

Hot or not?

Räumliche Analyse von Airbnb-Listings in Deutschland, Berlin,
Hamburg, München und Köln

Working Paper, 3

Julian Reif



Zusammenfassung

Die Buchungsplattform Airbnb ist weltweit zu einem relevanten Buchungskanal im Tourismus geworden. Mit Blick auf die vielfältigen sozio-ökonomischen Auswirkungen der Plattform ist die Kenntnis über die räumliche Lage des Airbnb-Angebotes von hoher Bedeutung. Für Deutschland gibt es bisher keine umfassende, auf die räumliche Verteilung des Airbnb-Angebotes abzielende Analyse. Der vorliegende Artikel untersucht daher die räumliche Konzentration von Airbnb-Angeboten in Deutschland und den vier einwohnerstärksten Städten Deutschlands. Neben visuellen Analysen werden mit Hilfe räumlicher Statistik erstmals Maßzahlen zur Airbnb-Konzentration vorgelegt. Dabei wird die Methodik der räumlichen Autokorrelation verwendet. Die Ergebnisse zeigen, dass es eine starke positive räumliche Konzentration des Airbnb-Angebotes gibt. Bundesweit zeigen sich über 2.200 statistisch signifikante Airbnb-Hotspots, die sich i. d. R. an der Verteilung der deutschen Großstädte orientieren. Der Blick auf die Millionenstädte ergibt ebenfalls ein starkes räumliches Konzentrationsmaß. In Berlin sind die Airbnb-Listings am stärksten konzentriert, gefolgt von Köln, Hamburg und München. Die Ergebnisse dienen als Grundlage für weitere Forschung und als Ansatz für planerische Fragestellungen.

Abstract

Airbnb has become a relevant booking channel for tourism. As the socio-economic impacts of the platform are much discussed, knowledge about the spatial location of Airbnb-Listings is of high importance. However, so far there is no comprehensive analysis of the spatial distribution of Airbnb offers in Germany. This paper, therefore, examines the spatial concentration of Airbnb in Germany and the four largest cities. For the first time, measures of Airbnb concentration are presented using spatial autocorrelation. Findings reveal that there is a strong spatial concentration of Airbnb-Listings in Germany and the four major cities with over a million inhabitants. We found over 2,200 statistically significant Airbnb hotspots, which are generally oriented towards the distribution of the major German cities. Furthermore, Airbnb offers are most concentrated in Berlin, followed by Cologne, Hamburg, and Munich. Results serve as a basis for further research and as an approach to planning issues.

Stichworte: Räumliche Autokorrelation, Moran's I, Airbnb-Listings, Big Data, Städtetourismus

Key words: Spatial Autocorrelation, Moran's I, Airbnb-Listings, Big Data, Urban Tourism

Autor

Julian Reif, Deutsches Institut für Tourismusforschung
E-Mail: reif@fh-westkueste.de

Zitationsempfehlung

Reif, J. (2022): *Hot or not? Räumliche Analyse von Airbnb-Listings in Deutschland, Berlin, Hamburg, München und Köln*. Heide/Holstein (Working Paper Series des Deutschen Instituts für Tourismusforschung, 3). 10.48590/t0pr-5t03.

Working Paper, 3

Dezember 2022

DOI: <https://doi.org/10.48590/t0pr-5t03>

Diese Publikation wurde intern begutachtet.

Impressum

Fachhochschule Westküste
Deutsches Institut für Tourismusforschung
Fritz-Thiedemann-Ring 20
25746 Heide

Telefon +49(0) 481 8555-566

Telefax +49(0) 481 8555-121

Working Paper Series des Deutschen Instituts für Tourismusforschung

ISSN 2749-1552 (Online)

Herausgeber:

Bernd Eisenstein, Christian Eilzer, Manon Krüger

Bibliografische Information der Deutschen Nationalbibliothek:

Die Deutsche Nationalbibliothek verzeichnet diese Publikation in der Deutschen Nationalbibliographie; detaillierte bibliographische Daten sind im Internet über <http://dnb.de> abrufbar.

© Deutsches Institut für Tourismusforschung, Heide, 2022

Inhaltsverzeichnis

1 Einführung	5
2 Theoretischer Rahmen.....	6
3 Räumliche Autokorrelation	7
3.1 Globale räumliche Autokorrelation	7
3.2 Lokale räumliche Autokorrelation	8
4 Datengrundlage, Datenbearbeitung und Vorgehensweise.....	10
5 Ergebnisse und Diskussion	10
5.1 Visuelle Analyse der räumlichen Verteilung von Airbnb-Angeboten in Deutschland	10
5.2 Geostatistische Analyse der räumlichen Verteilung von Airbnb-Angeboten in Deutschland	14
5.2.1 Globale räumliche Autokorrelation	14
5.2.2 Lokale räumliche Autokorrelation	15
6 Fazit und Ausblick.....	18
Literaturverzeichnis.....	20

Danksagung

Ich bedanke mich bei Bernd Eisenstein, Anne Köchling, Sylvia Müller, Dirk Schmücker (NIT) und Sabrina Seeler für die inhaltlichen Diskussionen sowie die hilfreichen Anregungen und Vorschläge für das Manuskript.

1 Einführung

Innerhalb weniger Jahre hat sich die Sharing Economy-Plattform Airbnb zu einem wichtigen Buchungsportal für Unterkünfte weltweit, aber auch im Deutschlandtourismus entwickelt und wird dabei als disruptive Innovation (Guttentag 2015) aufgefasst. Darüber hinaus gilt Airbnb als ein möglicher Katalysator von Overtourism (Dodds und Butler 2019) und muss daher insbesondere in Bezug auf die im Rahmen von Kurzzeitvermietungen vielfältig entstehenden sozial-räumlichen und ökonomischen Auswirkungen einer verstärkten Betrachtung unterzogen werden (Armas-Díaz, Smigiel und Janoschka 2021; Hall et al. 2022). Vor dem Hintergrund des new urban tourism-Diskurses (Sommer et al. 2019), bei dem u. a. „neue Städte-touristen“ (Stors 2014) Orte abseits klassischer Sehenswürdigkeiten besuchen (Füller und Michel 2014) und für die das Erleben alltäglicher Aktivitäten der urbanen Einwohner:innen einen möglichst authentischen Aufenthalt in der Stadt ausmacht (Maitland 2010), kann Airbnb als ein Treiber identifiziert werden, weshalb es zu Konflikten in den Wohngebieten der Einwohner:innen kommt. Das Portal sorgt durch das Angebot an Wohnungen nicht nur dafür, dass Tourist:innen an diesen alltäglichen Orten übernachten, sondern auch im Rahmen der buchbaren „Airbnb-Erlebnisse“ Aktivitäten durchführen können (Freytag und Kagermeier 2019; Sommer et al. 2019). Damit tritt das Unternehmen auch zu Reiseveranstaltern in Konkurrenz. Mit Blick auf das erhöhte Konfliktpotenzial und der Ansätze, Airbnb in Städten zu regulieren (Nieuwland und van Melik 2020) ist es angebracht, sich mit der räumlichen Konzentration von Airbnb in deutschen Städten bzw. in Deutschland insgesamt zu beschäftigen. Bislang gibt es jedoch keine Forschungsarbeit, die für deutsche Städte oder gar bundesweit die räumliche Verteilung von Airbnb-Angeboten analysiert und hinsichtlich der Konzentration statistische Maßzahlen ausweist. Insbesondere für die Hauptstadt Berlin ist eine klein-

räumige Analyse aufschlussreich, da viele Studien bereits die wichtige Rolle von Airbnb für die Stadt aufzeigen (Skowronnek, Vogel und Parnow 2015; Stors 2020; Duso et al. 2021; Gyódi und Nawaro 2021). Aber auch für die weiteren deutschen Millionenstädte Hamburg, München und Köln kann eine Analyse der räumlichen Muster von Airbnb neue Erkenntnisse über die räumliche Konzentration der Angebote der Onlineplattform liefern.

Ziel der vorliegenden Arbeit ist es, das räumliche Angebot von Airbnb in Deutschland insgesamt und in den deutschen Millionenstädten so zu analysieren, dass neben einer visuellen Analyse von Airbnb-Hotspots auf Basis thematischer Karten auch eine quantifizierende Aussage zur räumlichen Konzentration des Angebotes gegeben wird. Dafür wird anhand von Daten des Anbieters Airdna¹ für das Jahr 2019 die räumliche Verteilung der Airbnb-Listings (Angebote) mit Hilfe von räumlicher Autokorrelation analysiert. Die Ergebnisse sollen helfen, die räumliche Dimension von Airbnb-Angeboten in Deutschland besser zu verstehen und können eine Grundlage für weitere Forschung in diesem Bereich, aber auch ein Einstieg für planerische Fragestellungen sein.

Folgende Leitfragen wurden formuliert:

1. Verteilen sich die Listings von Airbnb bundesweit zufällig oder gibt es eine räumliche Autokorrelation (Clusterung)?
2. Lassen sich statistisch signifikante Hot- und Coldspots hinsichtlich der Airbnb-Lage in Deutschland ermitteln?
3. Wie stark sind Airbnb-Angebote in den Städten Berlin, Hamburg, München und Köln konzentriert und wo finden sich signifikante Hotspots wieder?

¹ <https://www.airdna.com/>.

2 Theoretischer Rahmen

Die Kurzzeitvermietung von privatem Wohnraum über digitale Plattformen ist erst seit rund zehn Jahren Gegenstand der touristischen Forschung. Das Unternehmen Airbnb, das bei den Forschungsarbeiten zu diesem Thema meist im Fokus steht, wurde 2007 gegründet und ab 2009 in den Medien online und offline diskutiert (Rao 2009). Eine der ersten akademischen Auseinandersetzungen mit dieser speziellen Form der Sharing Economy wurde 2013 von Guttentag (2015) erstellt. Die möglichen Auswirkungen des Privatvermietungsmarktes wurden bereits ab 2012 in San Francisco diskutiert (Said 2012). Ab 2013 stand ein erstes Skript zur Verfügung, mit dem es möglich war, die Website von Airbnb auszulesen (Daten-Scraping) und damit flächendeckende Daten zu den Listings auf der Plattform zu extrahieren und zu analysieren (Slee 2013). Diese Möglichkeit hatte zahlreiche Veröffentlichungen zu Städten auf der ganzen Welt zur Folge (Oses Fernández, Kepa Gerrikagoitia und Alzua-Sorzabal 2018). Bis heute deutlich erkennbar bleibt dabei der Fokus der Forschung auf den Städte-tourismus und die Wirkung von Airbnb in Städten (Schäfer und Hirsch 2017; Stors und Kagermeier 2017; Zekan, Önder und Gunter 2019; Petruzzi et al. 2020; Stors 2020; Xia, Yeh und Zhang 2020; Duso et al. 2021).

