen genügen (KLINK & LORENTZ 2022).

Die räumlichen Bevölkerungsdaten liegen als *comma-separated-values* (CSV) vor und enthalten die absoluten Bevölkerungszahlen in Gitterzellen mit einer Seitenlänge von 100 m (STATISTISCHE ÄMTER DES BUNDES UND DER LÄNDER 2024). Einwohner mit einem Aufenthaltsort außerhalb Deutschlands werden in diesen Daten nicht berücksichtigt. Nur die Gitterzellen, denen eine Bevölkerung zugewiesen wurde, sind im Datensatz enthalten. Ihre Lage wird durch die x- und y-Koordinaten des Gitterzellenschwerpunkts im Koordinatenreferenzsystem „EPSG:3035“ beschrieben.

#### 4.1.2 Datenvorbereitung

Alle Arbeitsschritte zur Datenvorbereitung wurden in der QGIS-Version 3.32 (QGIS.ORG 2024) durchgeführt. Die administrativen Grenzen der Stadt Bonn wurden durch die Erstellung eines Puffers um 5 km erweitert, wobei die Ausgangsdaten an dieses Untersuchungsgebiet angepasst wurden. Der gewählte Pufferwert entspricht dem von WOLFF (2021) verwendeten Wert. Für die Gebäudedaten wurden sämtliche Gebäude ausgeschlossen, die aufgrund ihrer Typisierung eindeutig keine Wohngebäude sind. Außerdem wurde das Straßennetzwerk angepasst, indem Autobahnen und Autobahnausfahrten entfernt und das Netzwerk mit dem Plug-In „Disconnected Islands“ bereinigt wurde (SMYTHE 2016). Dieses Plug-In ermöglicht die Identifikation und Entfernung unverbundener Segmente im Straßennetzwerk. Aus den „Urban-Atlas“-Daten wurden Grünflächen und Wälder extrahiert. Im südlichen Teil des Untersuchungsgebiets liegt ein kleiner Bereich, der nicht durch die „Urban-Atlas“-Daten abgedeckt wird. Dieser Bereich umfasst jedoch lediglich eine relevante Grünfläche, die auf Basis der OSM-Daten manuell ergänzt wurde. Um die Zugänge zu den Grünflächen zu bestimmen, wurden die Schnittpunkte zwischen dem Straßennetzwerk und den Grenzen der Grünflächen berechnet. Für einige Grünflächen wurden jedoch keine Zugänge erstellt. Eine manuelle Überprüfung hat gezeigt, dass diese Flächen für die Untersuchung vernachlässigt werden können. Eine Übersicht aller durchgeführten Schritte zur Datenbereinigung und -vorbereitung zeigt Anhang 1.

#### 4.2 Methodik

Die Methodik der Arbeit besteht aus der Berechnung verschiedener Indizes, die zur Bewertung der Erreichbarkeit innerstädtischer Grünflächen dienen sollen. Im ersten Schritt, der Disaggregation der Bevölkerungsdaten, wird die Bevölkerung den Wohngebäuden zugeordnet. Anschließend wird die 2SFCA-Methode angewendet, um die Erreichbarkeit der innerstädtischen Grünflächen zu berechnen. Im zweiten Teil der Arbeit werden Grünflächen und Wohngebäude als Netzwerk von Angebot und Nachfrage betrachtet und als Graph modelliert. Auf Grundlage dieses Graphen sollen die von WOLFF (2021) vorgeschlagenen Indizes berechnet und ein Community-Detection-Algorithmus, wie bei SALGADO et al. (2022) angewendet werden.

### 4.2.1 Disaggregation der Zensus-Daten

Für die Berechnung der 2SFCA-Analyse und der Indizes für den Graph müssen die Bevölkerungsdaten auf Gebäudeebene vorliegen. WOLFF (2021) nutzt dafür einen einfachen flächengewichteten Ansatz, der von GOODCHILD U. LAM (1980) eingeführt wurde. Die Disaggregation nach dieser Methode beruht auf der Annahme, dass die Bevölkerung homogen auf der Fläche verteilt ist. Die Menge, die einer Zielregion zugewiesen wird, wird berechnet, indem der Anteil der Zielregion an der Ursprungsregion bestimmt wird. Dieses Verhältnis dient dann als Gewichtung für die Zuordnung der Menge. Die folgende Formel (1) dient zur Berechnung der Bevölkerung im Zielgebiet und wurde für diese Arbeit angepasst (GREGORY & ELL 2005; LI et al. 2007):

$$P_g = \sum_z \frac{A_{gz} \times P_z}{A_z} \quad (1)$$

$P_g$  beschreibt die geschätzte Einwohnerzahl im Gebäude  $g$  und  $P_z$  steht für die Bevölkerung in Gitterzelle  $z$ .  $A_z$  beschreibt die Gesamtfläche der Zelle, die von Wohngebäuden bedeckt ist, und  $A_{gz}$  gibt die Schnittfläche des Gebäudes  $g$  mit der Gitterzelle  $z$  an. Nach REIBEL (2007) ist die Genauigkeit dieses Ansatzes zufriedenstellend. Außerdem stellt dieser Ansatz sicher, dass das Gesamtvolumen der Disaggregation nicht das der aggregierten Daten übersteigt und ist einfach umzusetzen (WU et al. 2005; REIBEL 2007). Die Schwäche dieses Ansatzes liegt in der Annahme, dass die Bevölkerung gleichmäßig verteilt ist, da dies in der Regel nicht zutrifft. Es gibt genauere Alternativen zur Disaggregation von Bevölkerungsdaten, die jedoch häufig zusätzliche Daten benötigen (GREGORY & ELL 2005; WU et al. 2005; LI et al. 2007; REIBEL 2007). SAPENA et al. (2022) vergleichen verschiedene Methoden zur Disaggregation von Bevölkerungsdaten. Dabei zeigt sich, dass die Methode die Landnutzungsdaten und Gebäudehöhen integriert, die besten Ergebnisse liefert.

Dieser Ansatz wurde in Python unter Verwendung des Packages „GeoPandas“ (VAN DEN BOSCHÉ et al. 2024) umgesetzt (Anhang 2). Die Zuweisung der Bevölkerung erfolgt, indem jedes Rasterpolygon im Layer durchlaufen wird. Für jedes Rasterpolygon wird überprüft, wie viel Fläche von Wohngebäuden bedeckt wird. Dann wird für jedes Wohngebäude der Anteil an der überbauten Fläche berechnet. Auf Grundlage dieses Anteils wird die Bevölkerung proportional den Gebäuden zugeordnet. Befindet sich ein Gebäude in mehreren Rasterpolygonen, werden die Anteile aus den unterschiedlichen Polygonen summiert.

#### 4.2.2 Two-step floating catchment area-Methode

Zur Berechnung der Erreichbarkeit von Grünflächen gibt es zahlreiche Indikatoren. Eine Methode, die häufig genutzt wird und das Verhältnis von Angebot und Nachfrage miteinbezieht, ist die 2SFCA-Methode (XING et al. 2020; ZHANG et al. 2022; SUN et al. 2023).

Erstmalig wurde die Methode von RADKE & MU (2000) entwickelt, um die gleichmäßige Verteilung von Ärzten zu untersuchen. Grundlage für die Analyse war eine Karte, die die Bevölkerungsdichte angegeben hat. Durch die Definition von Einzugsgebieten mit einem festgelegten Radius rund um die Angebotsstandorte konnte die gesamte Bevölkerung innerhalb dieser Servicebereiche den jeweiligen Standorten zugeordnet werden. Das Verhältnis von Angebot und Nachfrage wurde dabei als Wahrscheinlichkeit interpretiert, mit der die Bevölkerung von einem bestimmten Standort versorgt wird. RADKE & MU (2000) gehen noch einen Schritt weiter und verschieben die Angebote von den überversorgten Gebieten in die unterversorgten Gebiete. So können Angebotsstandorte identifiziert werden, die zu einer Verbesserung der Versorgung führen. LUO & WANG (2003) haben die Methode zur weit verbreiteten 2SFCA-Methode weiterentwickelt. Sie führen eine strikte Trennung in zwei Schritte ein und verwenden dabei keine Karte der Bevölkerungsdichte. Stattdessen werden die Bevölkerungsstandorte als einzelne Punkte betrachtet. Außerdem verwenden LUO & WANG (2003) Reisezeiten zur Berechnung der Einzugsgebiete.

Zusätzlich werden in dieser Arbeit die Netzwerkdistanzen mittels einer Gaußfunktion gewichtet. DAI (2010) nutzt diese Funktion, um die Umsetzung der *Enhanced two-step floating catchment area* (E2SFCA)-Methode von LUO & QI (2009) zu vereinfachen. Bei der E2SFCA-Analyse definieren LUO & QI (2009) innerhalb der Einzugsgebiete Zonen mit unterschiedlicher Gewichtung. Die Gewichtung soll in beiden Schritten erfolgen, da dies laut den Autoren eine solide theoretische Grundlage in *Gravity*-Modellen hat. Die E2SFCA-Methode soll dabei bessere Ergebnisse liefern als die herkömmliche 2SFCA. Im Gegensatz dazu wird bei der gaußschen 2SFCA die Gewichtung kontinuierlich durchgeführt, sodass keine festen Zonen definiert werden müssen. Diese Variante der 2SFCA wird in verschiedenen aktuellen Studien verwendet (ZHANG et al. 2022; SUN et al. 2023).

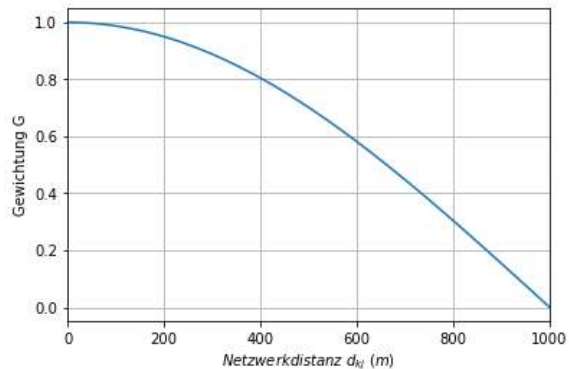


Abbildung 4: Gauß-Funktion zur Gewichtung in Abhängigkeit zur Netzwerkdistanz (eigene Darstellung)

Auch diese Methode soll bessere Ergebnisse gegenüber der regulären 2SFCA-Analyse liefern (ZHANG et al. 2022). Formel (2) zeigt die Gauß-Funktion, die zur Gewichtung genutzt wird (DAI 2010). In Abbildung 4 wird die Funktion visuell dargestellt.

$$G(d_{kj}, d_0) = \frac{e^{-0,5 \times \left(\frac{d_{kj}}{d_0}\right)^2} - e^{-0,5}}{1 - e^{-0,5}}, d_{kj} \leq d_0 \quad (2)$$

WANG (2012) betont, dass für die Auswahl der Gewichtungsfunktion reale Daten aus der Praxis erforderlich sind. Die Wahl des Schwellenwerts hat jedoch eine höhere Bedeutung, als die Wahl der Gewichtungsfunktion (SHI et al. 2012; CHEN & JIA 2019). Basierend auf dem Vergleich von 24 verschiedenen Funktionen wird auch von CHEN & JIA (2019) eine Gauß-Funktion empfohlen.

Die 2SFCA kann in zwei Schritte unterteilt werden (LUO & WANG 2003). Im ersten Schritt wird ausgehend vom Angebotsstandort der Populationsdruck auf das Angebot berechnet. Hierbei wird ein Versorgungsgebiet mit einem Schwellenwert festgelegt und innerhalb dieses Bereichs werden die Nachfrageorte dem Angebotsort zugewiesen. Das Angebots-Nachfrage-Verhältnis, das für eine Grünfläche berechnet wird, kann durch die Formel (3) beschrieben werden:

$$R_j = \frac{S_j}{\sum_{k \in \{d_{kj} \leq d_0\}} G(d_{kj}, d_0) \times P_k} \quad (3)$$

$R_j$  bezeichnet hier das Verhältnis von Angebot zu Nachfrage, wobei  $S_j$  die Fläche der Grünfläche ist und als Angebot interpretiert wird (ZHANG et al. 2022).  $P_k$  steht für die Bevölkerung an Punkt  $k$ , in diesem Fall ein Wohngebäude.  $G(d_{kj}, d_0)$  ist das Gewicht, das auf Basis der Gauß-Funktion, der Netzwerkdistanz und des Schwellenwerts berechnet wird. Im zweiten Schritt wird der Vorgang umgekehrt: Ausgehend von den Nachfrageorten wird überprüft, welche Angebotsstandorte innerhalb des Einzugsgebiets liegen. Dann werden die Angebots-Nachfrage-Verhältnisse  $R_j$  jeder Grünfläche, die für den jeweiligen Nachfrageort erreichbar sind, mithilfe der Gauß-Funktion gewichtet und aufsummiert. Dieser Schritt kann durch die folgende Formel (4) beschrieben werden:

$$A_i = \sum_{j \in \{d_{jk} \leq d_0\}} G(d_{kj}, d_0) \times R_j \quad (4)$$

$A_i$ , die Erreichbarkeit an Punkt  $i$ , stellt die Summe der gewichteten Angebots-Nachfrage-Verhältnisse der Grünflächen innerhalb des Einzugsgebiets dar. Die restlichen Formelzeichen und Buchstaben bleiben unverändert. Abbildung 5 bietet eine Übersicht über den Ablauf der 2SFCA-Analyse.

In dieser Arbeit wurden die beiden Schritte der 2SFCA-Analyse separat umgesetzt. Der erste Schritt, bei dem das Einzugsgebiet um die Grünflächen herum berechnet und die Einwohner basierend auf der Netzwerkdistanz den Grünflächen zugeordnet werden, erfolgte in QGIS. Hierfür wurde die Python-API genutzt, um die Berechnung zu automatisieren. Der zweite Schritt wurde in Python geschrieben und nutzt die bereits bezogenen Daten aus dem ersten Schritt.

Das Skript für den ersten Schritt der 2SFCA-Analyse (siehe Anhang 3) greift auf die Layer des geöffneten QGIS-Projekts zu. Im Rahmen der Analyse werden alle Grünflächen iterativ durchlaufen, wobei folgende Schritte ausgeführt werden: Für jede Grünfläche wird basierend auf der Netzwerkdistanz das Einzugsgebiet berechnet. Das Plug-In „QNEAT3“ (RAFFLER 2018), welches auch die Kosten für den Eintritt in das Netzwerk sowie für den Austritt aus dem Netzwerk berücksichtigt, berechnet eine Distanzmatrix zwischen allen Eingangspunkten und Wohngebäuden innerhalb des Einzugsgebiets. Mit Hilfe dieser Matrix wird nun unter Berücksichtigung der Gauß-Funktion ermittelt, wie viele Einwohner Zugang zu den jeweiligen Grünflächen haben. Als Ergebnis dieses Schritts wird die Distanzmatrix für das gesamte Untersuchungsgebiet sowie der Bevölkerungsdruck für jede Grünfläche ausgegeben.

Vor der Durchführung des zweiten Schritts (siehe Anhang 4) erfolgte eine manuelle Anpassung der Daten: Für jede Grünfläche wurde die Fläche berechnet, um das Angebots-Nachfrage-Verhältnis zu ermitteln. Im Rahmen der Analyse wird nun für jede Kombination aus Wohngebäude und Grünfläche die kürzeste Distanz ausgewählt. Anschließend wird die Accessibility berechnet, indem die Angebots-Nachfrage-Verhältnisse entsprechend der Gauß-Funktion gewichtet und je Wohngebäude aufsummiert werden. In QGIS kann den Geodaten nun die Accessibility auf Basis der ID zugeordnet werden.




Abbildung 5: Schematische Darstellung der 2SFCA-Methode (LUO & WANG 2003)



### 4.2.3 Untersuchung der Accessibility als Netzwerk

Dieser Abschnitt beschreibt die Analyse des Netzwerks aus Grünflächen und Wohngebäuden, wobei die Beziehung zwischen Grünflächen-Angebot und -Nachfrage im Vordergrund steht. WOLFF (2021) stellt bewährte Indikatoren wie die *local significance*, *degree centrality* und den Detour-Index für die Analyse solcher Netzwerke vor. Darüber hinaus werden Community-Detection-Algorithmen, wie sie von SALGADO et al. (2022) für solche Netzwerke verwendet werden, näher betrachtet.

Die Implementierung (siehe Anhang 5) der *local significance*, der *degree centrality* und des Detour-Index erfolgte in Python, wobei die folgenden Packages verwendet wurden: „NetworkX“, „Pandas“, „GeoPandas“ und „Shapely“ (HAGBERG et al.; MCKINNEY 2010; BONALD et al. 2020; GILLIES et al. 2024; VAN DEN BOSSCHE et al. 2024). Die Community-Detection wurde in einem separaten Skript (siehe Anhang 6) mit der „Scikit-Netzwerk“-Bibliothek durchgeführt, da diese eine andere Datenstruktur für den Graphen benötigt (BONALD et al. 2020).

#### 4.2.3.1 Local Significance

Die Gewichtung der Kanten in einem Graphen ergibt sich in der Regel aus dem Kontext und der jeweiligen Forschungsfrage (ESCH et al. 2014). ESCH et al. (2014) schlagen im Kontext der Untersuchung der Siedlungsstruktur einen Indikator vor, der die Bedeutung der Verbindung repräsentieren soll. Dieser setzt sich aus den Siedlungsflächen der verbundenen Flächen und deren Distanz zusammen. WOLFF (2021) setzt dieses Maß im Kontext der Erreichbarkeit von Grünflächen ein und berechnet die *local significance* LS auf Grundlage von Formel (5). Hier steht  $P_k$  für die Bevölkerung in Wohngebäude  $k$ ,  $S_j$  für die Fläche der Grünfläche  $j$  und  $d_{kj}$  für die Netzwerkdistanz zwischen dem Gebäude und der Grünfläche.

$$LS = \frac{P_k \times S_j}{d_{kj}^2} \quad (5)$$

#### 4.2.3.2 Der Grad

Der Grad eines Knotens ist durch die Anzahl seiner ausgehenden Kanten definiert (TITTMANN 2021). In gewichteten Netzwerken kann der Grad jedoch auch durch die Summe der angrenzenden Kantengewichte berechnet werden (BARRAT et al. 2004). In dieser Arbeit wird der Grad auf Basis der Kantengewichte berechnet, die durch die *local significance* ermittelt wurden. Ohne Berücksichtigung dieser Gewichtung würde der Grad nur die Anzahl der direkt verbundenen Wohngebäude anzeigen.

