



universität
wien

Diplomarbeit

Titel der Arbeit

**Räumliche Autokorrelationen und die Relevanz
räumlich simultan autoregressiver Modelle in der
psychologischen Forschung anhand europäischer
Suizidraten**

Verfasser

Christoph Strauß

Angestrebter akademischer Grad

Magister der Naturwissenschaften (Mag. rer. nat.)

Wien, im März 2012

Studienkennzahl: 298

Studienrichtung: Psychologie

Betreuer: Assistenzprof. Privatdoz. MMag. DDDr. Martin Voracek

Widmung und Danksagung

Ich widme diese Arbeit meinen beiden verstorbenen Großmüttern und meinem Großvater, die mich immer als ihren Enkel in allem unterstützt und als Menschen wertgeschätzt haben.

Ich danke vor allem meinen Eltern für ihre aufopferungsvolle Unterstützung und ihren Glauben an mich, der mir auch in schwierigen Zeiten viel Kraft gegeben hat. Für mich ist es das wertvollste Geschenk, das ich je bekommen konnte. Meinen Brüdern danke ich dafür, dass sie, wenn es darauf ankommt, immer zur Stelle sind.

Für seine Liebe danke ich Robert.

Für die mentale Unterstützung bedanke ich mich bei allen meinen Freunden, die auch in ärgerlichen, verzweifelten und lustlosen Momenten aufbauende Worte für mich gefunden und mein Klagen über sich ergehen haben lassen (müssen).

Für die unkomplizierte und flexible Betreuung, sowie die immer wieder aufbauende fachliche Inspiration danke ich meinem Diplomarbeitsbetreuer Assistenzprof. Privatdoz. MMag. DDDr. Martin Voracek, der mich motiviert hat und mir bei Fragen schnell und kompetent zur Seite stand.

Abschließend möchte ich für die weitere fachliche Unterstützung und die Tipps im Umgang mit „R“ David Preinerstorfer danken, der Zeit, Verständnis und Mühen für mich aufgebracht hat.

„Leider läßt sich eine wahrhafte Dankbarkeit mit Worten nicht ausdrücken.“

Johann Wolfgang von Goethe (dt. Dichter, 1749-1832)

Inhaltsverzeichnis

Einleitung	7
Theoretische Hintergründe	9
1 Räumliche Autokorrelationen („spatial autocorrelation“)	11
1.1 Begriffsdefinition	11
1.2 Mögliche Ursachen für räumliche Autokorrelationen	13
1.3 Auswirkungen für die psychologische Forschung.....	15
2 Methoden zur Überprüfung und Bestimmung räumlicher Autokorrelationen	17
2.1 Räumliche Autokorrelationskoeffizienten	17
2.1.1 <i>Moran's I</i>	17
2.1.2 <i>Geary's C</i>	19
2.1.3 <i>Statistische Voraussetzungen und Kritik</i>	20
2.1.4 <i>Globale und lokale räumliche Autokorrelationskoeffizienten</i>	22
2.2 Grafische Darstellungen von räumlichen Autokorrelationen	23
2.2.1 <i>Räumliche Korrelogramme („spatial correlograms“)</i>	23
3 Die räumlich gewichtete Nachbarschaftsmatrix („spatial weight matrix“)	26
3.1 Räumliche Nachbarschaften	26
3.1.1 <i>Gemeinsame räumliche Grenzen</i>	27
3.1.2 <i>Räumliche Distanzen</i>	28
3.2 Räumliche Gewichtungen	29
3.3 Praktische Leitlinien und kritische Anmerkungen	31
4 Räumliche Regressionsmodelle („spatial regression models“)	33
4.1 Statistische Voraussetzungen linearer Regressionsmodelle und räumliche Autokorrelationen.....	33
4.2 Räumlich simultan autoregressive Modelle	38
4.2.1 <i>Das räumlich verzogene Regressionsmodell („spatial lag model“)</i>	39

4.2.2	Das räumlich fehlerbezogene Regressionsmodell („spatial error model“)	41
4.2.3	Statistische Voraussetzungen	42
	Praktische Anwendungsbeispiele	45
5	Praktische Anwendungsbeispiele zur Analyse raumbezogener Suizidraten in Europa	47
5.1	Die räumliche Verteilung europäischer Suizidraten anhand von drei linearen Regressionsmodellen	47
5.2	Geostatistische Berechnungen und Darstellungen mit „R“	48
5.3	Die Überprüfung der linearen Regressionsmodelle aus drei Studien auf räumliche Autokorrelationen	49
5.3.1	Studie 1: Voracek, Fisher und Marušič (2003)	49
5.3.2	Studie 2: Voracek, Loibl und Kandrychyn (2007)	56
5.3.3	Studie 3: Voracek und Marušič (2008)	59
5.4	Räumlich simultan autoregressive Modellversuche	62
5.4.1	Ein räumlich verzogener Regressionsmodellversuch („spatial lag model“)	63
5.4.2	Ein räumlich fehlerbezogener Regressionsmodellversuch („spatial error model“)	66
6	Diskussion und Ausblick für geostatistische Verfahren in der psychologischen Forschung	71
	Zusammenfassung	75
	Abstract	77
	Anhänge	79
	Anhang 1: Beispiel für Codeschema der räumlichen Analyse in Studie 1 mit „R“	81
	Tabellenverzeichnis	87
	Abbildungsverzeichnis	89
	Literaturverzeichnis	91
	Curriculum Vitae	99

Einleitung

Die Vorhersage und Schätzung menschlichen Erlebens und Verhaltens mittels angemessener statistischer Verfahren ist in der angewandten und methodischen Psychologie von zentraler Bedeutung. Da psychologische Forschungsfragen häufig nicht exakt oder nur schwer von Fragestellungen aus anderen wissenschaftlichen Disziplinen, wie beispielsweise der Geografie, Ökologie oder Soziologie, klar abzugrenzen sind, kann es zur Optimierung der Vorhersagen und Schätzungen sinnvoll sein, das Wissen über statistische Verfahren aus anderen Wissenschaften zu nutzen, um es für die eigenen Fragestellungen zu adaptieren. Konkret setzt sich diese Arbeit mit der Relevanz und Anwendbarkeit von geostatistischen Verfahren für die psychologische Forschung auseinander.

Räumliche Autokorrelationen („spatial autocorrelation“) können die statistischen Voraussetzungen für lineare Regressionsmodelle verletzen und in Folge zu unangemessenen Schätzungen der Modellparameter führen. Es stellt sich die Frage, ob geostatistische Verfahren – im Speziellen räumlich simultan autoregressive Modelle – in der psychologischen Forschung für die Klärung räumlicher Einflüsse bei Suizidalität von Relevanz sein können. Die Vorgangsweise und Interpretation der Ergebnisse wird anhand von drei Studien praktisch illustriert werden.

In Kapitel 1 werden räumliche Autokorrelationen, deren Ursache und ihre derzeitige Bedeutung in der psychologischen Forschung beschrieben. Statistische Methoden zur Bestimmung von räumlichen Autokorrelationen – im Speziellen Moran's I (Kapitel 2.1.1) und Geary's C (Kapitel 2.1.2) – und grafische Methoden, wie räumliche Korrelogramme („spatial correlograms“, Kapitel 2.2.1), werden in Kapitel 2 erläutert. Die Unterscheidung zwischen globalen und lokalen Verfahren zur Bestimmung räumlicher Autokorrelationen wird in Kapitel 2.3 beschrieben. Die räumlich gewichtete Nachbarschaftsmatrix („spatial weight matrix“), welche durch die Definition und Gewichtung der räumlichen Nachbarschaften bestimmt wird, ist ein wesentlicher Bestandteil für die Entdeckung räumlicher Autokorrelationen und wird in Kapitel 3 beschrieben. Die Verletzung der statistischen Voraussetzungen für lineare Regressionsmodelle durch räumliche Autokorrelationen und der Versuch eine verbesserte Modellanpassung zu erzielen, sind die Ausgangspunkte für die Verwendung von simultan autoregressiven Modellen, wie das räumlich verzogene Regressionsmodell („spatial lag model“, Kapitel 4.2.1) oder das räumlich fehlerbezogene Regressionsmodell („spatial error model“, Kapitel 4.2.2), welche in Kapitel 4 beschrieben und diskutiert werden. Die Überprüfung auf räumliche Autokorrelationen mit Hilfe von räumlichen Korrelogrammen und dem räumlichen Autokorrelationskoeffizienten Moran's I wird in Kapitel 5 anhand von drei praktischen Anwendungsbeispielen demonstriert und Vergleiche zwischen den Modellanpassungen für die linearen Regressionsmodelle mit signifikanten räumlichen Autokorrelationen und je einem räumlich verzogenen und einem räumlich fehlerbezogenen Regressionsmodell angestellt. In

Kapitel 6 werden die Ergebnisse diskutiert und ein Ausblick auf zukünftige Verwendungsmöglichkeiten der beschriebenen geostatistischen Verfahren in der psychologischen Forschung gegeben.

Theoretische Hintergründe

1 Räumliche Autokorrelationen („spatial autocorrelation“)

In Kapitel 1.1 wird der Begriff der räumlichen Autokorrelation definiert und statistische Eigenschaften beschrieben. Mögliche Ursachen für räumliche Autokorrelationen werden in Kapitel 1.2 diskutiert und durch die Annahmen ökologischer Erklärungsmodelle verdeutlicht. Die Auswirkungen von räumlichen Autokorrelationen in der psychologischen Forschung werden in Kapitel 1.3 besprochen.

1.1 *Begriffsdefinition*

Eine Korrelation beschreibt das Ausmaß und die Richtung eines Zusammenhangs zwischen den Merkmalsausprägungen von zwei oder mehreren Variablen. Durch eine Korrelation wird beschrieben inwieweit sich zwei oder mehrere Variablen gegenseitig beeinflussen oder abhängig voneinander sind. Die Richtung einer Korrelation kann positiv oder negativ sein. Bei einer positiven Korrelation gehen hohe Ausprägungen des Merkmals der einen Variablen mit hohen Ausprägungen des Merkmals der anderen Variablen einher. Genauso können niedrige Ausprägungen der einen Variablen mit niedrigen Ausprägungen der anderen Variablen einhergehen. Bei einer negativen Korrelation gehen entgegengesetzte Ausprägungen der Variablen, also niedrige Ausprägungen der einen Variablen mit hohen Ausprägungen der anderen Variablen oder umgekehrt, einher. Bedingen sich zwei oder mehr Variablen nicht gegenseitig, sind sie statistisch unabhängig voneinander. In diesem Fall korrelieren die Variablen nicht miteinander. Das Ausmaß einer Korrelation kann mittels eines geeigneten Korrelationskoeffizienten berechnet werden. Beispielsweise kann das Ausmaß der Korrelation bei einer Pearson Produkt-Moment-Korrelation zwischen -1 und 1 variieren (Bortz & Döring, 2006).

Einen Spezialfall von Korrelationen stellen Autokorrelationen dar. Sie beschreiben das Ausmaß und die Richtung des Zusammenhangs zwischen zwei oder mehreren Merkmalsausprägungen einer einzigen Variablen. Die Variable korreliert so gesehen durch ihre eigenen Merkmalsausprägungen mit sich selbst (Griffith, 2009; Legendre, 1993). Folglich beeinflussen sich die beobachteten Merkmale der Variablen gegenseitigen und sind voneinander abhängig. Die Richtung und das Ausmaß der Autokorrelationen können ebenfalls durch geeignete Korrelationskoeffizienten bestimmt werden.

Was sind aber nun räumliche Autokorrelationen? Räumliche Autokorrelationen beschreiben das Ausmaß und die Richtung der Zusammenhänge zwischen zwei oder mehreren Merkmalsausprägungen einer einzigen Variablen bezüglich ihrer räumlichen Lage zueinander (Griffith, 2009). Die Richtung räumlicher Autokorrelationen kann positiv oder negativ sein. Bei positiven räumlichen Autokorrelationen sind sich räumlich nah beieinander liegende Beobachtungen sehr ähnlich (Anselin & Bera, 1998). Hohe beziehungsweise niedrige Werte

einer Beobachtung liegen in einer bestimmten Nähe zu ebenso hohen oder niedrigen Werten der benachbarten Beobachtungen. Negative räumliche Autokorrelationen zeichnen sich durch entgegengesetzte Beobachtungen aus, die räumlich nah beieinander liegen. Folglich liegen hohe Werte einer Beobachtung nah an niedrigen Werten der benachbarten Beobachtungen und umgekehrt. Positive und negative räumliche Autokorrelationen lassen sich schematisch in einem einfachen Gittermodell veranschaulichen (Abbildung 1).

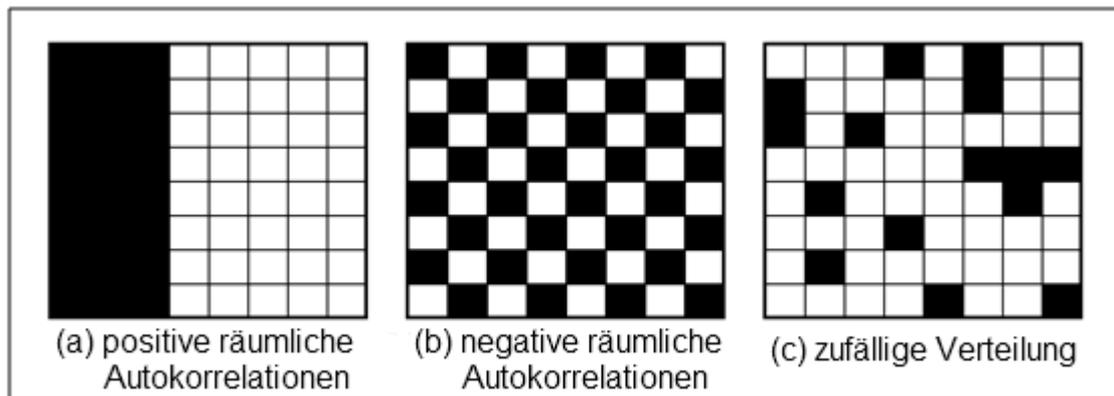


Abb. 1: Darstellungen im Gittermodell von (a) positiven räumlichen Autokorrelationen, (b) negativen räumlichen Autokorrelationen und (c) einer zufälligen Verteilung räumlicher Datenpunkte in Anlehnung an Lo und Yeung (2002).

Für das Ausmaß räumlicher Autokorrelationen einer Variablen spielt nach Tobler (1970, S. 3) die räumliche Distanz eine entscheidende Rolle. So lautet sein erstes Gesetz der Geografie: „...everything is related to everything else, but near things are more related than distant things.“ (Tobler, 1970, S. 3). Dementsprechend stehen räumlich oder geografisch nah beieinander liegende Beobachtungen in einem stärkeren räumlichen Zusammenhang miteinander als weit entfernte. Griffith (2009) fügt diesem Gesetz noch hinzu „...but not necessarily through the same mechanisms.“ (Griffith, 2009, S. 1). Der Nachweis von räumlichen Autokorrelationen sagt demnach zunächst nur wenig über die zugrundeliegenden räumlichen Prozesse aus, welche für die räumlichen Autokorrelationen ursächlich sind. Meist werden räumliche Autokorrelationen durch das Zusammenspiel mehrerer räumlicher Faktoren und Prozesse verursacht (Fortin, Dale & ver Hoef, 2002).

Bei räumlichen Autokorrelationen wird angenommen, dass sich nah beieinander liegende Ausprägungen einer Variablen ähnlicher sind als es der Zufall vermuten lassen würde (Anselin & Bera, 1998; Legendre, 1993). Die Beobachtungen folgen eher einer systematischen als einer zufälligen Verteilung über den Raum. Es wird weiter angenommen, dass je weiter die Beobachtungen voneinander entfernt liegen, die räumlichen Autokorrelationen schwächer werden und sich die Verteilung der Beobachtungen wieder umso mehr einer zufälligen Verteilung annähert. Räumliche Autokorrelationen zeigen als Funktion der räumlichen Distanz diesen Zusammenhang zwischen den Beobachtungen für eine bestimmte Variable an (Diniz-

Filho, Bini & Hawkins, 2003; Sokal & Oden, 1978a; Griffith, 1987). Zu beachten ist, dass bei vorliegenden räumlichen Autokorrelationen die Beobachtungen der Variablen nicht mehr unabhängig voneinander sind.

Definitionen räumlicher Autokorrelationen nehmen ebenso Bezug auf die räumlichen Zusammenhänge zwischen den Residuen der Beobachtungen einer Variablen. Residuen entsprechen den Abweichungen der Beobachtungen von den wahren Werten. Autokorrelationen werden allgemein auch als Korrelationen zwischen den Residuen zweier Beobachtungen einer Variablen definiert (Field, 2005). Weisen die Residuen einer Variablen systematisch geordnete Muster über den Raum auf, existieren räumliche Autokorrelationen (LeSage, 1997; Fotheringham, Brunson & Charlton, 2000). Genau wie ihre Beobachtungen sind systematisch geordnete Residuen räumlich nicht mehr unabhängig voneinander.

Zusammenfassend beschreiben räumliche Autokorrelationen die Richtung und das Ausmaß von räumlichen Zusammenhängen zwischen den in einer bestimmten räumlichen Entfernung liegenden Beobachtungen einer einzelnen Variablen. Über die zugrundeliegenden räumlichen Prozesse sagen räumliche Autokorrelationen jedoch zunächst nur wenig aus. Anzumerken ist, dass unterschiedliche räumliche Prozesse dasselbe Ausmaß und dieselbe Richtung von räumlichen Autokorrelationen erzeugen können (Sokal & Oden, 1978b). Ausmaß und Richtung räumlicher Autokorrelationen können mittels geeigneter räumlicher Autokorrelationskoeffizienten berechnet werden (Kapitel 2.1). Theorien über die möglichen Ursachen von räumlichen Autokorrelationen werden im folgenden Kapitel beschrieben.

1.2 Mögliche Ursachen für räumliche Autokorrelationen

In der geografischen Forschung setzten sich bereits Ende der 1960er Jahre Cliff und Ord (1969) mathematisch mit dem Phänomen räumlicher Autokorrelationen auseinander. Trotz der bereits frühen Werke fanden räumliche Autokorrelationen in der Wissenschaft zunächst nur wenig Beachtung (Getis, 2009). Erst einige Zeit später folgten beispielsweise ökologische Studien (Legendre, 1993). Nach dieser Zeit wurde bei der Erforschung räumlicher Autokorrelationen biologischen Faktoren zunehmend mehr Beachtung geschenkt (Diniz-Filho, Bini & Hawkins, 2003). In der Ökologie werden zum Teil biologische Prozesse als Ursache für räumliche Autokorrelationen vermutet, die einen Bezug zur räumlichen Nähe zwischen den Beobachtungen aufweisen (Legendre & Legendre, 1998). Zu diesen biologischen Prozessen zählen unter anderen die Bildung, das Aussterben, die Ausbreitung und Interaktionen von und zwischen Lebewesen (Dormann, McPherson, Araujo, Bivand, Bolliger, Carl et al., 2007).

Ökologische Erklärungsmodelle unterscheiden häufig zwischen räumlich endogenen und räumlich exogenen Prozessen als Ursache für räumliche Autokorrelationen (Diniz-Filho, Bini & Hawkins, 2003; Fortin & Dale, 2005; Kissling & Carl, 2008; Legendre, 1993; Legendre &

Legendre, 1998; Perez, Diniz-Filho, Bernal & Gonzalez, 2010). Bei räumlich endogenen Prozessen wird angenommen, dass die räumlichen Autokorrelationen durch räumlich inhärente Eigenschaften der abhängigen Variablen selbst verursacht werden. Die räumlich autokorrelierende Variable ist so angelegt, dass sich häufig ähnliche Ausprägungen näher beieinander beobachten lassen als es der Zufall vermuten lassen würde. Hingegen beziehen sich räumlich exogene Prozesse auf räumliche Umweltfaktoren, die unabhängig von der abhängigen Variablen wirken und räumliche Autokorrelationen von außen induzieren. Die räumliche Strukturierung dieser externen Umweltfaktoren wirkt sich auf die räumliche Struktur der unabhängigen Variablen aus und erzeugt in Folge räumliche Autokorrelationen zwischen den einzelnen Ausprägungen der abhängigen Variablen.

Physikalische Prozesse können ebenso für räumlich geordnete Muster und räumliche Autokorrelationen zwischen Beobachtungen verantwortlich sein (Legendre & Legendre, 1998). Zur Veranschaulichung der Entstehung von räumlichen Autokorrelationen dient folgendes simples Beispiel aus der Physik, welches die räumlichen Einflüsse eines Magnetfeldes beschreibt. Man stelle sich viele kleine Metallspäne vor, die zufällig verteilt auf einer Glasplatte liegen. Die Späne liegen zufällig teils dichter aneinander, teils weiter voneinander entfernt. Nun legt man einen Magneten in die Mitte der verteilten Späne. Durch den Einfluss des Magnetfeldes entsteht ein charakteristisches räumliches Muster. Metallspäne, die im Einflussbereich des Magnetfeldes liegen, werden selbst magnetisiert und üben als aktive, kleinere Magnete mit ihrem eigenen Magnetfeld zusätzlich einen Einfluss auf die benachbarten Späne aus. Dieser räumliche Prozess ist nicht nur auf die Physik beschränkt, sondern lässt sich auch darüber hinaus in anderen Wissenschaften beobachten. In den Geowissenschaften ist dieses räumliche Phänomen unter dem Begriff „spatial spillovers“ bekannt (Griffith, 2009). Ward und Gleditsch (2008) beschreiben vergleichbare räumliche Prozesse in der Soziologie, bei denen sich der räumliche Einfluss einer Beobachtung auf die benachbarten Beobachtungen wie bei einer Kettenreaktion über den Raum fortsetzt und sogar auf die anfängliche Beobachtung rückwirken kann. Jedoch ist der Einfluss eines jeden Magnetfeldes begrenzt und beeinflusst nur jene Metallspäne, welche eine bestimmte Reichweite nicht überschreiten. In Übereinstimmung mit Tobler's erstem Gesetz der Geografie verliert das Magnetfeld seinen Einfluss auf die zunehmend weiter entfernt liegenden Metallspäne. Folglich werden auch die Magnetfelder der einzelnen Metallspäne und ihr Einfluss untereinander abgeschwächt je weiter diese vom aussendenden Magneten entfernt liegen. Wird der Einflussbereich des Magnetfeldes überschritten, bleiben die Metallspäne unverändert liegen.

Je nach wissenschaftlicher Disziplin und Fragestellung bestehen unterschiedliche Hypothesen über die räumlichen Prozesse und Faktoren, welche als ursächlich für die zu beobachtenden räumlichen Zusammenhänge gelten. In der Ökologie werden häufig die Einflüsse von externen Faktoren, die zu erklärende Variable selbst oder beide gemeinsam als

Ursache für räumliche Autokorrelationen vermutet (Fortin & Dale, 2005). Im oben beschriebenen Beispiel aus der Physik ist die Ursache für die räumlichen Autokorrelationen zwischen den Metallspänen eindeutig und klar ersichtlich. Unglücklicherweise lassen sich die Ursachen für räumliche Autokorrelationen in anderen wissenschaftlichen Forschungsfeldern häufig nicht so einfach ergründen und auf einen einzigen ursächlichen Faktor wie in dem oben beschriebenen Beispiel aus der Physik zurückführen und reduzieren (Dungan, Perry, Dale, Legendre, Citron-Pousty, Fortin et al., 2002). In den meisten Naturwissenschaften sind es komplexe Zusammenhänge von mehreren räumlichen Prozessen und Faktoren, welche die räumlichen Autokorrelationen zwischen den Beobachtungen bedingen und eine genaue Bestimmung der Ursachen erschweren (McMillen, 2003).

1.3 Auswirkungen für die psychologische Forschung

Die räumliche Verteilung von Beobachtungen aus der natürlichen Umwelt entspricht meist nicht dem theoretisch angenommenen Zufallsprinzip aus der Wissenschaft (Legendre & Legendre, 1998). Dazu gehören unter anderem auch räumliche Prozesse, welche im Zusammenhang mit menschlichem Erleben und Verhalten stehen. Demnach sind räumliche Autokorrelationen nicht nur in der Geografie (Cliff & Ord, 1969; Griffith, 1987), der Ökologie (Dormann et al., 2007; Fortin & Dale, 2005; Legendre, 1993), sowie der Ökonomie (Anselin, 2001) und der Soziologie (Ward & Gleditsch, 2008), sondern auch sehr wahrscheinlich in der Psychologie existent und verlangen nach angemessenen statistischen Verfahren. Ohne angemessene statistische Verfahren können räumliche Autokorrelationen zu Trugschlüssen und Fehleinschätzungen führen, welche besonders im klinischen Bereich gravierende Folgen haben können. Durch die räumliche Analyse können zudem bislang unbekannte Risikofaktoren im Bereich der „Public Health“ und der Epidemiologie entdeckt werden (Bivand, Pebesma & Gómez-Rubio, 2008; Schmid, 2004). Bedauerlicherweise gibt es nach derzeitigem Stand der Wissenschaft nur wenige psychologische Studien, die sich statistisch mit räumlichen Autokorrelationen und deren Ursachen auseinandersetzen.