Guttentag (2019) zeigt bei seiner umfassenden Literaturanalyse sechs Kategorien auf, in denen zu Airbnb geforscht wird: (1) Gäste von Airbnb, (2) Gastgeber von Airbnb, (3) das Angebot und die Auswirkungen auf die Destination, (4) Regulierung von Airbnb, (5) Auswirkungen auf den Tourismussektor sowie (6) das Unternehmen selbst. Eine spezifisch auf den Raum bzw. auf die räumliche Lage von Airbnb-Angeboten oder die räumlichen Nachfragemuster von Airbnb abzielende Kategorie findet sich nicht. Allerdings gibt es bereits einige Arbeiten, die sich mit der geographischen Lage von Airbnb, insbesondere in Städten, auseinandersetzen. Diese Forschungsarbeiten zeigen auf, dass Angebote in städtischen Zentren dort zu finden sind, wo auch die touristischen Attraktionen und die entsprechende Infrastruktur vorhanden sind, also eine ähnliche räumliche Konzentration vorweisen, wie dies auch in der klassischen Hotellerie der Fall ist (Guttentag 2019). Dabei wird oftmals herausgestellt, dass sich Airbnb-Angebote vor allem in den von Gentrifizierungsprozessen betroffenen Stadtgebieten wiederfinden (Kagermeier 2021), also innenstadtnah liegen. Dies zeigen sowohl Arbeiten, die im europäischen Kontext angesiedelt sind, wie bspw. in Barcelona (Gutiérrez et al. 2017; Lagonigro, Martori und Aparicio 2020), als

auch Arbeiten, die sich mit der Situation in ausgewählten US-amerikanischen Städten befassen (Quattrone et al. 2018). Ein weiteres Prinzip, welches anhand der räumlichen Verteilung von Airbnb-Angeboten erkennbar wird, ist ein Zentrum-Peripherie-Gefälle (distance-decay): mit zunehmender Entfernung vom Stadtzentrum – exemplarisch an mehreren europäischen Städten belegt – nimmt die Anzahl der Airbnb-Listings ab (Gutiérrez et al. 2017; Quattrone et al. 2018; Oskam 2019; Smigiel et al. 2019). Weitere Faktoren, die die räumliche Nachfrage von Airbnb beeinflussen, lassen sich mit der Lage touristischer Attraktionen (Eugenio-Martin, Cazorla-Artiles und González-Martel 2019), dem Zugang oder der Entfernung zu öffentlichen Transportmitteln wie U-Bahnen, Flughäfen etc. (Ki und Lee 2019), Einkaufsmöglichkeiten oder aber auch dem Haus- und Wohnungsmarkt (bspw. Anzahl Zweitwohnungen etc.) der jeweiligen Region (Adamiak et al. 2019) zusammenfassen.

Für Deutschland gibt es nur wenige Studien, die sich mit der räumlichen Konzentration von Airbnb beschäftigen. Die Arbeit von Skowronnek, Vogel und Parnow (2015) bietet aufgrund der Datentiefe jedoch die Möglichkeit im Rahmen von thematischen Karten die räumliche Konzentration in Berlin, bspw. in Relation zur Einwohnerzahl, aufzuzeigen (Kagermeier 2021). Bisweilen finden sich für Berliner Airbnb-Listings auch Punkt-Darstellungen auf Datengrundlage von *Insideairbnb*² (Müller et al. 2019). Für die Stadt Hamburg belegt Brauckmann (2017), dass sich Airbnb-Angebote vor allem in den Stadtteilen Hamburg Neustadt, St. Georg, St. Pauli, Sternschanze und Altona/Ottensen wiederfinden und dazu führen können, Interessenskonflikte von Wohnen, Hotellerie und Sharing Economy zu schüren. Andere Arbeiten bestätigen die räumliche Konzentration der Airbnb-Listings in Hamburg in den genannten Vierteln (Reif, Horster und Schmücker 2021). Für die Stadt München wird ebenfalls eine Fokussierung auf die zentrumsnahen Innenstadtbezirke beobachtet (Namberger 2021).

Während bei den Analysen zu räumlichen Mustern von Airbnb in anderen europäischen Städten bereits Methoden der räumlichen Statistik angewendet wurden, bleiben die Analysen in Deutschland bislang deskriptiv. Dabei gibt es über die Deskription hinausgehende Ansätze aus der Spatial Data Analysis, die sich die Tourismusforschung bei der Betrachtung von Airbnb-Angeboten zu Nutze machen kann. Neben

² <http://insideairbnb.com/>.

Hotspot-Analysen mit Hilfe von Getis-Ord G_i^* -Statistiken ist hier insbesondere die räumliche Autokor-

relation (engl. spatial autocorrelation) zu nennen.

3 Räumliche Autokorrelation

Die Grundidee hinter der räumlichen Autokorrelation basiert auf dem „ersten Gesetz der Geographie“ von Tobler (1970, S. 236): „everything is related to everything else, but near things are more related than distant things.“ Bei der räumlichen Analyse von Punkt-Features (bspw. Hotels in einer Destination) ergibt sich daraus die Frage, ob diese Punkte zufällig im Raum verteilt sind oder einem bestimmten Muster folgen und ggf. vorhandene Punkthäufungen statistisch signifikant sind. Dabei können grundsätzlich drei Möglichkeiten unterschieden werden (Longley et al. 2008, S. 347):

1. Zufällig (random): Punkte sind zufällig verteilt und alle Orte im Raum sind gleich wahrscheinlich
2. Geclustert (clustered): Manche Orte im Raum sind wahrscheinlicher als andere
3. Dispers (dispersed): Das Muster ist verstreut (Dispersion)

Bei der räumlichen Autokorrelation handelt es sich um ein Prüfverfahren, das statistische Aussagen über diese drei Möglichkeiten erlaubt. Es dient dazu, räumliche Beziehungen zwischen Werten einer Variablen zu beschreiben, und wird definiert als die Korrelation der Ausprägungen einer Variablen mit sich selbst im Raum (Burt, Barber und Rigby 2009, S. 544). Während die normale Autokorrelation den Zusammenhang zwischen Messungen in aufeinanderfolgenden *Zeitintervallen* misst, erfasst die räumliche Autokorrelation also den Zusammenhang zwischen den Messungen in zunehmenden *räumlichen* Abständen (Kirilenko 2022). Räumliche Autokorrelation besteht immer dann „whenever a variable exhibits a regular pattern over space in which its values at a set of locations depend on values of the same variable at other locations.“ (Odland 1988, S. 7). Anders ausgedrückt: Wenn das Vorhandensein einer bestimmten Menge in einem Raum, bspw. in einer Gemeinde, das Vorhandensein einer Größe in benachbarten Gemeinden wahrscheinlicher oder unwahrscheinlicher macht, handelt es sich um räumliche Autokorrelation (Cliff und Ord 1973, S. 1). Für die räumliche Autokorrelation gibt es zwei

Messwerte:

1. Die *globale* räumliche Autokorrelation (Global Moran's I statistic) und
2. die *lokale* räumliche Autokorrelation (Anselin Local Moran's I), auch bekannt als LISA-Statistik (Local Indicators of Spatial Association) (Anselin 1995).

Beide Maßzahlen der räumlichen Autokorrelation werden als Inferenzstatistik verwendet (Kirilenko 2022). Bei beiden Verfahren wird also gegen die Nullhypothese getestet, dass das vorhandene räumliche Punktemuster zufällig verteilt ist.

3.1 Globale räumliche Autokorrelation

Die *globale* räumliche Autokorrelation (Global Moran's I) erlaubt Aussagen über die Konzentration über alle räumlichen Einheiten hinweg. Sie gibt demnach Auskunft darüber, ob es eine Clusterung gibt, nicht aber, wo diese aufzufinden ist (vgl. Abb. 1).³ Es handelt sich um eine Index-Berechnung, bei der drei Kennwerte generiert werden, deren Interpretation Aufschluss über den statistisch-räumlichen Zusammenhang⁴ geben:

1. Morans I-Indexwert,
2. p-Wert (Signifikanz-, Wahrscheinlichkeitswert) und
3. z-Wert (Standardabweichung).

Von einer starken räumlichen Autokorrelation wird gesprochen, wenn nahegelegene Werte einer Variablen in einer engen Beziehung zueinander stehen (Burt, Barber und Rigby 2009). Die räumliche Autokorrelation kann positiv oder negativ sein. Negative räumliche Autokorrelation liegt vor, wenn nahegelegene Variablen unähnlich sind (Burt, Barber und Rigby 2009). Der Morans I-Wert kann von -1 bis +1 reichen, wobei man bei Werten von +0,3 von einer starken positiven räumlichen Autokorrelation und bei Werten von -0,3 von einer stark negativen räumlichen Autokorrelation ausgehen kann (O'Sullivan und Unwin 2010, S. 206).

³ Für diese Aussage wird die lokale räumliche Autokorrelation genutzt (siehe Abschnitt 3.2).

⁴ „Wenn das Z-Ergebnis oder der p-Wert auf statistische Bedeutung hinweist, zeigt ein positiver Morans I-Indexwert eine Tendenz zur Cluster-Bildung und ein negativer Morans I-Indexwert eine Tendenz zur Streuung an.“ (ESRI 2021).

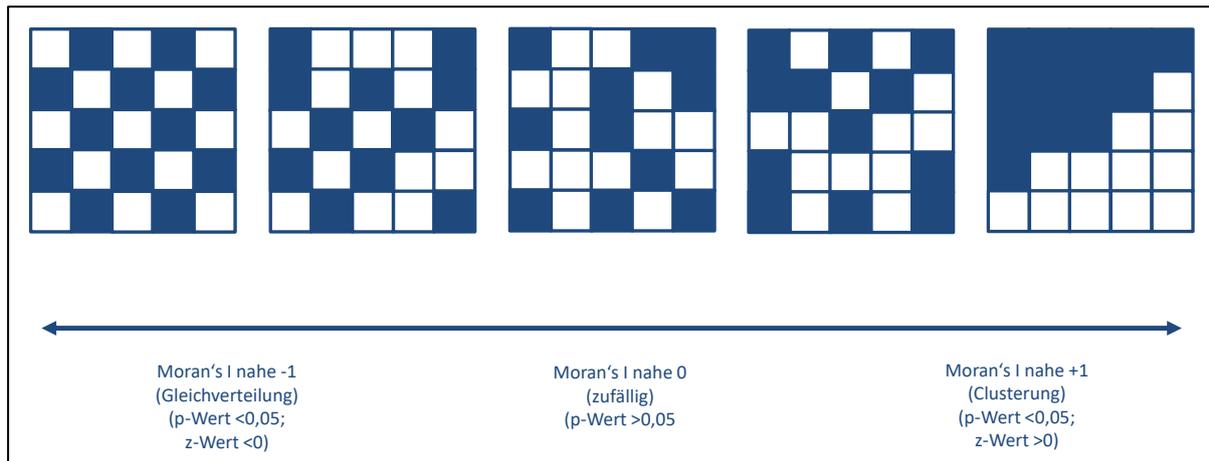


Abb. 1: Global Moran's I und räumliche Autokorrelation

(Quelle: Leicht verändert und eigene Übersetzung auf Basis von Grekousis 2020, S. 213.)