Die Nutzung der *local significance* integriert zusätzliche Informationen, wie die Größe der Grünfläche, die verbundene Bevölkerung und die Entfernung zu den Wohnorten. Formel (6) zeigt die Berechnung. Dabei ist  $D_j$  der Grad,  $a_{jk}$  eine angrenzende Kante und  $w_{jk}$  das Gewicht dieser Kante.

$$D_j = \sum_{k=1}^N a_{jk} w_{jk} \quad (6)$$

#### 4.2.3.3 Detour-Index

Für Graphen, die räumlich eingebettet sind, kann der Detour-Index berechnet werden (BARTHÉLEMY 2022). Dieser ist als das Verhältnis der euklidischen Distanz zur Netzwerkdistanz definiert und wird verwendet, um Rückschlüsse auf physische Barrieren zu ziehen (WOLFF 2021). WOLFF (2021) verwendet dabei eine leicht abgewandelte Version des Detour-Index. Im Gegensatz zu BARTHÉLEMY (2022) wird nicht die Netzwerkdistanz durch die euklidische Distanz geteilt, sondern umgekehrt. Die Berechnung des Detour-Index erfolgt für jedes Gebäude, indem der durchschnittliche Detour-Index zu den Grünflächen innerhalb des Schwellenwerts von 1000 m bestimmt wird. Die Formel (7) für den Detour-Index lautet wie folgt:

$$DI = \frac{d_{kj}}{nd_{kj}} \quad (7)$$

Der Detour-Index DI ist der Quotient aus der euklidischen Distanz  $d_{kj}$  und der Netzwerkdistanz  $nd_{kj}$ . Da die Netzwerkdistanz immer größer als die euklidische Distanz ist, liegt das Ergebnis zwischen 0 und 1. Ein Wert nahe 1 bedeutet, dass der Weg zu den Grünflächen weniger durch physische Barrieren behindert wird (WOLFF 2021; BARTHÉLEMY 2022).

#### 4.2.3.4 Community-Detection

Community-Detection-Algorithmen sind ein wertvolles Werkzeug zur Untersuchung großer, komplexer Netzwerke und dienen zur besseren Veranschaulichung ihrer Eigenschaften (BARTHÉLEMY 2022). Diese Methoden gehen davon aus, dass das untersuchte Netzwerk von Natur aus in Gruppen unterteilt ist und sollen diese identifizieren (NEWMAN 2006). Die Anzahl und Größe der Communities ergibt sich aus dem Netzwerk selbst.

Es gibt eine Reihe von Anwendungsfällen, für die Community-Detection-Algorithmen genutzt werden können (KARATAS & SAHIN 2018). Häufig werden sie in sozialen Netzwerken, in der Biologie oder der Kriminologie genutzt. Sie werden jedoch auch bei räumlichen Graphen eingesetzt, um Muster und Informationen über die räumliche Verteilung hinaus zu entdecken (GUIMERA et al. 2005; KALUZA et al. 2010; MONTIS et al. 2013). GUIMERA et al. (2005) zeigen beispielsweise, dass das Flugroutennetzwerk sowohl durch geographische als auch durch politische Faktoren beeinflusst wird. Auch in der Untersuchung von Grünflächen wurde bereits ein Community-Detection-Algorithmus eingesetzt (SALGADO et al. 2022). Hier wurde der Algorithmus genutzt, um die ethnische Zusammensetzung von Nutzergruppen zu analysieren.

Grundlage für die verwendeten Algorithmen ist die Modularität (BLONDEL et al. 2008; TRAAG et al. 2019). Die Modularität ist ein Maß, das die Verbindungen eines Netzwerks, das in Communities unterteilt ist, gegenüber einem Netzwerk, das in dieselben Communities unterteilt ist, aber zufällige Verbindungen enthält, vergleicht (NEWMAN & GIRVAN 2004). Da sich bipartite Netzwerke von unipartiten Netzwerken unterscheiden, wurde für solche Netzwerke eine angepasste Modularität entwickelt (BARBER 2007). Diese angepasste Modularität hat ähnliche Einschränkungen wie die unipartite Modularität, darunter das Auflösungsproblem. Substrukturen könnten bei einer großen Anzahl von Knoten und Kanten in Communities verborgen bleiben. Da die Modularität durch den Vergleich mit der erwarteten Anzahl an Verbindungen funktioniert, bestimmt die Gesamtzahl der Knoten die Auflösung der Community-Detection (FORTUNATO & BARTHÉLEMY 2007).

In dieser Arbeit wird zur Community *Detection* der Leiden-Algorithmus genutzt, welcher eine Weiterentwicklung des Louvain-Algorithmus darstellt (TRAAG et al. 2019). Der Louvain-Algorithmus funktioniert, indem zunächst jedem Knoten eine eigene Klasse zugeordnet wird (BLONDEL et al. 2008). Im ersten Schritt wird für jeden Knoten geprüft, ob das Wechseln seiner Klasse zu der eines Nachbarn zu einer Erhöhung der Modularität führt. Anschließend wird der Knoten in der Community platziert, für die die Modularität am meisten steigt. Wenn keine Verbesserung erzielt wird, bleibt der Knoten in seiner aktuellen Community. Dieser Prozess wird wiederholt, bis keine weiteren Verbesserungen möglich sind. Im zweiten Schritt werden die entstandenen Communities als Knoten betrachtet, und die Kanten repräsentieren die addierten Gewichte der Kanten zwischen den Communities. Nun wird der erste Schritt erneut mit dem aktualisierten Netzwerk ausgeführt. Dieser Prozess wird solange wiederholt, bis sich die Communities nicht mehr ändern und sich die Modularität nicht weiter verbessert.

Der Leiden-Algorithmus wurde entwickelt, da beobachtet wurde, dass es zur Bildung von Klassen kommen kann, die nicht zusammenhängend sind (TRAAG et al. 2019). Dieses Problem tritt auf, wenn zur Schaffung eines lokalen Maximums ein Brückenknoten der Community entfernt wird. Der Louvain-Algorithmus verschiebt einzelne Knoten, um lokale Maxima der Modularität zu ermitteln. Die Aggregation im nächsten Schritt kann dazu führen, dass solche fehlerhaften Substrukturen in der Klassifikation gefestigt werden. Der Algorithmus gewährleistet, dass Communities gut voneinander getrennt sind, kann jedoch nicht garantieren, dass diese intern gut vernetzt sind. Der Leiden-Algorithmus soll dieses Problem beheben, indem vor der Aggregation der Knoten eine Optimierungs-Phase ergänzt wird. In dieser Phase werden den Knoten erneut eigene Klassen zugeordnet. Wie im ersten Schritt können die Knoten nun die Klassen wechseln, um die Modularität zu erhöhen. Allerdings ist es nur möglich, dass Klassen innerhalb der zuvor identifizierten Communities übertragen werden. Außerdem wird die Klasse eines Knotens zufällig aus den benachbarten Klassen mit positiven Modularitätszuwachs ausgewählt, und nicht basierend auf dem maximalen Modularitätszuwachs. Auf diese Weise können relevante Substrukturen innerhalb des Netzwerks identifiziert werden. Abbildung 6 zeigt den Ablauf des Algorithmus. TRAAG et al. (2019) garantieren, dass dieser Algorithmus keine unverbundenen Communities identifiziert.

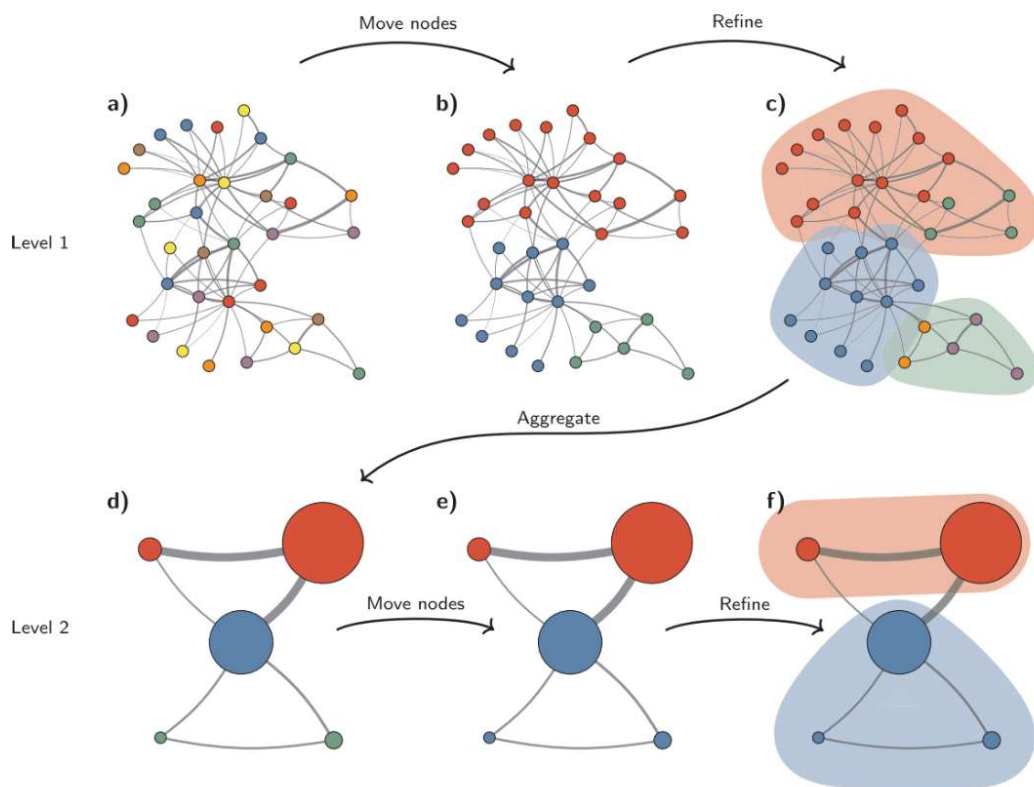


Abbildung 6: Ablauf des Leiden-Algorithmus (TRAAG et al. 2019)

Die Implementierung (siehe Anhang 6) erfolgte in Python unter Verwendung des Pakets „Scikit-Network“ (BONALD et al. 2020). Dieses Paket stellt eine Implementierung des Leiden-Algorithmus für bipartite Netzwerke zur Verfügung. Es wurde ein Graph erstellt, der alle Kanten mit einer Netzwerkdistanz von weniger als 1000 m umfasst und anschließend wurde die *local significance* berechnet. Auf Basis dieses Graphen wurde der Algorithmus angewendet, und die Ergebnisse den Geodaten anhand der ID zugeordnet.



## 5. Ergebnisse

Im folgenden Abschnitt wird die Erreichbarkeit von Grünflächen im Stadtgebiet von Bonn detailliert vorgestellt. Damit wird Untersuchungsfrage 1a, die sich mit der Erreichbarkeit von Grünflächen in Bonn und deren räumlicher Differenzierung befasst, ausführlich beantwortet. Abbildung 7 zeigt die Ergebnisse der 2SFCA-Analyse. Der Überblick über das Stadtgebiet von Bonn verdeutlicht, dass die Erreichbarkeit von Grünflächen sehr heterogen verteilt ist. Dabei lassen sich großräumige räumliche Muster erkennen. So weisen die Ausläufer der Stadt im Südosten und Südwesten hohe Accessibility-Werte auf.

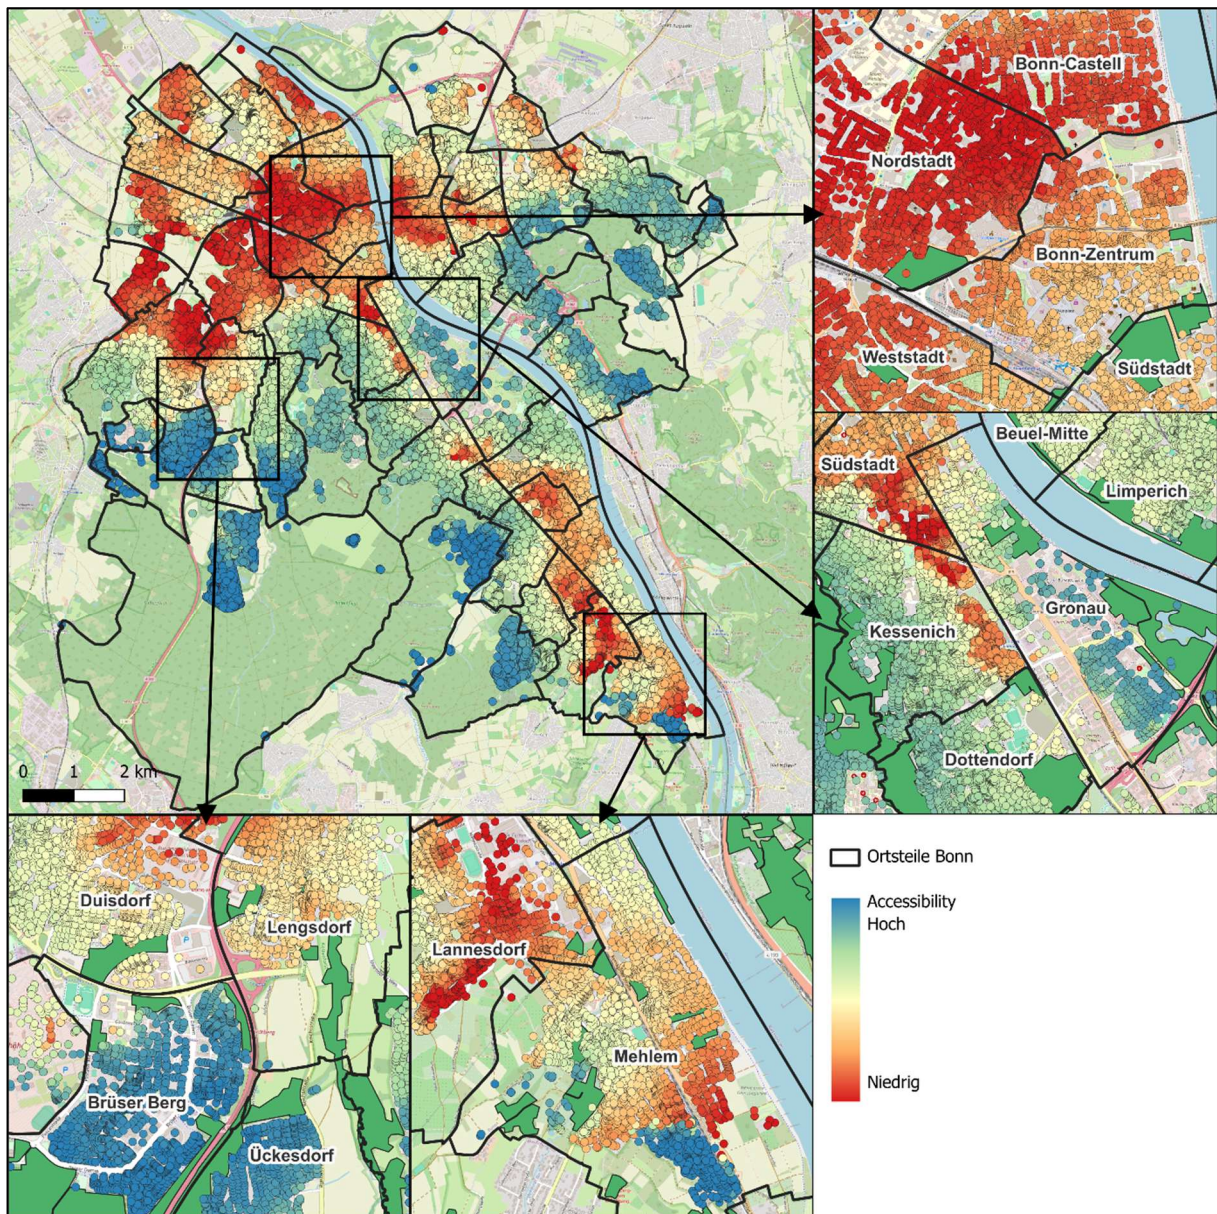


Abbildung 7: Erreichbarkeit innerstädtischer Grünflächen in Bonn (eigene Darstellung)

Die zentralen Bereiche der Stadtbezirke Bonn, Bad Godesberg und Bonn-Beuel kennzeichnen sich dagegen durch vergleichsweise geringe Accessibility-Werte. Insbesondere die Nordstadt Bonns sticht durch die besonders niedrigen Accessibility-Werte heraus. Dieser Bereich mit geringer Accessibility zieht sich bis in die westlichen Außenbereiche der Stadt.

Abbildung 7 zeigt eine Detailansicht der Bonner Innenstadt, während Abbildung 8 die Häufigkeitsverteilung der Accessibility in diesen Stadtteilen anhand eines Boxplots darstellt. Die in Abbildung 8 dargestellten Werte bestätigen das homogen niedrige Niveau der Accessibility von Grünflächen in der Nordstadt. Der Median liegt bei etwa 2,5, was diesen Ortsteil zur Region mit der geringsten Erreichbarkeit von Grünflächen in Bonn macht. Über 75% der Werte liegen unter 4. Die Accessibility in den anderen Ortsteilen der Bonner Innenstadt ist höher. Der Median in Bonn-Castell liegt bei etwa 5, wobei rund 50 % der Werte zwischen 4 und 16 liegen. Damit ist die Erreichbarkeit hier zwar etwas höher als in der Nordstadt, dennoch gibt es vor allem im Süden Bereiche mit sehr geringen Accessibility-Werten. In Bonn-Zentrum zeigt sich insgesamt eine homogenere Verteilung. Etwa 50 % der Werte bewegen sich zwischen 10 und 15, wobei die Accessibility in Richtung Norden abnimmt. Die Südstadt weist mit einem Median von etwa 10 ebenfalls eine bessere Accessibility auf. Allerdings sind auch hier im Süden der Bonner Südstadt Bereiche mit sehr niedrigen Accessibility-Werten zu erkennen.