In den Forschungsfeldern der Psychologie, welche einen Bezug zu räumlichen Autokorrelationen herstellen, findet sich nur eine sehr begrenzte Auswahl an Literatur. So lassen sich beispielsweise in der internationalen psychologischen Intelligenzforschung kaum Verweise für die Verwendung von Verfahren, welche räumliche Autokorrelationen berücksichtigen oder in bestehende Modelle integrieren, finden, obwohl gemeinsame raumbezogene Faktoren in ländervergleichenden Studien räumliche Autokorrelationen erzeugen. In der sehr aktuellen Studie von Hassall und Sherratt (2011), aus der die oben genannten Ergebnisse stammen, machen die Autoren weiter auf das Problem von vernachlässigten, aber dennoch existenten räumlichen Autokorrelationen aufmerksam. Als eine der wenigen Studien in der Psychologie reanalysieren die Autoren in ihrer Studie einige wesentliche Faktoren, welche

die räumlichen Variationen in den nationalen Intelligenzdurchschnittswerten erklären sollen, mit Hilfe von geostatistischen Verfahren, um die nachgewiesenen räumlichen Autokorrelationen zu kontrollieren und Modellanpassungsvergleiche mit den bisherigen linearen Modellen anzustellen. Es kann gezeigt werden, dass durch die statistische Kontrolle der nachgewiesenen räumlichen Autokorrelationen in den Modellen verbesserte Modellanpassungen zu erreichen sind. Räumliche Autokorrelationen haben demnach einen nachgewiesenen Einfluss auf die geschätzten Parameter und in Folge auf die Ergebnisse und Schlussfolgerungen. Mit diesen Ergebnissen unterstreichen die Autoren ihre Forderung nach einer unabdingbaren Überprüfung auf räumliche Autokorrelationen bei raumbezogenen Daten, um Trugschlüsse und Fehlinterpretationen ausschließen oder korrigierende Maßnahmen ergreifen zu können.

In der psychologischen Forschung sind räumliche Autokorrelationen trotz der Existenz über multidisziplinäre Grenzen hinaus kaum präsent. Ein möglicher Grund für die Missachtung räumlicher Autokorrelationen in der psychologischen Forschung könnte der Informationsmangel bezüglich adäquater statistischer Verfahren im Umgang mit räumlichen Autokorrelationen sein. In der Geografie stellt der statistische Umgang mit dem Einfluss von Ort- und Lagebeziehungen in den Daten die Grundlage der wissenschaftlichen Arbeit dar. In der Psychologie ist ein derart naheliegender und teilweise selbstverständlicher Umgang mit raumbezogenen Daten aufgrund nur einiger weniger psychologischer Studien, welche sich mit den Raum-Lage-Beziehungen von Datensätzen beschäftigen, nicht gegeben.

Räumlich autokorrelierende Beobachtungen können somit auch in der Psychologie die Voraussetzungen vieler statistischer Standardverfahren verletzen (Griffith, 2009). In Folge können diese Verletzungen der Voraussetzungen zu ungenauen Parameterschätzern, falschen Ergebnissen und massiven Trugschlüssen führen, wenn statistische Modelle nicht an die räumlichen Autokorrelationen angepasst werden. Dabei ist vor allem zu beachten, dass, beispielsweise im klinischen Bereich, Entscheidungen, welche auf Ergebnissen basieren, die durch räumliche Autokorrelationen verzerrt werden, gravierende Folgen für die Praxis haben können. Eine unumgängliche Überprüfung auf räumliche Autokorrelationen und die angemessene Verwendung von geostatistischen Verfahren bei raumbezogenen Daten wird daher dringendst empfohlen und durch die Ergebnisse von Hassall und Sherratt (2011) gestützt. Selbst der Nachweis von nicht signifikant räumlich autokorrelierenden Beobachtungen stellt eine wichtige Erkenntnis für den Entscheidungsprozess von angemessenen statistischen Verfahren und eine notwendige Absicherung der Ergebnisse, beispielsweise für die klinische Praxis, dar.

2 Methoden zur Überprüfung und Bestimmung räumlicher Autokorrelationen

Zur Überprüfung und Bestimmung räumlicher Autokorrelationen werden in dieser Arbeit räumliche Autokorrelationskoeffizienten (Kapitel 2.1) verwendet. Die räumlichen Autokorrelationskoeffizienten Moran's I (Kapitel 2.1.1) und Geary's C (Kapitel 2.1.2), sowie deren statistische Voraussetzungen und kritische Äußerungen (Kapitel 2.1.3) werden im Folgenden beschrieben. Unterschiede in der Verwendung globaler und lokaler räumlicher Autokorrelationskoeffizienten werden in Kapitel 2.1.4 besprochen. Die Möglichkeit räumliche Autokorrelationen mit Hilfe von grafischen Darstellungen zu bestimmen wird in Kapitel 2.2 diskutiert. Im Speziellen werden dazu räumliche Korrelogramme und ein Verfahren zur Distanzklassenbestimmung erläutert (Kapitel 2.2.1).

2.1 Räumliche Autokorrelationskoeffizienten

Ausmaß und Richtung räumlicher Autokorrelationen zwischen benachbarten Beobachtungen einer Variablen können mittels geeigneter räumlicher Autokorrelationskoeffizienten bestimmt werden (Legendre, 1993; Griffith, 1987; Sokal & Oden, 1978a, 1978b; Waller & Gotway, 2004). Im Folgenden werden zwei der bekanntesten räumlichen Autokorrelationskoeffizienten, Moran's I und Geary's C , beschrieben und diskutiert.

2.1.1 Moran's I

Der wohl bekannteste räumliche Autokorrelationskoeffizient, Moran's I , basiert auf den dafür entwickelten Teststatistiken des australischen Statistikers Patrick Alfred Pierce Moran (Moran, 1950). Die generalisierte Form des ursprünglichen Moran's I für die Überprüfung auf räumliche Autokorrelationen in Regressionsmodellen wurde von Cliff und Ord (1972) entwickelt und stellt in der Praxis die am häufigsten verwendete Variante des räumlichen Autokorrelationskoeffizienten dar (Bivand, Pebesma & Gómez-Rubio, 2008; Ward & Gleditsch, 2008). Die generalisierte Form des globalen räumlichen Autokorrelationskoeffizienten bestimmt die linearen Zusammenhänge zwischen den einzelnen Beobachtung und dem gewichteten Mittelwert der benachbarten Beobachtungen derselben Variablen (Anselin & Bera, 1998; Fortin, Dale & ver Hoef, 2002).

Neben der Ähnlichkeit mit dem Durbin-Watson Test für serielle Autokorrelationen (Durbin & Watson, 1950, 1951a, 1951b), besteht eine weitere Analogie zum Pearson Produkt-Moment-Korrelationskoeffizienten (Griffith, 2011; Legendre & Legendre, 1998; Waller & Gotway, 2004). Die Herleitung der Formel für Moran's I aus der Formel des Pearson Produkt-Moment-Korrelationskoeffizienten wird im Folgenden demonstriert.

Die Gleichung für den Pearson Produkt-Moment-Korrelationskoeffizienten lautet:

$$r_p = \frac{1}{n} \frac{\sum i (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum i \frac{(x_i - \bar{x})^2}{n}} \sqrt{\sum i \frac{(y_i - \bar{y})^2}{n}}} \quad (2.1)$$

Für Moran's I können ausschließlich räumliche Zusammenhänge zwischen den Beobachtungen der Variablen y bestehen. Die Beobachtungen der Variablen x werden durch die Beobachtungen der Variablen y_j ersetzt, wobei gilt $y_j \neq y_i$. Der Pearson Produkt-Moment-Korrelationskoeffizient wird durch den Term $\frac{1}{n}$ über den gesamten Stichprobenumfang gemittelt. Im Gegensatz dazu wird für Moran's I ein gewichtetes Mittel über die Gesamtanzahl der benachbarten Beobachtungen gebildet. n wird durch $\sum i \sum j w_{ij}$ ersetzt (Griffith, 2011). Folglich lautet die Formel für Moran's I :

$$I = \frac{1}{\sum i \sum j w_{ij}} \frac{\sum i \sum j w_{ij} (y_i - \bar{y})(y_j - \bar{y})}{\sqrt{\sum i \frac{(y_i - \bar{y})^2}{n}} \sqrt{\sum i \frac{(y_i - \bar{y})^2}{n}}} \quad (2.2)$$

Die Wurzeln des Nenners werden aufgelöst, wodurch folgt:

$$I = \frac{n}{\sum i \sum j w_{ij}} \frac{\sum i \sum j w_{ij} (y_i - \bar{y})(y_j - \bar{y})}{\sum i (y_i - \bar{y})^2} \quad (2.3)$$

In der Formel für Moran's I beschreibt n die gesamte Stichprobengröße, w_{ij} eine gewichtete Matrix der räumlich benachbarten Beobachtungen der Variablen y , y_i die i te Beobachtung der Variablen y , y_j die j te benachbarte Beobachtung der Beobachtung y_i und \bar{y} den Mittelwert der Variablen y .

Als Nullhypothese für Moran's I wird angenommen, dass keine räumlichen Autokorrelationen zwischen den benachbarten Beobachtungen bestehen. Die benachbarten Beobachtungen sind demnach statistisch unabhängig voneinander. Können jedoch signifikante Abweichungen vom Erwartungswert nachgewiesen werden, wird die Alternativhypothese angenommen. Dementsprechend gelten die Beobachtungen als räumlich abhängig und beeinflussen sich wechselseitig über den Raum (Ord & Getis, 1995). Der Erwartungswert von Moran's I kann durch $-\frac{1}{n-1}$ geschätzt werden (Waller & Gotway, 2004; Ward & Gleditsch, 2008).

Moran's I kann zwischen den Werten -1 bis 1 variieren (Fortin, Dale & ver Hoef, 2002; Legendre, Legendre, 1998). Der Wert 1 repräsentiert eine perfekt positive, der Wert -1 eine perfekt negative räumliche Autokorrelation. Bei einer perfekt positiven räumlichen Autokorrelation sind alle benachbarten Daten identisch. Die Werte einer Beobachtung würden mit denselben hohen beziehungsweise niedrigen Werten aller benachbarten Beobachtungen einhergehen und folglich ein und dieselbe Information liefern. Identische Informationen enthalten keine neuen Informationen und werden daher auch als redundante Informationen bezeichnet (Griffith, 2009). Dieser Informationsverlust bedingt gleichzeitig den Verlust an Freiheitsgraden und muss daher bei der Verwendung von statistischen Verfahren berücksichtigt werden, um eine mögliche Verfälschung der Schätzer zu verhindern (Anselin & Bera, 1998). Hingegen enthalten die benachbarten Beobachtungen bei einer perfekt negativen räumlichen Autokorrelation die exakt gegensätzlichen Informationen.

2.1.2 Geary's C

Ein weiteres Verfahren zur Bestimmung von räumlichen Autokorrelationen stellt der räumliche Autokorrelationskoeffizient Geary's C dar (Geary, 1954). Im Gegensatz zu Moran's I , bei dem das Ausmaß des Zusammenhangs zwischen den Beobachtungen einer Variablen verwendet wird, basiert Geary's C auf den Differenzen der benachbarten Beobachtungen einer Variablen (Fortin & Dale, 2005; Legendre & Legendre, 1998). Die Formel für Geary's C lautet:

$$C = \frac{n-1}{2 \sum_i \sum_j w_{ij}} \frac{\sum_i \sum_j w_{ij} (y_i - y_j)^2}{\sum_i (y_i - \bar{y})^2} \quad (2.4)$$

Im Vergleich zu Moran's I wird für die Schätzung der räumlichen Autokorrelationen bei Geary's C der unverfälschte Varianzschätzer $n-1$ anstelle von n verwendet. Zudem werden die gemittelten Differenzen $(y_i - y_j)$ quadriert, um negative Differenzen zu vermeiden (Griffith, 2011).

Die Werte von Geary's C können zwischen 0 und 2 variieren. Der Logik von Moran's I entgegengesetzt, entspricht der Wert 0 einer perfekt positiven und der Wert 2 einer perfekt negativen räumlichen Autokorrelation. Die Alternativ- und Nullhypothese bei existenten beziehungsweise nichtexistenten räumlichen Autokorrelationen entsprechen wiederum denen von Moran's I . Weisen die beobachteten Daten keine räumlichen Autokorrelationen auf, kann für Geary's C der Erwartungswert 1 angenommen werden (Fortin, Dale & ver Hoef, 2002; Griffith, 2009).

In der Praxis wird häufig Moran's I gegenüber Geary's C als globaler räumlicher Autokorrelationskoeffizient bevorzugt verwendet. Eine mögliche Begründung dafür ist vermutlich die Ähnlichkeit zum Pearson Korrelationskoeffizienten (Fortin & Dale, 2005). Über Voraussetzungen und kritische Positionen bezüglich der adäquaten Verwendung von Moran's I und Geary's C wird im folgenden Kapitel diskutiert.

2.1.3 Statistische Voraussetzungen und Kritik

Für die angemessene Verwendung von räumlichen Autokorrelationskoeffizienten wird vorausgesetzt, dass die Daten asymptotisch normalverteilt und randomisiert vorliegen (Anselin & Bera, 1998; Cliff & Ord, 1973, 1981). Es wird angenommen, dass sich die Verteilung der Daten mit größer werdendem Stichprobenumfang der Normalverteilung asymptotisch annähert. Aus nichtnormalverteilten Daten können ungenaue Schätzungen des Mittelwertes entstehen, die in einer Über- beziehungsweise Unterschätzung der räumlichen Autokorrelationen resultieren (Fortin & Dale, 2005). Damit sich die Daten asymptotisch einer Normalverteilung anpassen, werden große Stichprobengrößen benötigt (Cliff & Ord, 1971; Kelejian, 2001). Griffith (1996) empfiehlt eine Stichprobengröße von $n > 60$. In der Praxis stellen derart große Stichproben eher die Ausnahme dar. Mit einer zu kleinen Stichprobengröße können allerdings Zweifel an der Gültigkeit der asymptotischen Normalverteilung und den resultierenden Ergebnissen bestehen (Waller & Gotway, 2004). Anselin und Rey (1991) konnten jedoch zeigen, dass auch bei kleinen Stichproben die Teststärke für Moran's I groß genug ist, um eine asymptotische Normalverteilung voranzusetzen. Die Ergebnisse konnte in einer Folgestudie von Anselin und Florax (1995) repliziert werden.

Sollten die Daten dennoch nicht randomisiert vorliegen, so stellt die Monte Carlo-Simulation eine mögliche Methode zur Korrektur der Datenstruktur dar. Bei dieser Methode werden die Daten in der räumlich gewichteten Nachbarschaftsmatrix mehrmals zufällig zeilen- und spaltenweise vertauscht, bis eine zufällige Verteilung der Daten hergestellt ist (Besag & Newell, 1991; Cliff & Ord, 1981; Ward & Gleditsch, 2008).

Weiter wird vorausgesetzt, dass die Beobachtungen konstante Mittelwerte und Varianzen über den gesamten Stichprobenumfang aufweisen (Schabenberger & Gotway, 2005; Cliff & Ord, 1973). Diese Voraussetzung wird auch mit den Begriffen „Stationarität“ oder „Populationshomogenität“ beschrieben. Waller und Gotway (2004) kritisieren die Verwendung von Moran's I , sobald die Voraussetzung der Stationarität durch heterogene Populationen verletzt wird. Als Beispiel führen sie Inzidenzraten von Krankheiten an, bei denen häufig unterschiedlich große Populationsstichproben nah beieinander liegen. Als Ursache für die hohen Werte von Moran's I werden daher unter der Annahme eines konstanten Erkrankungsrisikos nicht die Inzidenzen, sondern die unterschiedlichen Populationsgrößen vermutet. Die Auto-

ren erkennen jedoch Moran's I als bedeutungsvollen statistischen Indikator für räumliche Autokorrelationen an.

Zwischen den räumlichen Autokorrelationskoeffizienten Moran's I und Geary's C besteht ein besonderes Verhältnis. Unter der Voraussetzung der zufälligen Normalverteilung der Daten gilt als Faustregel, dass sich die beiden räumlichen Autokorrelationskoeffizienten zum Wert 1 summieren. Es gilt approximativ:

$$I + C \approx 1 \quad (2.5)$$

Diese Beziehung ergibt sich aus den entgegengesetzten Werten für positive, wie negative räumliche Autokorrelationen. Ein größeres Abweichen vom Wert 1 kann als Indiz für die Verletzung der asymptotischen Normalverteilung der Daten interpretiert werden. So können für Moran's I und Geary's C widererwartende Werte resultieren, die über oder unter den eigentlichen Grenzwerten des jeweiligen räumlichen Autokorrelationskoeffizienten liegen (Fortin, Dale & ver Hoef, 2002; Griffith, 1987; Jong, Sprenger & Veen, 1984). Bei einer zu kleinen Stichprobengröße werden die Grenzwerte von Moran's I und Geary's C häufig überschritten (Fortin & Dale, 2005).

Extremen Ausreißern sollte bei der Verwendung der räumlichen Autokorrelationskoeffizienten ebenso Beachtung geschenkt werden (Fortin, Dale & ver Hoef, 2002). Moran's I reagiert sehr sensibel auf einzelne Beobachtungen, die stark von den anderen Beobachtungen abweichen. Bei Geary's C ist dieser negative Effekt durch die Quadrierung der Differenzen noch stärker ausgeprägt als bei Moran's I (Fortin & Dale, 2005). Moran's I scheint darüber hinaus im Durchschnitt und Vergleich zu Geary's C eine größere Teststärke zu besitzen (Griffith, 2009).

An der Verwendung von Moran's I kritisiert Tiefelsdorf (2002), dass in vielen Fällen die notwendigen Voraussetzungen verletzt oder nicht erfüllt werden. Dennoch ist Moran's I in der wissenschaftlichen Praxis der am häufigsten verwendete räumliche Autokorrelationskoeffizient. Der Kritik wird gegenübergestellt, dass jeweils mit und ohne Monte Carlo-Simulation für Moran's I häufig ähnliche Werte resultieren, welche auf die Gültigkeit der Voraussetzungen für die asymptotische Normalverteilung und Randomisierung der Daten schließen lassen (Anselin, 2001; Ward & Gleditsch, 2008). Anzumerken bleibt, dass im Allgemeinen die fehlerfreie Schätzung von Signifikanztests auch von der Robustheit des Verfahrens gegenüber Verletzungen der Voraussetzungen abhängig ist (Bortz & Schuster, 2010; Perez, Diniz-Filho, Bernal & Gonzalez, 2010).

2.1.4 Globale und lokale räumliche Autokorrelationskoeffizienten

Das Ziel räumlicher Autokorrelationskoeffizienten ist die Klärung, ob und in welchem Ausmaß räumliche Autokorrelationen in den Daten vorliegen. Lassen sich räumliche Autokorrelationen identifizieren, kann in Folge die Frage gestellt werden, um welche Art von räumlichen Autokorrelationen es sich dabei handelt. In der Literatur wird zwischen globalen und lokalen räumlichen Autokorrelationen unterschieden (Ord & Getis, 1995).

Globale räumliche Autokorrelationskoeffizienten beziehen sich häufig auf große Studienareale und beschreiben den Gesamtzusammenhang räumlicher Autokorrelationen zwischen den benachbarten Beobachtungen (Waller & Gotway, 2004). In der wissenschaftlichen Praxis werden globale Autokorrelationskoeffizienten am häufigsten verwendet (Bivand, Pebesma & Gómez-Rubio, 2008; Ward & Gleditsch, 2008).

Auf die Kritik hin, dass globale Verfahren spezifische Strukturen, wie beispielsweise „hot spots“, in den Daten übersehen und in diesen Fällen lokale Verfahren ein angemessenere Methode darstellen würden (Getis & Ord, 1992; Ord & Getis, 1995), wurden lokale Formen der räumlichen Autokorrelationskoeffizienten, die sogenannten „local indicators of spatial autocorrelation“ (LISAs), aus den globalen räumlichen Autokorrelationskoeffizienten entwickelt (Anselin, 1995). Lokale räumliche Autokorrelationskoeffizienten zielen auf einzelne kleinere Einheiten eines großen Datensatzes und deren räumlichen Zusammenhänge ab (Fortin, Dale & ver Hoef, 2002; Waller & Gotway, 2004).

In diesem Kontext unterscheiden Besag und Newell (1991) zwischen generellen und fokussierten, also globalen und lokalen, Verfahren für die Überprüfung auf räumliche Autokorrelationen von raumbezogenen Daten. Generelle Verfahren werden herangezogen, wenn der Fokus der Analyse auf großen räumlichen Gesamtmustern liegt, die anhand der einzelnen Beobachtungen untersucht werden sollen. Von Interesse sind dabei die groben und globalen Zusammenhänge von Beobachtungen über einen größeren Raum, die in Folge auch als Wegweiser für weitere Analysen mittels fokussierter Verfahren dienlich sein können. Fokussierte Verfahren sollten verwendet werden, wenn das Augenmerk auf einigen kleineren und genauer abgegrenzten Teilgebieten liegt. Von Interesse sind dabei die kleineren lokalen räumlichen Muster und Autokorrelationen zwischen den einzelnen Beobachtungen. Der Unterschied zwischen generellen und fokussierten Verfahren besteht somit einerseits in der Größe des räumlichen Forschungsgebietes, andererseits nehmen fokussierte Verfahren häufig Bezug auf bereits vorhandenes, wissenschaftlich abgesichertes Wissen, das mittels genereller Verfahren gewonnen wurde. Generelle Verfahren sind daher als eher explorative Methode zu sehen, welche Informationen über die räumlichen Gesamtzusammenhänge liefern und für die Generierung von spezifischen Fragestellungen und Hypothesen von fokussierten Verfahren bereitstellen.

Fortin und Dale (2005) empfehlen als Entscheidungsgrundlage für globale oder lokale Autokorrelationskoeffizienten das Ziel der Studie und das Wissen oder Nichtwissen über die Stationarität der Daten heranzuziehen. Bei fehlendem Wissen über die Stationarität der Daten sollte schrittweise vorgegangen und zunächst globale räumliche Autokorrelationskoeffizienten verwendet werden. Sind keine globalen räumlichen Autokorrelationen nachzuweisen, können die Forschungsgebiete verkleinert und mittels lokaler räumlicher Autokorrelationskoeffizienten auf das Vorliegen von spezifischeren räumlichen Autokorrelationen hin überprüft werden.

In Bezug auf die Reliabilität der Verwendung von globalen und lokalen räumlichen Autokorrelationskoeffizienten verweisen Dungan et al. (2002) auf das gewählte Stichprobendesign. Entscheidend ist, ob die raumbezogenen Daten nur einzelne und lokale Stichproben oder eine gesamte und globale Population repräsentieren.

2.2 Grafische Darstellungen von räumlichen Autokorrelationen

Grafische Darstellungen können bei der Überprüfung auf räumliche Autokorrelationen dienlich und für die Illustrierung von räumlichen Mustern hilfreich sein. Räumliche Cluster und Ansammlungen können in Grafiken dargestellt, erkannt und kenntlich gemacht werden.

Zu beachten ist jedoch, dass die Beurteilung von räumlich systematisch geordneten Mustern allein in grafischen Darstellungen der Daten nur dem subjektiven Zugang des Betrachters obliegt. In den grafisch dargestellten Daten können durch individuelle Erfahrungen und Schlussfolgerungen räumliche Muster erkannt und für signifikant gehalten werden, obwohl diese keinerlei statistisch signifikante Relevanz besitzen. Die Auffassungen über das Vorliegen von räumlichen Autokorrelationen können demnach auch je nach Betrachter stark variieren (Waller & Gotway, 2004). Die Bestimmung räumlicher Autokorrelationen allein anhand von räumlichen Grafiken ist daher sehr ungenau. Für eine objektive und allgemeingültige Überprüfungen auf räumliche Autokorrelationen sind räumliche Autokorrelationskoeffizienten besser geeignet und heranzuziehen (Bivand, Pebesma & Gómez-Rubio, 2008). Graphische Darstellungen haben dennoch einen großen explorativen Wert und stellen ein wichtiges Hilfsmittel zur Illustrierung von räumlichen Autokorrelationen dar.

2.2.1 Räumliche Korrelogramme („*spatial correlograms*“)

Räumliche Korrelogramme stellen räumliche Autokorrelationen grafisch dar und visualisieren die Werte des räumlichen Autokorrelationskoeffizienten als Funktion räumlicher Distanzklassen im Koordinatensystem (Fortin, Dale & ver Hoef, 2002; Perez, Diniz-Filho, Bernal & Gonzalez, 2010; Sokal & Oden, 1978a). Die Werte des räumlichen Autokorrelationskoeffizienten werden auf der Ordinatenachse (*y*-Achse) gegen die gewählten Distanzklassen auf

der Abszissenachse (x-Achse) aufgetragen (Fortin & Dale, 2005; Legendre & Fortin, 1989; Legendre, 1993).

Handelt es sich nur um eine einzige abhängige Variable, können univariate Moran's *I*- oder Geary's *C*-Korrelogramme erstellt werden (Legendre & Legendre, 1998). Für die bildhafte Darstellung von zwei oder mehreren abhängigen Variablen werden multivariate Mantel-Korrelogramme verwendet (Oden & Sokal, 1986; Sokal, 1986).

In räumlichen Korrelogrammen spiegeln sich die räumlichen Muster räumlicher Autokorrelationen wider. Beim Vergleich mehrerer räumlicher Korrelogramme können ähnliche oder abweichende räumliche Muster der räumlichen Autokorrelationen anhand der Funktionsverläufe erkannt werden (Sokal & Oden, 1978b). Solange derselbe räumliche Autokorrelationskoeffizient mit derselben räumlichen Nachbarschaftsmatrix verwendet wurde, lassen vergleichbare Grafen in den räumlichen Korrelogrammen auf ähnlich wirksame räumliche Prozesse schließen (Kissling & Carl, 2008).