3.2 Lokale räumliche Autokorrelation

Während die globalen Indexwerte angeben, ob eine Clusterung vorliegt oder nicht, sind lokale Indizes in der Lage zu bestimmen, wo sich diese befinden. Die LISA-Statistik zur Berechnung der räumlichen Dichte von Flächen basiert auf dem von Moran (1950) entwickelten Autokorrelationsindex. Zur Berechnung wird nicht nur betrachtet, welche Messwerte eine zu betrachtende Region zeigt, sondern auch, welche Messwerte die jeweils angrenzenden Flächen aufweisen. Damit kann analysiert werden, ob eine Region in einem Cluster von anderen, im Hinblick auf den Messwert ähnlichen, Regionen zu finden ist. Um die benachbarten Flächen in die Berechnung einzu beziehen, wird ermittelt, ob der Messwert (im vorliegenden Beispiel die Anzahl der Airbnb-Angebote) für die betrachtete Region vom Mittelwert in positiver oder negativer Richtung abweicht und welche Abweichungen vom Mittelwert in den angrenzenden Regionen zu beobachten sind. Weisen die Abweichungen der betrachteten Region und der benachbarten Regionen in die gleiche Richtung, resultiert ein positiver lokaler Indexwert, bei gegenläufiger Abweichung ein negativer Indexwert und bei nur geringen Abweichungen ein Indexwert nahe 0. Entscheidend für die Anwendung und Interpretation von lokaler räumlicher Autokorrelation ist demnach

das Prinzip der räumlichen Nachbarschaft. Die Definition von räumlicher Nachbarschaft ist zentral, da sie maßgeblich die Ergebnisse der lokalen räumlichen Autokorrelation bestimmt. Räumliche Nachbarschaft kann dabei auf zwei Arten konzeptualisiert werden:

1. auf Basis angrenzender Nachbarn (contiguity-based) oder
2. auf Basis distanzbasierter Nachbarn (distance-based).

Bei der zweiten Möglichkeit werden räumliche Nachbarn anhand der Entfernung zueinander definiert, während bei der „contiguity-based“-Option davon ausgegangen wird, dass Region A ein Nachbar von Region B ist, sobald Region A an Region B angrenzt. Dabei gibt es wiederum zwei Möglichkeiten der Angrenzung:

1. Teilen einer Grenze *oder* eines Punktes (Queen) oder
2. Teilen einer gemeinsamen Grenze (Rook).

Bei der „Queen-Contiguity“ gibt es demnach mehr räumliche Nachbarn, die in die Untersuchung einbezogen werden können (Lloyd 2010, S. 57) (vgl. Abb. 2).

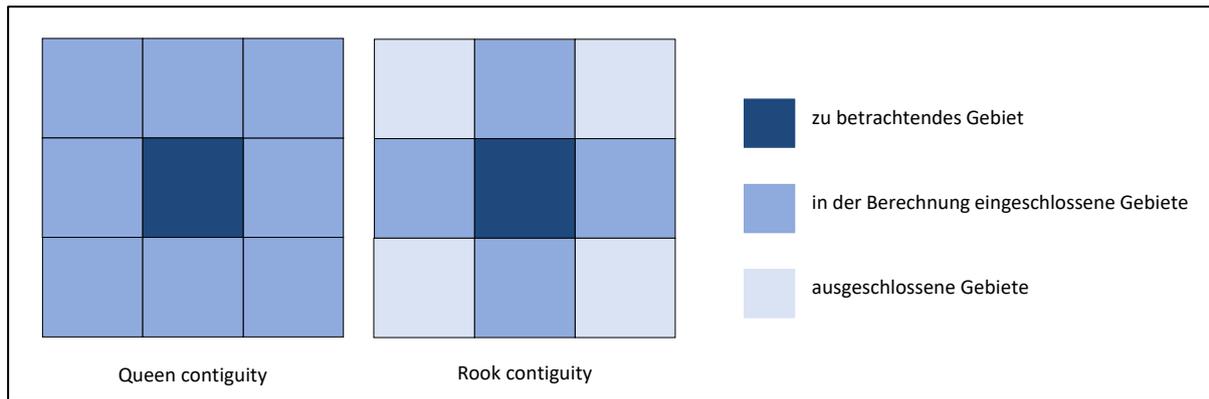


Abb. 2: Räumliche Nachbarn: Queen und Rook Contiguity
(Quelle: Leicht verändert und eigene Übersetzung auf Basis von Lloyd 2010, S. 57.)

Der wesentliche Vorteil der *lokalen* räumlichen Autokorrelation ist, dass jede Region anhand ihrer Beziehung zu den Nachbarregionen in eine von fünf Klassen eingeteilt werden kann. Es lassen sich Hotspots, Coldspots und Ausreißer identifizieren. Für Regionen der ersten beiden Klassen lässt sich ein raumstruktureller Effekt für die Ausprägung der Messwerte vermuten, während für die Klassen drei und vier eher individuelle Treiber zu vermuten sind.

1. **High-High:** Regionen mit hohem Messwert in einer Umgebung von Regionen mit ebenfalls hohen Messwerten („Hotspots“)
2. **Low-Low:** Regionen mit niedrigem Messwert in einer Umgebung von Regionen mit ebenfalls niedrigen Messwerten („Coldspots“)
3. **High-Low:** Regionen mit hohem Messwert in einer Umgebung von Regionen mit niedrigen Messwerten (ein „Ausreißer“ in die positive Richtung)
4. **Low-High:** Regionen mit niedrigem Messwert in einer Umgebung von Regionen mit hohen Messwerten (ein „Ausreißer“ in die negative Richtung)
5. **Nicht signifikant:** Regionen mit nur geringen Abweichungen vom Mittelwert

Räumliche Autokorrelation wird in der tourismusgeographischen Forschung u. a. angewendet, um statistisch signifikante Aussagen über die Verteilung von Touristenankünften zu tätigen (Stankov et al. 2017) oder auf Basis von Instagram-Bildern Tourismushotspots zu ermitteln (Paül i Agustí 2020). Hinsichtlich der räumlichen Verteilung von Airbnb-Angeboten können Arbeiten für einzelne europäische Städte wie Barcelona angeführt werden (Gutiérrez et al. 2017). Ein Ergebnis der Forschungen in den europäischen Städten ist, dass neben den Parametern Größe und Qualität die Lage ein entscheidender Treiber für Airbnb-Preise ist (Gyódi und Nawaro 2021). Auch finden sich Analysen, die abseits großer Metropolen die räumliche Verteilung von Airbnb-Angeboten mit Hilfe von räumlicher Autokorrelation untersuchen, bspw. auf den kanarischen Inseln (Eugenio-Martin, Cazorla-Artiles und González-Martel 2019).

4 Datengrundlage, Datenbearbeitung und Vorgehensweise

Die in der vorliegenden Studie genutzten Daten stammen vom kommerziellen Anbieter Airdna. Airdna liest die öffentlich verfügbaren Daten der Plattformen Airbnb und Homeaway von der jeweiligen Website ab (Data Scraping), veredelt diese und vertreibt sie weiter. Durch regelmäßiges Auslesen dieser Daten ist es möglich, nicht nur über das Angebot (Listings), sondern auch über die Nachfrage (Reservierungstage) je Listing Informationen zu erhalten (James 2018). Die für die vorliegende Arbeit genutzte Datengrundlage beinhaltet monatsweise die aus dem Web zusammengestellten Informationen für das Jahr 2019, bei der nur die Angebotsseite berücksichtigt wurde. In Summe konnten Daten über zwölf Monate von 340.127 Property IDs (Listings) von Airbnb ausgewertet werden. Zu jedem Listing gehört u. a. eine Längen- und Breitenangabe im WGS84-Format. Weitere aus diesem Datensatz stammende Analysen, bspw. zur Teilnahme deutscher Gemeinden am Übernachtungstourismus, finden sich in der Arbeit von Schmücker und Reif (2022).

Die in Abschnitt 3 vorgestellten statistischen Kenngrößen werden nun mit dem Ziel der Messung der räumlichen Konzentration der Airbnb-Listings in Deutschland und den vier größten Städten ange-

wendet. Die Daten wurden als CSV aus SPSS exportiert und als Punkt-Koordinaten in ArcGis eingelesen und mit einem Gemeinde-Layer hinterlegt. Im Rahmen der Analyse wurden sowohl die in ArcGis integrierten Spatial Statistics Tools als auch die Software GeoDa sowie QGIS genutzt. Für Deutschland sowie analog für die deutschen Metropolen wurde ein Hexagonraster⁵ mit der entsprechenden Ausdehnung der amtlichen Gebietsgrenzen generiert. Für Deutschland wurde eine Polyongröße von fünf Quadratkilometern, für die Metropolen Berlin, Hamburg, München und Köln von 0,05 Quadratkilometern gewählt. Mit der Join-Funktion erfolgte die Zählung der Summe der Listings je Polygon. Zunächst erfolgt eine visuelle Analyse der räumlichen Verteilung. Darauf folgend wird zunächst je Betrachtungsgebiet der globale Moran's I-Wert mit Hilfe des Tools „Räumliche Autokorrelation (Morans I)“ aus der ArcMap Spatial Statistics Toolbox berechnet und im Nachgang geprüft, wo es statistisch signifikante Hotspots der Airbnb-Listings gibt. Dabei kommt die „Cluster- und Ausreißeranalyse (Anselin Local Morans I)“ zum Einsatz. Nachbarschaften wurden hierbei als Queen-Contiguity konzeptualisiert. Die nachfolgende Analyse zeigt die Ergebnisse für Deutschland und die vier deutschen Millionenstädte.

5 Ergebnisse und Diskussion

5.1 Visuelle Analyse der räumlichen Verteilung von Airbnb-Angeboten in Deutschland

Bei der visuellen Analyse der räumlichen Muster von Airbnb-Listings in Deutschland fällt auf, dass diese der Verteilung der urbanen Räume folgt. Die Hexagone mit den meisten Listings lassen sich in den Metropolen Berlin, München, Hamburg und Köln identifizieren. Aber auch in Leipzig, Hannover oder Düsseldorf gibt es eine bemerkenswerte Anzahl an Airbnb-Angeboten

mit Hexagonen über 1.000 Listings. Im Vergleich dazu weist Berlin mit 6.537 Listings bundesweit das Hexagon mit den meisten Airbnb-Angeboten auf. Gleichzeitig zeigt sich, dass es sich bei der Verbreitung der Airbnb-Angebote nicht nur um ein städte-touristisches Phänomen handelt. Auch die Gebiete an der Nord- und Ostseeküste sowie im Alpenvorland weisen eine beachtliche Anzahl an Listings auf und sind auf der Karte deutlich zu erkennen (Abb. 3).