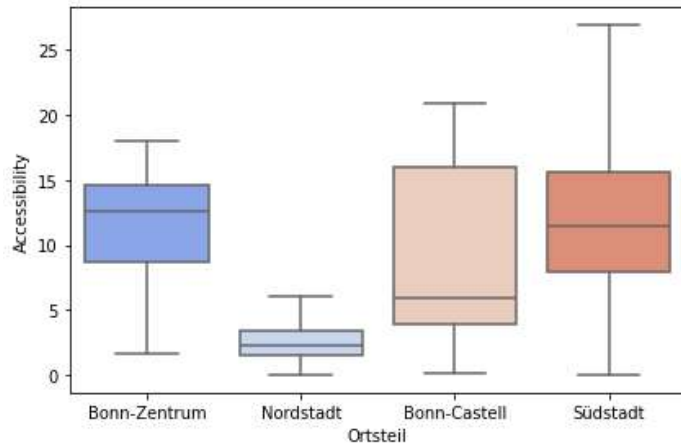


Abbildung 8: Statistische Verteilung der Accessibility in den Ortsteilen Bonn-Zentrum, Nordstadt, Bonn-Castell und Südstadt (eigene Darstellung)

Innenstadtnahe Bereiche mit einer besseren Accessibility sind Kessenich, Dottendorf und Gronau. Im Vergleich zu den zuvor betrachteten Ortsteilen weisen diese Gebiete deutlich höhere Accessibility-Werte auf (siehe Abbildung 9). In Gronau ist die Spannweite der Werte besonders groß: Hier gibt es sowohl sehr niedrige Werte nahe Null als auch Werte über 500.

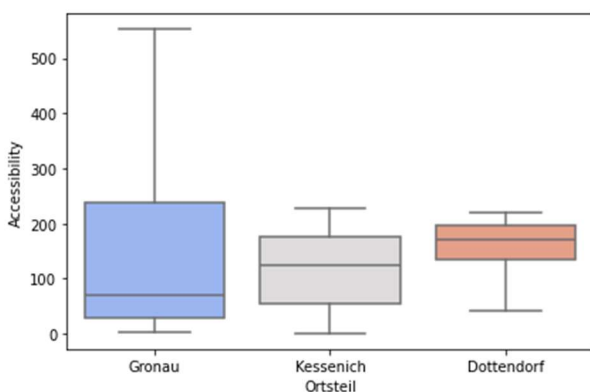


Abbildung 9: Statistische Verteilung der Accessibility in den Ortsteilen Gronau, Kessenich und Dottendorf (eigene Darstellung)

Der Median liegt jedoch knapp unter 100 und ist damit der niedrigste unter den drei betrachteten Stadtteilen. Räumlich ist in Gronau eine Zunahme der Accessibility-Werte in Richtung Südosten zum Rhein hin zu erkennen. In Kessenich sind die Werte mit einem Median knapp über 100 gleichmäßiger verteilt. Die niedrigsten Werte finden sich hier im Osten, während die Accessibility-Werte nach Westen hin ansteigen. Dottendorf weist den höchsten Medianwert auf, der knapp unter 200 liegt. Zudem liegen die Accessibility-Werte in Dottendorf im Vergleich besonders eng beieinander. Räumliche Variationen sind daher nur geringfügig erkennbar.

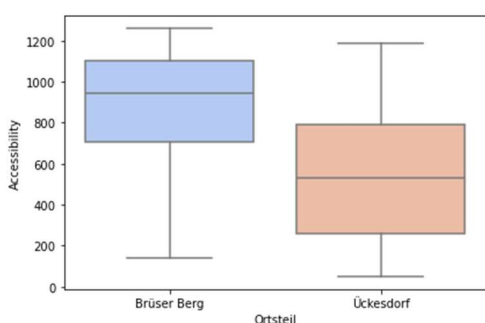


Abbildung 10: Statistische Verteilung der Accessibility in den Ortsteilen Brüser Berg und Ückesdorf (eigene Darstellung)

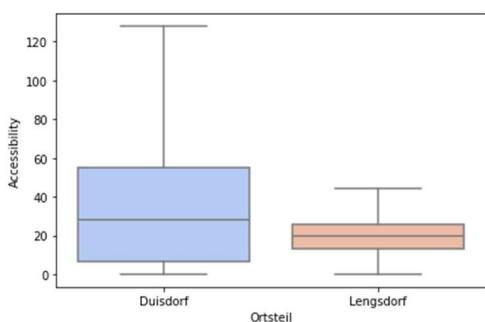


Abbildung 11: Statistische Verteilung der Accessibility in den Ortsteilen Duisdorf und Lengsdorf (eigene Darstellung)

Weiter außerhalb liegen die Stadtteile Brüser Berg, Lengsdorf, Duisdorf und Ückesdorf. Abbildung 10 und 11 zeigen die Häufigkeitsverteilung der Accessibility in diesen Stadtteilen anhand eines Boxplots. Während die Erreichbarkeit von Grünflächen in Ückesdorf und Brüser Berg mit Werten von bis zu über 1.000 zu den besten im gesamten Stadtgebiet zählt, ist die Accessibility in Lengsdorf und Duisdorf deutlich niedriger. Im Ortsteil Brüser Berg liegt der Median bei etwa 1.000. Dabei bewegen sich 50 % der Werte zwischen 700 und 1.100. Räumlich sind die Accessibility-Werte hier relativ gleichmäßig verteilt, wobei sie nach Norden hin leicht abnehmen. In Ückesdorf liegt der Median bei ungefähr 500, und mehr als die Hälfte der Werte liegen zwischen 200 und 800. Auch hier zeigt sich eine insgesamt gleichmäßige Verteilung, jedoch nehmen die Werte in Richtung Süden leicht ab.

In Duisdorf reichen die Werte von nahezu Null bis über 120, wobei der Median bei nur 30 liegt. Räumlich ist hier ein deutlicher Rückgang der Accessibility-Werte in Richtung Nordosten zu erkennen. Lengsdorf zeigt eine sehr enge Verteilung der Werte. Der Median liegt bei 20, und die Streuung um diesen Wert ist minimal. Diese Homogenität ist auch in der Karte in Abbildung 7 klar zu erkennen.



Ein letzter Blick soll auch auf die Stadtteile Lannesdorf und Mehlem geworfen werden. In Lannesdorf ist die Accessibility mit Werten zwischen 0 und 50 relativ niedrig (Abbildung 12). Der Median liegt knapp über 10, wobei die Werte im Süden niedriger sind als im Norden. In Mehlem sind die Accessibility-Werte höher, 50 % der Werte liegen zwischen 15 und 45, und der Median liegt knapp über 20. Räumlich fällt im Süden von Mehlem ein Bereich mit sehr hohen Accessibility-Werten auf, die zwischen 2.000 und 4.000 liegen und die als Ausreißer nicht im Boxplot abgebildet werden. In Lannesdorf und Mehlem zeigt sich dadurch ein Nebeneinander von sehr guter und eher niedriger Erreichbarkeit von Grünflächen.

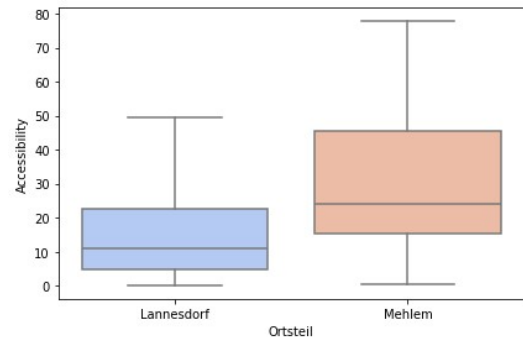


Abbildung 12: Statistische Verteilung der Accessibility in den Ortsteilen Lannesdorf und Mehlem (eigene Darstellung)

Abbildung 13 zeigt die Verteilung des Detour-Index über das gesamte Stadtgebiet hinweg. Ein hoher Detour-Index deutet dabei auf direkte Wege zu den Grünflächen hin, während ein niedriger Detour-Index längere Umwege auf der Strecke signalisiert. Die Differenzierung des Detour-Index ist generell kleinräumiger, mit weniger geglätteten räumlichen Mustern und starken Gefällen. Im unmittelbaren Innenstadtbereich lässt sich ein relativ homogener Bereich mit relativ hohen Detour-Index-Werten identifizieren. Im Süden der Bonner Südstadt und im Nordosten von Kessenich zeigt sich ein scharf abgegrenzter Bereich mit sehr niedrigen Werten im Detour-Index. Der Rest der Südstadt ist durch hohe Werte des Detour-Index geprägt. In Kessenich sind die Werte im Nordwesten stark durchmischt, während im Süden des Stadtteils ein Anstieg der Werte zu beobachten ist. Auch in Mehlem ist der Detour-Index eher gemischt. Im Süden lassen sich jedoch zwei Bereiche erkennen: Einer, der von relativ direkten Routen zu Grünflächen geprägt ist, und ein anderer, bei den längeren Umwegen in Kauf genommen werden müssen. In Lannesdorf zeigen sich im Süden relativ hohe Werte, während der Norden durch längere Umwege charakterisiert ist. In beiden Detailansichten werden die scharfen lokalen Gegensätze des Detour-Index deutlich.

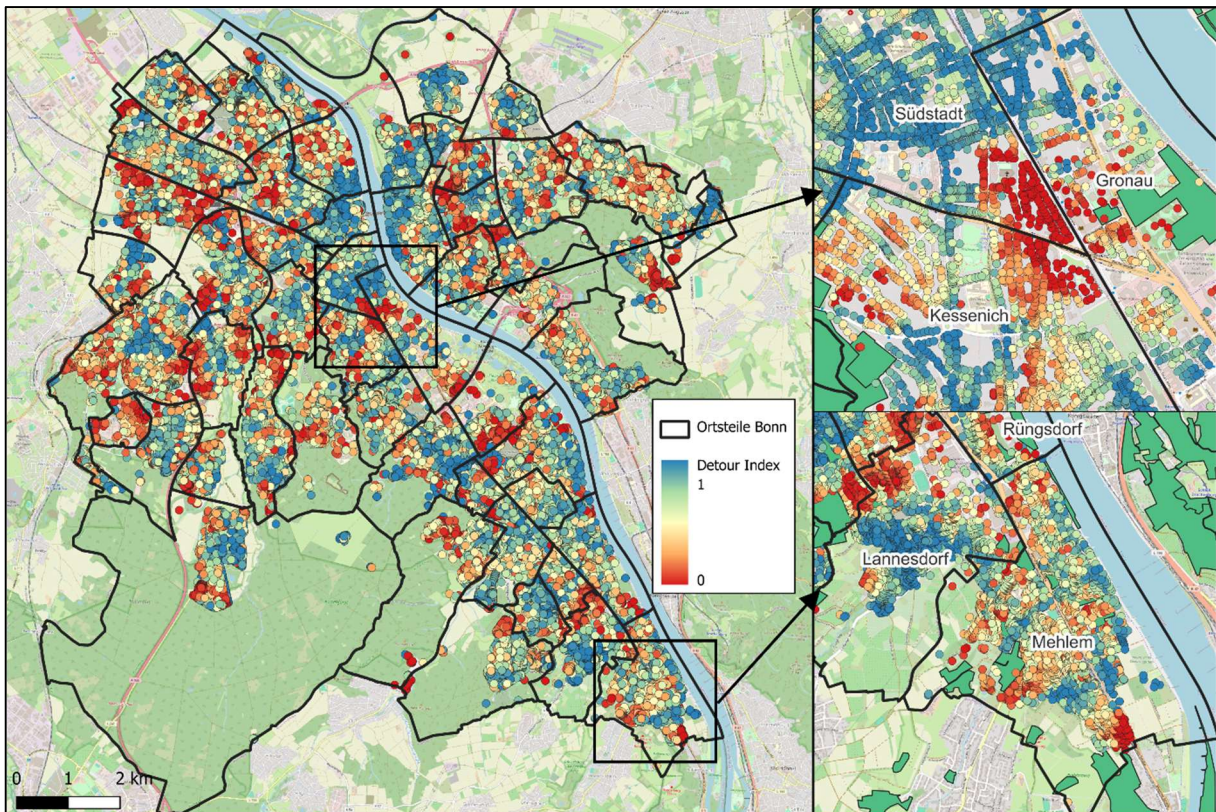


Abbildung 13: Detour-Index in der Stadt Bonn: Dieser zeigt an, wie groß der Umweg ist, der durch das Straßennetzwerk auf dem Weg zur Grünfläche genommen werden muss. (eigene Darstellung)

Abbildung 14 zeigt die Modellierung des Angebots und der Nachfrage von Grünflächen als Netzwerk. Hier wird die Stärke der Beziehung zwischen Gebäuden und Grünflächen durch die *local significance* dargestellt. Der Grad einer Grünfläche ergibt sich aus der Summe aller eingehenden Kanten und deren *local significance*. Besonders die Grünflächen außerhalb der Innenstadtbereiche weisen viele Verbindungen mit hoher Relevanz auf. Auch einzelne Grünflächen in der Innenstadt, wie der Hofgarten oder die Rheinaue, zeigen einige Verbindungen mit mittlerer bis hoher Relevanz. Diese Grünflächen werden auch durch ihren hohen Grad hervorgehoben. Insbesondere die Knotenpunkte außerhalb der Innenstadt werden hier besonders betont.



Außerdem lassen sich in Abbildung 14 Subnetzwerke identifizieren. Sehr gut erkennbar ist ein Subnetzwerk im Innenstadtbereich, das aus Hofgarten, Altem Zoll, Poppelsdorfer Allee und Poppelsdorfer Schloss besteht. Ein weiteres Subnetzwerk entlang des Rheins beginnt mit der Rheinaue und verläuft in südlicher Richtung. Schließlich finden sich auch enge Verbindungen im Südwesten von Bonn. Außerdem wird die trennende Funktion des Rheins durch die Netzwerkkartierung deutlich. Hier bestehen nur sehr wenige Verbindungen, meist von geringer Relevanz.

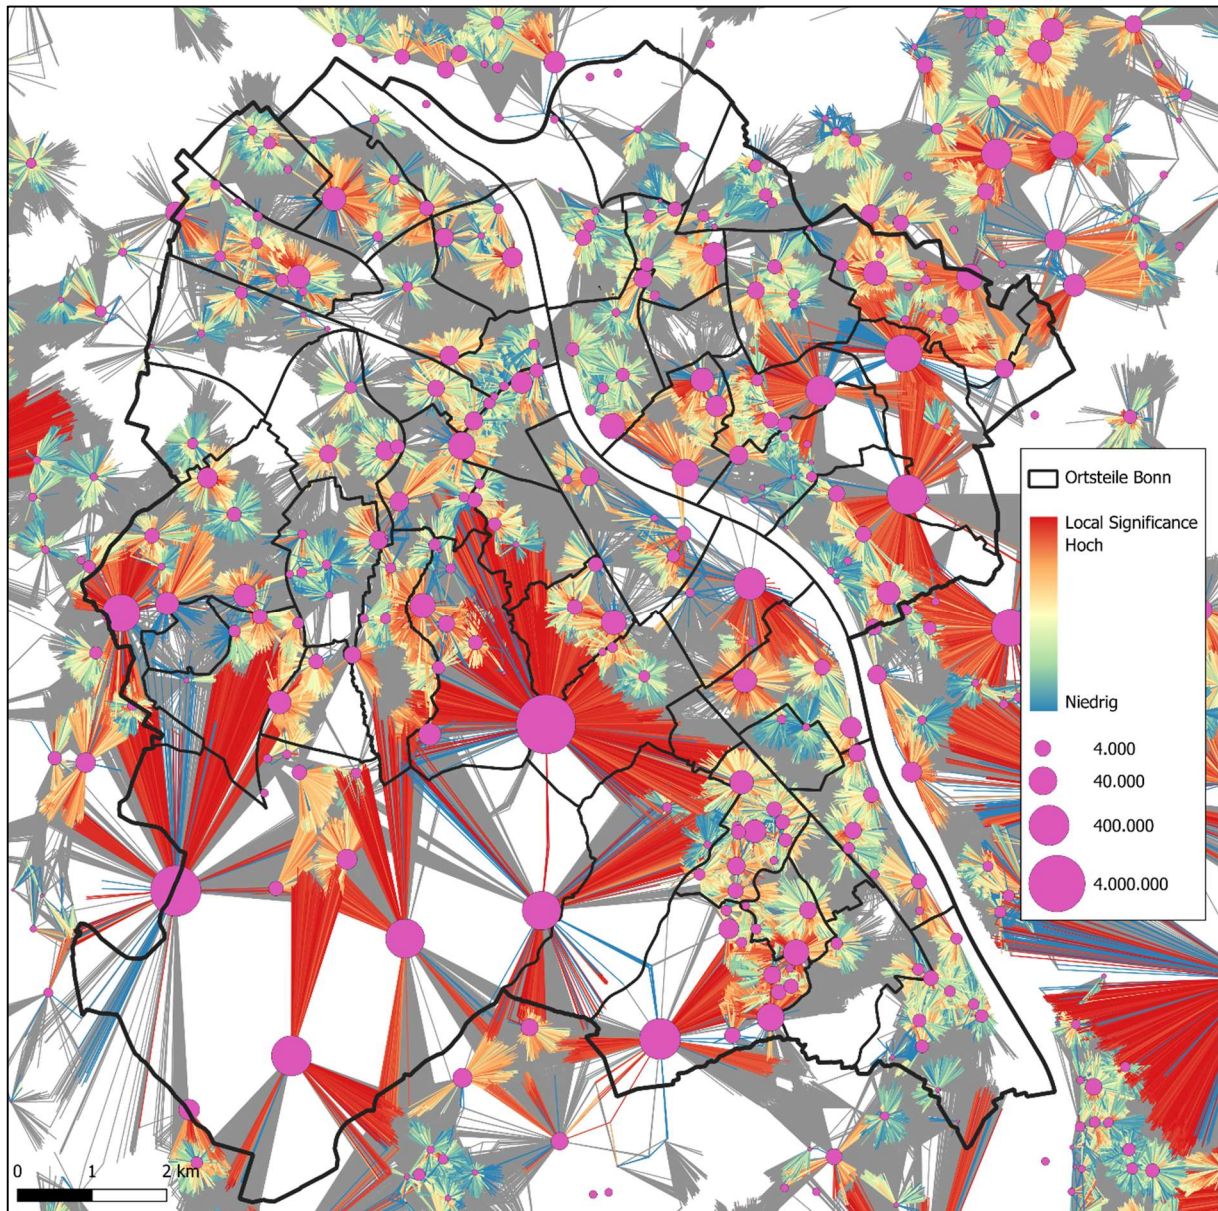


Abbildung 14: Darstellung des Angebots und der Nachfrage von Grünflächen als Netzwerk. Die Knoten repräsentieren die Grünflächen und sind an deren geometrischen Schwerpunkt positioniert. Die Kanten stellen die Beziehung eines Wohngebäudes mit einer Grünfläche dar. (eigene Darstellung)