In Übereinstimmung mit Tobler's erstem Gesetz der Geografie lassen sich häufig positive Autokorrelationen in den ersten Distanzklassen finden, die mit größer werdendem Abstand immer kleiner werden und schließlich gegen Null gehen. Die räumlichen Autokorrelationen werden mit wachsender Distanz vom Ausgangspunkt immer schwächer. Dieser Prozess wird in Abbildung 2 schemenhaft dargestellt. Der Schnittpunkt des Graphen mit dem Erwartungswert des jeweiligen räumlichen Autokorrelationskoeffizienten kennzeichnet dabei das wirksame Distanzausmaß der räumlichen Autokorrelation (Fortin, Dale & van Hoef, 2002).

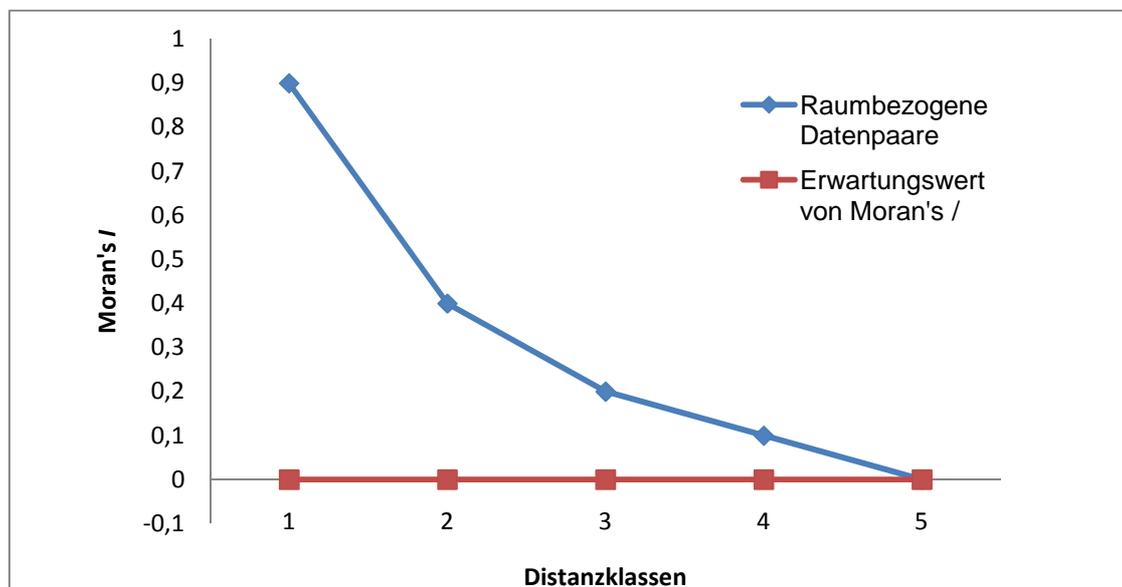


Abb. 2: Modellhafte Darstellung eines räumlichen Moran's *I*-Korrelogramm. Die räumlichen Autokorrelationen schwächen mit größer werdender Entfernung ab und treffen den Erwartungswert von Moran's *I* in der fünften Distanzklasse.

Die Anzahl der Distanzklassen in räumlichen Korrelogrammen ist frei wählbar. Eine sinnvolle Wahl der Distanzklassen sollte jedoch eine gut erkennbare Darstellung der räumlichen Autokorrelationen bei gleichzeitig ausreichend großer Teststärke gewährleisten (Legendre & Legendre, 1998). Zur Bestimmung der geeigneten Anzahl von Distanzklassen kann die Regel von Sturge (1926) herangezogen werden. Basierend auf der Stichprobengröße ergibt sich folgende Formel mit n als Stichprobenumfang:

$$D = 1 + 3.3 \times \lg\left(\frac{n(n-1)}{2}\right) \quad (2.6)$$

Für gewöhnlich wird zwischen Distanzklassen mit gleichen Intervallen (äquidistant) oder mit derselben Anzahl an Nachbarschaften (äquifrequent) unterschieden. Da äquidistante Distanzklassen in der Literatur am häufigsten verwendet werden, besteht der Vorteil in der besseren Vergleichbarkeit mit anderen Studien. Der Nachteil ergibt sich aus der Anzahl der Nachbarschaften innerhalb der Distanzklassen, die unter Umständen stark variieren und sich daher negativ auf die Reliabilität der geschätzten räumlichen Parameter auswirken kann. Der Vorteil äquifrequenter Distanzklassen ist eine genauere Schätzung der räumlichen Autokorrelationen in jeder Distanzklasse aufgrund der gleichgroßen Anzahl von Nachbarschaften. Gleichzeitig kann sich aus den variierenden Abständen zwischen den Distanzklassen bei der Schätzung der räumlichen Parameter ein Nachteil bezüglich der Vergleichbarkeit mit anderen Studien ergeben. Äquifrequente Distanzklassen werden deswegen in der Wissenschaft nur sehr selten verwendet (Fortin & Dale, 2005).

3 Die räumlich gewichtete Nachbarschaftsmatrix („spatial weight matrix“)

Anselin (1988) definiert die räumlich gewichtete Nachbarschaftsmatrix („spatial weight matrix“) als einen formalen Ausdruck der räumlichen Abhängigkeiten zwischen den einzelnen Beobachtungen einer Stichprobe. Im Idealfall gibt die räumlich gewichtete Nachbarschaftsmatrix eine genaue Abbildung der realen räumlichen Muster im theoretischen Modell wider (Bivand, Pebesma & Gómez-Rubio, 2008; Perez, Diniz-Filho, Bernal & Gonzalez, 2010). Der Bestimmung einer räumlich gewichteten Nachbarschaftsmatrix sollte besondere Beachtung geschenkt werden, da sie einen großen Einfluss auf die Ergebnisse der verwendeten geostatistischen Verfahren hat (Anselin & Florax, 1995). Im Folgenden wird der Begriff der räumlich gewichteten Nachbarschaftsmatrix als Synonym, wie beispielsweise bei Schmid (2004), für den englischen Begriff „spatial weight matrix“ verwendet.

Die Bestimmung räumlicher Nachbarschaften werden in Kapitel 3.1 am Beispiel gemeinsamer räumlicher Grenzen (Kapitel 3.1.1) und räumlicher Distanzen (Kapitel 3.1.2) beschrieben. Die Verwendung von räumlichen Gewichten, welche von ebenso großer Bedeutung ist und bis dato in der Literatur nur wenig Aufmerksamkeit erlangt hat, wird in Kapitel 3.2 behandelt. Praktische Leitlinien für die Bestimmung und kritische Anmerkungen zur Verwendung von räumlich gewichteten Nachbarschaftsmatrizen werden in Kapitel 3.3 beschrieben.

3.1 Räumliche Nachbarschaften

Räumliche Nachbarschaften können in Ordnungen unterteilt werden. Nachbarschaften 1. Ordnung sind direkt mit einander verbundene räumliche Einheiten. Nachbarschaften der 2. Ordnung beschreiben zwei räumliche Einheiten, die über eine dritte Einheit indirekt miteinander verbunden sind. Die räumliche Nachbarschaftsordnung kann stetig mit zunehmender Anzahl der räumlichen Einheiten, welche die beiden benachbarten Einheiten miteinander verbinden, weitergeführt werden (Schulze, 1993). Ebenso kann eine Ordnung der Nachbarschaften nach zunehmender Entfernung vom Ausgangspunkt einer Beobachtung hergestellt werden, wobei die nächstgelegenen Beobachtungen als Nachbarn 1. Ordnung und dementsprechende die zweitnächstgelegenen Beobachtungen als Nachbarn 2. Ordnung bezeichnet werden (Fortin & Dale, 2005)

Die Definition der räumlichen Nachbarschaften hat einen bedeutenden Einfluss auf die Entdeckung räumlicher Autokorrelationen (Dacey, 1968) und kann sich auf die Teststärke, sowie die asymptotischen Eigenschaften der Schätzer auswirken (Anselin & Rey, 1991). Um Beobachtungen als räumlich benachbart bestimmen zu können, müssen dafür zuvor räumliche Nachbarschaftskriterien definiert werden. Räumliche Nachbarschaftskriterien zeigen die

räumlichen Nachbarschaftsbeziehungen zwischen den Beobachtungen an und beschreiben deren räumliche Abhängigkeiten untereinander (Bivand, Pebesma & Gómez-Rubio, 2008). Beobachtungen gelten als räumlich abhängig und benachbart, wenn diese räumliche Gemeinsamkeiten aufweisen. In der Statistik werden diese räumlichen Gemeinsamkeiten häufig durch eine gemeinsame Grenze („first-order contiguity“) (LeSage, 1997) oder eine bestimmte Distanz zwischen den Beobachtungen („distance-based contiguity“) definiert (Anselin, 2001; Anselin & Bera, 1998; Perez, Diniz-Filho, Bernal & Gonzalez, 2010; Schabenberger & Gotway, 2005; Waller & Gotway, 2004). Diese beiden Möglichkeiten werden in den folgenden Kapiteln näher erläutert. Eine Aufzählung weiterer Nachbarschaftskriterien ist bei Getis und Aldstadt (2004) zu finden.

3.1.1 Gemeinsame räumliche Grenzen

Bestehende geografische und politische Grenzen können für die Bestimmung räumlicher Nachbarschaften sehr nützlich sein, um ein reales Abbild der räumlichen Muster widerzugeben. Problematisch werden diese Grenzen nur, wenn die Grenzen der interessierenden Einheiten sich über die Zeit verändern. Bei Längsschnittstudien beispielsweise kann es zu Problemen kommen, wenn sich die geografischen oder politischen Grenzen während der Studienlaufzeit verändern. Dieses Problem ist unter der Bezeichnung „modifiable areal unit problem“ bekannt (Waller und Gotway, 2004). Eine Veränderung der Grenzen und damit der räumlichen Einheiten kann zu unterschiedlichen Ergebnissen und Interpretationen führen. Zu beachten ist, dass jede gewählte Einteilung der Beobachtungen in räumliche Einheiten einen Einfluss auf das statistische Ausmaß der räumlichen Autokorrelationen hat.

Nachbarschaftsbeziehungen anhand von Grenzen können schematisch in einem geordneten Gittermodell dargestellt werden (Anselin & Bera, 1998; Fortin & Dale, 2005; Schabenberger & Gotway, 2005). Analog zum Schachspiel wird zwischen den folgenden drei möglichen Nachbarschaftskriterien unterschieden:

- Der **Turm („rook“)** bestimmt jegliche Felder als Nachbarn, die durch horizontale und vertikale Bewegungen erreicht werden.
- Der **Läufer („bishop“)** bestimmt jegliche Felder als Nachbarn, welche durch diagonale Bewegungen erreicht werden.
- Die **Königin („queen“)** bestimmt jegliche Felder als Nachbarn, die sowohl durch die vertikalen und horizontalen Bewegungen des Turms („rook“), als auch durch die diagonalen Bewegungen der Läufer („bishop“) erreicht werden.

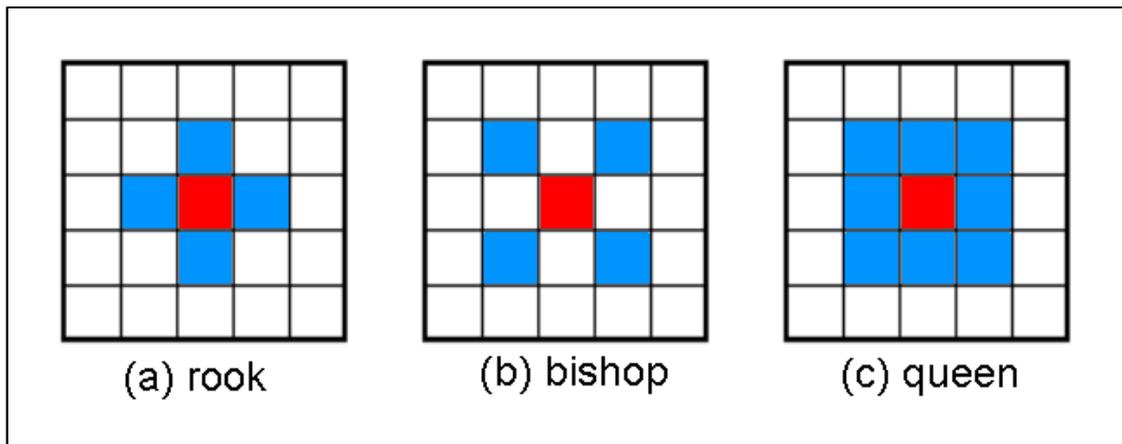


Abb. 3: Darstellung der räumlichen Nachbarschaftskriterien (a) Turm („rook“), (b) Läufer („bishop“) und (c) Königin („queen“) im geordneten Gittermodell für räumliche Nachbarschaften 1. Ordnung.

Die räumlichen Nachbarschaftskriterien in Abbildung 3 zeigen alle theoretisch möglichen räumlichen Nachbarschaftsbeziehungen 1. Ordnung im geordneten Gittermodell anhand gemeinsamer Grenzen auf. In der Praxis werden häufig nur solche räumliche Nachbarschaftskriterien verwendet, welche sich am besten an die reellen räumlichen Muster anpassen lassen (Cressie, 1993).

3.1.2 Räumliche Distanzen

Bei unregelmäßig verteilten räumlichen Einheiten werden häufig Distanzen als räumliches Nachbarschaftskriterium bestimmt, innerhalb derer die Beobachtungen als räumlich benachbart gelten (Schabenberger & Gotway, 2005). Typischerweise wird die direkte geografische Distanz zwischen zwei Beobachtungen, die euklidische Distanz, verwendet (Legendre, 1993). Die Distanzen zwischen den Beobachtungen lassen sich ebenso anhand der geografischen Lagepositionen mittels ihrer Koordinaten bestimmen (Bivand, Pebesma & Gómez-Rubio, 2008; Perez, Diniz-Filho, Bernal & Gonzalez, 2010).

Eine Methode, welche die Distanzen zwischen den Beobachtungen als räumliches Nachbarschaftskriterium nutzt, ist die „ k nächstgelegenen Nachbarn“ Methode (k nearest neighbors). „ k “ beschreibt die Ordnungszahl der räumlichen Nachbarschaften, welche zuvor meist anhand der Ordnung mit den meisten Beobachtungen definiert wird. Alle Beobachtungen, welche sich im räumlichen Umkreis der k -ten Ordnung befinden, sind die nächstgelegenen Nachbarn zur Ausgangsbeobachtung (Fortin & Dale, 2005; Pinkse & Slade, 1998). Zu beachten ist, dass für eine nächstgelegene Nachbarschaft einer Beobachtung mit einer anderen Beobachtung der umgekehrten Fall nicht zwingend gelten muss. Wechselseitige räumliche Nachbarschaftsbeziehungen können, müssen aber nicht notwendigerweise bestehen. Folglich sind die räumlichen Nachbarschaften zwischen den Beobachtungen nach diesem räumlichen Nachbarschaftskriterium nicht notwendigerweise reziprok (Waller & Gotway,

2004). Die größte Distanz unter allen nächstgelegenen benachbarten Beobachtungen ist gleichzeitig die minimale Distanz unter der Bedingung, dass jede Beobachtung mindestens einen räumlich nächstgelegenen Nachbarn besitzt.

Als räumliches Nachbarschaftskriterium können ebenso Grenzwerte für bestimmte Distanzen festgelegt („distance thresholds“) und erst im Nachhinein die Anzahl der räumlichen Nachbarschaften bestimmt werden. Das größte Problem dieses räumlichen Nachbarschaftskriteriums ist, dass es zu großen Differenzen in der Anzahl von räumlichen Nachbarschaften zwischen den Beobachtungen kommen kann, wenn die räumliche Verteilung der einzelnen Beobachtungen sehr unregelmäßig ist. Es kann zudem bei diesem räumlichen Nachbarschaftskriterium vorkommen, dass Beobachtungen ohne eine einzige räumliche Nachbarschaft entstehen, was nach Möglichkeit immer zu vermeiden ist, da andernfalls der Verlust an Freiheitsgraden droht (Anselin & Bera, 1998).

Sollen räumliche Distanzen zwischen Ländern bestimmt werden, können dafür beispielsweise die geografischen Lageschwerpunkte, die Bevölkerungsdichte, sowie die geografische Lage der Hauptstädte mittels ihre Koordinaten herangezogen werden (Bivand, Pebesma & Gómez-Rubio, 2008). Auffällig scheint allerdings, dass je größer die Fläche eines Landes ist, die räumliche Distanz zwischen dem geografischen Schwerpunkt und der Landeshauptstadt zunehmend voneinander abweichen (Ward & Gleditsch, 2008). Der geografische Schwerpunkt scheint daher weniger als repräsentative Lageposition für die Beobachtungen von menschlichen Verhaltensweisen zu fungieren.

Es gibt eine Vielzahl an unterschiedlichen räumlichen Nachbarschaftskriterien und Herangehensweisen, die evaluiert wurden und ihr Anwendung in statistischen Modellen finden (Getis & Aldstadt, 2004). Zu beachten ist, dass räumliche Nachbarschaftskriterien, welche die zugrundeliegenden räumlichen Muster im theoretischen Modell nur bedingt realitätsgetreu wiedergeben, zu ungenauen Schätzungen und verfälschten Ergebnissen führen können (Bivand, Pebesma & Gómez-Rubio, 2008).

3.2 Räumliche Gewichtungen

Der Mangel an Literatur zur Verwendung von räumlichen Gewichten, führt häufig dazu, dass die Möglichkeiten der Gewichtung räumlicher Nachbarschaften in der wissenschaftlichen Forschung kaum genutzt und außer Acht gelassen werden (Bivand, Pebesma & Gómez-Rubio, 2008). Dabei kann die Bestimmung räumlicher Gewichtungen einen ebenso großen Einfluss auf die Ergebnisse und die Entdeckung räumlicher Autokorrelationen wie die Bestimmung von räumlichen Nachbarschaftskriterien haben. Zu beachten ist, dass die räumlichen Gewichtungen derart zu wählen sind, dass die Voraussetzungen, welche für die verwendeten statistischen Verfahren angenommen werden, nicht verletzt werden (Anselin &

Bera, 1998). Räumliche Gewichtungen müssen daher positiv und endlich sein und einem angemessenen Skalenniveau entsprechen (Anselin, 1980).

Räumliche Nachbarschaften können einheitlich oder relativ anhand von bestimmten Kriterien, wie beispielsweise der Grenzlänge oder der absoluten Distanz, gewichtet werden. Wird nur binär zwischen der Möglichkeit einer Nachbarschaft unterschieden, ist die räumliche Gewichtung einheitlich ausgeprägt. Für den Fall einer genaueren Bestimmung von benachbarten Datenpunkten, können spezifischere Gewichtungen gewählt werden (Waller & Gotway, 2004).

Räumliche Gewichtungen können ebenso anhand von bestehendem Vorwissen über wirksame räumliche Prozesse bestimmt werden (Cliff & Ord, 1973). Ein Beispiel dafür ist die inverse Distanzgewichtung („inverse distances“) unter der Annahme von Tobler (1970), dass räumlich nah beieinanderliegende Beobachtungen sich ähnlicher sind als weiter entfernte (Bivand, Pebesma & Gómez-Rubio, 2008). Der sich mit zunehmender räumlicher Distanz abschwächende Prozess wird als räumliche Gewichtung in die räumlich gewichtete Nachbarschaftsmatrix integriert. Der Gewichtungsterm beinhaltet in der einfachsten Form die Distanzen zwischen den Beobachtungen im Nenner und den Wert 1 im Zähler ($\frac{1}{d}$). Diese räumliche Gewichtung kann jedoch auch an die jeweilige Stärke der räumlichen Zusammenhänge angepasst werden. Dafür wird die räumliche Distanz zwischen den Beobachtungen im Nenner potenziert. Die bekannteste Form der inversen Distanzgewichtung ist die quadrierte Form ($\frac{1}{d^2}$). Als Faustregel für die räumliche Gewichtung gilt, dass je stärker die räumlichen Zusammenhänge zwischen den benachbarten Beobachtungen und je schwächer die der weiter entfernten Beobachtungen sind, desto exponentiell höher die Distanzen zwischen den Beobachtungen im Nenner gewichtet werden (Getis & Aldstadt, 2004).

Cliff und Ord (1973, 1981) entwickelten eine generalisierte Gewichtung, die Cliff-Ord Gewichtung, für räumliche Nachbarschaften durch eine gemeinsame Grenze. Dabei wird die relative gemeinsame Grenzlänge durch die entgegengesetzte Distanz zwischen den zwei Beobachtungen korrigiert. Eine weitere Möglichkeit der räumlichen Gewichtung ist es den relativen Flächenanteil einer räumlichen Einheit in Bezug zur Gesamtfläche aller räumlichen Einheiten zu setzen (Dacey, 1968). Ebenso können räumliche Gewichtungen eingesetzt werden, um zu unterscheiden, ob benachbarte Individuen zu demselben sozialen Netzwerk gehören oder nicht (Doreian, 1980). Die räumlichen Gewichtungsmöglichkeiten, welche in dieser Arbeit beschrieben wurden, sind bei weitem keine vollständige Aufzählung, sondern sollen nur einen Eindruck der vielfältigen Möglichkeiten für räumliche Gewichtungen vermitteln.

Aufgrund der späteren Verwendung der Computersoftware „R“ (R Development Core Team, 2011) und dem Zusatzpaket „spdep“ (Bivand, 2011) für die praktischen Anwendungsbeispiele wird im Folgenden insbesondere auf drei räumliche Gewichtungen eingegangen,

welche die Software beinhaltet. Unterschieden wird zwischen binären („binary“), zeilenstandardisierten („row-standardised“) und varianzstabilisierenden („variance-stabilizing“) Gewichtungen. Die simpelste Methode stellt die binäre Gewichtung dar, welche nur zwischen benachbarten Beobachtungen mit dem Wert 1 und nichtbenachbarten Beobachtungen mit dem Wert 0 unterscheidet. Die Summe der Gewichtungen variiert dementsprechend je nach der Anzahl der räumlichen Nachbarschaften einer Beobachtung. Bei der zeilenstandardisierten Gewichtung wird jede Nachbarschaft einer Beobachtung durch die Gesamtanzahl aller Nachbarschaften dieser einen Beobachtung dividiert (Waller & Gatway, 2004). Folglich summieren sich die Werte für eine Beobachtung in jeder Zeile der räumlichen Nachbarschaftsmatrix zum Wert 1. Bei der varianzstabilisierenden Gewichtung variieren die unterschiedlichen Gewichte in den Zeilen selbst weniger als bei der zeilenstandardisierten Gewichtung, jedoch weichen dafür die Summen der Gewichtungen über die Zeilen mehr voneinander ab. Tiefelsdorf, Griffith und Boots (1999) verweisen auf zuletzt genannte Methode der räumlichen Gewichtung, welche das Ziel hat über die Summierung aller räumlichen Nachbarschaften die Varianz zu stabilisieren.

Für die Bestimmung von räumlichen Gewichtungen für beispielsweise räumliche Autokorrelationskoeffizienten kann auf keine natürliche Vorgabe bezüglich der Richtung der räumlichen Autokorrelationen, wie es für Zeitreihenmodelle möglich ist, Bezug genommen werden (Anselin & Bera, 1998). Da es keine universellen räumlichen Gewichtungen gibt, die in der Wissenschaft standardmäßig eingesetzt werden, sollte die Bestimmung von räumlichen Gewichtungen anhand der räumlichen Struktur der Daten inhaltlich nachvollziehbar ausgerichtet sein (Schulze, 1993). Zu beachten ist daher, dass die Ergebnisse immer unter Berücksichtigung der inhaltlichen Stärken und Schwächen der verwendeten räumlichen Gewichtungen zu interpretieren sind.

3.3 *Praktische Leitlinien und kritische Anmerkungen*

Griffith (1996) empfiehlt einige grobe Leitlinien, welche bei der praktischen Bestimmung einer räumlich gewichteten Nachbarschaftsmatrix behilflich sein können. Diese Leitlinien besagen zunächst, dass für Daten, die in irgendeinem räumlichen Zusammenhang stehen könnten, eher räumliche Abhängigkeiten anzunehmen sind als diese von vornherein auszuschließen. Indirekt wird damit empfohlen die Daten auf räumliche Autokorrelationen hin zu überprüfen. Weiter werden eine großer Stichprobenumfang und räumliche Modelle niedriger Ordnung gegenüber räumlichen Modellen hoher Ordnung bevorzugt empfohlen. Zu komplexe räumliche Modelle sollten gemieden werden, da diese zu mehr Problemen führen können als die simpleren Alternativen. Aus ähnlichem Grund wird darauf hingewiesen, dass es sinnvoll erscheint, eher weniger als zu viele räumliche Nachbarschaften zu bestimmen. Als

Faustregel scheint daher folgender Merksatz zu gelten: Weniger Komplexität ist einfach mehr.