⁵ Zur Verwendung von Hexagonen im Vergleich zu Rechtecken siehe bspw. Birch, Oom und Beecham (2007). Hierbei ist wichtig zu betonen, dass es bei der Nutzung von anderen räumlichen Einheiten, bspw. von Rechtecken, Ortsteilen, statistischen Bezirken, Gemeindegrenzen oder Reisegebieten zu anderen Ergebnissen hinsichtlich der räumlichen Konzentration kommen kann.

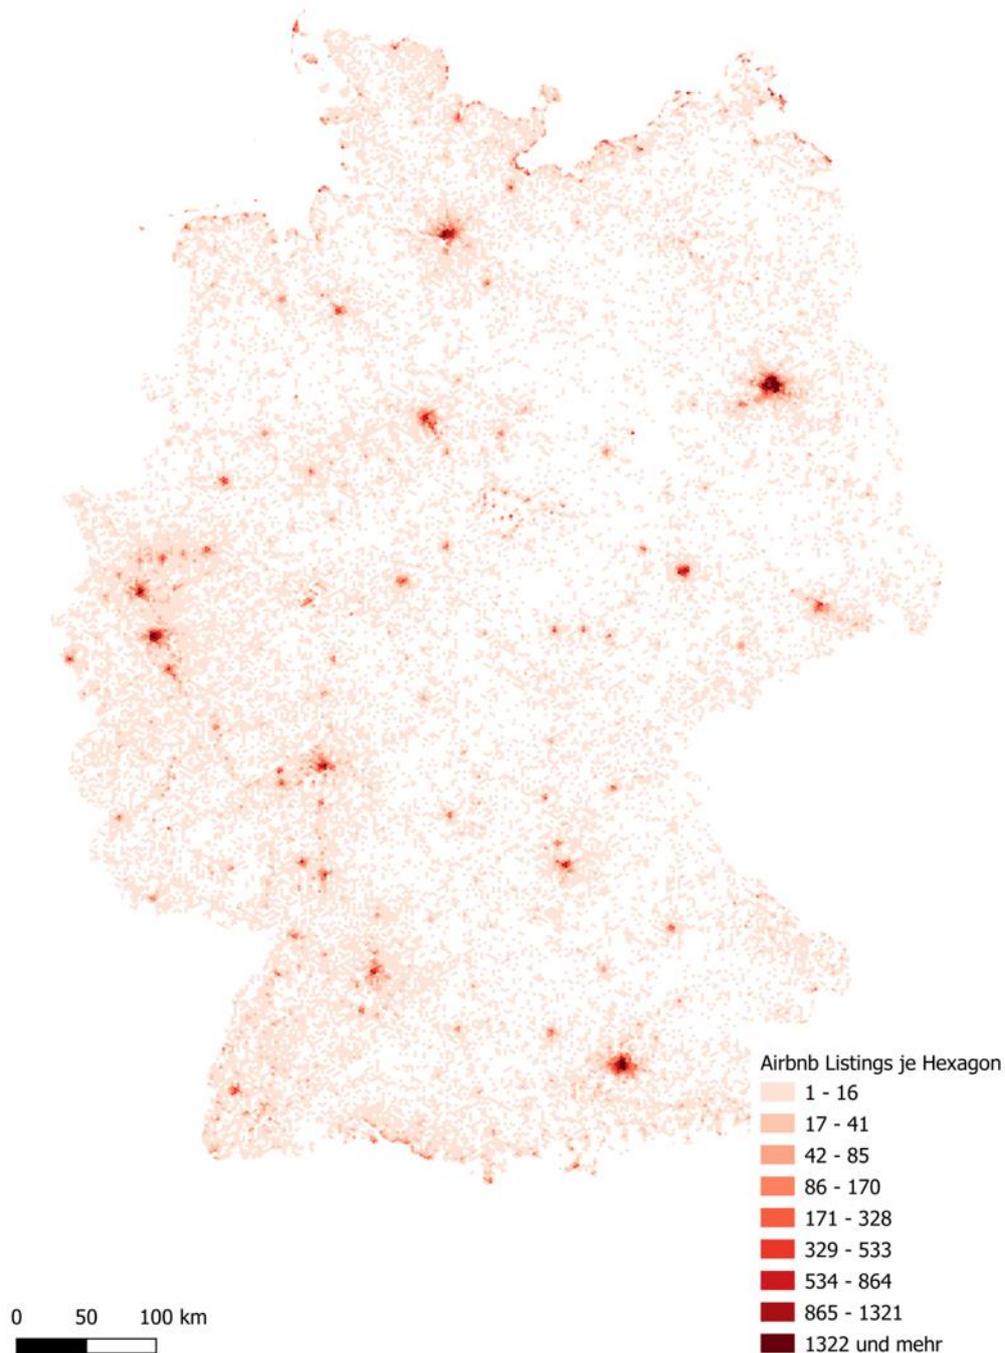


Abb. 3: Räumliche Verteilung von Airbnb-Listings in Deutschland 2019 nach Hexagonen (Quelle: Eigene Darstellung, Datengrundlage: Airdna.)

Die räumliche Verteilung der Airbnb-Listings in Berlin lässt bereits eine deutliche Clusterung vermuten (Abb. 4). Gut zu erkennen sind die Häufungen von Listings nördlich bzw. (süd)östlich vom Zentrum mit den Kiezen Prenzlauer Berg, Friedrichshain und Neukölln.

Die Außenbezirke von Berlin, insbesondere der Südwesten und der Südosten, weisen kaum Angebote von Airbnb auf. Zudem lässt sich bei der Betrachtung ein deutliches Zentrum-Peripherie-Gefälle der Angebote erkennen.

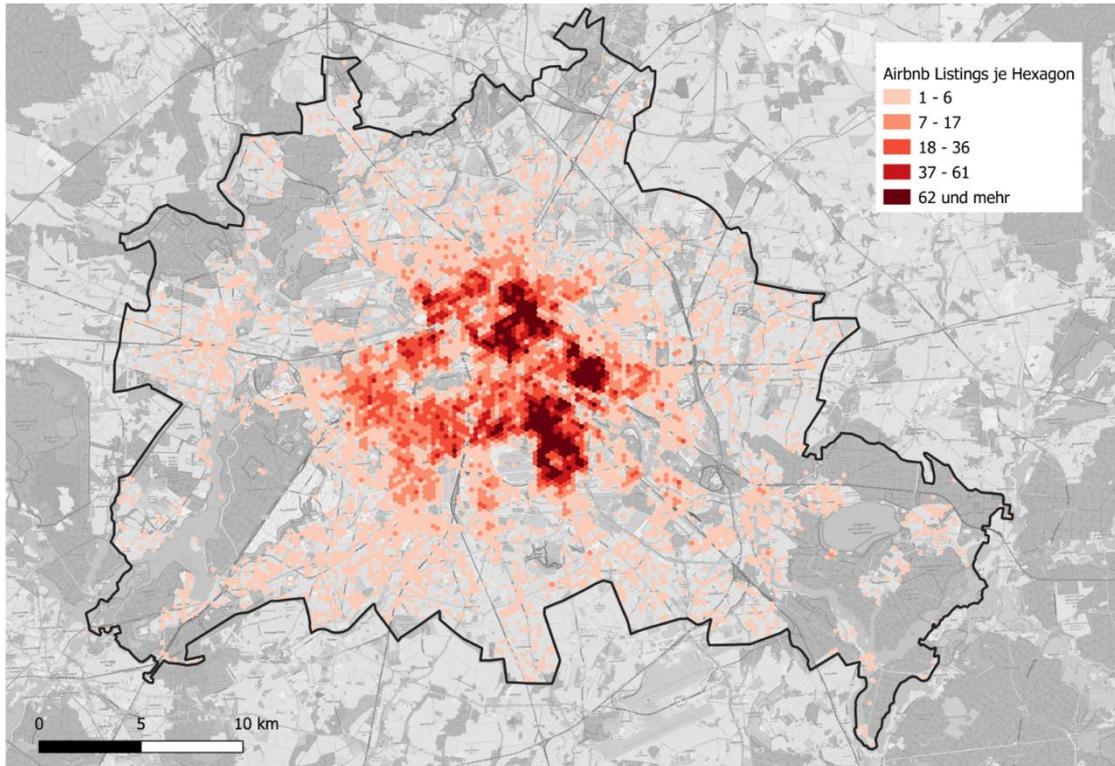


Abb. 4: Räumliche Verteilung von Airbnb-Listings in Berlin 2019 nach Hexagonen (Quelle: Eigene Darstellung. Datengrundlage: Airdna.)

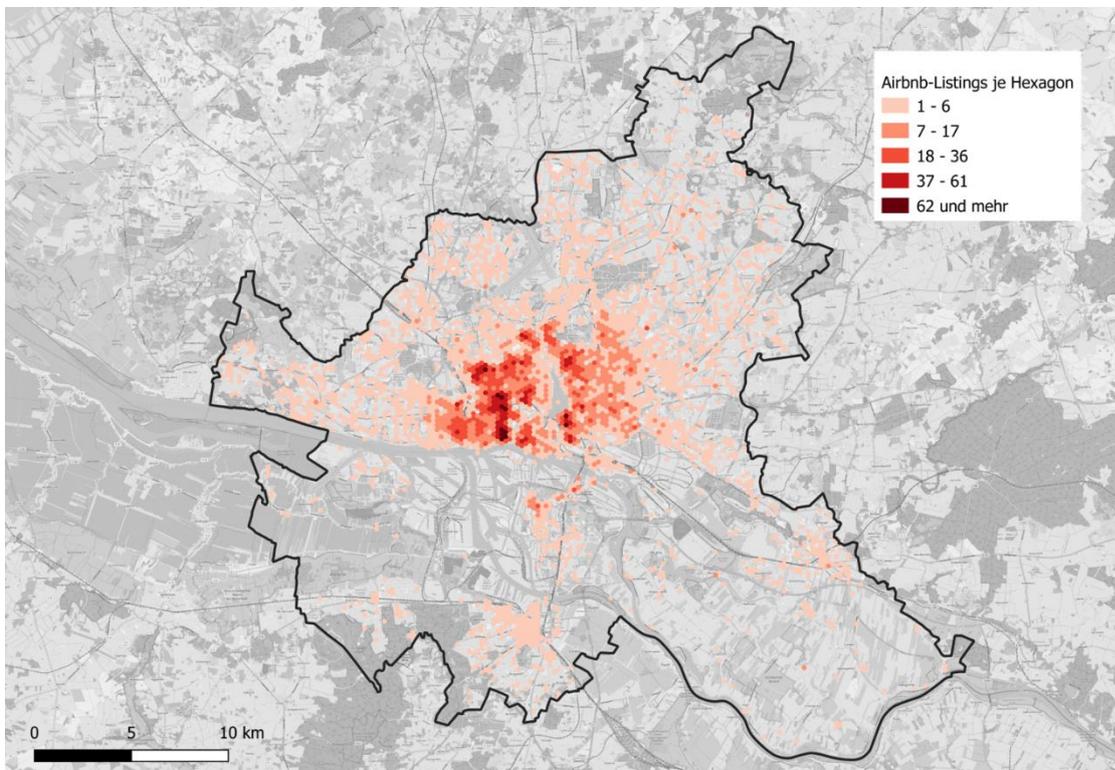


Abb. 5: Räumliche Verteilung von Airbnb-Listings in Hamburg 2019 nach Hexagonen (Quelle: Eigene Darstellung. Datengrundlage: Airdna.)