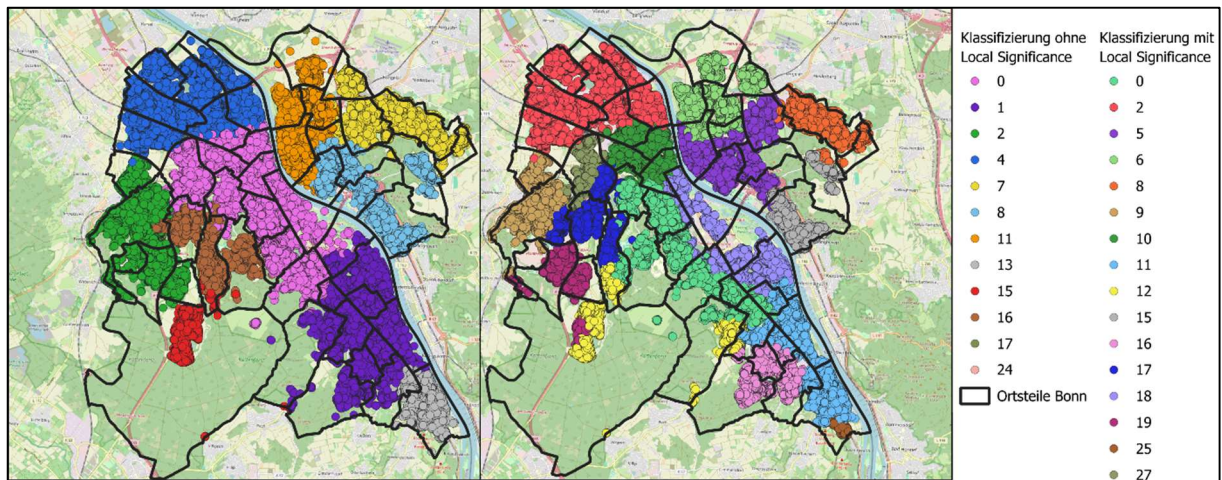


Abbildung 15: Ergebnisse der Community-Detection: Während die Berechnung der Community Detection auf der linken Seite ohne Einbezug der *local significance* erfolgte, wurde auf der rechten Seite die *local significance* miteinbezogen. (eigene Darstellung)

Im letzten Schritt wurde eine Community-Detection auf Grundlage des Netzwerks durchgeführt. Abbildung 15 zeigt die Ergebnisse der Community-Detection. Die Community-Detection ohne Einbezug der *local significance*, dargestellt auf der linken Seite von Abbildung 15, hat sehr große Communities erstellt, die sich über viele Stadtteile erstrecken und nur wenig Anhaltspunkte zur Interpretation bieten. Die Community Detection unter Einbezug der *local significance*, dargestellt auf der rechten Seite, hat deutlich differenziertere und kleinteiligere Communities ergeben. Diese stimmen in Teilen mit den Subnetzwerken überein, die durch die Darstellung des Netzwerks in Abbildung 14 sichtbar gemacht werden konnten. So konnte eine Community im Innenstadtbereich identifiziert werden, die überwiegend Gebäude aus Bonn-Zentrum, Poppelsdorf, der Nordstadt und der Südstadt enthält. Aber auch entlang der Rheinaue wurde eine eigene Community identifiziert. Betrachtet man Community 12 genauer und vergleicht die räumlichen Ausmaße mit der Verteilung der Accessibility in Abbildung 2, so lässt sich feststellen, dass in dieser Community überwiegend Gebäude mit sehr guter Erreichbarkeit von Grünflächen enthalten sind. Auch Community 25 in Mehlem unterscheidet sich von der benachbarten Community durch die Auswahl von Gebäuden mit sehr hohen Accessibility-Werten.

## 6. Diskussion

### 6.1 Die Erreichbarkeit von Grünflächen in Bonn

Die 2SFCA-Analyse hat hinsichtlich der Erreichbarkeit von Grünflächen detaillierte Ergebnisse für das gesamte Stadtgebiet geliefert. Hinsichtlich Untersuchungsfrage 1a ist die wichtigste Feststellung, dass die Erreichbarkeit von Grünflächen stark ungleich über das Stadtgebiet verteilt ist. Die Erreichbarkeit variiert sowohl in innenstadtnahen Bereichen als auch in den weiter außerhalb gelegenen Gebieten.

Frage 1c thematisiert, wie die Projekte der Stadt Bonn vor dem Hintergrund der Ergebnisse dieser Untersuchung zu bewerten sind. Es zeigt sich, dass der Masterplan „Innere Stadt“ Bonn mit seinem Leitmotiv „Grüne Trittsteine“ differenziert zu bewerten ist. Der Masterplan setzt seinen Schwerpunkt in den Ortsteilen, die Bonn-Zentrum umgeben (WACHTEN et al. 2012). So ist Bonn-Zentrum bereits durch wichtige Grünflächen, wie den Hofgarten, die Poppelsdorfer Allee oder den Alten Zoll versorgt. Diese Grünflächen sind aus der Innenstadt gut erreichbar und weisen eine hohe Qualität auf (ROCH et al. 2010; PTOCK 2016). Auch in der Südstadt ist durch den Einfluss dieser Grünflächen die Erreichbarkeit von Grünflächen vergleichsweise gut. In den anderen Ortsteilen, die Bonn-Zentrum umgeben, sind Grünflächen eher schlecht zu erreichen. Viele der Gebiete in der Nordstadt, Bonn-Castell und der Weststadt sind nicht gut mit Grünflächen versorgt. Auch im Süden der Südstadt gibt es Gebiete, in denen physische Barrieren, wie Bahnstrecken, die Erreichbarkeit von Grünflächen beeinträchtigen. Das zeigt, dass der Masterplan „Innere Stadt“ Bonn grundsätzlich die richtigen Gebiete identifiziert, in denen eine Verbesserung des Grünflächenangebots notwendig ist. Gleichzeitig zeigt das jedoch auch, dass die ergriffenen Maßnahmen nicht ausreichen, um eine gute Erreichbarkeit von Grünflächen in der Innenstadt zu gewährleisten. Dies liegt vermutlich an der Zielsetzung des Masterplans „Innere Stadt“ Bonn, der darauf abzielt, die Nutzung der Grünflächen durch eine verbesserte Konnektivität zu steigern. Zu diesem Zweck wurden vor allem bestehende Flächen und Verbindungsachsen umgestaltet. Da diese Maßnahmen jedoch keine ausreichende Erreichbarkeit von Grünflächen sicherstellen konnten und ein Defizit im Grünflächenangebot deutlich wird, besteht die Notwendigkeit, verstärkt neue Grünflächen zu schaffen. DONG et al. (2020) stellen außerdem fest, dass die Konnektivität innerstädtischer Grünflächen nicht zwingend zu einer Mehrnutzung von Grünflächen führt.



Ein grundlegendes Problem in diesem Zusammenhang ist, dass dicht besiedelte urbane Räume ein erhöhtes Risiko für den Verlust von Grünflächen und eine unzureichende Versorgung aufweisen (HAALAND & VAN DEN BOSCH 2015). Gleichzeitig ist Dichte jedoch, wie DOVEY & PAFKA (2020) betonen, ein zentrales Element für die *Walkability*. Dieser Zielkonflikt erfordert laut MADUREIRA & MONTEIRO (2021) weitere Untersuchungen, da er von komplexen Wechselwirkungen und skalenabhängigen Faktoren geprägt ist. Ein besseres Verständnis dieses Spannungsfelds könnte dazu beitragen, die Versorgungssituation in der Bonner Innenstadt zu verbessern.

Insgesamt zeigt der Detour-Index starke kleinräumige Variationen. Physische Barrieren, wie Hauptverkehrswege, Flüsse oder Eisenbahnstrecken, können die fußläufige Durchquerbarkeit von Räumen beeinträchtigen (DROIN et al. 2024). Dies kann ein wichtiger Einflussfaktor auf die Accessibility sein (DOVEY & PAFKA 2020). Abbildung 7 und Abbildung 13 verdeutlichen, wie eine Eisenbahnstrecke in der Südstadt den Detour-Index und die Accessibility maßgeblich beeinflusst. Zudem zeigt sich, dass Sackgassen häufig weniger stark in das Straßennetzwerk integriert sind (JOHNSON & BOWERS 2010). Solche Sackgassen weisen häufig niedrige Detour-Indizes auf. Im Bereich der Innenstadt wurde ein relativ homogener Bereich mit vergleichsweise hohen Detour-Indizes festgestellt. Dieses Ergebnis steht im Einklang mit den Erkenntnissen von DROIN et al. (2024) zur fußläufigen Durchquerbarkeit von Räumen in Städten. Dort wurde aufgezeigt, dass die Durchlässigkeit der Umgebung für Fußgänger in Innenstädten häufig höher ausfällt als im Umland.

Untersuchungsfrage 1b lautet: „Wodurch zeichnet sich das räumliche Netzwerk von Grünflächenangebot und -nachfrage in Bonn aus?“. Die Analyse des Netzwerks zeigt, wie bedeutend Wälder in Bonn für die Versorgung mit Grünflächen sind. Diese werden durch die Netzwerkcharakteristika hervorgehoben und führen zu hohen Accessibility-Werten für angrenzende Wohngebäude. Auch SCHÄFFER & ERDMANN (2015) stellen fest, dass die Bevölkerung Bonns verschiedene Möglichkeiten hat, nahegelegenen Wälder zur Freizeitgestaltung und zu Erholungszeiten zu nutzen. Auch die innerstädtischen Grünflächen Hofgarten, Poppelsdorfer Allee, Poppelsdorfer Schloss und Rheinaue konnten in den Analysen als besonders bedeutsame Grünflächen identifiziert werden. Diese Grünflächen bilden eigene Subnetzwerke, wie die Darstellung als Netzwerk und die Community-Detection zeigen. Die Bedeutung dieser Grünflächen für Bonn wird durch die Forschung von ROCH et al. (2010) und PTOCK (2016) bestätigt.

## 6.2 Limitationen der Methodik

Das Ergebnis der 2SFCA-Analyse wird stark von der Festlegung der einzelnen Parameter bestimmt. So wurden zum Beispiel nur Wälder und Parks in die Analyse miteinbezogen. GASCON et al. (2017) belegen jedoch auch die Bedeutsamkeit von Wasserflächen für die Gesundheit. Besonders für Bonn, das durch den Rhein geprägt ist, könnte der Einbezug dieser Flächen die Ergebnisse der 2SFCA-Analyse erheblich verändern. Zudem wurden landwirtschaftliche Flächen nicht in die Analyse einbezogen, was zu schlechten Accessibility-Werten in Gebieten rund um das Meßdorfer Feld führt. Das Meßdorfer Feld erfüllt jedoch eine wichtige Funktion für die Erholung der Bevölkerung in Bonn und wurde daher auch im Rahmen des Projekts „Grünes C“ berücksichtigt (REGIONALE 2010-AGENTUR 2012; BUNDESSTADT BONN 2018).

Ein weiterer wichtiger Einflussfaktor auf die Ergebnisse 2SFCA-Analyse ist der angesetzte Schwellenwert (DAI 2010). Es wurde versucht, diesen Parameter möglichst ausgewogen zu wählen. In der Literatur gibt es jedoch eine Vielzahl von Schwellenwerten, die unterschiedlich angesetzt werden (AHMED et al. 2023).

Im Rahmen des Masterplans „Innere Stadt“ Bonn wurden überwiegend öffentlichen Räume und Grünflächen umgestaltet. Solche Maßnahmen, konnten sich bei der Analyse vermutlich nicht auf die Ergebnisse auswirken, da lediglich die Größe und keine weiteren Qualitätsmerkmale der Grünflächen miteinbezogen wurden. Hier könnte eine umfassende Analyse der Qualität von Grünflächen, wie sie KRAEMER & KABISCH (2021) durchführen, zusätzliche Erkenntnisse liefern. Außerdem wurden bei der Disaggregation einige Inkonsistenzen festgestellt. Beispielsweise wurden der Oper Bonn Einwohner zugeschrieben, da dieser keine passende Klasse in OSM zugeordnet war. Ein Einbezug zusätzlicher Daten, wie etwa Landnutzungsinformationen oder Gebäudehöhen, könnte die Genauigkeit der Analyse weiter erhöhen (WU et al. 2005; SAMPENA et al. 2022).

### 6.3 Potenziale von Netzwerkcharakteristika zur Untersuchung von Accessibility

Hinsichtlich Untersuchungsfrage 2a hat sich gezeigt, dass sich die Methodik und die vorgeschlagenen Indikatoren von WOLFF (2021) als aussagekräftig erwiesen haben. Die Analyse des Netzwerks ermöglicht präzise Rückschlüsse auf die Beziehungen zwischen dem Angebot an Grünflächen und den Orten der Grünflächen-Nachfrage. Zudem kann die Bedeutung einzelner Grünflächen durch Einbeziehung der *local significance* und des Grads gut ermittelt werden. Auch die Identifizierung von Subnetzwerken ist möglich. Die Interpretation der Netzwerkdarstellung, wie sie WOLFF (2021) zeigt, hat jedoch auch Schwächen. Aufgrund der unübersichtlichen Gestaltung kann die Analyse schwierig sein. Möglicherweise wäre eine Disaggregation auf eine höhere räumliche Ebene sinnvoll, um die Beziehungen zwischen einzelnen Regionen besser zu visualisieren.

Der Detour-Index eignet sich als wertvolles Werkzeug zur Ergänzung der Beurteilung von Accessibility, da er zusätzliche Informationen bietet, die in bestimmten Fällen Rückschlüsse ermöglichen. Im Süden der Bonner Südstadt beispielsweise zeigt sich ein Bereich niedriger Accessibility-Werte. Hier weisen die Gebäude auch einen geringen Detour-Index auf. In der Analyse wird deutlich, dass eine Bahnstrecke vorhanden ist, die nur über die Reuterbrücke oder eine weiter entfernte Unterführung überwunden werden kann. In anderen Gebieten konnten solche eindeutigen Zusammenhänge zwischen Accessibility und Detour-Index jedoch nicht festgestellt werden. An dieser Stelle könnte ein Vergleich oder eine Ergänzung der von DROIN et al. (2024) vorgeschlagenen Methodik zur Untersuchung der fußläufigen Durchquerbarkeit von Räumen interessant sein.

Ein Potenzial könnte außerdem in der Verwendung des Detour-Index als Proxy für die Wahrnehmung der Streckenlänge dienen. RALPH et al. (2020) haben gezeigt, dass Umwege die Wahrnehmung der Entfernung negativ beeinflussen. Darüber hinaus könnte der Detour-Index die Möglichkeit bieten, Ansätze aus dem *Space Syntax* zu integrieren, wo die Routenwahl von Fußgängern durch den *least directional change* geschätzt wird (SHATU et al. 2019). Der Detour-Index könnte möglicherweise mit dem *least directional change* zusammenhängen, da eine besonders direkte Strecke tendenziell weniger Abbiegungen bzw. weniger starke Richtungsänderungen aufweisen sollte. Dies ist auf jeden Fall nicht immer der Fall und nicht sicher gegeben, weshalb hier mögliche weitere Untersuchungen ansetzen könnten.



Untersuchungsfrage 2b thematisiert die Nutzung eines Community-Detection-Algorithmus im Rahmen der Netzwerkanalyse. Die Ergänzung eines Community Detection-Algorithmus basierend auf dem Netzwerk, wie es auch SALGADO et al. (2022) durchführen, kann die Identifikation von Subnetzwerken erleichtern. Durch den Einbezug der Kantengewichte konnten differenziertere Ergebnisse erzeugt werden, die besser mit der visuellen Analyse übereinstimmten. SALGADO et al. (2022) verwenden diese Methode außerdem weiter, um die Nutzergruppen von Parks zu analysieren.

Die umfangreichen Berechnungen in dieser Arbeit bieten außerdem noch erhebliche Potenziale für weitere statistische Auswertungen. So könnten Grünflächen, Wohngebäude und die gebildeten Communities noch genauer statistisch untersucht werden.

## 7. Fazit

Zusammenfassend lässt sich feststellen, dass sich diese Arbeit in die bestehende Forschung zur Erreichbarkeit von Grünflächen einreicht, diese am Beispiel der Stadt Bonn für deutsche Großstädte detailliert untersucht, neue methodische Ansätze erprobt und zu deren Weiterentwicklung beiträgt. Untersuchungsziel 1 strebt eine ausführliche Analyse und Bewertung der Erreichbarkeit von Grünflächen in Bonn an. Dabei hat sich ein sehr differenziertes Bild der Accessibility in Bonn ergeben, das starke Variationen sowohl innerhalb als auch außerhalb der Innenstadt zeigt. Besonders auffällig ist ein Bereich in der Nordstadt, der durch eine geringe Erreichbarkeit von Grünflächen geprägt ist. Vor dem Hintergrund der Entwicklungsziele der Stadt Bonn lässt sich eine gemischte Bilanz ziehen: In Bonn-Zentrum ist die Accessibility aufgrund der historisch bedingten Grünflächen relativ gut, während die Räume rund um das Zentrum durch eine eher geringere Accessibility geprägt sind. Die stadtplanerischen Ziele haben hier die richtigen Bereiche für Verbesserungen identifiziert, jedoch konnte eine gute Erreichbarkeit von Grünflächen in diesen Räumen nicht gewährleistet werden. Dies könnte daran liegen, dass Maßnahmen wie eine Aufwertung der Flächen und eine Verbesserung der Konnektivität durch Begrünung der Verbindungsstrecken in der Analyse nicht einbezogen wurden. Zudem könnte die mangelnde Schaffung neuer, großer Grünflächen und die Zielsetzung zur Verbesserung der Konnektivität kritisiert werden, da eine höhere Konnektivität nicht immer mit einer gesteigerten Nutzung der Grünflächen einhergeht. Darüber hinaus zeigt diese Arbeit die Bedeutung der Waldflächen für die Versorgung der Bewohner außerhalb des Zentrums auf, wo teilweise sehr hohe Accessibility-Werte erreicht werden.