Dacey (1965) kritisiert, dass die räumlichen gewichteten Nachbarschaftsmatrizen häufig unangemessen gewichtet werden und in Folge räumlich topologisch invariant sind. Die Kritik ist darauf zurückzuführen, dass für viele unterschiedliche räumliche Muster der Beobachtungen in den räumlich gewichteten Nachbarschaftsmatrizen dieselben räumlichen Gewichtungen verwendet werden, was zu denselben Ergebnissen trotz räumlicher Unterschiede führen kann. Das Ziel der räumlich gewichteten Nachbarschaftsmatrix sollte es jedoch sein die unterschiedlichen räumlichen Beziehungen und Muster möglichst realitätsgetreu im statistischen Modell zu repräsentieren (Cliff & Ord, 1969). Trotz dieser frühen Erkenntnis, stieß die Forderung nach flexiblen Gewichtungen der räumlichen Nachbarschaften in der Wissenschaft auf wenig Resonanz (Getis, 2009; Schulze, 1993). Dabei ermöglicht beispielsweise die generalisierte Cliff-Ord Gewichtung (Cliff & Ord, 1973, 1981) es dem Wissenschaftler die räumlichen Gewichtung derart zu wählen, dass diese an das wissenschaftliche Vorwissen und die eigenen Hypothesen bezüglich der räumlichen Prozesse angepasst werden kann. Dennoch wurde und wird häufig nur die einfachste Form einer gewichteten Nachbarschaftsmatrix mit binären Gewichten verwendet. Gründe dafür können einerseits das fehlende wissenschaftliche Vorwissen für spezifischere Gewichtungen und andererseits die damals zu simplen Computerprogramme sein, welche nur die Möglichkeit einer binären Gewichtung boten (Getis, 2009). Heutzutage ist eine Vielzahl an Programmen meist kostenlos über das Internet erhältlich, welche für den Nutzer diverse Möglichkeiten der räumlichen Gewichtung zur Verfügung stellt.

Spezifischere Gewichtungen bilden räumliche Prozesse und Strukturen in den statistischen Modellen genauer ab. Dies setzt jedoch voraus, dass genügend Wissen über die räumlichen Prozesse und Strukturen im Vorhinein vorhanden ist. Wenn die räumlichen Prozesse nicht ausreichend genau genug bestimmt werden können, scheint es wiederum angemessen auf einfachere räumliche Gewichtungen zur Bestimmung der räumlichen Nachbarschaften und Strukturen zurückzugreifen, obwohl das Problem der räumlich topologischen Invarianz bestehen bleibt (Getis, 2009; Yu et al., 2010).

4 Räumliche Regressionsmodelle („spatial regression models“)

Die angemessene Verwendung von linearen Regressionsmodellen bei räumlichen Autokorrelationen und alternative räumliche Regressionsmodelle werden in diesem Kapitel diskutiert. Im Folgenden werden die grundlegenden statistischen Voraussetzungen für lineare Regressionsmodelle und die Auswirkungen verletzter Voraussetzungen durch räumliche Autokorrelationen in Kapitel 4.1 beschrieben. In Kapitel 4.2 werden räumlich simultan autoregressive Modell erläutert und zwei Beispiele, das räumlich verzogene Regressionsmodell („spatial lag model“, Kapitel 4.2.1) und das räumlich fehlerbezogene Regressionsmodell („spatial error model“, Kapitel 4.2.2), als Modellanpassungsversuche bei signifikanten räumlichen Autokorrelationen vorgestellt. Statistische Voraussetzungen zu diesen beiden räumlich simultan autoregressiven Modellen werden in Kapitel 4.2.3 erläutert.

4.1 *Statistische Voraussetzungen linearer Regressionsmodelle und räumliche Autokorrelationen*

Für die folgenden Ausführungen wird ein grundlegendes Verständnis von linearen Regressionsmodellen vorausgesetzt. In einer vereinfachten Form kann die mathematische Formel für lineare Regressionsmodelle wie folgt dargestellt werden (Fotheringham, Brunson & Charlton, 2000):

$$y = \beta_0 + \beta X + \varepsilon \quad (4.1)$$

X ist eine n mal m große Matrix mit n Beobachtungen von m unabhängigen Variablen, β stellt die m Regressionskoeffizienten der unabhängigen Variablen dar, β_0 zeigt den y -Achsenabschnitt des Regressionsmodells unter den Bedingungen $X = 0$ und $\varepsilon = 0$ an und ε ist ein Fehlerterm, welcher alle Einflüsse der externen Variablen, die nicht in das theoretische Modell integriert werden, und alle zufälligen Verhaltensweisen der abhängigen Variablen beinhaltet (Berry, 1993).

In der Psychologie können lineare Regressionsmodelle dazu verwendet werden, um die linearen Zusammenhänge zwischen einer oder mehreren unabhängigen Variablen und einer abhängigen Variablen, beispielsweise dem Auftreten von gesundheitsgefährdenden Verhaltensweisen, zu beschreiben oder vorherzusagen. Mit linearen Regressionsmodellen können ebenso Beobachtungen auf ihre Konsistenz bezüglich wissenschaftlicher Modelltheorien überprüft werden. Aus einzelnen Stichproben werden dazu die Populationsparameter in ei-

nem linearen Regressionsmodell geschätzt und mit den zu erwartenden Parametern verglichen. Damit die statistische Bedeutsamkeit dieser Vergleiche und die angemessene Verwendung von Regressionsmodellen zu rechtfertigen ist, müssen bestimmte statistische Voraussetzungen erfüllt sein (Field, 2005). Eine umfassende Beschreibung über die statistischen Voraussetzungen für lineare Regressionsmodelle liefert Berry (1993, S. 12):

1. Alle unabhängigen Variablen sind quantitativ oder dichotom. Die abhängige Variable ist quantitativ, stetig und unbeschränkt. Dabei werden alle Variablen fehlerfrei erhoben.
2. Alle unabhängigen Variablen variieren in ihren Beobachtungen. Die Varianz der unabhängigen Variablen muss ungleich null sein.
3. Es besteht keine perfekte Multikollinearität. Die unabhängigen Variablen korrelieren nicht perfekt miteinander.
4. Der Mittelwert aller Fehlerterme der unabhängigen Variablen ist gleich null.
5. Die Kovarianzen zwischen jeder unabhängigen Variablen und dem Fehlerterm sind gleich null. Jede unabhängige Variable korreliert folglich nicht mit dem Fehlerterm.
6. Die Varianzen der unabhängigen Variablen sind konstant und somit auch die Varianzen der Fehlerterme. Diese Voraussetzung wird als Homoskedastizität oder Homogenität der Varianzen bezeichnet. Es wird angenommen, dass alle Stichproben aus derselben Population entstammen.
7. Die Kovarianzen zwischen den Fehlertermen der Beobachtungen einer Variablen sind gleich null. Die Fehlerterme der einzelnen Beobachtungen und die Beobachtungen selbst autokorrelieren nicht miteinander.
8. Die Fehlerterme der unabhängigen Variablen sind normalverteilt. Damit sind die Fehlerterme unabhängig voneinander.

Die ersten sieben Voraussetzungen werden auch als Gauss-Markov-Voraussetzungen bezeichnet. Parameterschätzer, welche die Gauss-Markov-Voraussetzungen erfüllen, gelten als unverfälscht und effizient (Berry, 1993). Unter der Bedingung erfüllter Voraussetzungen kann die angemessene Verwendung von Inferenzstatistiken, wie beispielsweise Signifikanztests oder die Konstruktion von Konfidenzintervallen, angenommen werden (Field, 2005). Inferenzstatistiken können auch für die Überprüfung der Passgenauigkeit der Beobachtungen mit dem angenommenen Modell verwendet werden.

Räumliche Autokorrelationen können die oben beschriebenen Voraussetzungen für lineare Regressionsmodelle verletzen und in Folge wichtige Eigenschaften der Schätzer beeinflussen. Räumliche Autokorrelationen verletzen auf den ersten Blick zumindest die siebente der oben angeführten Voraussetzungen. Können räumliche Autokorrelationen in den Daten nachgewiesen werden, sollte bereits auf Grundlage dieser Erkenntnis die Verwendung eines

standardisierten linearen Regressionsmodells überdacht und die Integration der räumlichen Informationen in Erwägung gezogen werden.

Die Qualität der Schätzer linearer Regressionsmodelle kann durch räumliche Autokorrelationen gemindert werden. Griffith (1987) zeigt anhand von vier statistischen Kriterien die Effekte von räumlichen Autokorrelationen, welche sich auf die Qualität der geschätzten Parameter auswirken können. Diese vier Kriterien, welche im Folgenden allgemein und bei vorliegenden räumlichen Autokorrelationen beschrieben werden, sind „unbiasedness“, „efficiency“, „sufficiency“ und „consistency“.

Mit „unbiasedness“ wird die fehlerfreie Schätzung der Populationsparameter beschrieben, wenn der Mittelwert über unendlich viele randomisierte Stichproben berechnet werden würde. Für unverfälschte Schätzer wird angenommen, dass diese den wahren Populationsparametern entsprechen. Beispielsweise können mithilfe von erhobenen Daten der Stichprobenmittelwert, die Regressionskoeffizienten, die Stichprobenvarianz und die Korrelationskoeffizienten berechnet und geschätzt werden. Die beiden erstgenannten Parameter werden in den meisten Fällen durch räumliche Autokorrelationen nicht wesentlich beeinflusst. Im Gegensatz dazu ist es sehr wahrscheinlich, dass die Stichprobenvarianz und die Korrelationskoeffizienten durch räumliche Autokorrelationen verfälscht werden. Davon ist in Folge auch die Schätzung des Standardfehlers betroffen.

Geschätzte Parameter weisen „efficiency“ auf, wenn diese unverfälscht sind und zusätzlich die minimalste Varianz und den minimalsten Standardfehler besitzen. In Datensätzen mit räumlichen Abhängigkeiten liegen positive räumliche Autokorrelationen am häufigsten vor und können zu einer Überschätzung der Stichprobenvarianz führen. Eine überschätzte Stichprobenvarianz wirkt sich wiederum auf die Schätzung des Standardfehlers aus. Bei positiven räumlichen Autokorrelationen können sich Informationen der Beobachtungen einer Variablen überschneiden oder einzelne Beobachtungen durch andere Beobachtungen vorhergesagt werden. Dies führt zu einer Informationsreduktion. Informationen, welche durch räumliche Autokorrelationen in identer Form vorliegen oder vorherzusagen sind, werden als redundante Informationen bezeichnet (Bivand, 2008; Anselin & Bera, 1998). In weiterer Folge führen positive räumliche Autokorrelationen zu einer Überschätzung der Stichprobengröße und einer Reduktion von Freiheitsgraden der räumlich autokorrelierenden Variablen (Fortin & Dale, 2005; Legendre, 1993).

Die Verwendung aller Informationen, welche für die unverfälschte und effiziente Schätzung eines Parameters aus den Stichprobendaten als hinreichend gelten, wird mit dem Begriff „sufficiency“ beschrieben. Räumliche Autokorrelationen können einen bedeutenden Erklärungsanteil der Varianz der abhängigen Variablen darstellen und sind als potentiell hinreichende Informationen für die Schätzung von Parametern anzusehen. Aufgrund fehlender Überprüfung und Missachtung werden jedoch häufig räumliche Autokorrelationen als Infor-

mationsträger übersehen. Räumliche Autokorrelationen sollten daher nicht als lästige Störfaktoren, sondern vielmehr als nützliche Informationsträger gesehen werden, die eine hinreichend genaue Schätzung der Parameter und eine verbesserte Modellanpassung ermöglichen, wenn diese in das theoretische Modell integriert werden (Anselin & Bera, 1998; Kühn, 2007).

Die Annahme, dass sich die geschätzten Parameter den wahren Werten asymptotisch annähern, wenn die Stichprobengröße gegen unendlich geht, wird mit dem Begriff „consistency“ beschrieben. Dieser asymptotische Prozess wird durch räumliche Autokorrelationen verlangsamt, sodass bei nur kleinen Stichproben die Schätzer stark von den wahren Parametern abweichen können.

Die Auswirkungen von verletzten Voraussetzungen linearer Regressionsmodelle durch räumliche Autokorrelationen sind denen bei Heteroskedastizität, also der verletzten Voraussetzung von konstanten Stichprobenvarianzen (Homoskedastizität), sehr ähnlich. Die geschätzten Parameter können trotz räumlicher Autokorrelationen und Heteroskedastizität unverfälscht bleiben, gelten aber nicht mehr als effizient. Räumliche Autokorrelationen und Heteroskedastizität können bei der Schätzung des Standardfehlers und der Standardabweichung zu verfälschten Parametern führen. Zu beachten ist daher, dass ineffiziente Parameterschätzer eher ungeeignet für inferenzstatistische Verfahren sind (Berry, 1993; Legendre, 1993).

Räumliche Autokorrelationen haben Einflüsse auf die abhängige, aber auch auf die unabhängigen Variablen, selbst wenn die räumlichen Autokorrelationen missachtet werden (Anselin & Bera, 1998; Griffith, 2009). Aus dem theoretischen Modell ausgeschlossene oder nicht beachtete räumliche Autokorrelationen sind im Fehlerterm enthalten. Räumliche Autokorrelationen verursachen daher korrelative Zusammenhänge zwischen den unabhängigen Variablen und dem Fehlerterm. Die Kovarianzen zwischen den unabhängigen Variablen und dem Fehlerterm müssen folglich von null abweichen und verletzen somit die fünfte der oben genannten Voraussetzung für lineare Regressionsmodelle. Räumliche Autokorrelationen, welche nicht explizit in das theoretische Modell integriert werden, können daher auch zu einer nicht hinreichend genauen Schätzung der Parameter im Sinne der „sufficiency“ führen.

Die normalverteilten und unabhängigen Fehlerterme der unabhängigen Variablen entsprechen der achten Voraussetzung für lineare Regressionsmodelle. Diese Voraussetzung gilt auch für die Residuen der Daten (Fotheringham, Brunson & Charlton, 2000). Durch ungenaue Messungen oder den Ausschluss von wichtigen erklärenden Variablen, können räumliche Autokorrelationen in den Residuen entstehen (Cliff & Ord, 1981; Haining, 2003). Die Verletzung der oben beschriebenen Voraussetzung durch räumliche Autokorrelationen erhöht in Folge das Risiko einem Fehler 1. Art zu unterliegen (Anselin, 2002; Diniz-Filho, Bini und Hawkins, 2003; Dormann et al., 2007; Fortin & Dale, 2005; Fortin, Dale & ver Hoef,

2002; Kissling & Carl, 2008; Legendre, 1993; Perez, Diniz-Filho, Bernal & Gonzalez, 2010; Ward & Gleditsch, 2008). Der Fehler 1. Art beschreibt die fälschlicherweise getroffene Entscheidung gegen die Nullhypothese zugunsten der Alternativhypothese, obwohl die Nullhypothese in Wahrheit zu trifft. In weiterer Folge sind redundante Informationen der Beobachtungen sehr wahrscheinlich, wodurch die Anzahl der Freiheitsgrade reduziert wird. Dies unterstützt die Vermutung, dass lineare Regressionsmodelle bei räumlichen Autokorrelationen für die Schätzung der Parameter nicht hinreichend gut genug geeignet sind (Anselin & Bera, 1998; Fotheringham, Brunsdon & Charlton, 2000).

Zum Problem bei der Konstruktion linearer Regressionsmodelle können auch zugrundeliegende nichtlineare Prozesse und Interaktionen zwischen den unabhängigen Variablen werden (Dormann et al., 2007; Field, 2005). Lineare Regressionsmodelle können jedoch für die Schätzung von nichtlinearen oder interaktionalen Parametern verwendet werden, wenn die Eigenschaften des Modells als „intrinsisch linear und additiv“ gelten. Folglich können Parameter, welche aus nichtlinearen oder interaktionellen Modell stammen, mit Hilfe linearer Verfahren hinreichend genau geschätzt werden, wenn sich das Modell durch mathematische Transformation in ein lineares Modell umwandeln lässt (Berry, 1993). In der Praxis werden häufig zunächst lineare Regressionsmodellversuch zur Erklärung herangezogen. Kritisch ist diese Vorgehensweise zu sehen, wenn trotz besseren Wissens über nichtlineare und interaktionelle Eigenschaften der Daten lineare Regressionsmodelle ohne eine Überprüfung der Angemessenheit verwendet werden.

Werden die Voraussetzungen für lineare Regressionsmodelle nicht überprüft oder missachtet, sind ineffiziente Schätzer und Trugschlüsse nicht auszuschließen. Dementsprechend gehen Schlussfolgerungen, die auf der Annahme räumlich unabhängiger Beobachtungen basieren, bei bestehenden räumlichen Autokorrelationen von falschen Voraussetzungen aus und das Risiko verfälschte Ergebnisse zu erhalten ein. Die Effekte von räumlichen Autokorrelationen in linearen Regressionsmodellen können bei einer Missachtung derart stark sein, dass fälschlicherweise Regressionskoeffizienten in die entgegengesetzte Richtung geschätzt und nichtsignifikante Schätzer für signifikant gehalten werden (Kühn, 2007). Diese Ergebnisse resultieren dann in ebensolch falschen Interpretationen und Trugschlüssen bei der inferenzstatistischen Überprüfung von wissenschaftlichen Hypothesen. Daher sollte bei raumbezogenen Daten eher von der Existenz räumlicher Autokorrelationen ausgegangen werden (Griffith, 1996). Durch die Überprüfung räumlicher Autokorrelationen mittels geeigneter räumlicher Autokorrelationskoeffizienten und der Verwendung räumlicher Regressionsmodelle wird häufig die Modellanpassung verbessert und das Risiko für verfälschte Ergebnisse gemindert (Diniz-Filho, Bini & Hawkins, 2003; Lennon, 2000).

4.2 *Räumlich simultan autoregressive Modelle*

Für die unterschiedlichen räumlichen Regressionsmodelle gibt es in der Wissenschaft mehrere Begrifflichkeiten. Ward und Gleditsch (2008) kritisieren die Bezeichnung „räumlich autoregressive Modelle“ („spatial autoregressive models“; Anselin, 1988), da der Begriff „autoregressiv“ in der Geostatistik auch für andere räumliche Modelle verwendet wird und daher missverstanden werden könnte. Um diesen Missverständnissen entgegenzuwirken, wird die Bezeichnung „räumlich simultan autoregressive Modelle“ in dieser Arbeit als Überbegriff für räumliche Regressionsmodelle, welche räumliche Autokorrelationen berücksichtigen und diese als eigenständige Variable in die Regressionsmodelle integrieren, verwendet.

Räumliche Autokorrelationen werden in der wissenschaftlichen Forschung häufig als lästiges Übel bei der statistischen Auswertung von raumbezogenen Daten empfunden. Räumliche Autokorrelationen können die statistische Angemessenheit linearer Regressionsmodelle und entsprechender inferenzstatistischer Verfahren gefährden. Dennoch sind räumliche Autokorrelationen nicht zwingend als eine Bedrohung der statistischen Verfahren zu sehen, sondern können vielmehr als Chance genutzt werden, um zusätzliche Informationen über räumliche Prozesse und Einflussfaktoren zu sammeln, welche dann in die wissenschaftlichen Modelle mit einfließen können (Fortin und Dale, 2005; Kühn, 2007). Im Gegensatz zu den standardisierten linearen Regressionsmodellen berücksichtigen räumlich simultan autoregressive Modelle die räumlichen Zusammenhänge der Daten in ihren Schätzungen (Cressie, 1993; Haining, 2003). Dafür werden die räumlichen Autokorrelationen in die Regressionsmodelle als eine eigenständige Variable integriert (Kissling & Carl, 2008). Das Ziel räumlich simultan autoregressiver Modelle ist eine verbesserte Modellanpassung durch die statistische Kontrolle der räumlichen Autokorrelationen.

Räumlich simultan autoregressive Modelle werden hauptsächlich für die Abbildung von räumlichen Autokorrelationen und Strukturen in den Daten und weniger für die Schätzung von nicht erfassten räumlichen Beobachtungen verwendet. Statistische Verfahren zur Schätzung von fehlenden räumlichen Daten anhand bestehender Beobachtungen werden räumliche Interpolationen genannt (Fortin & Dale, 2005). Dazu gehören Verfahren wie beispielsweise das „Kriging“ (Krige, 1951). Das „Kriging“ ist ein optimiertes lineares Verfahren zur Schätzung unbekannter raumbezogener Daten, welches bei der Wahl der räumlichen Gewichtungen die räumlichen Varianzen aus einem zugrundeliegenden räumlichen Variogramm berücksichtigt. Die Parameter eines linearen Modells können dadurch ohne systematische Fehler erwartungsgetreu und effizient geschätzt werden.

In räumlich simultan autoregressiven Modellen werden räumlich gewichtete Nachbarschaftsmatrizen verwendet, welche die räumlichen Beziehungen zwischen den Beobachtungen beschreiben und individuell gewichtet werden können (Anselin & Bera, 1998; Fortin &

Dale, 2005). Die räumlich gewichtete Nachbarschaftsmatrix im räumlich simultan autoregressiven Modell erklärt die räumlichen Abhängigkeiten in der abhängigen Variablen, welche durch die benachbarten Beobachtungen und nicht durch die unabhängigen Beobachtungen der Variablen erklärt werden (Kissling & Carl, 2008).

Analogien zu seriell autoregressiven Zeitreihenmodellen bestehen bei räumlich simultan autoregressive Modelle in der formalen Struktur (Anselin & Bera, 1998; Ward & Gleditsch, 2008). Ein wesentlicher Unterschied besteht jedoch in den Richtungen, welche die zeitlichen beziehungsweise räumlichen Autokorrelationen annehmen können. Zeitliche Autokorrelationen lassen sich in die natürlichen Komponenten der Vergangenheit und Gegenwart unterteilen. Die somit vorgegebene Richtung der Effekte ist folglich nur einseitig und unilateral möglich. Hingegen bestehen für räumliche Autokorrelationen keine natürlichen Vorgaben bezüglich der Richtung. Wechselseitige und multilaterale Abhängigkeiten sind in für räumliche Autokorrelationen in den unterschiedlichsten Richtungen möglich (Cliff & Ord, 1981). Die meisten der räumlichen Autokorrelationen scheinen dennoch bilateraler Natur zu sein (Schulze, 1993).

Die zwei räumlich simultan autoregressiven Modelle, welche im Folgenden beschrieben werden, unterscheiden sich im Wesentlichen in ihrer Annahme bezüglich der vermuteten Verortung der räumlichen Autokorrelationen. Zur Verdeutlichung dieser Annahmen wird für jedes räumlich simultan autoregressive Modell auf das in Kapitel 1.2 beschriebene ökologische Erklärungsmodell für räumliche Autokorrelationen Bezug genommen.

4.2.1 Das räumlich verzogene Regressionsmodell („spatial lag model“)

Die Bezeichnung „spatial lag“ stammt vom Begriff „time lag“, welcher bei seriellen Zeitreihenmodellen verwendet wird (Anselin, 2001). Synonym für die englische Bezeichnung „spatial lag model“ wird in dieser Arbeit der deutsche Term „räumlich verzogenes Regressionsmodell“ verwendet, um einen erkennbaren Bezug zum Faktor Raum herzustellen.

Das räumlich verzogene Regressionsmodell stellt eine Möglichkeit dar, um die räumlichen Autokorrelationen der benachbarten Beobachtungen in das Regressionsmodell zu integrieren und den Informationsverlust auszugleichen, welcher durch die abhängigen Stichproben verursacht wird (Anselin & Bera, 1998). Dafür wird eine eigenständige und unabhängige Variable in die Regressionsgleichung eingefügt, welche den räumlich autokorrelierenden Anteil der abhängigen Variablen erklären soll (Fotheringham, Brunson & Charlton, 2000).

Für die Verwendung des räumlich verzogenen Regressionsmodells sollten zunächst räumliche Autokorrelationen nachgewiesen werden können. Konnte gezeigt werden, dass räumliche Autokorrelationen vorliegen, können Annahmen über die Verortung der räumlichen Autokorrelationen angestellt werden. Für das räumlich verzogene Regressionsmodell wer-

den die räumlichen Autokorrelationen allein zwischen den benachbarten Beobachtungen der abhängigen Variablen vermutet (Kissling & Carl, 2008). Die benachbarten Beobachtungen der abhängigen Variablen haben dabei einen direkten räumlichen Einfluss aufeinander. Häufig wird weiter davon ausgegangen, dass die räumlichen Autokorrelationen mit zunehmender Distanz zwischen den Beobachtungen schwächer werden (Anselin, 2001). Werden die räumlichen Autokorrelationen in der abhängigen Variablen vermutet, sind für die Ursache endogene und inhärente räumliche Prozesse nach dem ökologischen Erklärungsmodell für räumliche Autokorrelationen aus Kapitel 1.2. sehr wahrscheinlich. Die abhängige Variable ist demnach durch ihre eigenen Eigenschaften für die räumlichen Cluster von sich ähnelnden Beobachtungen ursächlich.

Die formale Darstellung des räumlich verzogenen Regressionsmodells lässt sich aus der Gleichung für lineare Regressionsmodelle herleiten (Griffith, 2011). Die Gleichung des räumlich verzogenen Regressionsmodells lautet:

$$y = \beta_0 + \beta X + \rho W y + \varepsilon \quad (4.2)$$

Die Modifikation des linearen Regressionsmodells besteht in der Integration einer unabhängigen Variablen, die sich aus dem räumlichen Autokorrelationskoeffizienten ρ und der räumlich gewichteten Nachbarschaftsmatrix $W y$ zusammensetzt (Anselin, 2001). $W y$ fasst alle räumlich benachbarten und nichtbenachbarten Beobachtungen der abhängigen Variablen in einer Matrix zusammen. Das Ausmaß der räumlichen Autokorrelationen in der abhängigen Variablen wird durch den Parameter ρ in der Regressionsgleichung beschrieben (LeSage, 1997). Die räumlichen Nachbarschaften zwischen den Beobachtungen in der Matrix können beispielsweise binär mit $w_{ij} = 0$, wenn keine räumliche Nachbarschaft besteht, und mit $w_{ij} = 1$, wenn eine räumliche Nachbarschaft zwischen den Beobachtungen i und j existiert, definiert und gewichtet werden (Fotheringham, Brunson & Charlton, 2000). Zur Vereinheitlichung und besseren Vergleichbarkeit mit anderen Studien werden die räumlichen Nachbarschaften in der Matrix häufig auch zeilenstandardisiert gewichtet (Anselin & Bera, 1998).