Auch die räumliche Verteilung von Airbnb-Listings in Hamburg (vgl. Abb. 5) lässt eine Clusterung erkennen. Im Wesentlichen weist die nördliche Stadthälfte Angebote auf, während südlich der Elbe nur vereinzelt Angebote zu finden sind. Auch die Listings in Hamburg finden sich maßgeblich in den Kiezen wieder – allen voran in St. Pauli/Sternschanze, aber auch in St. Georg. Die Angebotsdichte nimmt auch in Hamburg vom Zentrum hin zu den Außenbezirken ab.

Die visuelle Analyse der Listings in München (vgl. Abb. 6) lässt vermuten, dass die Stadt auf den ersten Blick –

vor allem im Vergleich zu den anderen Metropolen – eine weniger starke Clusterung der Listings vorweist. Der Englische Garten und der Schlosspark Nymphenburg durchschneiden die sonst fast flächendeckende Verbreitung von Airbnb in der Stadt. Auch in der bayerischen Hauptstadt zeigen sich Hotspots wie bspw. in der Maxvorstadt und um die TU München, südöstlich von der Theresienwiese am Schlachthof/Goetheplatz und im Westend. In der Münchner Altstadt hingegen finden sich zwar auch Listings, aber weit weniger als in den umliegenden Vierteln.

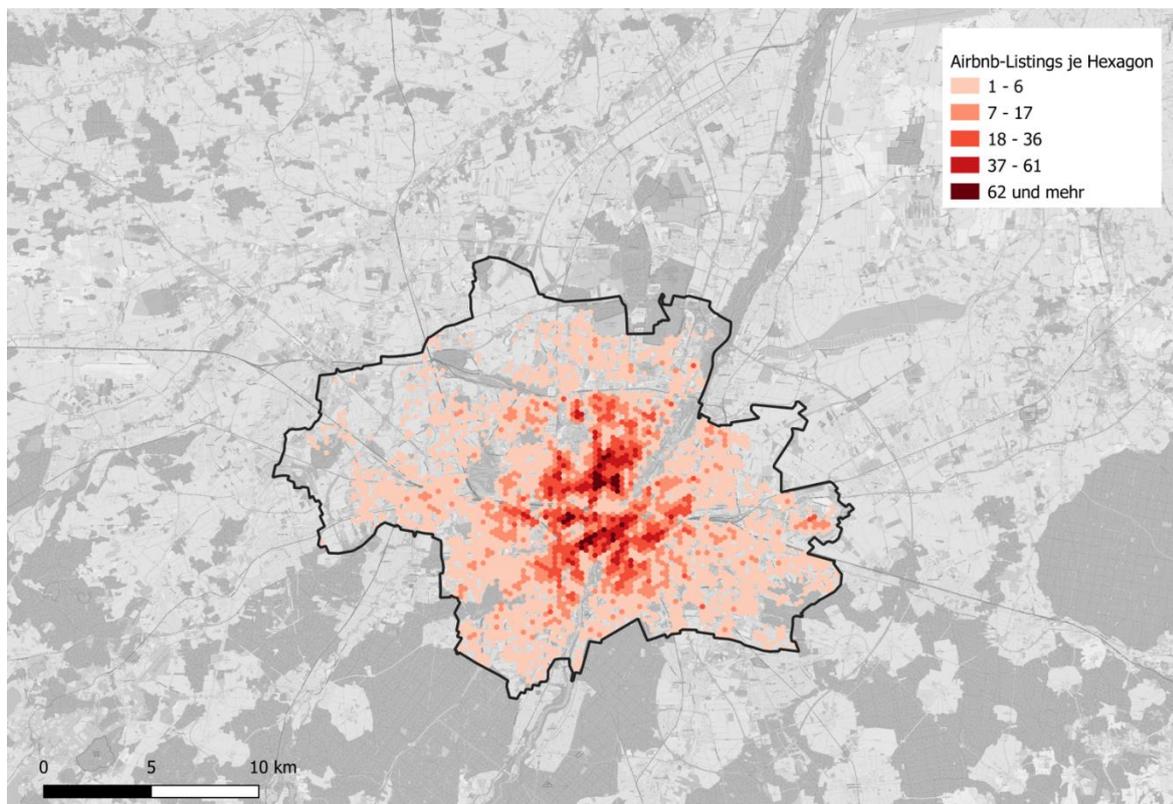


Abb. 6: Räumliche Verteilung von Airbnb-Listings in München 2019 nach Hexagonen (Quelle: Eigene Darstellung. Datengrundlage: Airdna.)

In Köln (vgl. Abb. 7) zeigt sich eine Art ringförmige Ausbreitung der Listings auf dem linken Rheinufer. Zwar lassen sich auch rechtsrheinisch Airbnb-Angebote – vor allem in Deutz – erkennen, die meisten Airbnb-Listings befinden sich jedoch in einem Ring ausgehend vom Agnesviertel im Norden über das Belgische Viertel bis hin zum Studentenviertel und der Südstadt.

In Summe weist die visuelle Analyse der Angebote in Deutschland und den einzelnen Städten eine deutliche Konzentration von Airbnb auf. Der nachfolgende Abschnitt zeigt mittels räumlicher Statistik, ob die identifizierten Konzentrationen statistisch signifikant sind.

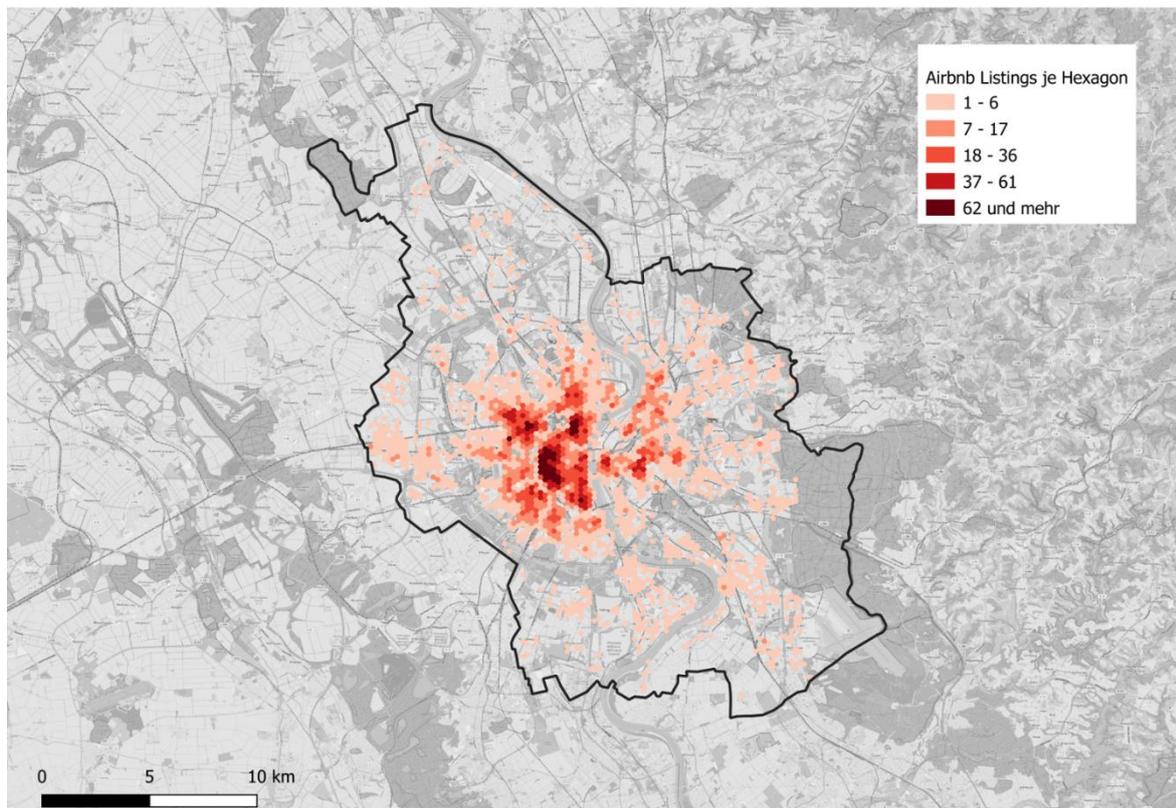


Abb. 6: Räumliche Verteilung von Airbnb-Listings in Köln 2019 nach Hexagonen (Quelle: Eigene Darstellung. Datengrundlage: Airdna.)

5.2 Geostatistische Analyse der räumlichen Verteilung von Airbnb-Angeboten in Deutschland

5.2.1 Globale räumliche Autokorrelation

Bevor kontrolliert wird, ob die in Deutschland insgesamt, aber auch in den deutschen Metropolen gefundenen Punkthäufungen von Airbnb-Angeboten statistisch signifikant sind, wird zunächst geprüft, ob überhaupt eine Tendenz zur Clusterung vorliegt. Hierzu werden für das Feature der Listings mit dem Tool „Räumliche Autokorrelation (Morans I)“ aus der ArcMap Spatial Statistics Toolbox der globale, also über den gesamten Datensatz in Deutschland bzw. in den Städten bestehende, Morans I-Wert sowie ein z-Wert und ein p-Wert berechnet.