Die Limitationen dieser Arbeit liegen überwiegend in den getroffenen Annahmen. Hier lässt sich diskutieren, welche Flächen in die Untersuchung miteinbezogen werden sollten und welche nicht. Auch der festgelegte Schwellenwert hat erheblichen Einfluss auf die Ergebnisse und sollte hinterfragt werden. Das zweite Untersuchungsziel strebt eine Erprobung und Weiterentwicklung der von WOLFF (2021) vorgeschlagenen Methodik an. Es hat sich gezeigt, dass die Darstellung als Netzwerk und die Nutzung dieser Indikatoren als ergänzende Methoden gut geeignet sind. Mittels Graphentheorie und Community-Detection lassen sich außerdem Subnetzwerke identifizieren, die Rückschlüsse auf Nutzergruppen zulassen könnten. Darüber hinaus bietet der Detour-Index Ansätze zur Beschreibung des Fußgängerverhaltens in der Stadt, die in weiteren Forschungen weiter untersucht werden sollten.

## Quellenverzeichnis

- AHMED, N., LEE, J., LIU, D., KAN, Z. u. J. WANG (2023): Identifying urban green space deserts by considering different walking distance thresholds for healthy and socially equitable city planning in the Global South. In: *Urban Forestry & Urban Greening* 89, S. 128123. DOI: 10.1016/j.ufug.2023.128123.
- ALMANZA, E., JERRETT, M., DUNTON, G., SETO, E. u. M. A. PENTZ (2012): A study of community design, greenness, and physical activity in children using satellite, GPS and accelerometer data. In: *Health & place* 18 (1), S. 46–54. DOI: 10.1016/j.healthplace.2011.09.003.
- ASTELL-BURT, T., FENG, X. u. G. S. KOLT (2013): Does access to neighbourhood green space promote a healthy duration of sleep? Novel findings from a cross-sectional study of 259 319 Australians. In: *BMJ Open* 3 (8), e003094. DOI: 10.1136/bmjopen-2013-003094.
- ASTELL-BURT, T., FENG, X. u. G. S. KOLT (2014): Is neighborhood green space associated with a lower risk of type 2 diabetes? Evidence from 267,072 Australians. In: *Diabetes Care* 37 (1), S. 197–201. DOI: 10.2337/dc13-1325.
- BARBER, M. J. (2007): Modularity and community detection in bipartite networks. In: *Physical Review E* 76 (6 Pt 2), S. 66102. DOI: 10.1103/PhysRevE.76.066102.
- BARRAT, A., BARTHÉLEMY, M., PASTOR-SATORRAS, R. u. A. VESPIGNANI (2004): The architecture of complex weighted networks. In: *Proceedings of the National Academy of Sciences of the United States of America* 101 (11), S. 3747–3752. DOI: 10.1073/pnas.0400087101.
- BARTHÉLEMY, M. (2022): Spatial networks. A complete introduction: from graph theory and statistical physics to real-world applications (Springer) Cham.
- BATTY, M. (2009): Accessibility: In Search of a Unified Theory. In: *Environment and planning. B, Planning & design* 36 (2), S. 191–194. DOI: 10.1068/b3602ed.
- BILJECKI, F., CHOW, Y. S. u. K. LEE (2023): Quality of crowdsourced geospatial building information: A global assessment of OpenStreetMap attributes. In: *Building and Environment* 237, S. 110295. DOI: 10.1016/j.buildenv.2023.110295.
- BLONDEL, V. D., GUILLAUME, J.-L., LAMBIOTTE, R. u. E. LEFEBVRE (2008): Fast unfolding of communities in large networks. In: *Journal of Statistical Mechanics: Theory and Experiment* 2008 (10), P10008. DOI: 10.1088/1742-5468/2008/10/P10008.
- BONALD, T., LARA, N. DE, QUENTIN LUTZ, Q. u. B. CHARPENTIER (2020): Scikit-network: Graph Analysis in Python. In: *Journal of Machine Learning Research* 21 (185), S. 1–6. Online verfügbar unter <https://www.jmlr.org/papers/v21/20-412.html>, zuletzt geprüft am 26.12.2024.
- BOWLER, D. E., BUYUNG-ALI, L., KNIGHT, T. M. u. A. S. PULLIN (2010): Urban greening to cool towns and cities: A systematic review of the empirical evidence. In: *Landscape and Urban Planning* 97 (3), S. 147–155. DOI: 10.1016/j.landurbplan.2010.05.006.
- BRETSCHI, C., SEIBEL, S., VORNDRAN, I. u. M. PFAHL (2024): Ermittlung der Einwohnerzahl im Zensus 2022. Hrsg. v. Statistische Ämter des Bundes und der Länder. Online verfügbar unter [https://www.zensus2022.de/DE/Wie-funktioniert-der-Zensus/\\_dokumente/Methodenpapier-Einwohnerzahl-Zensus2022.pdf?\\_\\_blob=publicationFile&v=2](https://www.zensus2022.de/DE/Wie-funktioniert-der-Zensus/_dokumente/Methodenpapier-Einwohnerzahl-Zensus2022.pdf?__blob=publicationFile&v=2), zuletzt geprüft am 26.12.2024.
- BROWNING, M. u. K. LEE (2017): Within What Distance Does "Greenness" Best Predict Physical Health? A Systematic Review of Articles with GIS Buffer Analyses across the Lifespan. In: *International journal of environmental research and public health* 14 (7). DOI: 10.3390/ijerph14070675.

- BUNDESTADT BONN (2018): Bericht zum Freiraum Monitoring der Bundesstadt Bonn 2017. Online verfügbar unter <https://www.bonn.de/medien-global/amt-67/stadtgruen/Bericht-zum-Freiraum-Monitoring-2017.pdf>, zuletzt geprüft am 26.12.2024.
- BUNDESTADT BONN (2020): Nachhaltigkeitsbericht der Stadt Bonn. 2016-2018. Online verfügbar unter [https://www.bonn.de/medien-global/amt-67/lokale-agenda/Nachhaltigkeitsbericht\\_Bonn\\_2016-19\\_Juni2020\\_WEB.pdf](https://www.bonn.de/medien-global/amt-67/lokale-agenda/Nachhaltigkeitsbericht_Bonn_2016-19_Juni2020_WEB.pdf), zuletzt geprüft am 26.12.2024.
- BUNDESTADT BONN (Hrsg.) (2023): Bevölkerung in der Bundesstadt Bonn. Online verfügbar unter <https://www2.bonn.de/statistik/dl/ews/Bevoelkerungsstatistik2022.pdf>, zuletzt geprüft am 26.12.2024.
- CARDINALI, M., BEENACKERS, M. A., VAN TIMMEREN, A. u. U. POTTGIESSER (2024): The relation between proximity to and characteristics of green spaces to physical activity and health: A multi-dimensional sensitivity analysis in four European cities. In: *Environmental Research* 241, S. 117605. DOI: 10.1016/j.envres.2023.117605.
- CHEN, X. u. P. JIA (2019): A comparative analysis of accessibility measures by the two-step floating catchment area (2SFCA) method. In: *International Journal of Geographical Information Science* 33 (9), S. 1739–1758. DOI: 10.1080/13658816.2019.1591415.
- CURRAN, K., CRUMLISH, J. u. G. FISHER (2012): OpenStreetMap. In: *International Journal of Interactive Communication Systems and Technologies* 2 (1), S. 69–78. DOI: 10.4018/ijicst.2012010105.
- DADVAND, P., VILLANUEVA, C. M., FONT-RIBERA, L., MARTINEZ, D., BASAGAÑA, X. u. J. BELMONTE, et al. (2014): Risks and benefits of green spaces for children: a cross-sectional study of associations with sedentary behavior, obesity, asthma, and allergy. In: *Environmental Health Perspectives* 122 (12), S. 1329–1335. DOI: 10.1289/ehp.1308038.
- DAI, D. (2010): Black residential segregation, disparities in spatial access to health care facilities, and late-stage breast cancer diagnosis in metropolitan Detroit. In: *Health & place* 16 (5), S. 1038–1052. DOI: 10.1016/j.healthplace.2010.06.012.
- DIESTEL, R. (2017<sup>5</sup>): *Graph Theory (Graduate Texts in Mathematics, 173)* (Springer) Berlin.
- DIJKSTRA, L. u. H. POELMAN (2012): Cities in Europe. The new OECD-EC definition. EUROPEAN COMMISSION (Regional Focus, RF 01/2012). Online verfügbar unter <https://land.copernicus.eu/en/technical-library/oecd-definition-of-functional-urban-area-fua/@@download/file>, zuletzt geprüft am 26.12.2024.
- DONG, Y., LIU, H. u. T. ZHENG (2020): Does the Connectivity of Urban Public Green Space Promote Its Use? An Empirical Study of Wuhan. In: *International journal of environmental research and public health* 17 (1), S. 297. DOI: 10.3390/ijerph17010297.
- DORN, H., TÖRNROS, T. u. A. ZIPF (2015): Quality Evaluation of VGI Using Authoritative Data—A Comparison with Land Use Data in Southern Germany. In: *ISPRS International Journal of Geo-Information* 4 (3), S. 1657–1671. DOI: 10.3390/ijgi4031657.
- DOVEY, K. u. E. PAFKA (2020): What is walkability? The urban DMA. In: *Urban Studies* 57 (1), S. 93–108. DOI: 10.1177/0042098018819727.
- DROIN, A., WURM, M. u. H. TAUBENBÖCK (2023): The Individual Walkable Neighborhood - Evaluating people-centered spatial units focusing on urban density. In: *Computers, Environment and Urban Systems* 99, S. 101893. DOI: 10.1016/j.compenvurbsys.2022.101893.
- DROIN, A., WURM, M., WEIGAND, M., GAWLAS, C., KÖBERL, M. u. H. TAUBENBÖCK (2024): How does pedestrian permeability vary in and across cities? A fine-grained assessment for all large cities in Germany.

- In: *Computers, Environment and Urban Systems* 110, S. 102115. DOI: 10.1016/j.compenvurbsys.2024.102115.
- EKKEL, E. D. u. S. de VRIES (2017): Nearby green space and human health: Evaluating accessibility metrics. In: *Landscape and Urban Planning* 157, S. 214–220. DOI: 10.1016/j.landurbplan.2016.06.008.
- ESCH, T., MARCONCINI, M., MARMANIS, D., ZEIDLER, J., ELSAYED, S. u. A. METZ, et al. (2014): Dimensioning urbanization – An advanced procedure for characterizing human settlement properties and patterns using spatial network analysis. In: *Applied Geography* 55, S. 212–228. DOI: 10.1016/j.apgeog.2014.09.009.
- EUROPEAN COMMISSION (2020): Urban Atlas Mapping Guide v6.3. for a European Urban Atlas. Online verfügbar unter [https://land.copernicus.eu/en/technical-library/urban\\_atlas\\_2012\\_2018\\_mapping\\_guide/@@download/file](https://land.copernicus.eu/en/technical-library/urban_atlas_2012_2018_mapping_guide/@@download/file), zuletzt geprüft am 26.12.2024.
- EWING, R. u. S. HANDY (2009): Measuring the Unmeasurable: Urban Design Qualities Related to Walkability. In: *Journal of Urban Design* 14 (1), S. 65–84. DOI: 10.1080/13574800802451155.
- FORTUNATO, S. u. M. BARTHÉLEMY (2007): Resolution limit in community detection. In: *Proceedings of the National Academy of Sciences of the United States of America* 104 (1), S. 36–41. DOI: 10.1073/pnas.0605965104.
- FRENK, J. (1992): The concept and measurement of Accessibility. In: WHITE, K. L. (Hrsg.): Health services research. An anthology (Scientific publication / Pan-American Health Organization, 534) Washington, D. C., S. 842–855. Online verfügbar unter [https://www.researchgate.net/profile/Julio-Frenk/publication/19080047\\_Concept\\_and\\_measurement\\_of\\_accessibility/links/5575db2708ae75363751a314/Concept-and-measurement-of-accessibility.pdf](https://www.researchgate.net/profile/Julio-Frenk/publication/19080047_Concept_and_measurement_of_accessibility/links/5575db2708ae75363751a314/Concept-and-measurement-of-accessibility.pdf), zuletzt geprüft am 26.12.2024.
- GASCON, M., ZIJLEMA, W., VERT, C., WHITE, M. P. u. M. J. NIEUWENHUIJSEN (2017): Outdoor blue spaces, human health and well-being: A systematic review of quantitative studies. In: *International Journal of Hygiene and Environmental Health* 220 (8), S. 1207–1221. DOI: 10.1016/j.ijheh.2017.08.004.
- GILLIES, S., VAN DER WEL, C., VAN DEN BOSSCHE, J., TAVES, M. W., ARNOTT, J. u. B. C. WARD (2024): Shapely. Online verfügbar unter <https://shapely.readthedocs.io/en/2.0.3/manual.html>, zuletzt geprüft am 26.12.2024.
- GOODCHILD, M. F. (2007): Citizens as sensors: the world of volunteered geography. In: *GeoJournal* 69 (4), S. 211–221. DOI: 10.1007/s10708-007-9111-y.
- GOODCHILD, M. F. u. N. S.-N. LAM (1980): Areal Interpolation: a variant of the the traditional spatial problem. In: *Geo-Processing* (1), S. 297–312. Online verfügbar unter [https://www.researchgate.net/publication/239654534\\_Areal\\_Interpolation\\_A\\_Variant\\_of\\_the\\_Traditional\\_Spatial\\_Problem](https://www.researchgate.net/publication/239654534_Areal_Interpolation_A_Variant_of_the_Traditional_Spatial_Problem), zuletzt geprüft am 26.12.2024.
- GREGORY, I. N. u. P. S. ELL (2005): Breaking the Boundaries: Geographical Approaches to Integrating 200 Years of the Census. In: *Journal of the Royal Statistical Society Series A: Statistics in Society* 168 (2), S. 419–437. DOI: 10.1111/j.1467-985X.2005.00356.x.
- GUIMERA, R., MOSSA, S., TURTSCHI, A. u. L. A. N. AMARAL (2005): The worldwide air transportation network: Anomalous centrality, community structure, and cities' global roles. In: *Proceedings of the National Academy of Sciences of the United States of America* 102 (22), S. 7794–7799. DOI: 10.1073/pnas.0407994102.

- HAALAND, C. u. C. K. VAN DEN BOSCH (2015): Challenges and strategies for urban green-space planning in cities undergoing densification: A review. In: *Urban Forestry & Urban Greening* 14 (4), S. 760–771. DOI: 10.1016/j.ufug.2015.07.009.
- HAGBERG, A., SWART, P. J. u. D. A. SCHULTZ): Exploring network structure, dynamics, and function using NetworkX (Los Alamos National Laboratory (LANL), Los Alamos, NM (United States), LA-UR-08-05495; LA-UR-08-5495). Online verfügbar unter <https://www.osti.gov/biblio/960616>, zuletzt geprüft am 26.12.2024.
- HANSEN, W. G. (1959): How Accessibility Shapes Land Use. In: *Journal of the American Institute of Planners* 25 (2), S. 73–76. DOI: 10.1080/01944365908978307.
- HELBICH, M., AMELUNXEN, C., NEIS, P. u. A. ZIPF (2012): Comparative spatial analysis of positional accuracy of OpenStreetMap and proprietary geodata. In: *Angewandte Geoinformatik*, S. 24–33. Online verfügbar unter [https://gispoint.de/fileadmin/user\\_upload/paper\\_gis\\_open/537521013.pdf](https://gispoint.de/fileadmin/user_upload/paper_gis_open/537521013.pdf), zuletzt geprüft am 26.12.2024.
- HOOK, H. (2024): Is 23 minutes walking distance?: Factors determining walking time thresholds of Twitter users. In: *Journal of Urban Mobility* 5, S. 100073. DOI: 10.1016/j.urbmob.2024.100073.
- INGRAM, D. R. (1971): The concept of accessibility: A search for an operational form. In: *Regional Studies* 5 (2), S. 101–107. DOI: 10.1080/09595237100185131.
- JACKSON, L. E. (2003): The relationship of urban design to human health and condition. In: *Landscape and Urban Planning* 64 (4), S. 191–200. DOI: 10.1016/S0169-2046(02)00230-X.
- JOHNSON, S. D. u. K. J. BOWERS (2010): Permeability and Burglary Risk: Are Cul-de-Sacs Safer? In: *Journal of Quantitative Criminology* 26 (1), S. 89–111. DOI: 10.1007/s10940-009-9084-8.
- KALUZA, P., KÖLZSCH, A., GASTNER, M. T. u. B. BLASIUS (2010): The complex network of global cargo ship movements. In: *Journal of the Royal Society, Interface* 7 (48), S. 1093–1103. DOI: 10.1098/rsif.2009.0495.
- KARATAS, A. u. S. SAHIN (2018): Application Areas of Community Detection: A Review. In: International Congress on Big Data, Deep Learning and Fighting Cyber Terrorism. 2018 International Congress on Big Data, Deep Learning and Fighting Cyber Terrorism (IBIGDELFT). Ankara, Turkey, 12/3/2018 - 12/4/2018. Institute of Electrical and Electronics Engineers (IEEE) Piscataway, S. 65–70.
- KLINK, S. u. K. LORENTZ (2022): Auswahlplan und Stichprobenhauptziehung für den Zensus 2022. In: *WISTA - Wirtschaft und Statistik* 74 (1), S. 13–24. Online verfügbar unter <https://www.econstor.eu/handle/10419/250082>, zuletzt geprüft am 26.12.2024.
- KONDO, M. C., FLUEHR, J. M., MCKEON, T. u. C. C. BRANAS (2018): Urban Green Space and Its Impact on Human Health. In: *International journal of environmental research and public health* 15 (3), S. 445. DOI: 10.3390/ijerph15030445.
- KRAEMER, R. u. N. KABISCH (2021): Parks in context: advancing citywide spatial quality assessments of urban green spaces using fine-scaled indicators. In: *Ecology and Society* 26 (2). DOI: 10.5751/ES-12485-260245.
- LEVESQUE, J.-F., HARRIS, M. F. u. G. RUSSELL (2013): Patient-centred access to health care: conceptualising access at the interface of health systems and populations. In: *International Journal for Equity in Health* 12 (1), S. 18. DOI: 10.1186/1475-9276-12-18.
- LI, T., PULLAR, D., CORCORAN, J. u. R. STIMSON (2007): A comparison of spatial disaggregation techniques as applied to population estimation for South East Queensland (SEQ), Australia. In: *Applied GIS* 3 (9), S. 1–16. DOI: 10.4225/03/57E9AECEBA789.