Für die Interpretation des räumlichen Autokorrelationskoeffizienten ρ im räumlich verzogenen Regressionsmodell ist zu beachten, dass trotz der vermuteten räumlich endogenen Prozesse der abhängigen Variablen als Ursache für die räumlichen Autokorrelationen zwischen zwei Prozessen unterschieden werden kann. Erstens kann ein signifikantes ρ als Indikator für räumliche Übertragungsprozesse („spatial spillovers“) der räumlichen Autokorrelationen stehen. Die räumlichen Autokorrelationen werden endogen durch bestimmte Eigenschaften der abhängigen Variablen selbst von einer benachbarten Beobachtung zur nächs-

ten übertragen und nehmen mit zunehmender Distanz an Intensität ab. Zweitens können die räumlichen Autokorrelationen im räumlich verzogenen Regressionsmodell aber auch durch externe räumliche Prozesse und Faktoren induziert werden, welche beispielsweise bei der Erhebung der abhängigen Variablen nicht erfasst wurden (Anselin & Bera, 1998).

4.2.2 Das räumlich fehlerbezogene Regressionsmodell („spatial error model“)

Die Begriffe „spatial moving average models“ (Cliff & Ord, 1981; Fotheringham, Brunson & Charlton, 2000; Haining, 1988, 1990) und „spatial error models“ (Anselin, 2001; Ward & Gleditsch, 2008) meinen nicht dasselbe und können zu Missverständnissen führen. In dieser Arbeit sind mit dem Begriff „räumlich fehlerbezogene Regressionsmodelle“ nur solche „spatial error models“ gemeint, welche räumliche Autokorrelationen im Fehlerterm vermuten und diese als eigenständige Variable in das Regressionsmodell integrieren.

Wird die Ursache der räumlichen Autokorrelationen weder durch den direkten Einfluss der benachbarten Beobachtungen in der abhängigen Variablen, noch durch den direkten Einfluss der Beobachtungen der unabhängigen Variablen vermutet, wird meist das räumlich fehlerbezogene Regressionsmodelle dem räumlich verzogenen Regressionsmodelle vorgezogen (Anselin, 2001; Kissling & Carl, 2008). Für das räumlich fehlerbezogene Regressionsmodell wird die Verortung der räumlichen Autokorrelationen allein im Fehlerterm des Regressionsmodells angenommen (Dormann et al., 2007; Ward & Gleditsch, 2008). Nicht die benachbarten Beobachtungen der abhängigen Variablen selbst autokorrelieren räumlich miteinander, sondern deren Fehler.

Räumliche Autokorrelationen im Fehlerterm können sowohl durch räumliche Eigenschaften externer Variablen induziert, als auch durch räumlich inhärente Eigenschaften der abhängigen Variablen verursacht werden (Kissling & Carl, 2008). Für das räumlich fehlerbezogene Regressionsmodell werden nach dem ökologischen Erklärungsmodell aus Kapitel 1.2 jedoch hauptsächlich räumlich exogene Prozesse, welche die räumlichen Autokorrelationen induzieren, als Ursache angenommen. Mögliche Ursachen für die induzierten räumlichen Autokorrelationen können beispielsweise bedeutende räumliche Faktoren sein, welche nicht erhoben und in das Regressionsmodell als erklärende Variablen integriert wurden (Diniz-Filho, Bini & Hawkins, 2003; Legendre, 1993). Die Missachtung von externen räumlichen und varianzerklärenden Faktoren ist auch noch in neuen wissenschaftlichen Forschungsfeldern zu beobachten, was durch den bestehende Informationsmangel über räumliche Autokorrelationen und deren Einflüsse erklärt werden könnte (Ward & Gleditsch, 2008).

Die räumlichen Autokorrelationen, welche zwischen den Fehlern der benachbarten Beobachtungen bestehen, haben für die standardisierten Regressionsmodelle keine direkten Auswirkungen auf die geschätzten Regressionskoeffizienten, jedoch können die geschätzten

Standardfehler der Beobachtungen indirekt verfälscht werden, wodurch die Effizienz wiederum eingeschränkt wäre (Anselin, 2001; Ward & Gleditsch, 2008).

Für räumlich fehlerbezogene Regressionsmodelle wird der Fehlerterm in einen abhängigen und einen unabhängigen Fehlerterme aufgeteilt. Der abhängige Fehlerterm $\lambda W\mu$ kontrolliert die räumlichen Autokorrelationen, wohingegen der Fehlerterm ε durch die Korrektur des abhängigen Fehlerterms als unabhängig gilt (Ward & Gleditsch, 2008). Die Formel für räumlich fehlerbezogene Regressionsmodelle lautet demnach:

$$\mathbf{y} = \boldsymbol{\beta}_0 + \boldsymbol{\beta}\mathbf{X} + \lambda\mathbf{W}\boldsymbol{\mu} + \boldsymbol{\varepsilon} \quad (4.3)$$

λ entspricht dem räumlichen Autokorrelationskoeffizienten, welcher das Ausmaß der räumlichen Autokorrelationen zwischen den Fehlern der Beobachtungen anzeigt und $W\mu$ steht für die räumliche Nachbarschaftsmatrix, welche die räumlichen Nachbarschaften zwischen den voneinander abhängigen Fehlern der Beobachtungen definiert.

4.2.3 Statistische Voraussetzungen

Eine wichtige statistische Voraussetzung für die angemessene Verwendung von simultan autoregressiven Modellen ist die Erfüllung der räumlichen Stationarität (Cressie, 1993; Dormann et al., 2007; Fortin, Dale & ver Hoef, 2002; Legendre & Legendre, 1998). Es wird angenommen, dass die räumlichen Autokorrelationen und externen Einflüsse der Umwelt über die Beobachtungen hinweg konstant sind. Für räumlich nichtstationäre Daten, die beispielsweise häufig in der Artenverbreitung anzufinden sind, gibt es derzeit nur wenige und qualitativ unterschiedliche statistische Verfahren (Osborne, Foody & Suárez-Seoane, 2007). Eines dieser Verfahren stellen jedoch geografisch gewichtete Regressionsmodelle („geographically weighted regressions“) dar (Fotheringham, Brunson & Charlton, 2002). Für geografisch gewichtete Regressionsmodelle können räumlich nichtstationäre Datensätze verwendet werden, da die räumlichen Varianzen für die einzelnen Teilgebiete des Datensatzes berücksichtigt und durch individuelle Gewichtungen ausgeglichen werden. Der Fokus wird dabei vor allem auf die lokalen räumlichen Zusammenhängen und Prozesse in den beobachteten Daten gerichtet.

Die Wahl der räumlich simultan autoregressiven Modelle richtet sich meist nach dem vermuteten Ursprung der räumlichen Autokorrelationen. Häufig wird nur zwischen den beiden Möglichkeiten unterschieden, dass die räumlichen Autokorrelationen entweder in der abhängigen Variablen oder dem Fehlerterm verortet sind. Sind die größten Anteile der räumlichen Autokorrelationen im Fehlerterm zu erkennen, kann jedoch auch vermutet werden, dass die räumlich globalen autoregressiven Modelle den raumbezogenen Daten nicht ge-

recht werden, wodurch die Verwendung von räumlich lokalen autoregressiven Modellen angemessener erscheint (Fotheringham, Brunsdon & Charlton, 2000).

Sind trotz der Verwendung von räumlich simultan autoregressiven Modellen weiterhin räumliche Autokorrelationen zu beobachten, können dafür fehlerhafte Modellanpassungen, wie beispielsweise durch ausgeschlossene Variablen, welche bedeutende Anteile an den räumlichen Autokorrelationen erklären (Berry, 1993; Dormann et al., 2007), oder unabhängige Variablen, die in einer inadäquaten Form in das Modell integriert wurden (Bivand, Pebesma & Gómez-Rubio, 2008), ursächlich sein. Fehlerhafte Modellanpassungen können auch durch unangemessene Annahmen über die räumlichen Zusammenhänge oder zugrundeliegenden räumlichen Prozesse der beobachteten Daten entstehen. Werden die räumlich simultan autoregressiven Modellversuche den räumlichen Strukturen der Daten nicht gerecht, sind ungenaue Schätzungen der Parameter möglich. Die Evaluierung der abhängigen Variablen wird dadurch erschwert und inferenzstatistische Verfahren können zu falschen Schlussfolgerungen und Interpretationen führen (Dormann et al., 2007; Kissling & Carl, 2008).

Zuletzt ist zu beachten, dass Unterschiede in den Annahmen bezüglich der Reichweite der räumlichen Effekte zwischen dem räumlich verzogenen und dem räumlich fehlerbezogenen Regressionsmodell bestehen. Das räumlich fehlerbezogene Regressionsmodell nimmt an, dass alle Fehler der beobachteten Daten miteinander korrelieren und abhängig voneinander sind. Die räumlichen Abhängigkeiten beschränken sich somit nicht nur auf die nächstgelegenen und benachbarten Beobachtungen. Hingegen geht das räumlich verzogene Regressionsmodell von der Annahme aus, dass nur die direkt benachbarten Beobachtungen miteinander korrelieren und voneinander abhängig sind (Fotheringham, Brunsdon & Charlton, 2000).

Praktische Anwendungsbeispiele

5 Praktische Anwendungsbeispiele zur Analyse raumbezogener Suizidraten in Europa

5.1 *Die räumliche Verteilung europäischer Suizidraten anhand von drei linearen Regressionsmodellen*

Betrachtet man die Verteilung der Suizidraten in Europa, so fällt auf, dass sich die höchsten Suizidraten für Frauen und Männer in einem zusammenhängenden, J-förmigen Gürtel im Osten Europas ballen (Marušič & Farmer, 2001). Für die Suizidraten europäischer Landeshauptstädte mit dieser räumlichen Ballung im Osten bestimmten Voracek, Fisher und Marušič (2003) ein lineares Regressionsmodell anhand der geografischen Breiten- und Längengrade. Im Modell werden die Suizidraten durch einen Interaktionsterm mit quadriertem Breiten- und einfachem Längengrad und einer weiteren unabhängigen Variablen, welche aus dem einfachen Breitengrad besteht, am besten erklärt. In zwei weiteren Studien wurden diese geografisch auffälligen Muster der Suizidraten in Europa genauer untersucht. Voracek, Loibl und Kandrychyn (2007) fanden in ihrer späteren Studie dieselben signifikanten Prädiktoren wie Voracek, Fisher und Marušič (2003), bestehend aus dem Interaktionsterm mit quadriertem Breiten- und einfachem Längengrad und dem einfachen Breitengrad, anhand eines vergrößerten Datensatzes mit regionalen und gemittelten Suizidraten. In einer letzten Studie von Voracek und Marušič (2008) wurden nur die Daten der Bevölkerungsgruppe von 65jährigen und älteren Personen aus denselben 34 europäischen Landeshauptstädten wie bei Voracek, Fisher und Marušič (2003) verwendet. Die Suizidraten wurden einerseits nach Geschlecht aufgeteilt und andererseits ein Gesamtmittelwert über den Zeitraum von 1970-2002 für die vorhandenen Daten berechnet. In den linearen Regressionsmodellen für die Frauen, Männer und den gemittelten Gesamtwert konnte nur der Interaktionsterm aus quadriertem Breiten- und einfachem Längengrad einen signifikanten Anteil der Suizidraten erklären. Die Existenz von räumlichen Autokorrelationen wurde in diesem Zusammenhang für keine der erwähnten Studien überprüft.

In dieser Arbeit wird geklärt, ob räumliche Autokorrelationen für die linearen Regressionsmodelle der europäischen Suizidraten in den drei oben genannten Studien vorliegen. Sind räumliche Autokorrelationen nachzuweisen, werden zwei räumlich simultan autoregressive Modelle, ein räumlich verzogenes und ein räumlich fehlerbezogenes Regressionsmodell, geschätzt und die Modellanpassungen anhand des Akaike's Informationskriteriums (AIC) mit dem des ursprünglichen linearen Regressionsmodells verglichen. Prozesse der räumlichen Autokorrelationen linearer und räumlicher Regressionsmodelle über die räumlichen Distanzklassen hinweg werden in räumlichen Korrelogrammen bildlich dargestellt.

5.2 Geostatistische Berechnungen und Darstellungen mit „R“

Die Berechnung von räumlich simultan autoregressiven Modellen wurde in der Literatur schon früh beschrieben (Besag, 1974; Cliff & Ord, 1981), fand aber nur wenig praktische Anwendung in der wissenschaftlichen Forschung (Getis, 2009). Kissling und Carl (2008) führen dafür als einen möglichen Grund die intensive und sehr aufwändige Berechnung an. Häufig konnten die Möglichkeiten räumlich simultan autoregressiver Modelle aufgrund fehlender Berechnungs- und Softwaremöglichkeiten weder ausgeschöpft, noch evaluiert oder weiterentwickelt werden. Moderne und freizugängliche Softwareentwicklungen eröffneten der wissenschaftlichen Forschung in den letzten Jahren eine Vielzahl an neuen und umfangreichen Möglichkeiten bei der statistischen Analyse raumbezogener Daten. In dieser Arbeit wird die Statistiksoftware „R“ (R Development Core Team, 2011) mit den Zusatzpaketen „spdep“ (Bivand, 2011) und „ncf“ (Bjornstad, 2009) für die geostatistische Analyse und Auswertung der raumbezogenen Suizidraten verwendet. Für eine genauere Beschreibung zu den Softwarepaketen wird auf die im Internet freizugänglichen Manuale verwiesen. Im Folgenden soll „R“ anhand einiger Vor- und Nachteile kurz beschrieben werden.

„R“ steht als sogenanntes Open Source Programm jedem Internetnutzer kostenlos zur Verfügung. Mit „R“ können in der Basisversion simple Grundrechenarten, sowie einfache statistische Tests und Modelle berechnet werden. Zusätzlich und ebenso kostenlos können weitere Softwarepakete („packages“) installiert werden, welche spezifisch statistische Anwendungen und Berechnungen von komplexeren Modellen, wie beispielsweise geostatistischen Modellen, ermöglichen. Für jedes Softwarepaket ist in der Regel eine kostenlose Anleitung („manual“) online verfügbar. Die Anleitungen erleichtern das Verständnis der durchgeführten statistischen Anwendungen und machen die Berechnungsmethoden Schritt für Schritt nachvollziehbar. Als Open Source Programm ist es zudem jedem Internetnutzer möglich eigens programmierte Zusatzpakete anderen Internetnutzern zur Verfügung zu stellen. Damit kann sich die Entwicklung und Weiterentwicklung statistischer Methoden am aktuellen Stand der Wissenschaft orientieren und bietet gleichzeitig die Möglichkeit statistische Methoden aus anderen Wissenschaften für die eigene Forschung zu testen oder sogar zu adaptieren. Bis dato unübliche oder schwer zu realisierende statistische Methoden werden für ein breites wissenschaftliches Publikum zur Verfügung gestellt und für die Weiterentwicklung nutzbar gemacht. Die Evaluierung und Verbesserung der Zusatzpakete geschieht durch das Feedback der Nutzer selbst, welche sich teilweise auch an der Programmierung und Verbesserung der Softwarepakete beteiligen können. Ein weiterer Vorteil ist die große Kompatibilität von „R“. So stehen für die bekanntesten Betriebssysteme unterschiedliche Versionen von „R“ zur Verfügung. Datensätze aus anderen Statistikprogrammen, wie beispielsweise „SPSS“, können ebenso in „R“ eingelesen und statistisch ausgewertet werden.

Als nachteilig kann bei einem nur geringen Verständnis der Programmiersprache die kaum objektorientierte und nicht selbsterklärende Oberfläche der Software empfunden werden, da jede statistische Anwendung in Form von speziellen Kommandos in das Textfeld des Programms eingegeben und fallweise spezifiziert werden muss.

Für eine allgemeine Einführung in „R“ wird das kostenlose Skript „An Introduction to R“ (Venables, Smith & R Development Core Team, 2011) empfohlen. Eine spezifischere Einführung im Umgang mit raumbezogenen Daten bieten Bivand, Pebesma und Gómez-Rubio (2008).

5.3 Die Überprüfung der linearen Regressionsmodelle aus drei Studien auf räumliche Autokorrelationen

Die Residuen der linearen Regressionsmodelle werden mit dem globalen räumlichen Autokorrelationskoeffizienten Moran's I auf vorliegende räumliche Autokorrelationen überprüft und auf ihre Signifikanz hin getestet. Die Bestimmung der räumlichen Nachbarschaften erfolgt anhand einer zuvor definierten Distanz zwischen den Koordinaten der jeweiligen Datenpunkte. Das Nachbarschaftskriterium wurde nach einer Empfehlung von Anselin und Bera (1998) so gewählt, dass jeder Datenpunkt mindestens einen räumlichen Nachbarn aufweist.

5.3.1 Studie 1: Voracek, Fisher und Marušič (2003)

In dieser Studie wurde gezeigt, dass für die linearen Regressionsmodelle der Frauen und Männer ein Interaktionsterm aus quadriertem Breiten- und einfachem Längengrad mit zusätzlichem Breitengrad als weiteren Prädiktor die Suizidraten am besten erklären. Um der Empfehlung gerecht zu werden, dass jede Beobachtung mindestens einen räumlichen Nachbarn besitzt (Anselin & Bera, 1998), wird für das räumliche Nachbarschaftskriterium dieser Studie anhand der Suizidraten der 34 europäischen Landeshauptstädte ein Radius gewählt, welcher nur knapp über der größten Distanz 1. Ordnung zwischen zwei Landeshauptstädten liegt. Alle europäischen Landeshauptstädte, die sich innerhalb dieses Umkreises einer einzelnen Landeshauptstadt befinden, werden somit als räumliche Nachbarn dieser Landeshauptstadt definiert. Da die größte Distanz zwischen zwei Landeshauptstädten knapp unter 1500 Kilometern liegt, wird dieser Wert als obere Grenze und Radius für das räumliche Nachbarschaftskriterium festgelegt. Die aus dieser Nachbarschaftsdefinition resultierende räumliche Nachbarschaftsmatrix wurde für die weiteren Berechnungen zeilenstandardisiert gewichtet.

Die räumlichen Autokorrelationen zwischen den Residuen des linearen Regressionsmodells für Frauen und Männer werden zunächst in räumlichen Korrelogrammen bildlich dargestellt und interpretiert (Abbildung 4).

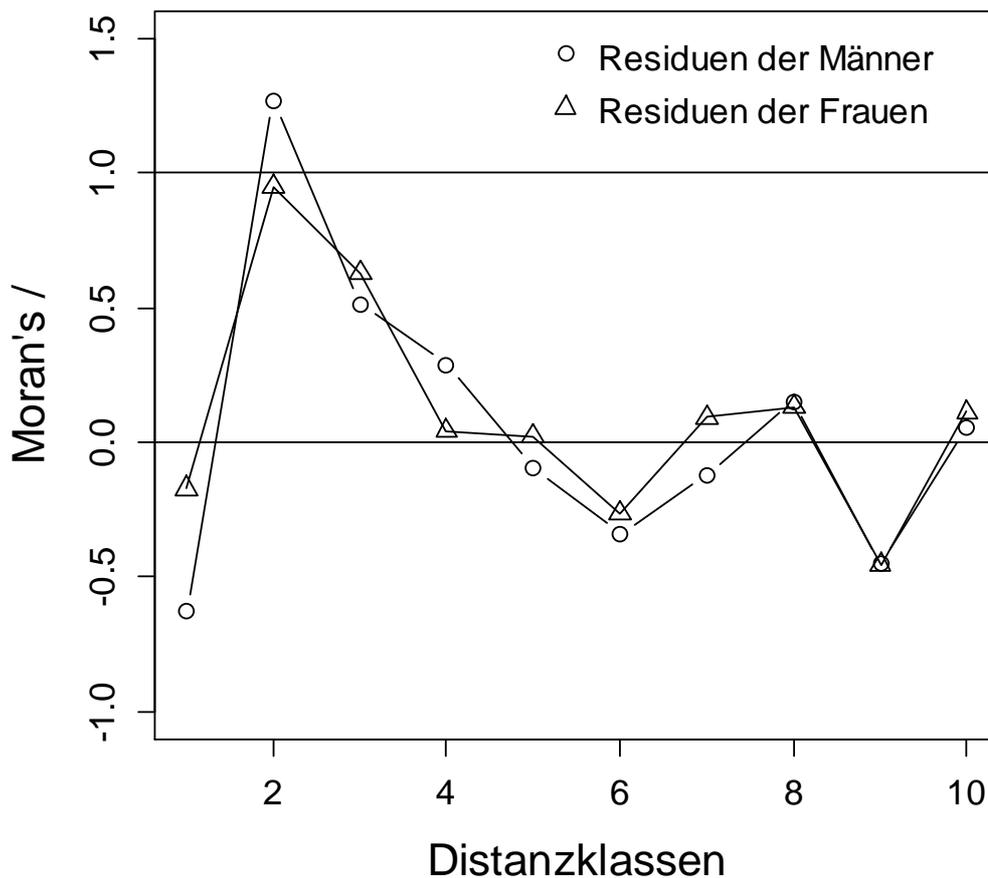


Abb. 4: Räumliches Korrelogramm von Residuen des linearen Regressionsmodells für Frauen und Männer nach Voracek, Fisher und Marušič (2003) mit einem Nachbarschaftskriterium von 1500 Kilometern.

Es fällt auf, dass bei den Männern in der zweiten Distanzklasse der obere Grenzwert von Moran's I , welcher durch die waagerechte Linie für den Wert 1 dargestellt ist, überschritten wird. Dies kann vor allem bei einem kleinen Stichprobenumfang durchaus vorkommen, wenn beispielsweise die Daten Ausreißer aufweisen oder nicht asymptotisch normalverteilt vorliegen (Fortin, Dale & ver Hoef, 2002). Betrachtet man die Verteilung der Suizidraten für Frauen und Männer, fallen die nicht gerade normalverteilten Strukturen der Daten auf (Abbildung 5 (a)-(b)). Diese sind sehr wahrscheinlich für die großen Sprünge bei Frauen und Männern, sowie die Grenzwertüberschreitung nur bei den Männern in den räumlichen Korrelogrammen verantwortlich. Bei den Frauen ist der höchste Wert für die räumlichen Autokorrelationen ebenso in der zweiten Distanzklasse zu beobachten. Dieser bleibt jedoch unterhalb des oberen Grenzwerts von Moran's I . Die räumlichen Autokorrelationen schwanken in unregelmäßigen Abständen um den Wert von Moran's I , welcher zu erwarten ist, wenn keine räumlichen Autokorrelationen existieren würden. Für Frauen und Männer sind in der ersten Distanzklasse negative räumliche Autokorrelationen zu beobachten, die in der zweiten Distanzklasse zu positiven räumlichen Autokorrelationen werden, was sehr wahrscheinlich auch aus der unregelmäßigen Verteilung der Suizidraten resultiert. Danach wech-

seln die räumlichen Autokorrelationen ab der sechsten Distanzklasse für die Frauen und ab der fünften für die Männer immer wieder in unregelmäßigen Abständen das Vorzeichen. Derartige Schwankungen der räumlichen Autokorrelationen um den Erwartungswert lassen vermuten, dass ein Gesamtwert der räumlichen Autokorrelationen wahrscheinlich nur sehr niedrig ausgeprägt und nicht signifikant sein wird.