Die Ergebnisse zeigen sowohl für Deutschland insgesamt als auch für die hier untersuchten Großstädte einen positiven Moran's I-Index mit jeweils einer stark

signifikanten positiven räumlichen Autokorrelation (vgl. Tab. 1). Es kann also davon ausgegangen werden, dass sowohl in Deutschland als auch in den vier untersuchten Metropolen eine Wahrscheinlichkeit von unter 1% besteht, dass das gefundene Muster von Airbnb ein zufälliges Ergebnis ist. Anders formuliert: Es gibt sowohl in Deutschland als auch in den deutschen Städten Berlin, Hamburg, München und Köln eine Clusterung des Airbnb-Angebotes bzw. eine positive räumliche Autokorrelation. Dabei weisen alle vier Städte eine überdurchschnittliche Konzentration von Airbnb-Angeboten auf, wobei die Konzentration von Angeboten in Berlin (Moran's I-Index: 0,835) am höchsten ist, gefolgt von Köln, Hamburg und München. Dies bestätigt die Ergebnisse aus der visuellen Analyse, wonach die Angebote von Airbnb in München weniger stark konzentriert sind als in Berlin oder Hamburg.

	Deutschland	Berlin	Hamburg	München	Köln
Anzahl Hexagone	73.068	18.424	15.275	6.515	8.476
Anzahl Listings	340.127	61.144	18.118	25.094	16.538
Listings pro Hexagon	4,7	3,3	1,2	3,9	2,0
Global Moran's I-Index	0,622	0,835	0,774	0,760	0,792
z-Wert	294,3	193,3	162,8	103,8	124,04
p-Wert	p<0.01	p<0.01	p<0.01	p<0.01	p<0.01

Tab. 1: Übersicht globale räumliche Autokorrelation von Airbnb-Listings in Deutschland 2019
(Quelle: Eigene Berechnung und Darstellung. Datengrundlage: Airdna.)

5.2.2 Lokale räumliche Autokorrelation

Die Anselin Local Morans I-Statistik produziert als Ergebnis bundesweit 2.277 statistisch signifikante Airbnb-Hotspots in Deutschland (High-High-Cluster) (vgl. Tab. 2). Dabei handelt es sich um Hexagone mit einer hohen Anzahl von Airbnb-Listings, die von Hexagonen mit einer ebenfalls hohen Anzahl von Listings umgeben sind. Daneben gibt es 147 High-Low-Ausreißer, also Hexagone mit einer hohen Anzahl an Listings, die jedoch von Hexagonen mit wenigen Listings umgeben sind. Bundesweit lassen sich zudem 890 statistisch signifikante Low-High-Ausreißer iden-

tifizieren. Dabei handelt es sich um Hexagone mit einer niedrigen Anzahl von Airbnb-Listings, die wiederum in direkter Nachbarschaft von Hexagonen mit einer hohen Anzahl von Listings liegen. Es ergeben sich lediglich 24 Hexagone mit einer niedrigen Anzahl von Listings, die sich neben Hexagonen mit einer ebenfalls niedrigen Anzahl von Listings befinden (Low-Low-Cluster) (Coldspots). Bei 95,4% aller Hexagone handelt es sich um eine zufällige Verteilung des Airbnb-Angebotes in Deutschland bzw. um Hexagone ohne Airbnb.

	Deutschland	Berlin	Hamburg	München	Köln
High-High-Cluster	2.277 (3,1%)	1.191 (6,5%)	803 (5,3%)	589 (9,0%)	495 (5,8%)
High-Low-Ausreißer	147 (0,2%)	1 (0,01%)	26 (0,2%)	3 (0,05%)	7 (0,1%)
Low-High-Ausreißer	890 (1,2%)	24 (0,1%)	55 (0,4%)	17 (0,3%)	21 (0,2%)
Low-Low-Cluster	24 (0,03%)	0 (0%)	0 (0%)	1.736 (26,6%)	0 (0%)
nicht signifikant	69.725 (95,4%)	17.208 (93,4%)	14.391 (94,2%)	4.170 (64,0%)	7.953 (93,8%)

Tab. 2: Übersicht lokale räumliche Autokorrelation von Airbnb-Listings in Deutschland 2019
(Quelle: Eigene Berechnung und Darstellung. Datengrundlage: Airdna. Einstellungen: Räumliche Beziehungen: Queen-Contiguity; Row-Standardization.)

In Abb. 8 deutlich zu erkennen sind die High-High-Cluster. Sie spiegeln i. d. R. die urbanen Gebiete Deutschlands wider. Die Low-High-Ausreißer finden sich entsprechend ringförmig um die angebotsstarken Bereiche wieder. Die High-Low-Ausreißer liegen bundesweit verstreut, insbesondere in den ländlichen Gebieten bspw. im Teutoburger Wald oder im Fläming in Brandenburg.

Im Abgleich mit den Ergebnissen der visuellen Analyse bestätigen sich die Hotspots in den deutschen Metropolen auch bei der lokalen räumlichen Autokorrelation: In Berlin gibt es bspw. 1.191 High-High-Cluster. Diese liegen zentral in Berlin. Vereinzelt Low-High-Cluster befinden sich ebenfalls im Berliner Zentrum. Es existiert lediglich ein signifikanter High-Low-Ausreißer südlich des Zentrums im Bereich Tempelhof. Die starke räumliche Autokorrelation der Airbnb-Angebote in Berlin lässt sich zudem anhand

eines Moran's I Streudiagramms ablesen (Abb. 9). Jeder Punkt im Diagramm steht für eine räumliche Einheit, in diesem Falle die Hexagone in Berlin. Auf der x-Achse wird die Summe der Listings je Hexagon abgetragen und auf der y-Achse die Summe der Listings, welche durch Mittelwertbildung an den Nachbarn des jeweiligen Hexagons berechnet wird (Lag-X-Variable). Jedes Hexagon hat demnach einen Merkmalswert (Summe der Listings) und einen entsprechenden Spatial-lag-Wert. Im Quadranten oben rechts werden die Hexagone angezeigt, bei denen es sich um High-High-Cluster handelt. Diese Hexagone haben einen hohen x-Wert und sind von weiteren Hexagonen umgeben, die ebenfalls hohe x-Werte, also eine hohe Anzahl an Listings, besitzen. Demnach ist auch der Durchschnittswert dieser benachbarten Hexagone hoch (positive räumliche Autokorrelation).⁶

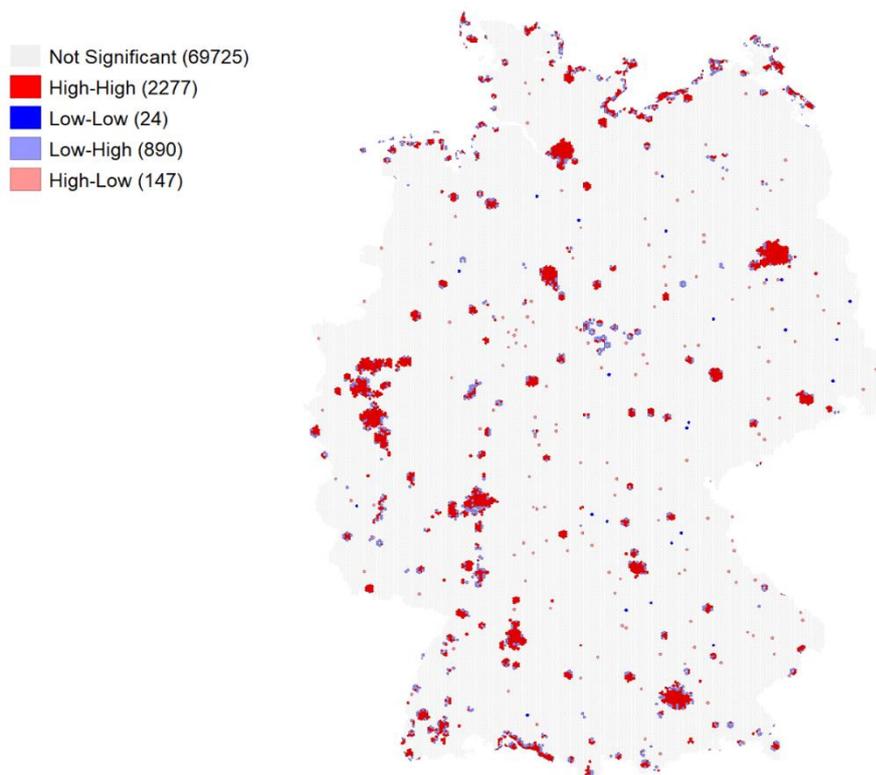


Abb. 8: Räumliche Cluster von Airbnb-Listings in Deutschland 2019
(Quelle: Eigene Darstellung mit GeoDa. Datengrundlage: Airdna.)

⁶ Für eine tiefere Interpretation des Moran's I Streudiagramms sei auf Grekousis (2020, 213f) verwiesen.

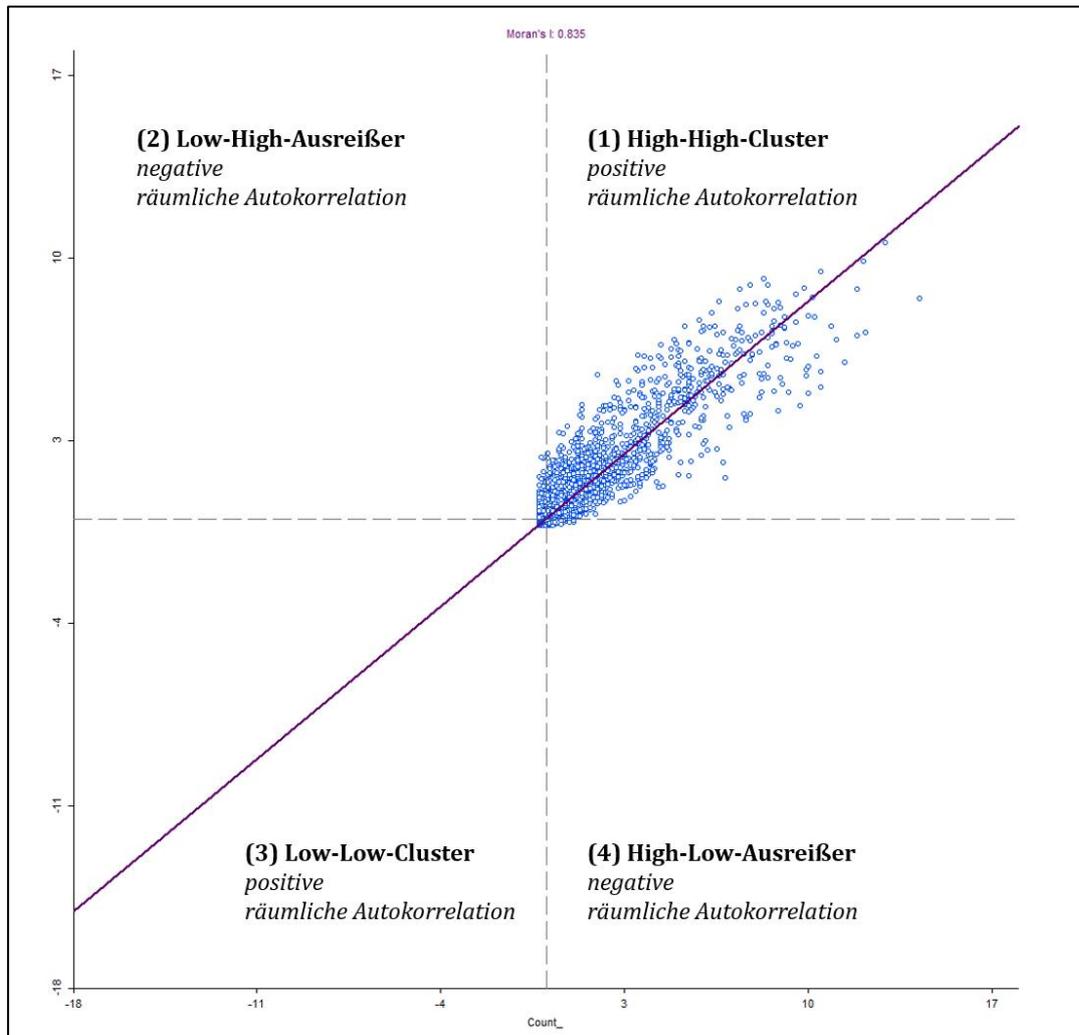


Abb. 9: Morans Streudiagramm für Berlin

(Quelle: Eigene Darstellung auf Grundlage von GeoDa. Datengrundlage: Airdna.)