- LO, R. H. (2009): Walkability: what is it? In: *Journal of Urbanism: International Research on Placemaking and Urban Sustainability* 2 (2), S. 145–166. DOI: 10.1080/17549170903092867.
- LUO, W. u. Y. QI (2009): An enhanced two-step floating catchment area (E2SFCA) method for measuring spatial accessibility to primary care physicians. In: *Health & place* 15 (4), S. 1100–1107. DOI: 10.1016/j.healthplace.2009.06.002.
- LUO, W. u. F. WANG (2003): Measures of Spatial Accessibility to Healthcare in a GIS Environment: Synthesis and a Case Study in Chicago Region. In: *Environment and planning. B, Planning & design* 30 (6), S. 865–884. DOI: 10.1068/b29120.
- MAAS, J., VERHEIJ, R. A., VRIES, S. DE, SPREEUWENBERG, P., SCHELLEVIS, F. G. u. P. P. GROENEWEGEN (2009): Morbidity is related to a green living environment. In: *Journal of Epidemiology & Community Health* 63 (12), S. 967–973. DOI: 10.1136/jech.2008.079038.
- MADUREIRA, H. u. A. MONTEIRO (2021): Going Green and Going Dense: A Systematic Review of Compatibilities and Conflicts in Urban Research. In: *Sustainability* 13 (19), S. 10643. DOI: 10.3390/su131910643.
- MCKINNEY, W. (2010): Data Structures for Statistical Computing in Python. In: Proceedings of the 9th Python in Science Conference (445), S. 56–61. Online verfügbar unter <https://pub.curvenote.com/01908378-3686-7168-a380-d82bbf21c799/public/mckinney-57fc0d4e8a08cd7f26a4b8bf468a71f4.pdf>, zuletzt geprüft am 26.12.2024.
- MILBERT, A. (2018): Wieviel (Re-)Urbanisierung durchzieht das Land? In: Bundesinstitut für Bau-, Stadt- und Raumforschung (BBSR) (Hrsg.): Gleichwertige Lebensverhältnisse im Spiegel demografischer Indikatoren. Dezentertagung des DGD-Arbeitskreises „Städte und Regionen“ in Kooperation mit dem BBSR Bonn am 30. November und 1. Dezember 2017 in Berlin (BBSR-Online-Publikation, 11), S. 68–75.
- MITCHELL, R. (2013): Is physical activity in natural environments better for mental health than physical activity in other environments? In: *Social science & medicine (1982)* 91, S. 130–134. DOI: 10.1016/j.socscimed.2012.04.012.
- MITCHELL, R. u. F. POPHAM (2007): Greenspace, urbanity and health: relationships in England. In: *Journal of epidemiology and community health* 61 (8), S. 681–683. DOI: 10.1136/jech.2006.053553.
- MITCHELL, R. u. F. POPHAM (2008): Effect of exposure to natural environment on health inequalities: an observational population study. In: *The Lancet* 372 (9650), S. 1655–1660. DOI: 10.1016/s0140-6736(08)61689-x.
- MONTIS, A. DE, CASCHILI, S. u. A. CHESSA (2013): Commuter networks and community detection: A method for planning sub regional areas. In: *The European Physical Journal Special Topics* 215 (1), S. 75–91. DOI: 10.1140/epjst/e2013-01716-4.
- MOONEY, P. u. M. MINGHINI (2017): A Review of OpenStreetMap Data. In: FOODY, G., SEE, L., FRITZ, S., MOONEY, P., OLTEANU-RAIMOND, A.-M., FONTE, C. C. u. V. ANTONIOU (Hrsg.): Mapping and the Citizen Sensor (Ubiquity Press) London, S. 37–59.
- NEIS, P. u. D. ZIELSTRA (2014): Recent Developments and Future Trends in Volunteered Geographic Information Research: The Case of OpenStreetMap. In: *Future Internet* 6 (1), S. 76–106. DOI: 10.3390/fi6010076.
- NEWMAN, M. E. J. (2006): Modularity and community structure in networks. In: *Proceedings of the National Academy of Sciences of the United States of America* 103 (23), S. 8577–8582. DOI: 10.1073/pnas.0601602103.

- NEWMAN, M. E. J. u. M. GIRVAN (2004): Finding and evaluating community structure in networks. In: *Phys. Rev. E* 69 (2 Pt 2), S. 26113. DOI: 10.1103/physreve.69.026113.
- NOWAK, D. J., CRANE, D. E. u. J. C. STEVENS (2006): Air pollution removal by urban trees and shrubs in the United States. In: *Urban Forestry & Urban Greening* 4 (3-4), S. 115–123. DOI: 10.1016/j.ufug.2006.01.007.
- PHILLIPS, J. D., SCHWANGHART, W. u. T. HECKMANN (2015): Graph theory in the geosciences. In: *Earth-Science Reviews* 143, S. 147–160. DOI: 10.1016/j.earscirev.2015.02.002.
- PTOCK, A. (2016): Stadtgrün statt Stress. In: *Standort* 40 (2), S. 129–137. DOI: 10.1007/s00548-016-0429-x.
- RADKE, J. u. L. MU (2000): Spatial Decompositions, Modeling and Mapping Service Regions to Predict Access to Social Programs. In: *Annals of GIS* 6 (2), S. 105–112. DOI: 10.1080/10824000009480538.
- RAFFLER, C. (2018): QNEAT3. Qgis Network Analysis Toolbox 3. Online verfügbar unter <https://plugins.qgis.org/plugins/QNEAT3/>, zuletzt geprüft am 26.12.2024.
- RALPH, K. M., SMART, M. J., NOLAND, R. B., WANG, S. u. L. CINTRON (2020): Is it really too far? Overestimating walk time and distance reduces walking. In: *Transportation Research Part F: Traffic Psychology and Behaviour* 74, S. 522–535. DOI: 10.1016/j.trf.2020.09.009.
- Regionale 2010-Agentur (2012): Dokumentation der Regionale 2010 in der Region Köln-Bonn. Köln. Online verfügbar unter [https://www.regionale2010.de/fileadmin/user\\_shares/web\\_downloads/Regionale\\_2010\\_Dokumentation.pdf](https://www.regionale2010.de/fileadmin/user_shares/web_downloads/Regionale_2010_Dokumentation.pdf), zuletzt geprüft am 26.12.2024.
- REIBEL, M. (2007): Geographic Information Systems and Spatial Data Processing in Demography: a Review. In: *Population Research and Policy Review* 26 (5-6), S. 601–618. DOI: 10.1007/s11113-007-9046-5.
- ROCH, I., BANSE, J. u. K.-H. EFFENBERGER (2010): Die Lebensbedingungen Wohnen und Freiraumqualität: Vergleichende Untersuchungen von Stadtgebieten in Bonn und Dresden. In: ROSENFELD, M. T. W. (Hrsg.): Gleichwertigkeit der Lebensverhältnisse zwischen Politik und Marktmechanismus. Empirische Befunde aus den Ländern Sachsen, Sachsen-Anhalt und Thüringen (Arbeitsmaterial der ARL, Nr. 351) (Akad. für Raumforschung und Landesplanung) Hannover, S. 33–70. Online verfügbar unter <https://www.econstor.eu/handle/10419/60177>.
- RODRÍGUEZ-LÓPEZ, C., SALAS-FARIÑA, Z. M., VILLA-GONZÁLEZ, E., BORGES-COSIC, M., HERRADOR-COLMENERO, M. u. J. MEDINA-CASAUBÓN, et al. (2017): The Threshold Distance Associated With Walking From Home to School. In: *Health education & behavior: the official publication of the Society for Public Health Education* 44 (6), S. 857–866. DOI: 10.1177/1090198116688429.
- SALGADO, A., YUAN, Z., CARIDI, I. u. M. C. GONZÁLEZ (2022): Exposure to parks through the lens of urban mobility. In: *EPJ data science* 11 (1), S. 42. DOI: 10.1140/epjds/s13688-022-00351-9.
- SAOUB, K. R. (2021): Graph theory. An introduction to proofs, algorithms, and applications (Chapman & Hall/CRC) Boca Raton.
- SAPENA, M., KÜHNEL, M., WURM, M., PATINO, J. E., DUQUE, J. C. u. H. TAUBENBÖCK (2022): Empiric recommendations for population disaggregation under different data scenarios. In: *PloS one* 17 (9), e0274504. DOI: 10.1371/journal.pone.0274504.
- SCHÄFFER, I. u. K.-H. ERDMANN (2013): Grüne Infrastruktur in der Bundesstadt Bonn –. In: *Standort* 37 (4), S. 211–216. DOI: 10.1007/s00548-013-0297-6.



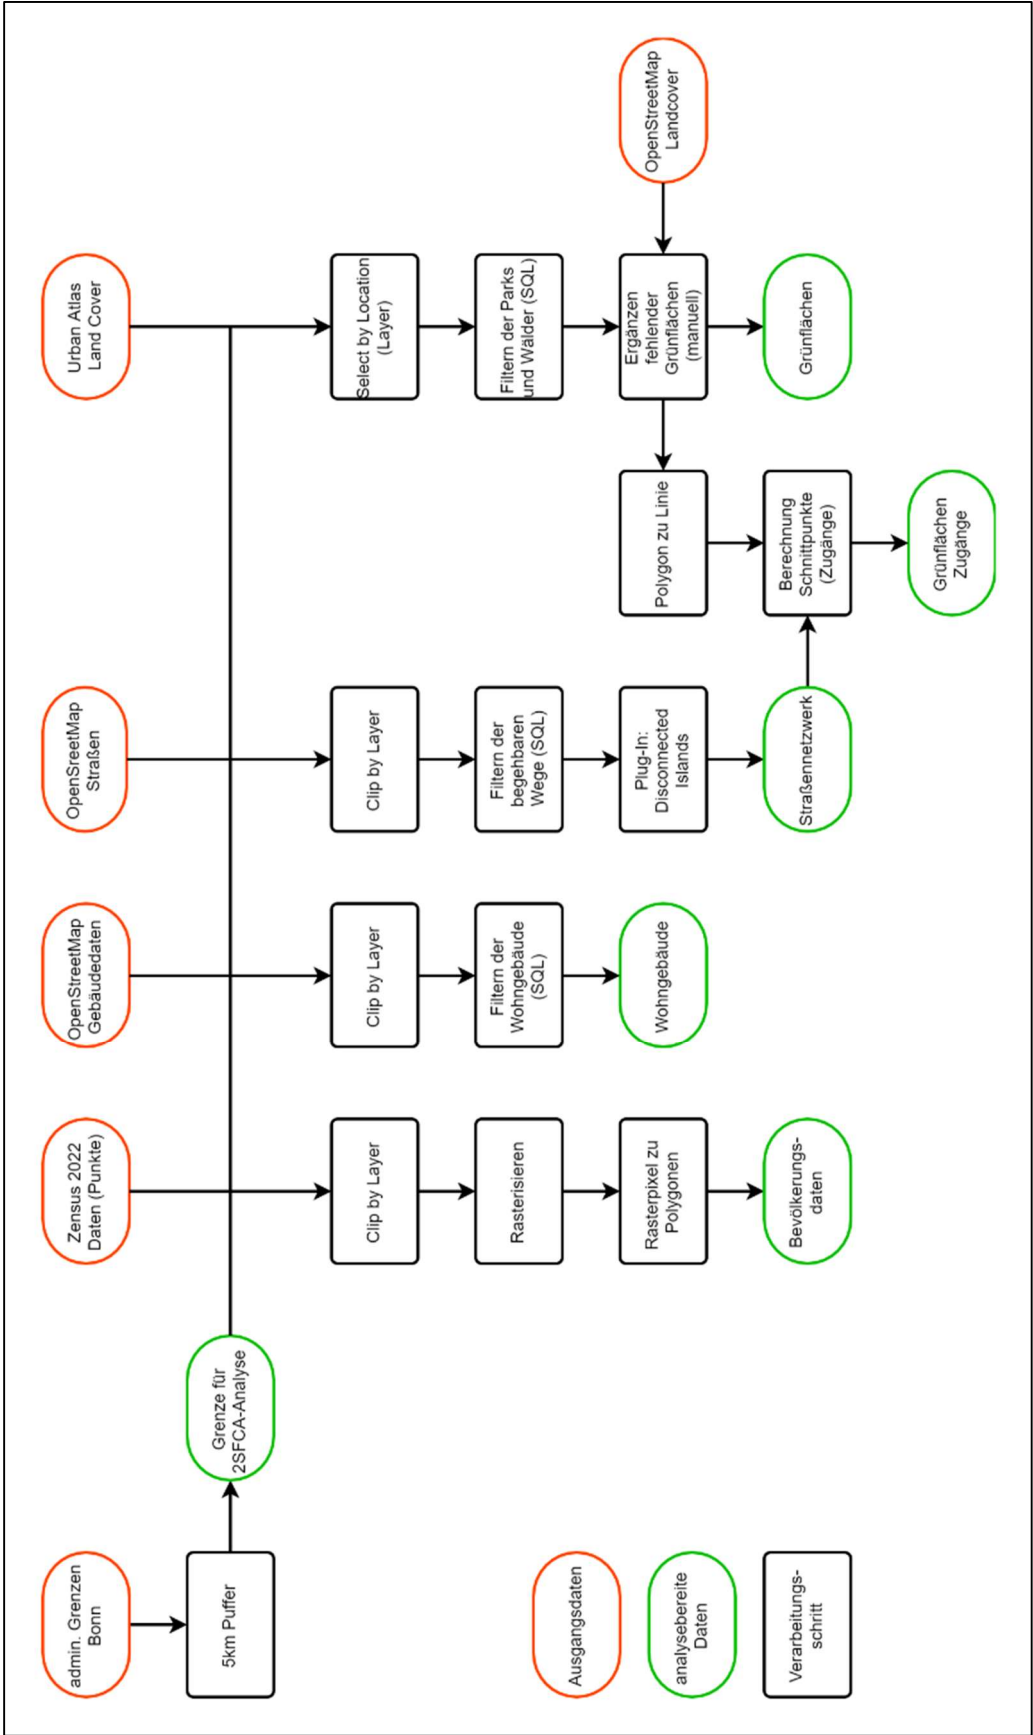
- SCHÄFFER, I. u. K.-H. ERDMANN (2015): Der Faktor „Grün“: Welche Bedeutung hat grüne Infrastruktur für Standorte? In: ERDMANN, K.-H., BORK, H.-R. u. H. JOB (Hrsg.): Naturschutz in geographischer Perspektive (BfN-Skripten, 400) (Bundesamt für Naturschutz) Bonn, S. 39–50.
- SCHINDLER, M., LE TEXIER, M. u. G. CARUSO (2022): How far do people travel to use urban green space? A comparison of three European cities. In: *Applied Geography* 141, S. 102673. DOI: 10.1016/j.apgeog.2022.102673.
- SCHNEIDER, F., DAAMEN, W. u. S. HOOGENDOORN-LANSER (2018): How Far Do people walk and cycle for different activities? Evidence from the Netherlands. HEART 2018: 7TH SYMPOSIUM OF THE EUROPEAN ASSOCIATION FOR RESEARCH IN TRANSPORTATION Athen. Online verfügbar unter <https://research.tudelft.nl/files/51317087/5274.pdf>, zuletzt geprüft am 26.12.2024.
- SHATU, F., YIGITCANLAR, T. u. J. BUNKER (2019): Shortest path distance vs. least directional change: Empirical testing of space syntax and geographic theories concerning pedestrian route choice behaviour. In: *Journal of Transport Geography* 74, S. 37–52. DOI: 10.1016/j.jtrangeo.2018.11.005.
- SHI, X., ALFORD-TEASTER, J., ONEGA, T. u. D. WANG (2012): Spatial Access and Local Demand for Major Cancer Care Facilities in the United States. In: *Annals of the Association of American Geographers* 102 (5), S. 1125–1134. DOI: 10.1080/00045608.2012.657498.
- SMYTHE, P. (2016): Disconnected Islands. Online verfügbar unter <https://plugins.qgis.org/plugins/disconnected-islands/>, zuletzt geprüft am 26.12.2024.
- STATISTISCHE ÄMTER DES BUNDES UND DER LÄNDER (Hrsg.) (2024): Bevölkerungszahlen in Gitterzellen. STATISTISCHES BUNDESAMT. Online verfügbar unter [https://www.zensus2022.de/static/Zensus\\_Veroeffentlichung/Regionaltabelle\\_Bildung\\_Erwerbstaetigkeit.xlsx](https://www.zensus2022.de/static/Zensus_Veroeffentlichung/Regionaltabelle_Bildung_Erwerbstaetigkeit.xlsx), zuletzt geprüft am 26.12.2024.
- STOIA, N. L., NIȚĂ, M. R., POPA, A. M. u. I. C. IOJĂ (2022): The green walk—An analysis for evaluating the accessibility of urban green spaces. In: *Urban Forestry & Urban Greening* 75, S. 127685. DOI: 10.1016/j.ufug.2022.127685.
- SUGIYAMA, T., FRANCIS, J., MIDDLETON, N. J., OWEN, N. u. B. GILES-CORTI (2010): Associations between recreational walking and attractiveness, size, and proximity of neighborhood open spaces. In: *American Journal of Public Health* 100 (9), S. 1752–1757. DOI: 10.2105/AJPH.2009.182006.
- SUN, Y., TIAN, D., ZHANG, M. u. Y. HOU (2023): Spatial Green Space Accessibility in Hongkou District of Shanghai Based on Gaussian Two-Step Floating Catchment Area Method. In: *Buildings* 13 (10), S. 2477. DOI: 10.3390/buildings13102477.
- TAKANO, T., NAKAMURA, K. u. M. WATANABE (2002): Urban residential environments and senior citizens' longevity in megacity areas: the importance of walkable green spaces. In: *Journal of epidemiology and community health* 56 (12), S. 913–918. DOI: 10.1136/jech.56.12.913.
- TAYLOR, J., WILKINSON, P., DAVIES, M., ARMSTRONG, B., CHALABI, Z. u. A. MAVROGIANNI, et al. (2015): Mapping the effects of urban heat island, housing, and age on excess heat-related mortality in London. In: *Urban Climate* 14, S. 517–528. DOI: 10.1016/j.uclim.2015.08.001.
- THOMPSON, C. W., OLIVEIRA, E. S. DE, WHEELER, B. W., DEPLEDGE, M. H. u. M. A. VAN DEN BOSCH (2016): Urban green spaces and health. A review of evidence. Hrsg. v. EGOROV, A. I., MUDU, P., BRAUBACH, M. U. M. MARTUZZI. WHO REGIONAL OFFICE FOR EUROPE Kopenhagen.
- TITTMANN, P. (2021<sup>4</sup>): Graphentheorie. Eine anwendungsorientierte Einführung (Hanser) München.
- TRAAG, V. A., WALTMAN, L. u. N. J. VAN ECK (2019): From Louvain to Leiden: guaranteeing well-connected communities. In: *Scientific reports* 9 (1), S. 5233. DOI: 10.1038/s41598-019-41695-z.