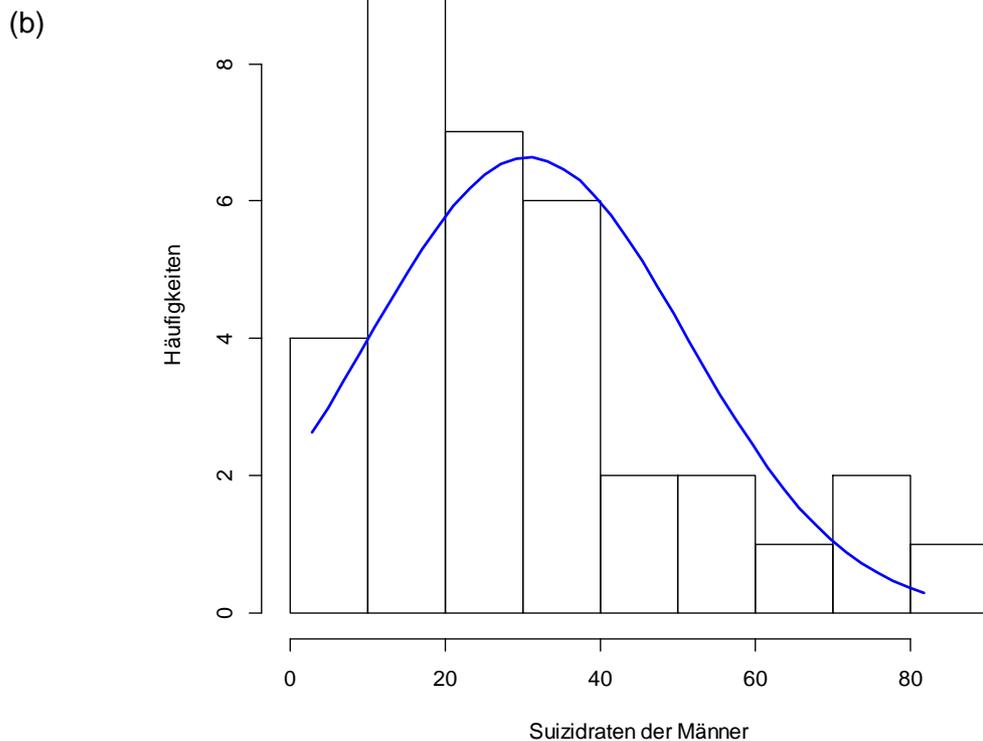
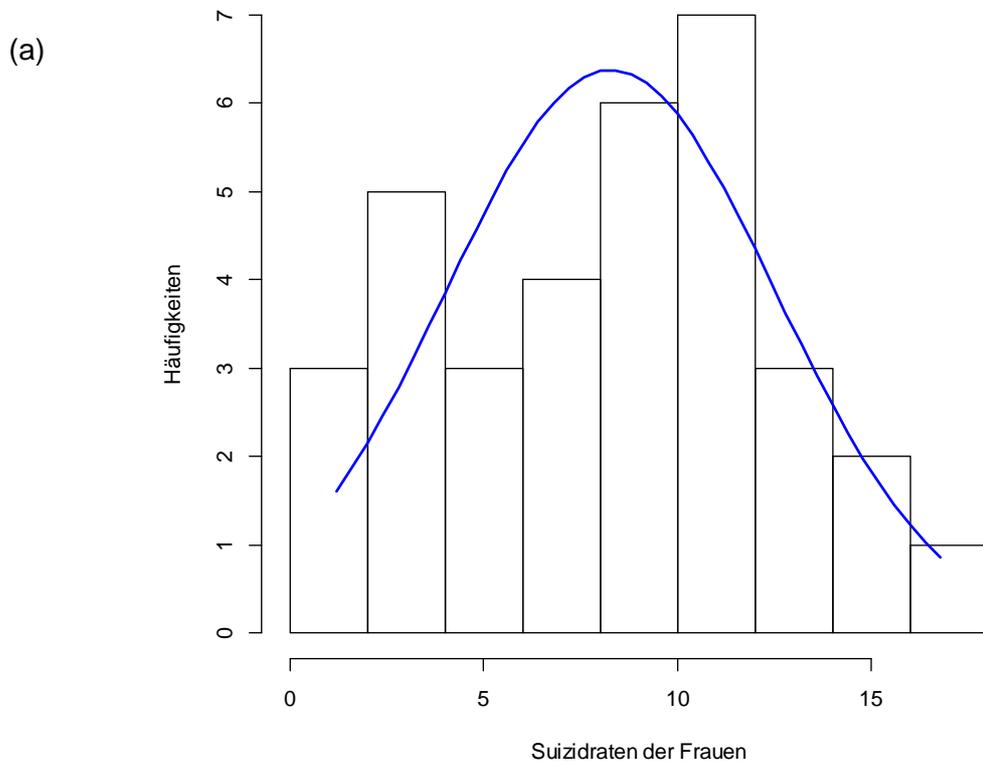


Abb. 5: Verteilung der Suizidraten der europäischen Landeshauptstädte für (a) Frauen und (b) Männern aus der Studie 1 mit angepasster Normalverteilungskurve.

Zur mathematischen Bestimmung der räumlichen Autokorrelationen zwischen den Residuen des linearen Regressionsmodells für Frauen und Männer, sowie deren Signifikanz werden die jeweiligen Gesamtwerte von Moran's I berechnet. In Übereinstimmung mit der Vermutung anhand der räumlichen Korrelogramme zeigt sich, dass bei den Frauen und Männern kaum räumliche Autokorrelationen ohne statistische Signifikanz vorliegen (Tabelle 1). Für die Frauen ergibt sich ein Wert von $I = -.02$ ($p = .20$) und für die Männer ein Wert von $I = -.03$ ($p = .29$).

Tab. 1: Räumliche Autokorrelationen der linearen Regressionsmodelle für Frauen und Männer mit Moran's I und räumlichem Nachbarschaftskriterium von 1500 Kilometern.

Residuen	Moran's I	p
Frauen	-.02	.20
Männer	-.03	.29

Diese Ergebnisse stehen im Widerspruch zu der Erwartung von existenten räumlichen Autokorrelationen, welche anhand der extremen räumlichen Ballung der höchsten Suizidraten im Osten Europas vermutet wurden. Es stellt sich nun die Frage, welche Gründe es für die nicht signifikanten und kaum vorhandenen räumlichen Autokorrelationen im linearen Regressionsmodell von Voracek, Fisher und Marušič (2003) geben kann. Einen großen Einfluss auf die Entdeckung räumlicher Autokorrelationen haben vor allem das räumliche Nachbarschaftskriterium und die dadurch definierte räumlich gewichtete Nachbarschaftsmatrix, welche im Folgenden noch einmal genauer überprüft werden.

Betrachtet man die durchschnittliche Nachbarschaftszahl einer Landeshauptstadt für das gewählte Nachbarschaftskriterium, so ist diese mit 18.41 recht hoch. Durch den großen Radius von 1500 Kilometern kommen derart viele räumliche Nachbarschaften zustande. Das Land mit den meisten räumlichen Nachbarschaften ist Ungarn mit 28 Nachbarschaften. Das Land mit den wenigsten räumlichen Nachbarschaften ist Island mit nur einer einzigen räumlichen Nachbarschaft. Island ist gleichzeitig das Land mit der größten Distanz zum nächstgelegenen räumlichen Nachbarn Irland. Ein Vergleich der Distanzen zwischen den benachbarten Landeshauptstädten 1. Ordnung zeigt, dass die Distanz zwischen Island und Irland mit Abstand die größte ist. Es fällt weiter auf, dass die zweit- und drittgrößten Distanzen der räumlichen Nachbarschaften 1. Ordnung mehr als um die Hälfte kleiner sind (Tabelle 2). Eine zu groß gewählte Distanz des räumlichen Nachbarschaftskriteriums kann dazu führen, dass bestehende räumliche Autokorrelationen nicht erkannt werden. Aus diesem Grund wird Island als „geografischer Ausreißer“ aus dem Datensatz entfernt und die Überprüfung auf räumliche Autokorrelationen erneut mit dem modifizierten Datensatz durchgeführt.

Tab. 2: Die drei größten Distanzen für die räumlichen Nachbarschaften 1. Ordnung.

Ausgangsland	Nachbarland 1. Ordnung	Distanz in km
Island	Irland	1494
Malta	Italien	689
Russland	Weißrussland	676

Da der Datensatz modifiziert wurde, wird das lineare Regressionsmodell nach Voracek, Fisher und Marušič (2003) bezüglich seiner Konsistenz mit dem modifizierten Datensatz ohne Island überprüft. Es zeigt sich, dass der Interaktionsterm aus quadriertem Breiten- und einfachem Längengrad weiterhin einen signifikanten Anteil der Suizidraten für Frauen und Männer erklärt. Jedoch gilt dies nicht mehr für die zweite unabhängige Variable, welche sich aus dem einfachen Breitengrad zusammensetzt. Der einfache Breitengrad erklärt weder für die Frauen, noch für die Männer einen weiteren signifikanten Anteil der Suizidraten ($p > .05$) und wird daher aus der Gleichung des linearen Regressionsmodells entfernt. Die statistischen Kennwerte und Koeffizienten der ursprünglichen und nun modifizierten linearen Regressionsmodelle können in Tabelle 3 direkt verglichen werden.

Tab. 3: Statistische Kennwerte und Koeffizienten der ursprünglichen und modifizierten linearen Regressionsmodelle mit und ohne Island für Frauen und Männer aus Studie 1.

	Ursprünglich lineare		Modifizierte lineare	
	Regressionsmodelle mit Island	Regressionsmodelle ohne Island	Regressionsmodelle mit Island	Regressionsmodelle ohne Island
	Frauen	Männer	Frauen	Männer
F	10.20	16.61	11.37	29.20
df	31	31	31	31
p	<.001	<.001	.002	<.001
R²	.39	.51	.24	.46
Intercept	-3.72	-29.63	5.71	13.33
Lat²long	0.000052	0.00030	0.000067*	0.00044**
Lat	0.20	0.99		

F-Test (F), Freiheitsgrade (df), p-Werte (p), Bestimmtheitsmaß R^2 (R^2), y-Achsenabschnitt (Intercept), Interaktionsterm aus quadriertem Breiten- und einfachem Längengrad (Lat²long), Term mit einfachem Breitengrad (Lat);* $p < .001$ und ** $p < .0001$

Die modifizierten linearen Regressionsmodellgleichungen der Frauen und Männer für den Datensatz ohne Island lauten demnach:

$$\text{Suizidrate}_{\text{Frauen}} = 5.71 + 0.000067 (\text{Breitengrad}^2 \times \text{Längengrad}) + \varepsilon$$

$$\text{Suizidrate}_{\text{Männer}} = 13.33 + 0.00044 (\text{Breitengrad}^2 \times \text{Längengrad}) + \varepsilon$$

Für die erneute Überprüfung auf räumliche Autokorrelationen wird das Nachbarschaftskriterium folglich an die Daten ohne Island angepasst. In einem Histogramm werden die häufigsten räumlichen Distanzen 1. Ordnung zwischen den europäischen Landeshauptstädten sichtbar (Abbildung 6). Der Median liegt bei 1265 Kilometern und das unterste Quartil bei 776 Kilometern, was 25% der kleinsten Distanzen beschreibt. Unter der Bedingung, dass jede Landeshauptstadt mindestens einen räumlichen Nachbarn aufweist soll, und weil das unterste Quartil größer als die größte Distanz 1. Ordnung zwischen zwei Landeshauptstädten ist, wird ein räumliches Nachbarschaftskriterium mit 700 Kilometern als angemessen angenommen und für weitere räumliche Analyse festgelegt.

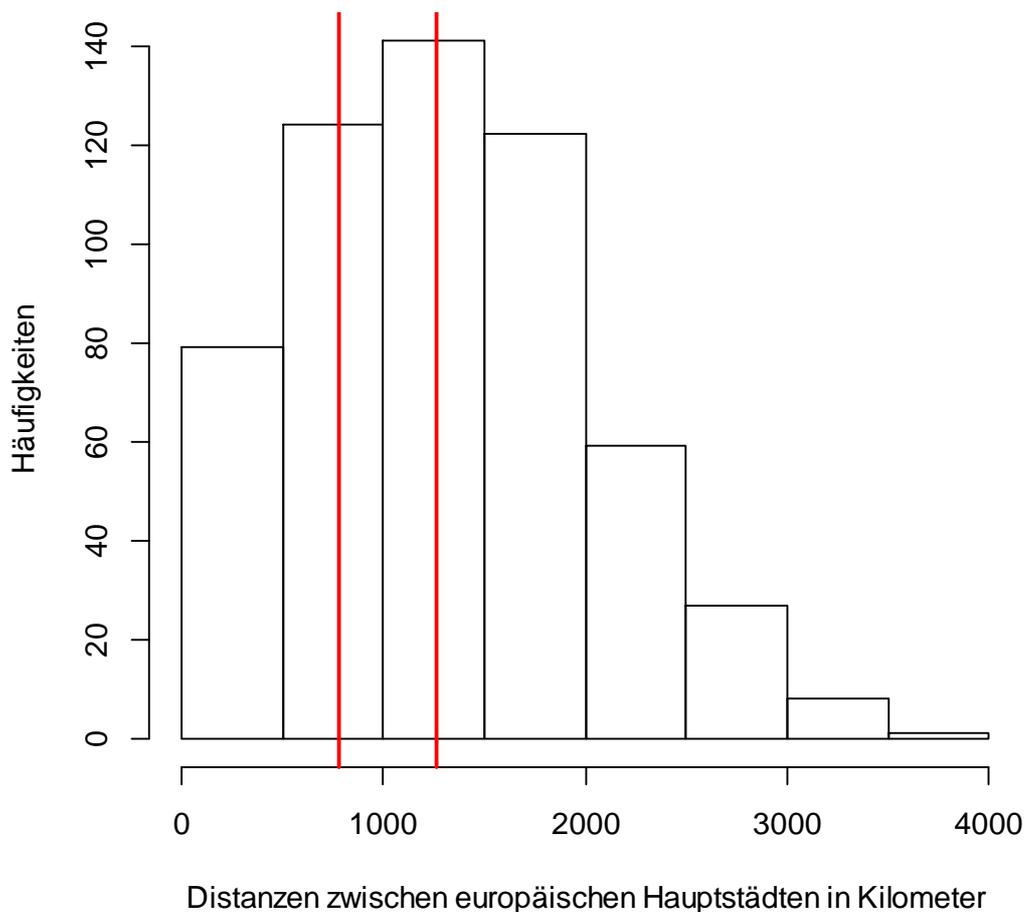


Abb. 6: Histogramm der Distanzen 1. Ordnung zwischen europäischen Hauptstädten ohne Island in Kilometer mit markiertem Median und unterem Quartil (25% der kleinsten Distanzen).

Die durchschnittliche Nachbarschaftszahl beträgt nun nur noch 5.39 pro Landeshauptstadt. Das Land mit den meisten Nachbarschaften ist jetzt die Schweiz mit 10 räumlichen Nachbarschaften. Die Länder mit den wenigsten Nachbarschaften sind Irland, Malta, Portugal und Spanien mit je nur einer räumlichen Nachbarschaft.

Mit Moran's I sind nun, wenn auch nicht sehr große, aber dennoch signifikante räumliche Autokorrelationen für Frauen und Männer nachzuweisen (Tabelle 4). Bei den Frauen ergibt sich ein Wert von $I = .15$ ($p = .02$) und den Männern ein Wert von $I = .14$ ($p = .03$). Da signifikante räumliche Autokorrelationen für Frauen und Männer vorliegen, können unverfälschte Parameter der linearen Regressionsmodelle nicht mehr sichergestellt werden. Die Modellanpassungen der linearen Regressionsmodelle werden daher mit räumlich simultan autoregressiven Modellen, welche die möglichen Einflüsse räumlicher Autokorrelationen konstant halten, in Kapitel 5.4 verglichen.

Tab. 4: Räumliche Autokorrelationen der linearen Regressionsmodelle ohne Island für Frauen und Männer mit Moran's I und räumlichem Nachbarschaftskriterium von 700 Kilometern.

Residuen	Moran's I	p
Frauen	.15	.02
Männer	.14	.03

Geringe Veränderungen der räumlichen Autokorrelationen für die Residuen der Frauen und Männer des modifizierten linearen Regressionsmodells ohne Island sind über die Distanzklassen hinweg in einem weiteren räumlichen Korrelogramm zu erkennen (Abbildung 7). Schwankungen um den Erwartungswert sind weiterhin zu erkennen, die jedoch nun zwischen der vierten und achten Distanzklasse weniger stark ausfallen. Auch die Grenzwertüberschreitung für die räumlichen Autokorrelationen bei den Männern in der zweiten Distanzklasse ist weiterhin vermutlich aus den oben beschriebenen Gründen zu beobachten.

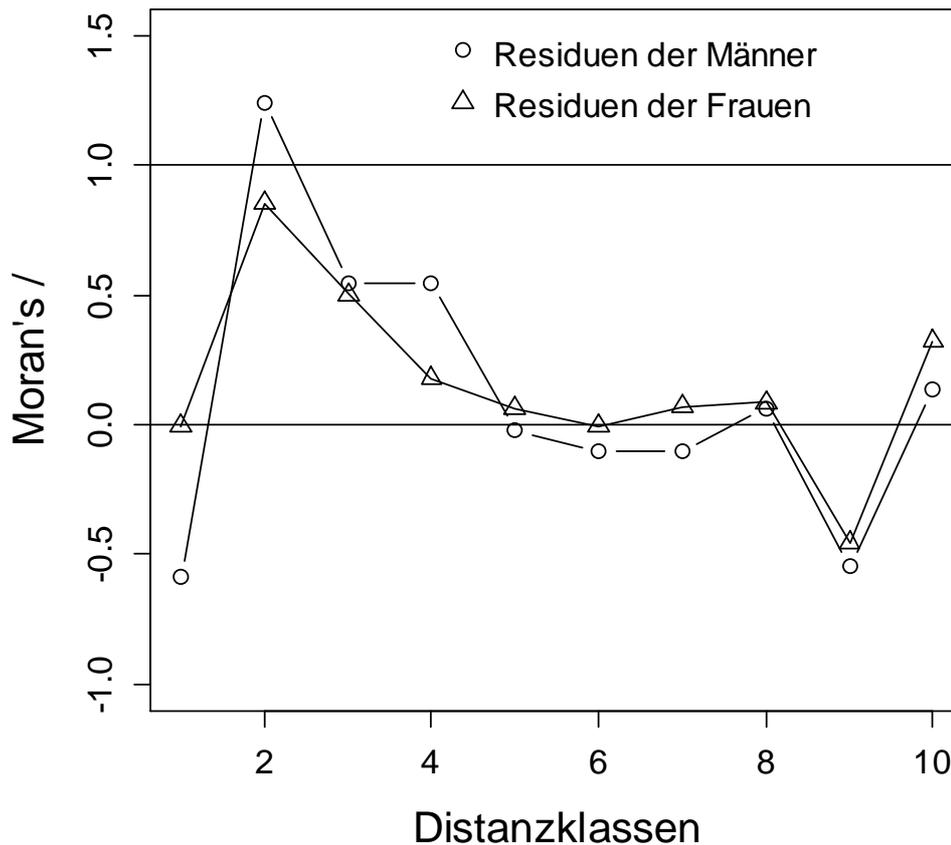


Abb. 7: Räumliche Korrelogramme von Residuen der modifizierten linearen Regressionsmodelle für Frauen und Männer ohne Island und einem Nachbarschaftskriterium von 700 Kilometern.

5.3.2 Studie 2: Voracek, Loibl und Kandrychyn (2007)

In dieser Studie erklären für das lineare Regressionsmodell ebenso der Interaktionsterm aus quadriertem Breiten- und einfachem Längengrad und der zusätzliche einfache Breitgrad am besten die gemittelten Suizidraten des Datensatzes. Für die räumliche Analyse des Datensatzes von Voracek, Loibl und Kandrychyn (2007) werden nur solche Suizidraten von Russland verwendet, welche als europäischer Teil Russlands gelten. Mit den Daten für Bosnien und Herzegowina, Mazedonien, Serbien und Montenegro, Weißrussland, Teilen der Ukraine und denen der 34 europäischen Landeshauptstädten ergibt sich ein Stichprobenumfang von 126 Datenpunkten.

Für die Überprüfung auf räumliche Autokorrelationen dieses Datensatzes wird mit derselben Begründung wie in Studie 1, dass jede Landeshauptstadt mindestens einen räumlichen Nachbarn besitzen sollte, ein räumliches Nachbarschaftskriterium mit einem Radius von 700 Kilometern verwendet. Island wird ebenso aus der räumlichen Analyse ausgeschlossen, womit sich der Stichprobenumfang auf 125 Datenpunkte reduziert. Die Überprüfung auf die Konsistenz des linearen Regressionsmodells mit dem modifizierten Datensatz zeigt, dass sich die statistischen Kennwerte kaum durch den Ausschluss von Island verändern und alle unabhängigen Variablen weiterhin signifikante Anteile an den gemittelten Sui-

zidraten erklären. Für den direkten Vergleich werden auch hier die statistischen Kennwerte und Koeffizienten der linearen Regressionsmodelle für die Datensätze mit und ohne Island tabellarisch gegenübergestellt (Tabelle 5).

Tab. 5: Statistische Kennwerte und Koeffizienten der linearen Regressionsmodelle mit und ohne Island aus Studie 2.

	<i>Lineares Regressionsmodell mit Island</i>	<i>Lineares Regressionsmodell ohne Island</i>
F	87.21	90.94
df	120	122
p	<.001	<.001
R²	.59	.59
Intercept	-17.30	-11.68
Lat²long	0.00020	0.00022**
Lat	0.57	0.42*

F-Test (F), Freiheitsgrade (df), p-Werte (p), Bestimmtheitsmaß R² (R²), y-Achsenabschnitt (Intercept), Interaktionsterm aus quadriertem Breiten- und einfachem Längengrad (Lat²long), Term mit einfachem Breitengrad (Lat); p<.01 und ** p<.0001*

Die Gleichung des linearen Regressionsmodells für den Datensatz ohne Island lautet demnach:

$$\text{Suizidrate} = -11.68 + 0.00022 (\text{Breitengrad}^2 \times \text{Längengrad}) + 0.42 \times \text{Breitengrad} + \varepsilon$$

Bei der Betrachtung aller Distanzen 1. Ordnung zwischen den Landeshauptstädten zeigt sich im Histogramm eine nur leicht schiefe Verteilung der Distanzen (Abbildung 8). Mit einem Median von 1262 Kilometern und einem unteren Quartil von 774, durch das 25% der kleinsten Distanzen berücksichtigt werden, liegt das räumliche Nachbarschaftskriterium mit 700 Kilometern immer noch unter diesen Werten und kann als angemessen angenommen werden.

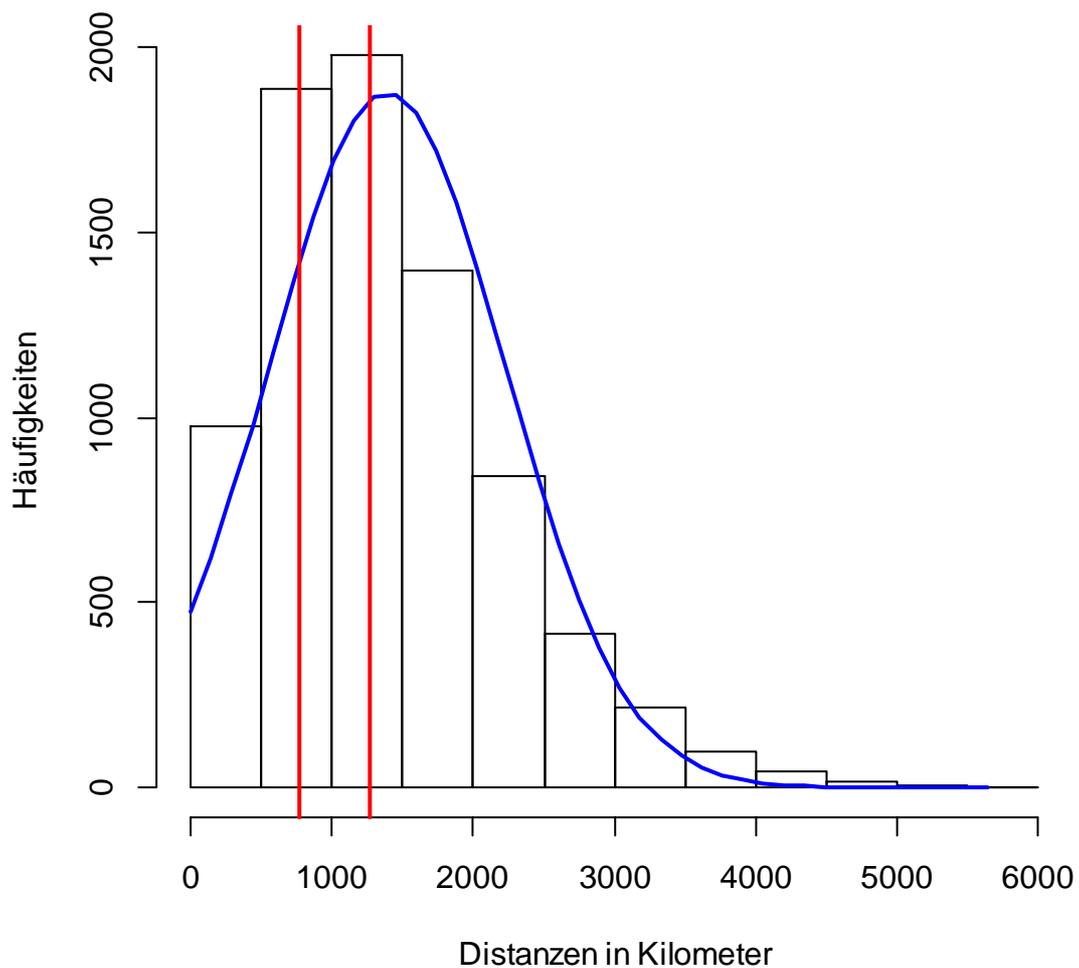


Abb. 8: Histogramm der Distanzen 1. Ordnung zwischen europäischen Hauptstädten und dem westlich europäischen Teil Russlands mit angepasster Normalverteilungskurve, Median und unterem Quartil (25% der kleinsten Distanzen).

Im räumlichen Korrelogramm sind nur schwach ausgeprägte räumliche Autokorrelationen über die Distanzklassen hinweg zu erkennen, die um den Erwartungswert von Moran's I in unregelmäßigen Abständen schwanken (Abbildung 9). Für den Gesamtwert von Moran's I sind daher nur sehr geringe und nicht signifikante räumliche Autokorrelationen zu erwarten.