Der in der Literatur bereits in anderen Großstädten nachgewiesene Distance-Decay-Effekt bestätigt sich neben der visuellen Analyse auch anhand von konkreten Werten in Berlin. Von den 61.144 Listings liegen 64% lediglich 5 km vom geographischen Zentrum Berlins entfernt. Die Verteilung der Entfernungen (als prozentualer Anteil an der Gesamtzahl der Listings) kann mittels einer einfachen linearen Regression modelliert werden. Die Distanz zum Zentrum kann demnach zur Vorhersage der Lage von rund 70% (R^2) der Airbnb-Listings herangezogen werden.

Neben Berlin (6,5% High-High-Cluster) befinden sich auch in Hamburg (5,3%), München (9,0%) und Köln (5,8%) die Hotspots zentrumsnah (Abb. 10). Während Hamburg mit 26 High-Low-Clustern über die Stadtfläche verteilt signifikante Ansammlungen von Airbnb-Angeboten vorweist, ist dies bei den anderen Städten weniger der Fall. München gilt auch hier als Sonderfall: Die bayerische Hauptstadt zeigt nicht nur im Rahmen der visuellen Analyse, sondern auch bei Betrachtung der Moran's I-Maßzahl, eine heterogenere Verteilung der Airbnb-Angebote auf. Gebiete wie die Low-Low-Cluster (im Nordwesten) lassen sich in anderen Städten bislang in dieser Art nicht nachweisen (Abb. 10 und Tab. 2).

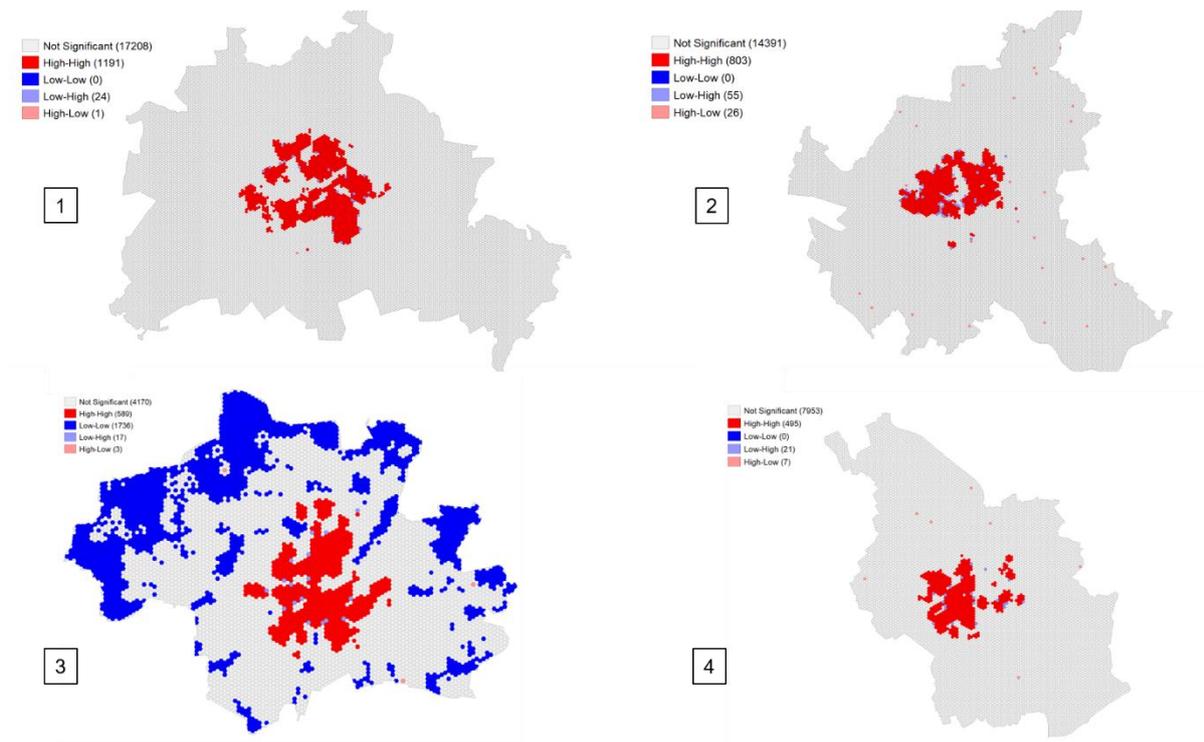


Abb. 10: Räumliche Cluster von Airbnb-Listings in (1) Berlin, (2) Hamburg, (3) München und (4) Köln 2019 (Quelle: Eigene Darstellung mit GeoDa. Datengrundlage: Airdna.)

6 Fazit und Ausblick

Die vorliegende Studie analysiert anhand von Daten des Anbieters Airdna erstmals die räumliche Verteilung des Airbnb-Angebotes in Deutschland und seinen vier einwohnerstärksten Städten. Dabei werden neben einer visuellen Analyse auch erstmals statistische Maßzahlen für die zunächst nur vermutete Clusterung von Airbnb-Angeboten berechnet und aufgezeigt, wo statistisch signifikante Cluster zu finden sind. Tab. 3 gibt einen zusammenfassenden Überblick über die in der vorliegenden Studie berechneten Werte. Bundesweit ist das Angebot von Airbnb stark räumlich konzentriert. Es zeigen sich über 2.000 statistisch signifikante Airbnb-Hotspots, die weitestgehend den urbanen Gebieten in Deutschland entsprechen, jedoch auch an der Nord- und Ostseeküste sowie im Alpenvorland zu finden sind. Die Ergebnisse zeigen weiterhin, dass sich Airbnb-Angebote im Vergleich der hier in der Studie betrachteten Großstädte am stärksten in Berlin konzentrieren. Es folgen Köln, Hamburg und München,

bei denen das Angebot deutlich heterogener in der Stadt verteilt ist.

Künftige bundesweite Analysen sollten einen Fokus auf die sogenannten High-Low-Ausreißer legen, um zu eruieren, was diese charakterisiert und was die Treiber dieses Angebots sind. Die Ergebnisse hier deuten auf tourismusintensive Gemeinden im ländlichen Raum hin. Es stellt sich zudem auf urbaner Ebene die Frage, wie die räumliche Konzentration bei den weiteren deutschen Großstädten ist. Gleichzeitig wäre es aufschlussreich, die hier ermittelten Cluster mit weiterführenden Sekundärdaten zu erklären. So lassen sich auf städtischer Ebene bspw. die Lage der klassischen Hotellerie oder Sehenswürdigkeiten hinzufügen. Zu denken wäre ebenfalls an weitere erklärende Variablen wie Immobilien- und Grundstückspreise oder quartiersbezogene Sozialstrukturen, die in zukünftigen Studien in Betracht gezogen werden könnten.

	Deutschland	Berlin	Hamburg	München	Köln
Anzahl Hexagone	73.068	18.424	15.275	6.515	8.476
Anzahl Listings	340.127	61.144	18.118	25.094	16.538
Listings pro Hexagon	4,7	3,3	1,2	3,9	2,0
Global Morans I-Index	0,622	0,835	0,774	0,760	0,792
z-Wert	294,3	193,3	162,8	103,8	124,04
p-Wert	p≤0.01	p≤0.01	p≤0.01	p≤0.01	p≤0.01
High-High-Cluster	2.277 (3,1%)	1.191 (6,5%)	803 (5,3%)	589 (9,0%)	495 (5,8%)
High-Low-Ausreißer	147 (0,2%)	1 (0,01%)	26 (0,2%)	3 (0,05%)	7 (0,1%)
Low-High-Ausreißer	890 (1,2%)	24 (0,1%)	55 (0,4%)	17 (0,3%)	21 (0,2%)
Low-Low-Cluster	24 (0,03%)	0 (0%)	0 (0%)	1.736 (26,6%)	0 (0%)
nicht signifikant	69.725 (95,4%)	17.208 (93,4%)	14.391 (94,2%)	4.170 (64,0%)	7.953 (93,8%)

Tab. 3: Übersicht globale und lokale räumliche Autokorrelation von Airbnb-Listings in Deutschland 2019

(Quelle: Eigene Berechnung und Darstellung. Datengrundlage: Airdna. Einstellungen: Räumliche Beziehungen: Queen-Contiguity; Row-Standardization.)