- ULRICH, R. S., SIMONS, R. F., LOSITO, B. D., FIORITO, E., MILES, M. A. u. M. ZELSON (1991): Stress recovery during exposure to natural and urban environments. In: *Journal of Environmental Psychology* 11 (3), S. 201–230. DOI: 10.1016/S0272-4944(05)80184-7.
- VAN DEN BOSSCHE, J., JORDAHL, K., FLEISCHMANN, M., RICHARDS, M., MCBRIDE, J. u. J. WASSERMAN, et al. (2024): geopandas/geopandas: v1.0.1. Online verfügbar unter <https://geopandas.org/en/stable/>, zuletzt geprüft am 26.12.2024.
- VILLENEUVE, P. J., JERRETT, M., SU, J. G., BURNETT, R. T., CHEN, H., WHEELER, A. J. u. M. S. GOLDBERG (2012): A cohort study relating urban green space with mortality in Ontario, Canada. In: *Environmental Research* 115, S. 51–58. DOI: 10.1016/j.envres.2012.03.003.
- VRIES, S. DE, VAN DILLEN, S. M. E., GROENEWEGEN, P. P. u. P. SPREEUWENBERG (2013): Streetscape greenery and health: stress, social cohesion and physical activity as mediators. In: *Social science & medicine* (1982) 94, S. 26–33. DOI: 10.1016/j.socscimed.2013.06.030.
- WACHTEN, K., HEHENKAMP, M. u. D. HESSING (2012): Masterplan "Innere Stadt" Bonn. Hrsg. v. Bundesstadt Bonn. Online verfügbar unter <https://www.bonn.de/medien-global/amt-61/ortsteilentwicklung/Broschuere-Masterplan-Innere-Stadt-Bonn.pdf>, zuletzt geprüft am 26.12.2024.
- WANG, F. (2012): Measurement, Optimization, and Impact of Health Care Accessibility: A Methodological Review. In: *Annals of the Association of American Geographers. Association of American Geographers* 102 (5), S. 1104–1112. DOI: 10.1080/00045608.2012.657146.
- WANG, S., WANG, M. u. Y. LIU (2021): Access to urban parks: Comparing spatial accessibility measures using three GIS-based approaches. In: *Computers, Environment and Urban Systems* 90, S. 101713. DOI: 10.1016/j.compenvurbsys.2021.101713.
- WEGSCHEIDER, S., LINDMAYER, A. u. A. STUMPF (2021): Urban Atlas 2018 Validation Report. EUROPEAN ENVIRONMENTAL AGENCY (EAA). Online verfügbar unter <https://land.copernicus.eu/en/technical-library/urban-atlas-2018-validation-report/@@download/file>, zuletzt geprüft am 26.12.2024.
- WEIGAND, M., WURM, M., DROIN, A., STARK, T., STAAB, J., RAUH, J. u. H. TAUBENBÖCK (2023): Are public green spaces distributed fairly? A nationwide analysis based on remote sensing, OpenStreetMap and census data. In: *Geocarto International* 38 (1). DOI: 10.1080/10106049.2023.2286305.
- WEN, C., ALBERT, C. u. C. von HAAREN (2020): Equality in access to urban green spaces: A case study in Hannover, Germany, with a focus on the elderly population. In: *Urban Forestry & Urban Greening* 55, S. 126820. DOI: 10.1016/j.ufug.2020.126820.
- WOLFF, M. (2021): Taking one step further – Advancing the measurement of green and blue area accessibility using spatial network analysis. In: *Ecological Indicators* 126, S. 107665. DOI: 10.1016/j.ecoind.2021.107665.
- WU, S., QIU, X. u. LE WANG (2005): Population Estimation Methods in GIS and Remote Sensing: A Review. In: *GIScience & Remote Sensing* 42 (1), S. 80–96. DOI: 10.2747/1548-1603.42.1.80.
- XING, L., LIU, Y. u. X. LIU (2018): Measuring spatial disparity in accessibility with a multi-mode method based on park green spaces classification in Wuhan, China. In: *Applied Geography* 94, S. 251–261. DOI: 10.1016/j.apgeog.2018.03.014.
- XING, L., LIU, Y., WANG, B., WANG, Y. u. H. LIU (2020): An environmental justice study on spatial access to parks for youth by using an improved 2SFCA method in Wuhan, China. In: *Cities* 96, S. 102405. DOI: 10.1016/j.cities.2019.102405.
- ZHANG, L., TAN, P. Y. u. J. A. DIEHL (2017): A conceptual framework for studying urban green spaces effects on health. In: *J Urban Ecol* 3 (1). DOI: 10.1093/jue/jux015.

ZHANG, S., YU, P., CHEN, Y., JING, Y. u. F. ZENG (2022): Accessibility of Park Green Space in Wuhan, China: Implications for Spatial Equity in the Post-COVID-19 Era. In: *International journal of environmental research and public health* 19 (9). DOI: 10.3390/ijerph19095440.

ZIELSTRA, D. u. ZIPF, A. (2010): Quantitative studies on the data quality of OpenStreetMap in Germany. Online verfügbar unter [https://www.researchgate.net/profile/alexander-zipf/publication/267989860\\_quantitative\\_studies\\_on\\_the\\_data\\_quality\\_of\\_openstreetmap\\_in\\_germany/links/54d99a590cf25013d0426ba0/quantitative-studies-on-the-data-quality-of-openstreetmap-in-germany.pdf](https://www.researchgate.net/profile/alexander-zipf/publication/267989860_quantitative_studies_on_the_data_quality_of_openstreetmap_in_germany/links/54d99a590cf25013d0426ba0/quantitative-studies-on-the-data-quality-of-openstreetmap-in-germany.pdf), zuletzt geprüft am 26.12.2024.

# Anhang 1: Übersicht über die Datenvorbereitung



## Anhang 2: Disaggregation der „Zensus 2022“-Daten

```
#Pfade zu den Dateien definieren
raster_cells_path = "Zensus2022_raster_vektorisiert.shp"
buildings_path = "wohngebaeude.shp"

#Dateien laden
raster_cells = gpd.read_file(raster_cells_path)
buildings = gpd.read_file(buildings_path)

#Berechnung der Gebäudegrundfläche
buildings["area"] = buildings.geometry.area

#Spalten initialisieren
raster_cells["building_area"] = 0.0
buildings["Einwohner"] = 0.0

#Über jede Rasterzelle iterieren
for i in range(len(raster_cells)):
    cell_geom = raster_cells.geometry.iloc[i] # Geometrie der Gitterzelle
    total_population_in_cell = raster_cells.at[i, "Einwohner"] # Bevölkerung in der Gitterzelle

    #Gebäude auswählen, die die Zelle schneiden
    buildings_within = buildings[buildings.geometry.intersects(cell_geom)]

    #Die Zelle wird übersprungen, wenn keine Gebäude darin liegen
    if buildings_within.empty:
        continue

    #Berechnung der gesamten überbauten Fläche in der Zelle
    total_intersection_area = cell_geom.intersection(buildings_within.unary_union).area
    raster_cells.at[i, "building_area"] = total_intersection_area

    #Über jedes Gebäude, das in der Rasterzelle liegt, iterieren
    for j in range(len(buildings_within)):
        building_geom = buildings_within.geometry.iloc[j] # Geometrie des Gebäudes
        intersection_area = cell_geom.intersection(building_geom).area # Schnittfläche der Geometrien

        #Bevölkerung auf Grundlage des Anteils an gesamter überbauter Fläche berechnen
        area_ratio = intersection_area / total_intersection_area
        population_increment = area_ratio * total_population_in_cell

        #Bevölkerung dem Gebäude im Original-Dataframe zuschreiben
        building_fid = buildings_within.iloc[j]["fid"]
        building_index = buildings[buildings["fid"] == building_fid].index[0]
        buildings.at[building_index, "Einwohner"] += population_increment

#Ergebnisse als shp-Datei speichern
buildings.to_file("Gebaeude_Einwohner.shp")
```

## Anhang 3: Erster Schritt 2SFCA-Methode

```
from qgis.core import *
import processing
import math
import pandas as pd
import os
import numpy as np
import time

MESSAGE_CATEGORY = "TaskFromFunction"

def heavyFunction(task):
    QgsMessageLog.logMessage("Started task {}".format(task.description()),
    MESSAGE_CATEGORY, Qgs.Info)

    #Laden der geöffneten Layer: Straßennetzwerk, Centroide der Gebäude,
    #Zugänge zu Grünflächen und Festlegung des Schwellenwerts
    network_layer = QgsProject.instance().mapLayersByName("Netzwerk")[0]
    centroids_layer = QgsProject.instance().mapLayersByName("Gebaeude")[0]
    entrances_layer = QgsProject.instance().mapLayersByName("Eingaenge")[0]
    output_directory = r"C:\Users\hendr\Downloads\split"
    d0 = 1000

    #Parameter zum Teilen der Grünflächen Zugaenge nach osm_id
    split_params = {
        "INPUT": entrances_layer,
        "FIELD": "osm_id",
        "FILE_TYPE": 0,
        "OUTPUT": output_directory
    }

    #Ausführen des Prozess
    processing.run("native:splitvectorlayer", split_params)

    #Layer definieren, dem alle Zugänge und deren zugehörige
    #Einwohnerdruck-Werte zugeordnet werden
    fields = QgsFields()
    fields.append(QgsField("destination_id", QVariant.Int))
    fields.append(QgsField("EinwohnerDruck", QVariant.Double))
    temp_layer = QgsVectorLayer("Point?crs=EPSG:3035", "temp_layer", "memory")
    temp_layer_data_provider = temp_layer.dataProvider()
    temp_layer_data_provider.addAttributes(fields)
    temp_layer.updateFields()

    #Dataframe erstellen, dem alle berechneten Distanzen hinzugefügt werden
    distances = pd.DataFrame()
```

```

#Iteriere über jede Grünfläche
for i, filename in enumerate(os.listdir(output_directory)):
    file_path = os.path.join(output_directory, filename)

    layer = QgsVectorLayer(file_path, filename, "ogr")

    #Parameter zu Berechnung des Einzugsgebiets auf Grundlage des Netzwerks
    catchment_params = {
        "START_POINTS": layer, # Zugänge
        "INPUT": network_layer, # OSM Straßennetz
        "DIRECTION_FIELD": "", # Keine Richtung, beidseitige Berechnung
        "DEFAULT_DIRECTION": 2, # Beide Richtungen
        "SPEED_FIELD": "", # Kein Geschwindigkeitsfeld
        "DEFAULT_SPEED": 50, # Default Geschwindigkeit
        "TOLERANCE": 0.1,
        "TRAVEL_COST": d0, # Maximale Entfernung in Metern
        "ENTRY_COST": 0,
        "OUTPUT_LINES": "memory:"
    }

    #Ausführen des Prozess
    catchment_layer = processing.run("native:serviceareafromlayer",
    catchment_params)["OUTPUT_LINES"]

    #Parameter zur Berechnung der Convex Hull
    convex_hull_params = {
        "INPUT": catchment_layer,
        "TYPE": 3, # Convex Hull
        "OUTPUT": "memory:"
    }

    #Ausführen des Prozess
    convex_hull_layer = processing.run("qgis:minimumboundinggeometry",
    convex_hull_params)["OUTPUT"]

    #Parameter zur Ausschneiden der Gebäudezentroide im Einzugsgebiet
    clip_params = {
        "INPUT": centroids_layer,
        "OVERLAY": convex_hull_layer,
        "OUTPUT": "memory:"
    }

    #Ausführen des Prozess
    clipped_centroids = processing.run("native:clip", clip_params)["OUTPUT"]

    #Parameter zur Berechnung der Distanz-Matrix zwischen
    #Grünflächeneingängen und Gebäudezentroiden
    distance_matrix_params = {
        "INPUT": catchment_layer,
        "FROM_POINT_LAYER": clipped_centroids, # Startpunkte sind die Zentroiden
        "FROM_ID_FIELD": "fid", # Ein eindeutiges ID-Feld für Zentroiden
        "TO_POINT_LAYER": layer, # Zielpunkte sind die Zugänge
        "TO_ID_FIELD": "fid", # Ein eindeutiges ID-Feld für Zugänge
        "STRATEGY": 0, # 0 für kürzeste Distanz
        "OUTPUT": "memory:"
    }

    #Ausführen des Prozess
    cost_table = processing.run("qgis:OdMatrixFromLayersAsTable",
    distance_matrix_params)["OUTPUT"]

```

```

#Umwandlung der Distanzmatrix in einen Dataframe
lyr = cost_table
cols = [f.name() for f in lyr.fields()]
datagen = ([f[col] for col in cols] for f in lyr.getFeatures())
cost_df = pd.DataFrame.from_records(data=datagen, columns=cols)

#Distanzmatrix dem Ausgabe-Dataframe hinzufügen
distances = pd.concat([distances, cost_df], ignore_index=True)

#Umwandlung der Gebäudezentroide in einen Dataframe
lyr = clipped_centroids
cols = [f.name() for f in lyr.fields()]
datagen = ([f[col] for col in cols] for f in lyr.getFeatures())
build_df = pd.DataFrame.from_records(data=datagen, columns=cols)

#Umwandlung der Grünflächenzugänge in einen Dataframe
lyr = layer
cols = [f.name() for f in lyr.fields()]
datagen = ([f[col] for col in cols] for f in lyr.getFeatures())
ent_df = pd.DataFrame.from_records(data=datagen, columns=cols)

#Wenn Distanzen fehlen, wird diesen eine Distanz oberhalb des Schwellenwerts zugewiesen
cost_df["total_cost"] = pd.to_numeric(cost_df["total_cost"], errors="coerce").fillna(d0 + 1)

#Minimale Distanz je Gebäudezentroid filtern
min_cost_origin = cost_df.loc[cost_df.groupby(
    ("origin_id")["total_cost"].idxmin()).drop_duplicates(subset=["origin_id"])

#Den Gebäudezentroiden wird die minimale
#Distanz zum nächsten Grünflächenzugang zugewiesen
min_cost_data = min_cost_origin.merge(build_df, left_on="origin_id",
right_on="fid", how="left")

#Falls es fehlende Werte gibt, werden diese mit 0 ersetzt
min_cost_data["Einwohner"] = min_cost_data["Einwohner"].fillna(0)

#Nur Distanzen unterhalb des Schwellenwerts werden bei der Berechnung berücksichtigt
min_cost_data = min_cost_data[min_cost_data["total_cost"] <= d0]

#Gewichtung der Einwohner auf Grundlage der Gauß-Funktion
min_cost_data["EinwohnerDruck"] = min_cost_data["Einwohner"] * (
    (np.exp(-0.5 * (min_cost_data["total_cost"] / d0)**2) - np.exp(-0.5)) / (1 - np.exp(-0.5)))

#Falls es fehlende Werte gibt, werden diese mit 0 ersetzt
min_cost_data["EinwohnerDruck"] = min_cost_data["EinwohnerDruck"].fillna(0)

#Aggregation des EinwohnerDruck nach Grünflächenzugängen
pop_pressure = min_cost_data.groupby("destination_id")["EinwohnerDruck"].sum().reset_index()

#Ids in Integer umwandeln
pop_pressure["destination_id"] = pop_pressure["destination_id"].astype(int)

#Falls es fehlende Werte gibt, werden diese mit 0 ersetzt
pop_pressure["EinwohnerDruck"] = pop_pressure["EinwohnerDruck"].fillna(0)

#Speichern der Daten im Layer
for index, row in pop_pressure.iterrows():
    feat = QgsFeature()
    feat.setGeometry(QgsGeometry())
    feat.setAttributes([int(row["destination_id"]), float(row["EinwohnerDruck"])])
    temp_layer_data_provider.addFeature(feat)

```



```

#Fortschrittsleiste aktualisieren
task.setProgress((i + 1) / len(os.listdir(output_directory)) * 100)

#Wenn die Task abgebrochen wurde, wird eine Nachricht ausgegeben
if task.isCanceled():
    QgsMessageLog.logMessage("Task was canceled", MESSAGE_CATEGORY, Qgis.Info)
    return None

#Dem Layer mit den Grünflächenzugängen werden
#die berechneten Einwohnerdruck-Werte hinzugefügt
join_params = {
    "INPUT": entrances_layer,
    "FIELD": "fid",
    "INPUT_2": temp_layer,
    "FIELD_2": "destination_id",
    "METHOD": 1,
    "DISCARD_NONMATCHING": False,
    "PREFIX": "joined_",
    "OUTPUT": "memory:"
}

#Ausführen des Prozess
entrances_layer = processing.run("native:joinattributetable", join_params)["OUTPUT"]

#Dateien speichern und in QGIS laden
distances.to_csv(r"C:\Users\hendr\Downloads\splitb\distances.csv", index=False)
csv_layer = QgsVectorLayer(r"C:\Users\hendr\Downloads\splitb\distances.csv", "Distances", "ogr")
QgsProject.instance().addMapLayer(csv_layer)
QgsProject.instance().addMapLayer(temp_layer)
QgsProject.instance().addMapLayer(entrances_layer)

#Funktion, die darüber informiert, wenn alle Berechnungen durchgeführt wurden
def workdone():
    QgsMessageLog.logMessage("All tasks are done!", MESSAGE_CATEGORY, Qgis.Info)

# Erstelle die Task und füge sie zur TaskManager-Warteschlange hinzu
task = QgsTask.fromFunction("heavy function", heavyFunction, on_finished=workdone)
QgsApplication.taskManager().addTask(task)