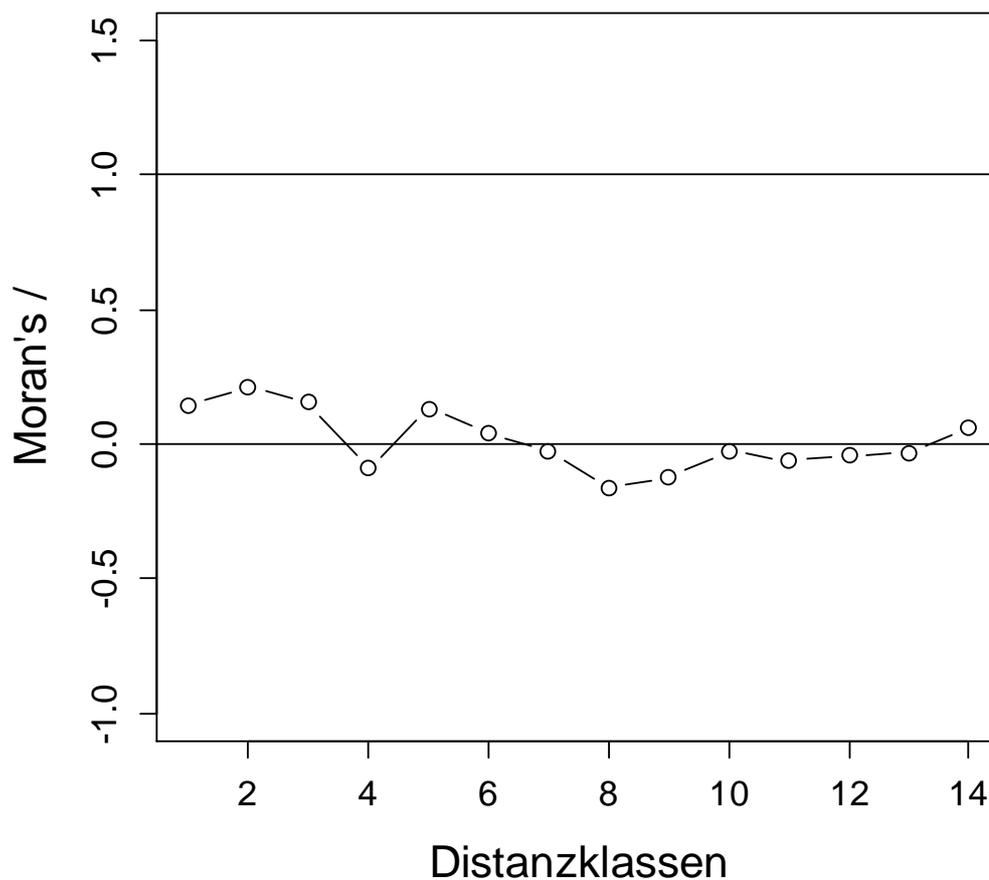


Abb. 9: Räumliches Korrelogramm von Residuen des linearen Regressionsmodells nach Voracek, Loibl und Kandrychyn (2007) ohne Island und einem Nachbarschaftskriterium von 700 Kilometern.

Die Berechnung des Gesamtwerts von Moran's I zeigt, dass sich die Beobachtungen im räumlichen Korrelogramm mit einem Wert von $I = -.03$ ($p = .70$) erneut statistisch belegen lassen und keine signifikanten räumlichen Autokorrelationen nachzuweisen sind. Globale Einflüsse auf die geschätzten Parameter des linearen Regressionsmodells durch räumliche Autokorrelationen sind folglich nicht anzunehmen. Daher wird für die Studie 2 kein statistischer Modellanpassungsversuch mit Hilfe von räumlich simultan autoregressiven Modellen angestellt.

5.3.3 Studie 3: Voracek und Marušič (2008)

In dieser Studie erklärt nur der Interaktionsterm der linearen Regressionsmodelle, welcher sich auch hier aus dem quadrierten Breiten- und einfachem Längengrad zusammensetzt, einen signifikanten Anteil an den Suizidraten. Die Daten setzen sich aus den Suizidraten derselben 34 europäischen Landeshauptstädten wie in Studie 1 zusammen. Jedoch wurden in dieser Studie nur die Werte von Frauen und Männern verwendet, die 65

Jahre und älter sind. Zusätzlich wurde ein gemittelter Gesamtwert aus den verfügbaren Jahressuizidraten der Länder für den Zeitraum von 1970-2002 gebildet.

Island wird aus demselben Grund wie in Studie 1 von der räumlichen Analyse ausgeschlossen, wodurch sich der Stichprobenumfang auf 33 europäische Landeshauptstädte reduziert. Das räumliche Nachbarschaftskriterium wurde mit einer Entfernung von maximal 700 Kilometern aus demselben Grund wie in Studie 1 an den modifizierten Datensatz angepasst.

Für die Konsistenz der linearen Regressionsmodelle mit dem modifizierten Datensatz ohne Island ergeben sich unterschiedliche Ergebnisse für Frauen, Männer und den gemittelten Gesamtwert. Für die Frauen erklärt der Interaktionsterm und damit das gesamte lineare Regressionsmodell keinen signifikanten Anteil mehr an den Suizidraten, wodurch eine Überprüfung auf räumliche Autokorrelationen hinfällig ist. Für die linearen Regressionsmodelle der Männer und des gemittelten Gesamtwertes erklärt der Interaktionsterm auch ohne Island weiterhin einen signifikanten Anteil an den Suizidraten. Zum Vergleich sind die statistischen Kennwerte der ursprünglichen und modifizierten linearen Regressionsmodelle in Tabelle 6 dargestellt.

Tab. 6: Statistische Kennwerte und Koeffizienten der linearen Regressionsmodelle mit und ohne Island für Frauen, Männer und den gemittelten Gesamtwert aus Studie 3.

	<i>Ursprünglich lineare</i>			<i>Modifizierte lineare</i>		
	<i>Regressionsmodelle mit Island</i>			<i>Regressionsmodelle ohne Island</i>		
	<i>Frauen</i>	<i>Männer</i>	<i>Gesamtwert</i>	<i>Frauen</i>	<i>Männer</i>	<i>Gesamtwert</i>
<i>F</i>	4.21	8.42	5.13	3.45	7.28	4.17
<i>df</i>	32	32	32	31	31	31
<i>p</i>	.048	.007	.03	.07	.01	.049
<i>R²</i>	.12	.21	.14	.07	.16	.09
<i>Intercept</i>	13.95	41.20	24.60	13.39	38.62	23.67
<i>La²long</i>	0.000095	0.00036	0.00017	0.00011*	0.00042**	0.00019**

F-Test (*F*), Freiheitsgrade (*df*), *p*-Werte (*p*), Bestimmtheitsmaß *R²* (*R²*), *y*-Achsenabschnitt (*Intercept*), Interaktionsterm aus quadriertem Breiten- und einfachem Längengrad (*La²long*); * *p*>.05 und ** *p*<.01

Die modifizierten linearen Regressionsgleichungen aus den Datensätzen ohne Island lauten demnach für die Männer und den Gesamtwert:

$$\text{Suizidrate}_{\text{Männer}} = 38.62 + 0.00042 (\text{Breitengrad}^2 \times \text{Längengrad}) + \varepsilon$$

$$\text{Suizidrate}_{\text{Gesamtwert}} = 23.67 + 0.00019 (\text{Breitengrad}^2 \times \text{Längengrad}) + \varepsilon$$

In den räumlichen Korrelogrammen lassen sich ähnliche Verläufe für die räumlichen Autokorrelationen der Männer und den Gesamtwert beobachten (Abbildung 10). Für die räumlichen Autokorrelationen der Männer kommt es hier nicht wie in Studie 1 zu keiner Grenzwertüberschreitung. Ähnlich sind auch für die Männer, wie auch für den Gesamtwert die Schwankungen der räumlichen Autokorrelationen um den Erwartungswert von Moran's I herum und der Sprung von negativen räumlichen Autokorrelationen in der ersten Distanzklasse hin zu hoch positiven in der zweiten Distanzklasse. Dadurch lässt sich wie in Studie 1 vermuten, dass nur geringe und kaum signifikante räumliche Autokorrelationen für die Männer und den Gesamtwert vorliegen.

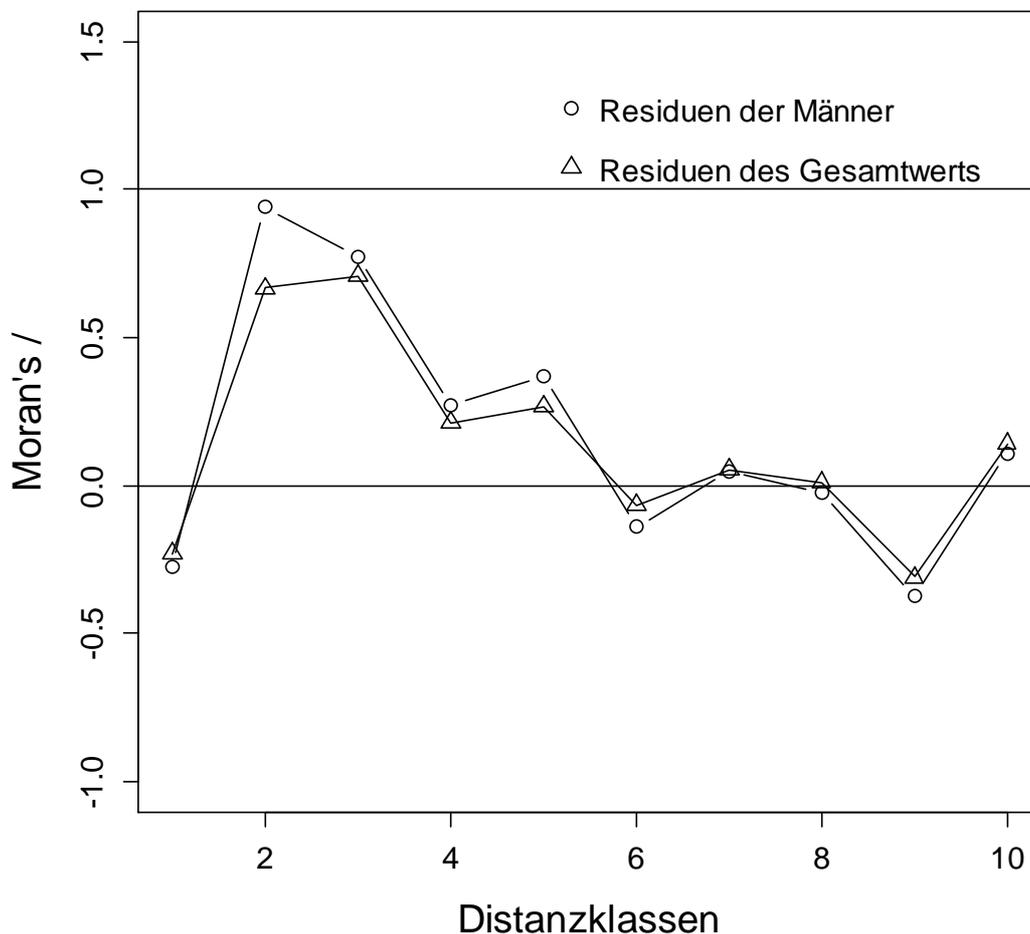


Abb. 10: Räumliche Korrelogramme von Residuen der linearen Regressionsmodelle für Männer und den Gesamtwert ohne Island und einem Nachbarschaftskriterium von 700 Kilometern.

Bei der Überprüfung auf räumliche Autokorrelationen mit Moran's I für die Männer und für den Gesamtwert ergeben sich unterschiedliche Ergebnisse. Mit einem Wert von $I = .14$ ($p = .03$) können nur für das lineare Regressionsmodell der Männer signifikante räumliche Autokorrelationen nachgewiesen werden. Für das lineare Regressionsmodell des gemittelten

Gesamtwertes ergibt sich ein Wert von $I = .11$ ($p = .05$), welcher, wenn auch nur knapp, nicht mehr signifikant ist (Tabelle 7). Signifikante Einflüsse durch die räumlichen Autokorrelationen auf ein lineares Regressionsmodell sind somit nur bei den Männer möglich. Der Modellanpassungsversuch mit Hilfe von räumlich simultan autoregressiven Modellen wird für die Männer im folgenden Kapitel 5.4 vorgenommen.

Tab. 7: Räumliche Autokorrelationen der linearen Regressionsmodelle ohne Island für Männer und den Gesamtwert mit Moran's I und räumlichem Nachbarschaftskriterium von 700 Kilometern.

<i>Residuen</i>	<i>Moran's I</i>	<i>p</i>
Männer	.14	.03
Gesamtwert	.11	.05

5.4 Räumlich simultan autoregressive Modellversuche

Signifikante räumliche Autokorrelationen können einen Einfluss auf die geschätzten Parameter und in Folge auch auf die Modellanpassungen linearer Regressionsmodelle haben (Kapitel 4.1). Da signifikante räumliche Autokorrelationen für die linearen Regressionsmodelle in den oben beschriebenen Studien 1 und 3 vorliegen, können Einflüsse auf die Schätzungen der Parameter nicht ausgeschlossen werden. Um mögliche Einflüsse der räumlichen Autokorrelationen konstant zu halten, werden zwei räumlich simultan autoregressive Modellversuche, ein räumlich verzogenes und ein räumliche fehlerbezogenes Regressionsmodell, angestellt. Die Modellanpassungen der Modelle werden mit Hilfe des Akaike's Informationskriteriums (AIC) bestimmt und mit den AICs der ursprünglichen linearen Regressionsmodelle aus den Studien 1 und 3 verglichen. Der AIC wird von Kissling und Carl (2008) für den Vergleich von linearen Regressionsmodellen mit räumlich simultan autoregressiven Modellen empfohlen, da dieser nicht nur die Modellanpassung, sondern auch die Modellkomplexität zur Berechnung heranzieht. Für den AIC gilt im Allgemeinen, je kleiner der Wert, desto besser passt sich das Modell an die Daten an. Zu beachten ist, dass sich bei Replikationen der folgenden Werte aufgrund der voreingestellten Anzahl von Replikationen für die Berechnungsmethode „Monte Carlo“ und des kleinen Stichprobenumfangs geringfügige Abweichungen ergeben können, die jedoch keine Auswirkungen auf die Signifikanz der Ergebnisse haben.

5.4.1 Ein räumlich verzogener Regressionsmodellversuch („*spatial lag model*“)

Für die Berechnungen der räumlich verzogenen Regressionsmodelle der Studien 1 und 3 werden die oben beschriebenen zeilenstandardisierten räumlichen Nachbarschaftsmatrizen mit einer maximalen Entfernung von 700 Kilometern und die Berechnungsmethode „Monte Carlo“ verwendet. Dabei werden die ursprünglichen linearen Regressionsmodelle um eine räumliche Variable, welche sich aus der räumlich gewichteten Nachbarschaftsmatrix und einem räumlichen Autokorrelationskoeffizienten zusammensetzt, ergänzt (Kapitel 4.2.1).

Für die Frauen aus Studie 1 lautet demnach das räumlich verzogene Regressionsmodell:

$$\text{Suizidrate}_{\text{FrauenRVR1}} = 4.37 + 0.000055 (\text{Breitengrad}^2 \times \text{Längengrad}) \\ + 0.21 Wy + \varepsilon$$

Für die Männer aus Studie 1 ergibt sich folgende Regressionsgleichung:

$$\text{Suizidrate}_{\text{MännerRVR1}} = 7.84 + 0.00029 (\text{Breitengrad}^2 \times \text{Längengrad}) \\ + 0.36 Wy + \varepsilon$$

Und für die Männer aus Studie 3 ergibt sich:

$$\text{Suizidrate}_{\text{MännerRVR3}} = 25.34 + 0.00032 (\text{Breitengrad}^2 \times \text{Längengrad}) \\ + 0.29 Wy + \varepsilon$$

Mit einem AIC von 186.76 für das räumlich verzogene Regressionsmodell der Frauen aus Studie 1 im Vergleich zu einem AIC von 184.76 für das modifizierte lineare Regressionsmodell und einem AIC von 283.93 für das räumlich verzogene Regressionsmodell der Männer aus Studie 1 im Vergleich zu einem AIC von 283.96 für das modifizierte lineare Regressionsmodell sind weder für die Frauen, noch für die Männer wesentliche Verbesserungen der Modellanpassung durch die räumlich verzogenen Regressionsmodellversuche festzustellen. Für die Frauen ist sogar eine tendenzielle Verschlechterung der Modellanpassung durch den etwas höheren AIC zu beobachten, welche möglicherweise auch auf den geringen Stichprobenumfang und die Berechnungsmethode „Monte Carlo“ zurückzuführen ist. Festzuhalten bleibt, dass sich keine Verbesserungen in den Modellanpassungen für die Studie 1 zeigen. Die räumlichen Autokorrelationskoeffizienten sind für die Frauen, wie für die Männer nicht signifikant, wodurch signifikante Einflüsse durch räumliche Autokorrelationen auf die Modellanpassungen der linearen Regressionsmodelle nicht anzunehmen sind.

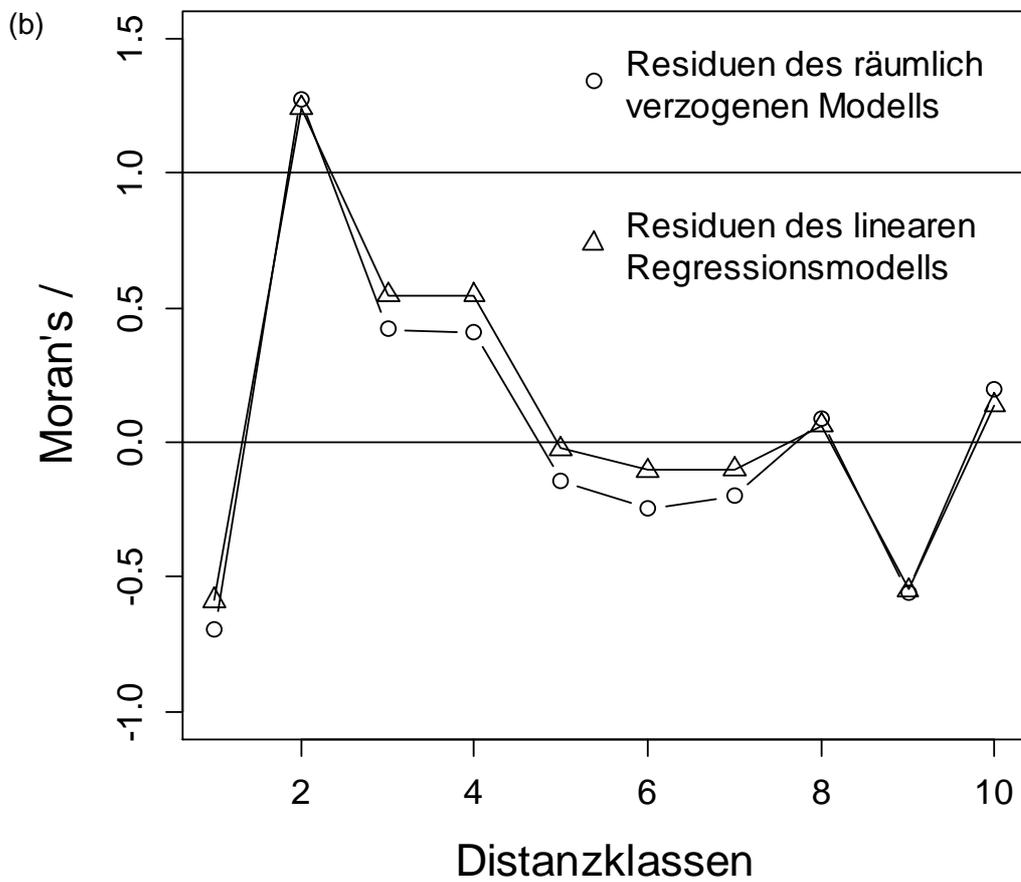
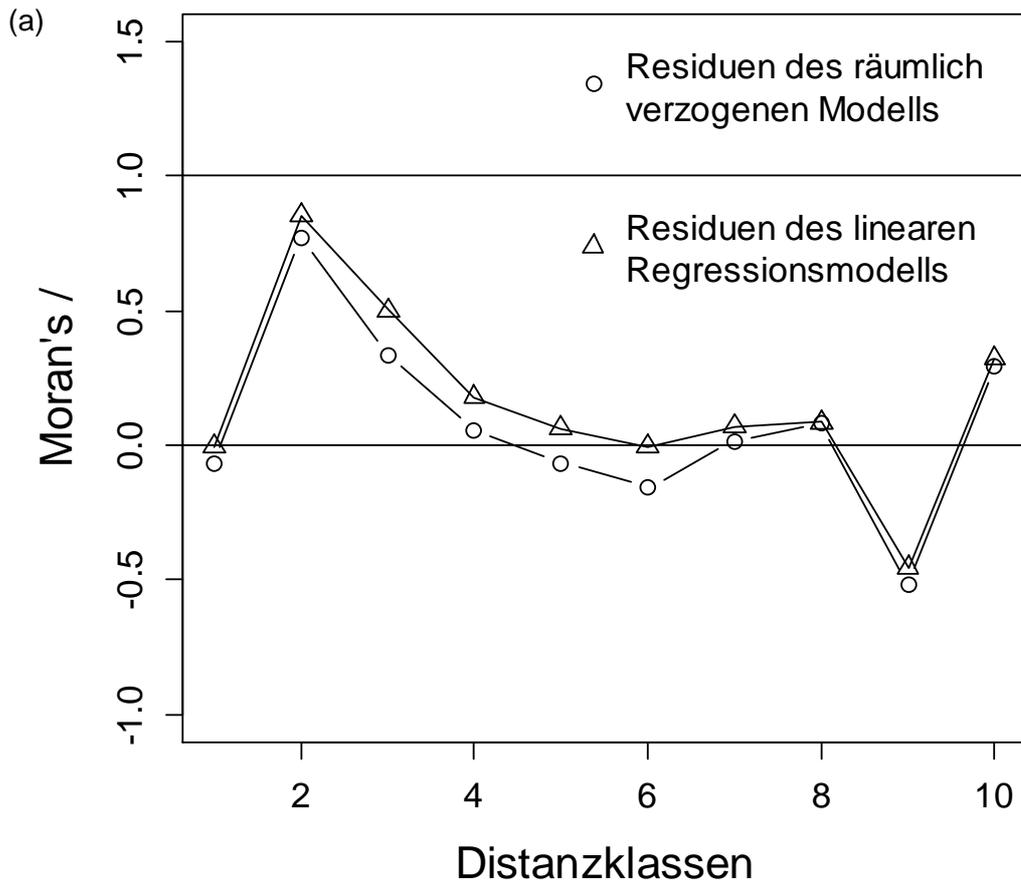
Für die Männer aus Studie 3 zeigt sich ein ähnliches Bild. Mit einem AIC von 318.72 für das räumlich verzogene und einem AIC von 318.06 für das ursprüngliche lineare Regressionsmodell lässt sich auch hier keine Verbesserung der Modellanpassung feststellen. Wie bei den Frauen aus Studie 1 ist eher eine tendenziell schlechtere Modellanpassung zu beobachten. Der räumliche Autokorrelationskoeffizient ist ebenso nicht signifikant und was bedeutet, dass die zuvor nachgewiesenen signifikanten räumlichen Autokorrelationen keinen signifikanten Einfluss auf die Modellanpassung des linearen Regressionsmodells der Männer aus Studie 3 haben. Eine Zusammenfassung der Ergebnisse der AICs ist in Tabelle 8 dargestellt.

Tab. 8: Vergleich der Modellanpassungen für die linearen und räumlich verzogenen Regressionsmodelle der Studien 1 und 3 anhand des AIC.

	<i>AIC der linearen Regressionsmodelle</i>	<i>AIC der räumlich verzogenen Regressionsmodelle</i>
Studie 1		
Frauen	184.76	186.76
Männer	283.96	283.93
Studie 3		
Männer	318.06	318.72

Trotz signifikanter räumlicher Autokorrelationen für die ursprünglichen linearen Regressionsmodelle der Studien 1 und 3 werden keine verbesserten Modellanpassungen mit den räumlich verzogenen Regressionsmodellen erzielt. Es kann angenommen werden, dass räumliche Autokorrelationen, welche von den Suizidraten als abhängiger Variablen selbst verursacht werden, keine signifikanten Einflüsse auf die linearen Regressionsmodelle haben. Folglich werden keine signifikanten Einflüsse durch die nachgewiesenen räumlichen Autokorrelationen auf die Modellanpassungen und Schätzungen der ursprünglichen und teilweise modifizierten linearen Regressionsmodelle aus den Studien 1 und 3 für die Datensätze ohne Island angenommen.

In den folgenden drei räumlichen Korrelogrammen sind aufgrund der kaum abweichenden Modellanpassungen beim Vergleich der linearen Regressionsmodelle mit den räumlich verzogenen Regressionsmodellen ähnliche Verläufe für die räumlichen Autokorrelationen der Residuen über die Distanzklassen hinweg zu erkennen (Abbildung 11 (a)-(c)).