Literaturverzeichnis

- Adamiak, C., Szyda, B., Dubownik, A. und García-Álvarez, D. (2019): Airbnb Offer in Spain—Spatial Analysis of the Pattern and Determinants of Its Distribution. *ISPRS International Journal of Geo-Information* 8 (3), 155. 10.3390/ijgi8030155.
- Anselin, L. (1995): Local Indicators of Spatial Association-LISA. *Geographical Analysis* 27 (2), 93–115. 10.1111/j.1538-4632.1995.tb00338.x.
- Armas-Díaz, A., Smigiel, C. und Janoschka, M. (2021): Stadt | Tourismus kritisch hinterfragt - Zur Einführung in ein aufstrebendes humangeographisches Forschungsfeld. *Berichte, Geographie und Landeskunde* 94 (1), 3–19.
- Birch, C. P., Oom, S. P. und Beecham, J. A. (2007): Rectangular and hexagonal grids used for observation, experiment and simulation in ecology. *Ecological Modelling* 206 (3-4), 347–359. 10.1016/j.ecolmodel.2007.03.041.
- Brauckmann, S. (2017): City tourism and the sharing economy – potential effects of online peer-to-peer marketplaces on urban property markets. *Journal of Tourism Futures* 3 (2), 114–126. 10.1108/JTF-05-2017-0027.
- Burt, J. E., Barber, G. M. und Rigby, D. L. (2009): *Elementary statistics for geographers*. New York, NY.
- Cliff, A. und Ord, J. K. (1973): *Spatial autocorrelation*. London.
- Dodds, R. und Butler, R. (2019): The enablers of overtourism. In: Dodds, R. und Butler, R. (Hrsg.): *Overtourism: Issues, realities and solutions*. Berlin, 6–21.
- Duso, T., Michelsen, C., Schäfer, M. und Tran, K. (2021): Durch Airbnb-Vermietungen steigen in Berlin die Mieten. *DIW Wochenbericht* 7, 95–102. 10.18723/diw_wb:2021-7-1.
- Eugenio-Martin, J. L., Cazorla-Artiles, J. M. und González-Martel, C. (2019): On the determinants of Airbnb location and its spatial distribution. *Tourism Economics* 25 (8), 1224–1244. 10.1177/1354816618825415.
- Freytag, T. und Kagermeier, A. (2019): Touristifizierung urbaner Räume: Vorwort der Bandherausgeber. In: Freytag, T. und Kagermeier, A. (Hrsg.): *Touristifizierung urbaner Räume*. Mannheim.
- Füller, H. und Michel, B. (2014): ‘Stop Being a Tourist!’ New Dynamics of Urban Tourism in Berlin-Kreuzberg. *International Journal of Urban and Regional Research* 38 (4), 1304–1318. 10.1111/1468-2427.12124.
- Grekousis, G. (2020): *Spatial Analysis Methods and Practice*. Oxford.
- Gutiérrez, J., García-Palomares, J. C., Romanillos, G. und Salas-Olmedo, M. H. (2017): The eruption of Airbnb in tourist cities: Comparing spatial patterns of hotels and peer-to-peer accommodation in Barcelona. *Tourism Management* 62, 278–291. 10.1016/j.tourman.2017.05.003.
- Guttentag, D. (2015): Airbnb: disruptive innovation and the rise of an informal tourism accommodation sector. *Current Issues in Tourism* 18 (12), 1192–1217. 10.1080/13683500.2013.827159.
- Guttentag, D. (2019): Progress on Airbnb: a literature review. *Journal of Hospitality and Tourism Technology* 10 (4), 814–844. 10.1108/JHTT-08-2018-0075.
- Gyódi, K. und Nawaro, Ł. (2021): Determinants of Airbnb prices in European cities: A spatial econometrics approach. *Tourism Management* 86, 104319. 10.1016/j.tourman.2021.104319.
- Hall, C. M., Prayag, G., Safonov, A., Coles, T., Gössling, S. und Naderi Koupaei, S. (2022): Airbnb and the sharing economy. *Current Issues in Tourism* 25 (19), 3057–3067. 10.1080/13683500.2022.2122418.
- James, L. (2018): *The AI that Fuels AirDNA*. Verfügbar unter: <https://www.airdna.co/blog/short-term-rental-data-methodology> [Zuletzt aufgerufen am 04.09.2020].
- Kagermeier, A. (2021): *Overtourism*. München.
- Ki, D. und Lee, S. (2019): Spatial Distribution and Location Characteristics of Airbnb in Seoul, Korea. *Sustainability* 11 (15), 4108. 10.3390/su11154108.
- Kirilenko, A. P. (2022): Geographic Information System (GIS). Making Sense of Geospatial Data. In: Egger, R. (Hrsg.): *Applied Data Science in Tourism*. Cham, 513–526.
- Lagonigro, R., Martori, J. C. und Apparicio, P. (2020): Understanding Airbnb spatial distribution in a southern European city: The case of Barcelona. *Applied Geography* 115, 102136. 10.1016/j.apgeog.2019.102136.
- Lloyd, C. D. (2010): *Spatial data analysis: An introduction for GIS users*. Oxford, New York.
- Longley, P. A., Goodchild, M. F., Maguire, D. J. und Rhind, D. W. (2008): *Geographical information systems and science*. Chichester.
- Maitland, R. (2010): Everyday life as a creative experience in cities. *International Journal of Culture, Tourism and Hospitality Research* 4 (3), 176–185. 10.1108/17506181011067574.

- Moran, P. A. P. (1950): Notes on Continuous Stochastic Phenomena. *Biometrika* 37 (1/2), 17. 10.2307/2332142.
- Müller, C., Raschke, A. L., Brandt, S., Frank, S. und Wellner, K. (2019): Städtische Quartiere in der Tourismus-falle? Zur Wahrnehmung von Tourismus und Airbnb in Berlin – Ein Werkstattbericht. In: Freytag, T. und Kagermeier, A. (Hrsg.): *Touristifizierung urbaner Räume*. Mannheim, 49–58.
- Namberger, P. (2021): Kurzzeitvermietungen in der Stadt München: Auswirkungen auf die Bewohner/-innen im eigenen Haus. *Berichte, Geographie und Landeskunde* 94, 82–98.
- Nieuwland, S. und van Melik, R. (2020): Regulating Airbnb: how cities deal with perceived negative externalities of short-term rentals. *Current Issues in Tourism* 23 (7), 811–825. 10.1080/13683500.2018.1504899.
- Odland, J. (1988): *Spatial Autocorrelation. Reprint*.
- Oses Fernández, N., Kepa Gerrikagoitia, J. und Alzua-Sorzabal, A. (2018): Sampling method for monitoring the alternative accommodation market. *Current Issues in Tourism* 21 (7), 721–734. 10.1080/13683500.2015.1127336.
- Oskam, J. A. (2019): *The future of Airbnb and the 'sharing economy': The collaborative consumption of our cities*. Bristol.
- O'Sullivan, D. und Unwin, D. J. (2010): *Geographic information analysis*. Hoboken, NJ.
- Paül i Agustí, D. (2020): Mapping tourist hot spots in African cities based on Instagram images. *International Journal of Tourism Research*. 10.1002/jtr.2360.
- Petruzzi, M. A., Marques, G. S., do Carmo, M. und Correia, A. (2020): Airbnb and neighbourhoods: an exploratory study. *International Journal of Tourism Cities* 6 (1), 72–89. 10.1108/IJTC-08-2019-0119.
- Quattrone, G., Greator, A., Quercia, D., Capra, L. und Musolesi, M. (2018): Analyzing and predicting the spatial penetration of Airbnb in U.S. cities. *EPJ Data Science* 7 (1). 10.1140/epjds/s13688-018-0156-6.
- Rao, L. (2009): *Y Combinator's Airbed And Breakfast Casts A Wider Net For Housing Rentals As AirBnB*. Verfügbar unter: <https://techcrunch.com/2009/03/04/y-combinators-airbed-and-breakfast-casts-a-wider-net-for-housing-rentals-as-airbnb/?guccounter=1> [Zuletzt aufgerufen am 22.07.2022].
- Reif, J., Horster, E. und Schmücker, D. (2021): Sharing Economy im Tourismus am Beispiel von Airbnb: Divide et loca - Teile und vermiete. In: Eisenstein, B., Kampen, J., Weis, R., Reif, J. und Eilzer, C. (Hrsg.): *Tourismusatlas Deutschland*. 2. Auflage. Tübingen, 144–145.
- Said, C. (2012): *Short-term rentals disrupting SF housing market: SHARING ECONOMY Explosion in short-term rentals disrupts market, runs afoul of regulations*. Verfügbar unter: <https://www.sfgate.com/realestate/article/Short-term-rentals-disrupting-SF-housing-market-3622832.php> [Zuletzt aufgerufen am 22.07.2022].
- Schäfer, P. und Hirsch, J. (2017): Do urban tourism hotspots affect Berlin housing rents? *International Journal of Housing Markets and Analysis* 10 (2), 231–255. 10.1108/IJHMA-05-2016-0031.
- Schmücker, D. und Reif, J. (2022): Geht Tourismus alle an? Teilnahme der deutschen Gemeinden am Übernachtungstourismus. *Zeitschrift für Tourismuswissenschaft* (aop). 10.1515/tw-2022-0011.
- Skowronnek, A., Vogel, L. und Parnow, J. (2015): *AirBnB vs. Berlin. Was sagen die Daten?* Verfügbar unter: <https://www.airbnbsberlin.de> [Zuletzt aufgerufen am 11.12.2022].
- Slee, T. (2013): *Notes on Airbnb's New York Business*. Verfügbar unter: <http://tomslee.net/2013/10/notes-on-airbnbs-new-york-business.html> [Zuletzt aufgerufen am 22.07.2022].
- Smigiel, C., Hof, A., Kautzschmann, K. und Seidl, R. (2019): No Sharing! Ein Mixed-Methods-Ansatz zur Analyse von Kurzzeitvermietungen und ihren sozialräumlichen Auswirkungen am Beispiel der Stadt Salzburg. *Raumforschung und Raumordnung* 78 (2). 10.2478/rara-2019-0054.
- Sommer, C., Stoltenberg, L., Frisch, T. und Stors, N. (2019): Entwicklungslinien und Perspektiven der New Urban Tourism-Forschung. In: Freytag, T. und Kagermeier, A. (Hrsg.): *Touristifizierung urbaner Räume*. Mannheim, 15–32.
- Stankov, U., Armenski, T., Klauco, M., Pavlukovic, V., Cimbalevic, M. und Drakulic-Kovacevic, N. (2017): Spatial autocorrelation analysis of tourist arrivals using municipal data: A Serbian example. *Geographica Pannonica* 21 (2), 106–114. 10.5937/GeoPan1702106S.
- Stors, N. (2014): Explorer-Touristen im Städtetourismus. *Zeitschrift für Tourismuswissenschaft* 6 (1), 97–106. 10.1515/tw-2014-0110.
- Stors, N. (2020): Constructing new urban tourism space through Airbnb. *Tourism Geographies*, 1–24. 10.1080/14616688.2020.1750683.
- Stors, N. und Kagermeier, A. (2017): The sharing economy and its role in metropolitan tourism. In: Gravari-Barbas, M. und Guinand, S. (Hrsg.): *Tourism and Gentrification in Contemporary Metropolises: International Perspectives*. Milton, 181–206.
-

- Tobler, W. R. (1970): A Computer Movie Simulating Urban Growth in the Detroit Region. *Economic Geography* 46, 234–240.
- Xia, C., Yeh, A. G.-O. und Zhang, A. (2020): Analyzing spatial relationships between urban land use intensity and urban vitality at street block level: A case study of five Chinese megacities. *Landscape and Urban Planning* 193, 103669. 10.1016/j.landurbplan.2019.103669.
- Zekan, B., Önder, I. und Gunter, U. (2019): Benchmarking of Airbnb-Listings: How competitive is the sharing economy sector of European cities? *Tourism Economics* 25 (7), 1029–1046. 10.1177/1354816618814349.
-