```

## Anhang 4: 2. Schritt 2SFCA-Methode

```
import pandas as pd
import numpy as np

#Funktion zur Berechnung der Accessibility
def calculate_weighted_einwohnerdruck(file_path, d0, output_file="weighted_einwohnerdruck_result.csv"):

    #Daten laden und Datentypen anpassen
    data = pd.read_csv(file_path, dtype={"origin_id": int}, decimal=".")
    data["total_cost"] = pd.to_numeric(data["total_cost"], errors="raise")
    data["QueryLayer_2_ratio"] = pd.to_numeric(data["pressure"], errors="raise")

    #Nur Distanzen unterhalb des Schwellenwerts werden berücksichtigt
    data = data[data["total_cost"] < d0]

    #Für jedes Wohngebäude wird die kürzeste Distanz zu jeder Grünfläche gefiltert
    min_cost_data = data.loc[data.groupby(["origin_id", "osm_id"])["total_cost"].idxmin()]

    #Berechnung der Gewichtung auf Grundlage der Gaußfunktion
    min_cost_data["weight"] = (np.exp(-0.5 * (min_cost_data["total_cost"]
    / d0)**2) - np.exp(-0.5)) / (1 - np.exp(-0.5))
    min_cost_data["weight"] = np.clip(min_cost_data["weight"], 0, 1)

    #Berechnung der Accessibility
    min_cost_data["weighted_Einwohnerdruck"] = min_cost_data["weight"] * min_cost_data["pressure"]
    final_result = min_cost_data.groupby("origin_id", as_index=False)["weighted_Einwohnerdruck"].sum()

    #Daten werden als csv-Datei gespeichert
    final_result.to_csv(output_file, index=False)
    print(f"Ergebnis als CSV-Datei gespeichert: {output_file}")

    return final_result

#Ausführen der Berechnung für den Datensatz
file_path = "distances.csv"
d0_value = 1000 #Schwellenwert
output_file = "Accessibility.csv"

calculate_weighted_einwohnerdruck(file_path, d0_value, output_file)
```

## Anhang 5: Netzwerkanalyse Teil 1

```
import pandas as pd
import networkx as nx
import geopandas as gpd
from shapely.geometry import Point, LineString

#Dateipfade definieren
file_path_data = "my-data.csv"
file_orgin_data = "Gebaeude_Einwohner_Centroide.gpkg"
file_dest_data = "Gruenflaechen_Zugaenge_Bonn.gpkg"
file_park_data = "Gruenflaechen_Bonn.gpkg"

#Schwellenwert
d0 = 1000

#Daten laden
origin_data = gpd.read_file(file_orgin_data)
dest_data = gpd.read_file(file_dest_data)
park_data = gpd.read_file(file_park_data)
path_data = pd.read_csv(file_path_data, dtype = {"origin_id": int}, decimal = ".")

#Koordinatenreferenzsysteme anpassen
origin_data = gpd.read_file(file_orgin_data).to_crs(epsg=3035)
dest_data = gpd.read_file(file_dest_data).to_crs(epsg=3035)
park_data = gpd.read_file(file_park_data).to_crs(epsg=3035)

#IDs beginnend mit 1 für Grünflächenzugänge erstellen
dest_data["id"] = dest_data.index + 1

#Datentypen anpassen
path_data["origin_id"] = path_data["origin_id"].astype(int)
path_data["destination_id"] = path_data["destination_id"].astype(int)
park_data["osm_id"] = park_data["osm_id"].astype(int)
dest_data["osm_id"] = dest_data["osm_id"].astype(int)

#Für jede Kombination von Gebäude und Grünfläche wird die kürzeste Distanz ausgewählt
min_cost_data = path_data.loc[path_data.groupby(["origin_id", "osm_id"])["total_cost"].idxmin()]

#Netzwerk wird initialisiert
G = nx.Graph()

#Knoten(Gebäude) aus origin_data hinzufügen
for idx, row in origin_data.iterrows():
    point_id = row["id"]
    point_geom = row["geometry"]
    point_pop = row["Einwohner"]
    point_type = "origin"
    x, y = point_geom.x, point_geom.y
    G.add_node(point_id, point_type=point_type, point_pop = point_pop, pos=(x, y))

#IDs für Grünflächen erstellen
offset = len(G.nodes) + 1
park_data["adjusted_id"] = park_data["osm_id"] + offset
```

```

#Knoten (Grünflächen) aus dest_data hinzufügen
for idx, row in park_data.iterrows():
    point_id = row["adjusted_id"]
    point_geom = row["geometry"].centroid
    point_area = row["area"]
    point_type = "destination"
    x, y = point_geom.x, point_geom.y
    G.add_node(point_id, point_type=point_type, point_area = point_area, pos=(x, y))

#Kanten hinzufügen, wenn die Distanz <= d0
for idx, row in min_cost_data.iterrows():
    origin_id = row["origin_id"]
    dest_id = row["destination_id"]
    distance = row["total_cost"]

    osm_id = dest_data.loc[dest_data["id"] == dest_id, "osm_id"].values
    if osm_id.size > 0:
        osm_id = osm_id[0]
        new_osm_id = osm_id + offset

    # Überprüfe, ob die Knoten im Graphen existieren
    if origin_id in G.nodes and new_osm_id in G.nodes:

        origin_type = G.nodes[origin_id]["point_type"]
        dest_type = G.nodes[new_osm_id]["point_type"]

        population = G.nodes[origin_id].get("point_pop", 0)
        area = G.nodes[new_osm_id].get("point_area", 1)

        # Berechnung der Local Significance
        if distance > 0:
            LS = (population * area) / (distance ** 2)

            # Nur Kanten zwischen Grünflächen und Gebäuden hinzufügen
            if origin_type == "origin" and dest_type == "destination" and distance <= d0:
                G.add_edge(origin_id, new_osm_id, weight=LS, distance = distance)

#Grad berechnen
degree = G.degree(weight="weight")
dict_degree = dict(degree)
nx.set_node_attributes(G, dict_degree, "degree")

```

```

#Berechnung der Detour-Index
min_cost_data["detour_index"] = None
for index, row in min_cost_data.iterrows():
    origin_id = row["origin_id"]
    dest_id = row["destination_id"]
    total_cost = row["total_cost"]

    if total_cost < 1000:
        dest_point = dest_data.loc[dest_data["id"] == dest_id, "geometry"].values[0]
        origin_point = origin_data.loc[origin_data["id"] == int(origin_id), "geometry"].values[0]

        #Berechne die direkte Entfernung
        dir_dist = origin_point.distance(dest_point)

        #Berechnung des Detour-Index
        if total_cost > 0:
            result = dir_dist / total_cost
            min_cost_data.at[index, "detour_index"] = result
        else:
            min_cost_data.at[index, "detour_index"] = None

    else:
        min_cost_data.at[index, "detour_index"] = None

#Datentyp nochmal anpassen
min_cost_data["detour_index"] = min_cost_data["detour_index"].astype(float)

#Berechnung des durchschnittlichen Detour Index pro origin_id
average_detour_index_df = (
    min_cost_data[min_cost_data["detour_index"].notnull()]
    .groupby("origin_id")["detour_index"]
    .mean()
    .reset_index()
    .rename(columns={"detour_index": "average_detour_index"})
)

#Umwandlung des DataFrames in ein Dictionary
average_detour_index_dict = {
    int(row["origin_id"]): row["average_detour_index"] for _, row in average_detour_index_df.iterrows()
}

#Knoten im Graph Detour-Index zuordnen
nx.set_node_attributes(G, average_detour_index_dict, "detour_index")

#Wenn kein Detour-Index zugewiesen wurde, wird None gespeichert
for node_id, data in G.nodes(data=True):
    if "detour_index" not in data:
        G.nodes[node_id]["detour_index"] = None

#Knoten als Punkte speichern
nodes = []
for node_id, data in G.nodes(data=True):
    point_geom = Point(data["pos"])
    nodes.append({
        "id": node_id,
        "point_type": data["point_type"],
        "degree": data["degree"],
        "detour_index": data["detour_index"],
        "geometry": point_geom
    })

```

```

#GeoDataFrame erstellen
nodes_gdf = gpd.GeoDataFrame(nodes, geometry="geometry", crs="EPSG:3035")

#Kanten als Linien speichern
edges = []
for u, v, data in G.edges(data=True):
    point_u = Point(G.nodes[u]["pos"]) # Startknoten
    point_v = Point(G.nodes[v]["pos"]) # Zielknoten
    line_geom = LineString([point_u, point_v]) # Linie zwischen den Knoten
    edges.append({
        "source": u,
        "target": v,
        "weight": data["weight"],
        "total_cost": data["distance"],
        "geometry": line_geom
    })

#GeoDataFrame erstellen
edges_gdf = gpd.GeoDataFrame(edges, geometry="geometry", crs="EPSG:3035")

#GeoDataFrame als GeoPackage speichern
output_path = "network_export.gpkg"
nodes_gdf.to_file(output_path, layer="nodes", driver="GPKG")
edges_gdf.to_file(output_path, layer="edges", driver="GPKG")

```

## Anhang 6: Netzwerkanalyse Teil 2

```
import pandas as pd
import geopandas as gpd
from sknetwork import data
from sknetwork.clustering import Leiden

#Dateipfade definieren
file_path_data = "my-data.csv"
file_orgin_data = "Gebaeude_Einwohner_Centroide.gpkg"
file_dest_data = "Gruenflaechen_ZUGaenge_Bonn.gpkg"
file_park_data = "Gruenflaechen_Bonn.gpkg"

#Schwellenwert
d0 = 1000 # Distanz-Schwelle

#Daten laden und Koordinatenreferenzsystem anpassen
origin_data = gpd.read_file(file_orgin_data).to_crs(epsg=3035)
dest_data = gpd.read_file(file_dest_data).to_crs(epsg=3035)
park_data = gpd.read_file(file_park_data).to_crs(epsg=3035)
path_data = pd.read_csv(file_path_data)

path_data["origin_id"] = path_data["origin_id"].astype(int)
path_data["destination_id"] = path_data["destination_id"].astype(int)
park_data["osm_id"] = park_data["osm_id"].astype(int)
dest_data["osm_id"] = dest_data["osm_id"].astype(int)

#IDs beginnend mit 1 für Grünflächenzugänge erstellen
dest_data["id"] = dest_data.index + 1

#IDs für Grünflächen erstellen
offset = len(origin_data)
park_data["adjusted_id"] = park_data["osm_id"] + offset

#Edge-Liste erstellen
edges = []

#Einzigartige IDs extrahieren
unique_origin_ids = path_data["origin_id"].unique()
unique_dest_ids = dest_data["osm_id"].unique() + offset

#Zuordnungstabellen für die IDs erstellen
origin_id_mapping = {old_id: new_id for new_id, old_id in enumerate(unique_origin_ids)}
dest_id_mapping = {old_id: new_id + len(unique_origin_ids) for new_id, old_id in enumerate(unique_dest_ids)}

#Für jede Kombination von Gebäude und Grünfläche wird die kürzeste Distanz ausgewählt
min_cost_data = path_data.loc[path_data.groupby(["origin_id", "osm_id"])["total_cost"].idxmin()]
```

```

#Kanten hinzufügen
for idx, row in min_cost_data.iterrows():
    origin_id = row["origin_id"]
    dest_id = row["destination_id"]
    distance = row["total_cost"]

    osm_id = dest_data.loc[dest_data["id"] == dest_id, "osm_id"].values
    if osm_id.size > 0:
        osm_id = osm_id[0]
        new_dest_id = dest_id_mapping.get(osm_id + offset, None)

    #Berechnung der Local Significance
    population = origin_data.loc[origin_data["id"] == origin_id, "Einwohner"].values[0]
    area = park_data.loc[park_data["adjusted_id"] == osm_id + offset, "area"].values[0]

    if new_dest_id is not None and distance > 0 and distance <= d0:
        LS = float((population * area) / (distance ** 2))
        new_origin_id = origin_id_mapping[origin_id]
        edges.append((new_origin_id, new_dest_id, LS))

# Erstellen der biadjacency-Matrix
biadjacency = data.from_edge_list(edges, bipartite=True)

#Community Detection
leiden = Leiden()
leiden.fit(biadjacency, force_bipartite = True)
labels_row = leiden.labels_row_
labels_col = leiden.labels_col_

#Labels den Gebäude-Ids zuordnen
origin_labels = pd.DataFrame({
    "origin_id": [k for k, v in origin_id_mapping.items()],
    "new_origin_id": [v for k, v in origin_id_mapping.items()],
    "cluster_label": labels_row
})

#Labels den Grünflächen-Ids zuordnen
labeled_osm_ids = [k - offset for k, v in dest_id_mapping.items() if v < len(labels_col)]
labeled_new_dest_ids = [v for k, v in dest_id_mapping.items() if v < len(labels_col)]
labeled_labels_col = labels_col[:len(labeled_osm_ids)]
dest_labels = pd.DataFrame({
    "osm_id": labeled_osm_ids,
    "new_dest_id": labeled_new_dest_ids,
    "cluster_label": labeled_labels_col
})

#Grünflächen mit den Labels verknüpfen
park_data_labeled = park_data.merge(dest_labels, on="osm_id", how="inner")
park_data_labeled = park_data_labeled[["osm_id", "geometry", "area", "cluster_label"]]

#Gebäude mit den Labels verknüpfen
origin_data_labeled = origin_data.merge(origin_labels, left_on="id", right_on="origin_id")
origin_data_labeled = origin_data_labeled[["origin_id", "geometry", "Einwohner", "cluster_label"]]

#Speichern der Daten als Geopackage
origin_data_labeled.to_file("origin_data_labeled.gpkg", layer="origin_data_clustered", driver="GPKG")
park_data_labeled.to_file("park_data_labeled.gpkg", layer="park_data_clustered", driver="GPKG")

```



## Anhang 7: Abbildungen

```
import matplotlib.pyplot as plt
import geopandas as gpd
import seaborn as sns
import numpy as np
import matplotlib.pyplot as plt

#Abbildung 4:
def G(d_kj, d_0=1000):
    if d_kj <= d_0:
        return (np.exp(-0.5 * (d_kj / d_0) ** 2) - np.exp(-0.5)) / (1 - np.exp(-0.5))
    else:
        return 0

#Werte für d_kj von 0 bis 1000
d_kj_values = np.linspace(0, 1000, 1000)
G_values = [G(d_kj) for d_kj in d_kj_values]

#Plot
plt.plot(d_kj_values, G_values)
plt.xlabel(r"$ Netzwerkdistanz\ d_{kj}\ (m)$")
plt.ylabel("Gewichtung G")
plt.xlim(0, 1000)
plt.grid(True)
plt.show()

file_park_data = "combined_stats_2.gpkg"
stats = gpd.read_file(file_park_data).to_crs(epsg=3035)

#Abbildung 8:
#Ortsteile auswählen
selected_ortsteile = ["Bonn-Zentrum", "Nordstadt", "Bonn-Castell", "Südstadt"]

#Filtere die Daten für die ausgewählten Ortsteile
filtered_stats = stats[stats["ortsteil_bez"].isin(selected_ortsteile)]

#Boxplot für die ausgewählten Ortsteile tem
plt.figure(figsize=(6, 4))
sns.boxplot(
    data=filtered_stats,
    x="ortsteil_bez",
    y="weighted_E",
    showfliers=False,
    palette="coolwarm"
)

#Titel und Achsenbeschriftungen
plt.xlabel("Ortsteil", fontsize=10)
plt.ylabel("Accessibility", fontsize=10)

#Layout anpassen
plt.tight_layout()
plt.show()
```

```

#Abbildung 9:
#Ortsteile auswählen
selected_ortsteile = ["Gronau", "Kessenich", "Dottendorf"]

#Filtere die Daten für die ausgewählten Ortsteile
filtered_stats = stats[stats["ortsteil_bez"].isin(selected_ortsteile)]

#Boxplot für die ausgewählten Ortsteile
plt.figure(figsize=(6, 4))
sns.boxplot(
    data=filtered_stats,
    x="ortsteil_bez",
    y="weighted_E",
    showfliers=False,
    palette="coolwarm"
)

#Titel und Achsenbeschriftungen
plt.xlabel("Ortsteil", fontsize=10)
plt.ylabel("Accessibility", fontsize=10)

#Layout anpassen
plt.tight_layout()
plt.show()

```

```

#Abbildung 10:
#Ortsteile auswählen
selected_ortsteile = ["Brüser Berg", "Ückesdorf"]

#Filtere die Daten für die ausgewählten Ortsteile
filtered_stats = stats[stats["ortsteil_bez"].isin(selected_ortsteile)]

#Boxplot für die ausgewählten Ortsteile
plt.figure(figsize=(6, 4))
sns.boxplot(
    data=filtered_stats,
    x="ortsteil_bez",
    y="weighted_E",
    showfliers=False,
    palette="coolwarm"
)

#Titel und Achsenbeschriftungen
plt.xlabel("Ortsteil", fontsize=10)
plt.ylabel("Accessibility", fontsize=10)

#Layout anpassen
plt.tight_layout()
plt.show()

```

```

#Abbildung 11:
#Ortsteile auswählen
selected_ortsteile = ["Duisdorf", "Lengsdorf"]

#Filtere die Daten für die ausgewählten Ortsteile
filtered_stats = stats[stats["ortsteil_bez"].isin(selected_ortsteile)]

#Boxplot für die ausgewählten Ortsteile
plt.figure(figsize=(6, 4))
sns.boxplot(
    data=filtered_stats,
    x="ortsteil_bez",
    y="weighted_E",
    showfliers=False,
    palette="coolwarm"
)

#Titel und Achsenbeschriftungen
plt.xlabel("Ortsteil", fontsize=10)
plt.ylabel("Accessibility", fontsize=10)

#Layout anpassen
plt.tight_layout()
plt.show()

```

```

#Abbildung 12:
#Ortsteile auswählen
selected_ortsteile = ["Lannesdorf", "Mehlem"]

#Filtere die Daten für die ausgewählten Ortsteile
filtered_stats = stats[stats["ortsteil_bez"].isin(selected_ortsteile)]

#Boxplot für die ausgewählten Ortsteile
plt.figure(figsize=(6, 4))
sns.boxplot(
    data=filtered_stats,
    x="ortsteil_bez",
    y="weighted_E",
    showfliers=False,
    palette="coolwarm"
)

#Titel und Achsenbeschriftungen
plt.xlabel("Ortsteil", fontsize=10)
plt.ylabel("Accessibility", fontsize=10)

#Layout anpassen
plt.tight_layout()
plt.show()

```