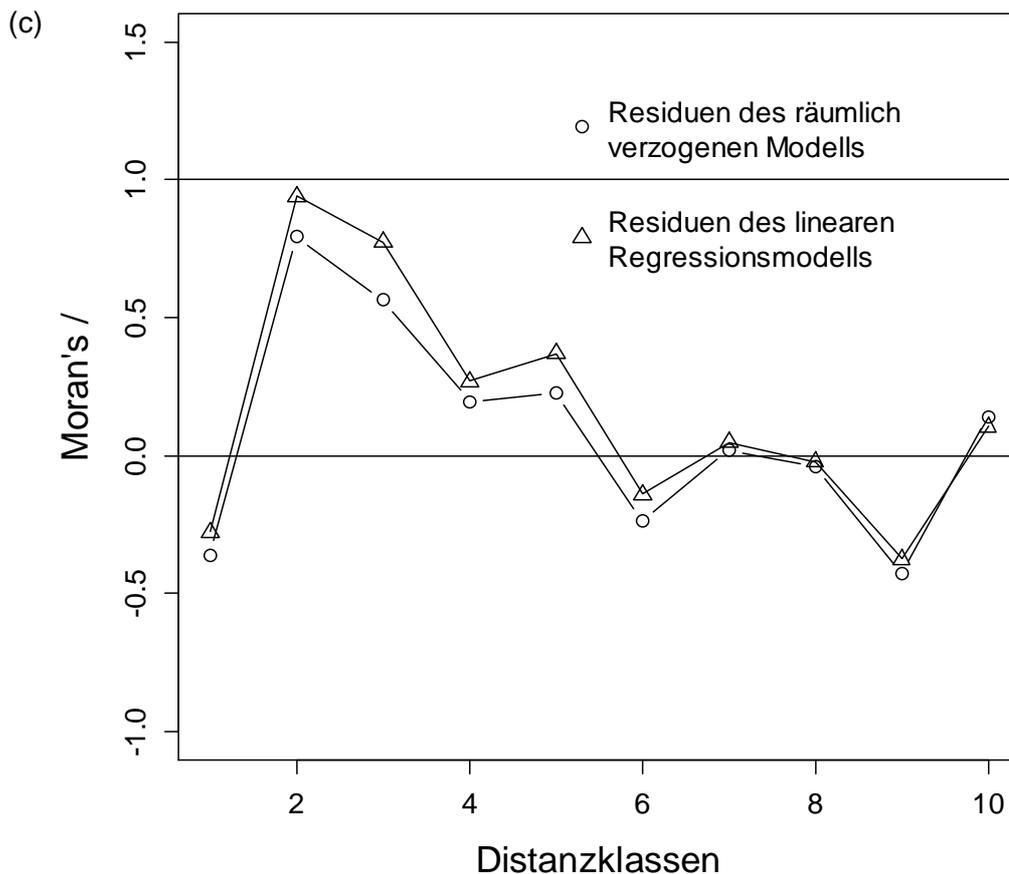


Abb. 11: Räumliche Korrelogramme von Residuen der linearen und räumlich verzogenen Regressionsmodelle für (a) Frauen und (b) Männer aus Studie 1 und (c) Männer aus Studie 3 ohne Island mit einem Nachbarschaftskriterium von 700 Kilometern.

5.4.2 Ein räumlich fehlerbezogener Regressionsmodellversuch („spatial error model“)

Für die räumlich fehlerbezogenen Regressionsmodellversuche der Studien 1 und 3 werden dieselben zeilenstandardisierten räumlichen Nachbarschaftsmatrizen über eine maximale Entfernung von 700 Kilometern und die Berechnungsmethode „Monte Carlo“ aus Kapitel 5.4.1 verwendet. Zur Modellkonstruktion wird der Fehlerterm des ursprünglichen linearen Regressionsmodells dafür in einen räumlich abhängigen Fehlerterm, bestehend aus einem räumlichen Autokorrelationskoeffizienten und einer räumlich gewichteten Nachbarschaftsmatrix, und in einen unabhängigen Fehlerterm aufgeteilt (Kapitel 4.2.2).

Für die Frauen aus Studie 1 gilt dieses räumlich fehlerbezogene Regressionsmodell:

$$\text{Suizidrate}_{\text{FrauenRFR1}} = 5.64 + 0.000066 (\text{Breitengrad}^2 \times \text{Längengrad}) + 0.29 W\mu + \varepsilon$$

Für die Männer aus Studie 1 ergibt sich folgende Regressionsgleichung:

$$\text{Suizidrate}_{\text{MännerRFR1}} = 13.78 + 0.00042 (\text{Breitengrad}^2 \times \text{Längengrad}) \\ + 0.26 W_{\mu} + \varepsilon$$

Und für die Männer aus Studie 3 ergibt sich:

$$\text{Suizidrate}_{\text{MännerRFR3}} = 36.69 + 0.00043 (\text{Breitengrad}^2 \times \text{Längengrad}) \\ + 0.32 W_{\mu} + \varepsilon$$

Für die räumlich fehlerbezogenen Regressionsmodelle lassen sich weder für die Frauen, noch für die Männer aus den Studien 1 und 3 Verbesserungen in der Modellanpassung nachweisen. Der AIC von 183.96 für das räumlich fehlerbezogene Regressionsmodell der Frauen aus Studie 1 unterscheidet sich kaum vom AIC des modifizierten linearen Regressionsmodells mit einem Wert von 183.29. Das räumlich fehlerbezogene Regressionsmodell der Männer aus Studie 1 unterscheidet sich mit einem AIC von 277.21 ebenso nur geringfügig vom modifizierten linearen Regressionsmodell mit einem AIC von 276.41. Beide Modelle weisen in diesem Fall sogar leicht höhere Werte für den AIC als die modifizierten linearen Regressionsmodelle auf, was für eine tendenzielle Verschlechterung in den Modellanpassungen spricht. Die räumlichen Autokorrelationskoeffizienten für die räumlich fehlerbezogenen Regressionsmodelle sind weder für die Frauen, noch für die Männer signifikant, was bedeutet, dass signifikante Einflüsse durch die nachgewiesenen räumlichen Autokorrelationen auf die Modellanpassungen und Schätzungen der modifizierten linearen Regressionsmodelle aus der Studie 1 nicht anzunehmen sind.

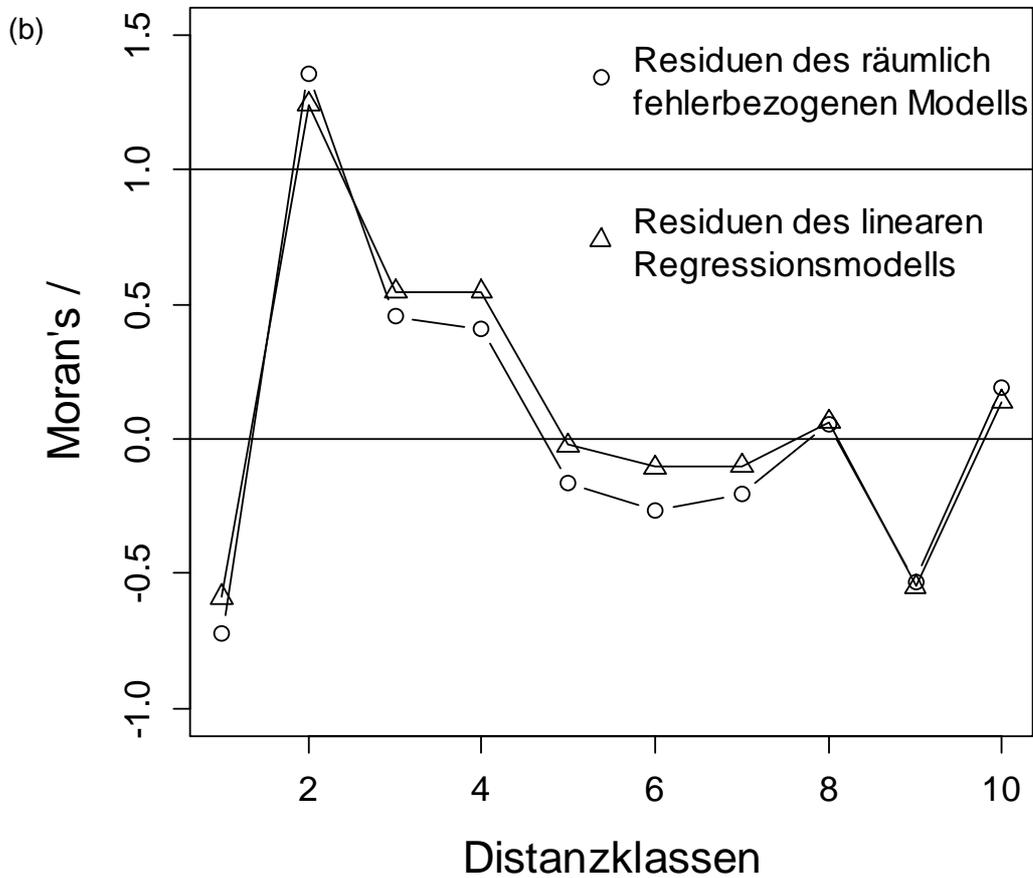
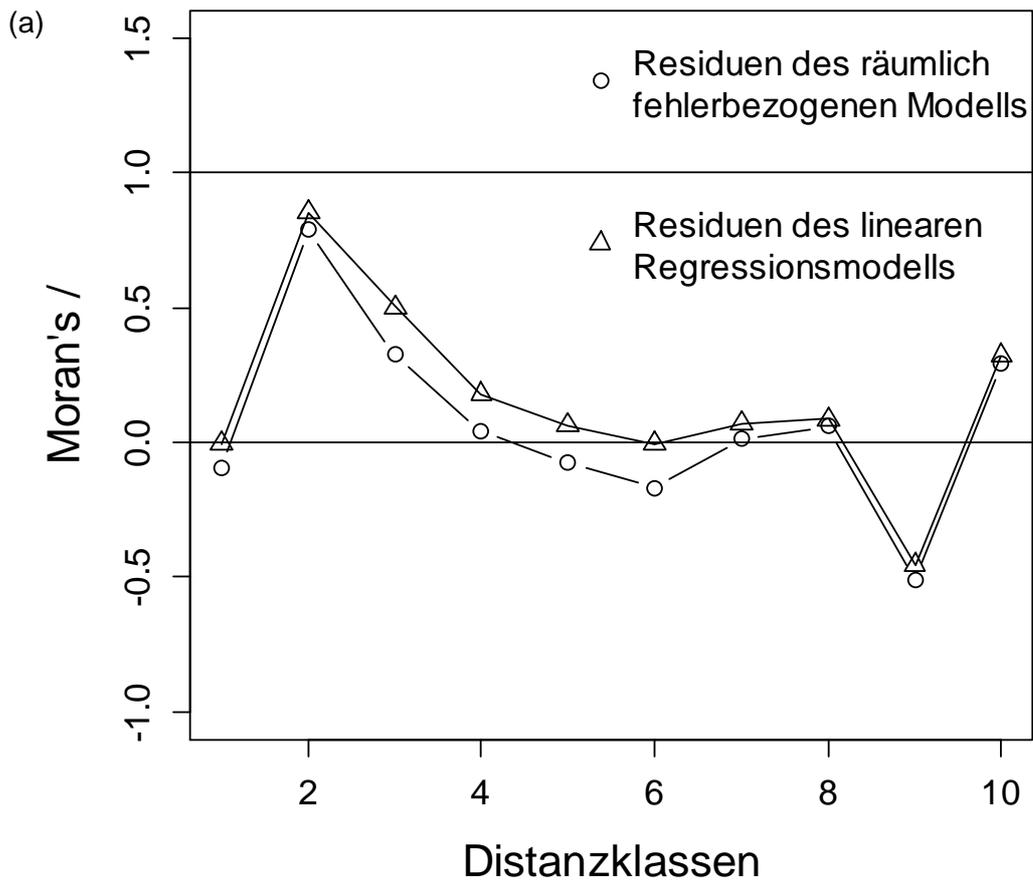
Für das räumlich fehlerbezogene Regressionsmodell der Männer aus Studie 3 ergeben sich ein AIC von 318.39 und ein AIC von 318.06 für das ursprüngliche lineare Regressionsmodell. Es können auch hier weder Verbesserungen in der Modellanpassung, noch signifikante räumliche Autokorrelationskoeffizienten nachgewiesen werden. Signifikante Einflüsse durch die nachgewiesenen räumlichen Autokorrelationen auf die Modellanpassung und Schätzungen des ursprünglichen linearen Regressionsmodells für die Männer aus Studie 3 sind daher auch hier nicht anzunehmen. Die Ergebnisse der Modellanpassungen sind in Tabelle 9 zusammengefasst.

Tab. 9: Vergleich der Modellanpassungen für die linearen und räumlich fehlerbezogenen Regressionsmodelle der Studien 1 und 3 anhand des AIC.

	<i>AIC der linearen Regressionsmodelle</i>	<i>AIC der räumlich fehlerbezogenen Regressionsmodelle</i>
Studie 1		
Frauen	183.29	186.96
Männer	276.41	277.21
Studie 3		
Männer	318.06	318.39

Die räumlich fehlerbezogenen Regressionsmodellversuche zeigen trotz signifikanter räumlicher Autokorrelationen in den linearen Regressionsmodellen für Frauen und Männer aus den Studien 1 und 3 weder eine Verbesserung in den Modellanpassungen, noch signifikante räumliche Autokorrelationskoeffizienten. Folglich werden keine signifikanten Einflüsse durch räumliche Autokorrelationen, welche durch externe oder unbekannte (Umwelt-) Faktoren verursacht werden, auf die Modellanpassungen und Schätzungen der linearen Regressionsmodelle angenommen. Demnach sichern diese Ergebnisse die Modellanpassungen und Schätzungen der teilweise modifizierten, teilweise ursprünglichen linearen Regressionsmodelle für die Datensätzen ohne Island aus den Studien 1 und 3 ab.

In den folgenden drei räumlichen Korrelogrammen sind erneut ähnliche Verläufe der räumlichen Autokorrelationen für die Residuen der linearen Regressionsmodelle und der räumlich fehlerbezogenen Regressionsmodelle über die Distanzklassen hinweg durch die kaum abweichenden Modellanpassungen zu beobachten (Abbildung 12 (a)-(c)).



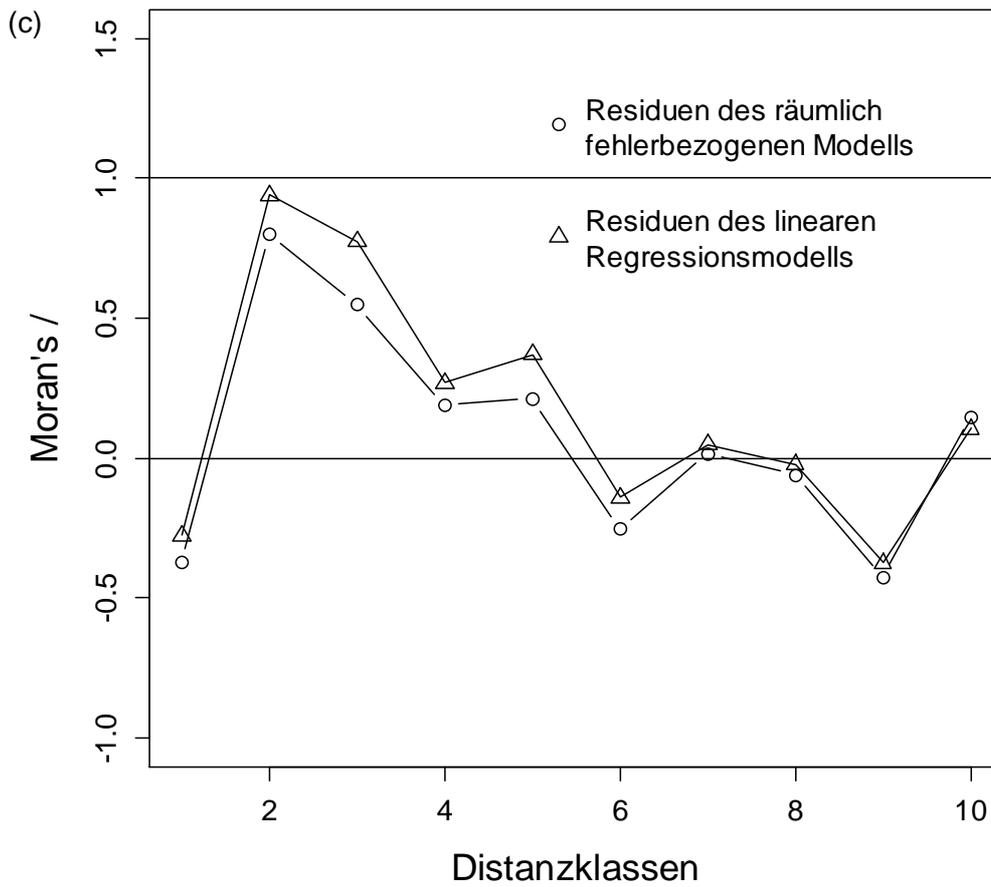


Abb. 12: Räumliche Korrelogramme von Residuen der linearen und räumlich fehlerbezogenen Regressionsmodelle für (a) Frauen und (b) Männer aus Studie 1 und (c) Männer aus Studie 3 ohne Island mit einem Nachbarschaftskriterium von 700 Kilometern.

6 Diskussion und Ausblick für geostatistische Verfahren in der psychologischen Forschung

Räumliche Autokorrelationen finden derzeit in der psychologischen Forschung kaum Beachtung. In dieser Arbeit wird jedoch darauf aufmerksam gemacht, dass die Schätzungen und Modellanpassungen linearer Regressionsmodelle durch räumliche Autokorrelationen beeinflusst werden können, was zu verzerrten Ergebnissen und Schlussfolgerungen führen und in sensiblen praktischen Bereichen, wie beispielsweise im klinischen Bereich und der „Public Health“, gravierende Folgen und Auswirkungen haben kann. Die Überprüfung linearer Regressionsmodelle mit raumbezogenen Daten auf räumliche Autokorrelationen wird daher für die psychologische Forschung in Übereinstimmung mit Hassall und Sherratt (2011) dringendst empfohlen, um eine hinreichend gute Modellanpassung absichern und folgerichtige Ergebnisse gewährleisten zu können.

In den praktischen Anwendungsbeispielen dieser Arbeit wird für die drei Studien eine Nachbarschaftsmatrix mit einem räumlichen Nachbarschaftskriterium von maximal 700 Kilometern bestimmt, die zeilenstandardisiert gewichtet wird. Die Entscheidung für dieses räumliche Nachbarschaftskriterium beruht auf der Empfehlung von Anselin und Bera (1998), welche besagt, dass jede Beobachtung mindestens einen räumlichen Nachbarn haben soll, um einen Verlust an Freiheitsgraden zu verhindern. Dafür wird nach dem Ausschluss aller Werte von Island aus den Datensätzen als „geografischer Ausreißer“ ein Radius von 700 Kilometern für jeden Datenpunkt festgelegt, welcher knapp über der größten Distanz 1. Ordnung zwischen zwei europäischen Landeshauptstädten liegt. Damit liegt das räumliche Nachbarschaftskriterium weit unter dem Median aller Distanzen 1. Ordnung und sogar unter 25% der kleinsten Distanzen zwischen zwei europäischen Landeshauptstädten, wodurch die Wahl in dieser Arbeit als angemessen angenommen werden kann. Bei der Wahl des räumlichen Nachbarschaftskriteriums sollte generell bedacht werden, dass dieses maßgeblich zur Entdeckung räumlicher Autokorrelationen beiträgt.

Durch die Exklusion von Island aus den Datensätzen werden die linearen Regressionsmodelle auf ihre Konsistenz mit den modifizierten Datensätzen hin überprüft und gegebenenfalls angepasst. Für die Studie 1 von Voracek, Fisher und Marušič (2003) wird der einfache Breitengrad als eigenständige Variable entfernt, da dieser nach der Exklusion von Island aus dem Datensatz keinen weiteren signifikanten Anteil an den Suizidraten der Frauen oder Männer erklärt. Das modifizierte lineare Regressionsmodell aus Studie 1 setzt sich somit nur noch aus dem Interaktionsterm mit quadriertem Breiten- und einfachem Längengrad zusammen. In der Studie 2 von Voracek, Loibl und Kandrychyn (2007) erklären auch nach der Exklusion von Island aus dem Datensatz für das lineare Regressionsmodell, welches sich aus demselben Interaktionsterm und dem zusätzlichen einfachen Breitengrad zusammensetzt, beide Terme weiterhin signifikante Anteile an den Suizidraten und daher keine Anpas-

sung des linearen Regressionsmodells an den Datensatz notwendig ist. Auch für die Studie 3 von Voracek und Marušič (2008) erklärte allein derselbe Interaktionsterm nach der Exklusion von Island aus dem Datensatz signifikante Anteile an den Suizidraten. Dies gilt jedoch nur für die Suizidraten der Männer und des Gesamtwerts, nicht aber für die Suizidraten der Frauen. Da sich das lineare Regressionsmodell aus Studie 3 allein aus dem Interaktionsterm zusammensetzt, welcher für die Frauen nicht signifikant ist, wird das lineare Regressionsmodell der Frauen aus der räumlichen Analyse ausgeschlossen.

Für das lineare Regressionsmodell der Studie 2 können keine signifikanten räumlichen Autokorrelationen nachgewiesen werden, weshalb auf die Kontrolle der räumlichen Autokorrelationen mit Hilfe von räumlich simultan autoregressiven Modellen verzichtet wird. Hingegen können für die teils modifizierten linearen Regressionsmodelle der Frauen aus Studie 1 und der Männer aus den Studien 1 und 3 signifikante räumliche Autokorrelationen nachgewiesen werden. Dies macht eine Überprüfung der Einflüsse durch die nachgewiesenen räumlichen Autokorrelationen auf die Modellanpassungen und Schätzungen der linearen Regressionsmodelle mit Hilfe von räumlich simultan autoregressive Modellen notwendig macht. Es zeigt sich, dass weder durch die räumlich verzogenen, noch durch die räumlich fehlerbezogenen Regressionsmodellversuche wesentliche Verbesserungen in den Modellanpassungen für die Frauen und Männer aus den Studien 1 und 3 erzielt werden können. Zudem sind alle räumlichen Autokorrelationskoeffizienten der räumlich verzogenen und räumlich fehlerbezogenen Regressionsmodelle nicht signifikant. Daraus folgt, dass weder räumliche Autokorrelationen, welche von der abhängigen Variablen selbst verursacht werden, noch räumliche Autokorrelationen, welche durch externe Faktoren verursacht werden, einen Einfluss auf die Modellanpassungen und Schätzungen der teils ursprünglichen, teils modifizierten linearen Regressionsmodelle haben.

Die Ergebnisse zeigen, dass die teils ursprünglichen, teils modifizierten linearen Regressionsmodelle aus den Studien 1 bis 3 auch nach dem Ausschluss von Island aus den Datensätzen offenbar gut für die Vorhersage der Suizidraten von Frauen und Männern aus den europäischen Landeshauptstädten geeignet sind und nicht in ihren Modellanpassungen und Schätzungen durch globale räumliche Autokorrelationen signifikant beeinflusst werden. Bis auf die Frauen in Studie 3 bleibt der Interaktionsterm aus quadriertem Breiten- und einfachem Längengrad in allen drei Studien trotz der Exklusion von Island weiterhin signifikant und ist damit der einflussreichste Prädiktor bei der Vorhersage für die europäischen Suizidraten der Landeshauptstädte anhand geografischer Koordinaten.

Zu beachten ist, dass es sich bei den in dieser Arbeit verwendeten geostatistischen Verfahren um globale Verfahren handelt, welche hauptsächlich für die Entdeckung von großflächigen räumlichen Autokorrelationen und deren Kontrolle verwendet werden. Es besteht daher die Möglichkeit, dass speziell für die Studie 2 lokale räumliche Autokorrelationen hier

nicht nachgewiesen und entdeckt werden konnten, aber dennoch existieren und mit lokalen Verfahren möglicherweise nachweisbar wären.

Wichtig ist auch anzumerken, dass entgegen der weitverbreiteten Meinung und in Übereinstimmung mit Kissling und Carl (2008) räumlich simultan autoregressive Modelle bei signifikanten räumlichen Autokorrelationen nicht zwingend Verbesserungen in den Modellanpassungen erzielen müssen. Dennoch wird dringend empfohlen raumbezogene Daten auf räumliche Autokorrelationen zu überprüfen und bei signifikanten räumlichen Autokorrelationen geostatistische Modelle, wie beispielsweise räumlich verzogene oder räumlich fehlerbezogene Regressionsmodelle, für einen Modellanpassungsversuch heranzuziehen, um die Modellanpassungen in einem weiteren Schritt mit denen der ursprünglichen linearen Regressionsmodelle zu vergleichen und signifikante Einflüsse durch räumliche Autokorrelationen auf die Schätzungen der linearen Regressionsmodelle zu überprüfen. Auch wenn, wie es in den drei oben beschriebenen Anwendungsbeispielen der Fall ist, nach der Überprüfung keine signifikanten räumlichen Autokorrelationen nachzuweisen oder räumlich simultan autoregressive Modelle nicht signifikant besser als die ursprünglichen linearen Regressionsmodelle an die Daten angepasst sind, so werden dennoch mögliche Fehlerquellen und Einflüsse durch räumliche Autokorrelationen bei der Verwendung von raumbezogenen Daten berücksichtigt und die Modellanpassungen und Schätzungen der linearen Regressionsmodelle können weiter als angemessen angenommen werden.

Kritisch ist in dieser Arbeit sicherlich der sehr kleine Stichprobenumfang für die Studien 1 und 3 mit nur 33 Datenpunkten zu sehen. Der kleine Stichprobenumfang und die nicht asymptotisch normalverteilte Datenstruktur der Suizidraten von Frauen und Männern sind sehr wahrscheinlich mit für die Überschreitung des Grenzwertes von Moran's I bei den Männern aus Studie 1, sowie die extremen Ausprägungen und Vorzeichenwechsel der räumlichen Autokorrelationen über die Distanzklassen hinweg verantwortlich. Ein weiterer kritischer Punkt ist das räumliche Nachbarschaftskriterium mit einem Radius von 700 Kilometern, welcher für den größeren Datensatz aus Studie 2 mit 126 Datenpunkten trotz der Anpassung immer noch recht groß erscheint. Im Histogramm wird deutlich, dass die zusätzlichen regionalen Daten mehrere kleinere Distanzen zwischen Datenpunkten aufweisen und sich die Verteilung in Richtung kleinerer Distanzen verschiebt. Möglicherweise könnten hier lokale geostatistische Autokorrelationskoeffizienten, auf die in dieser Arbeit kurz in Kapitel 2.1.4 eingegangen wird, neue Erkenntnisse liefern.

Für die zukünftige psychologische Forschung anhand raumbezogener europäischer Suizidraten wäre es daher interessant größere Datensätze, welche vermehrt kleinere und regionale Distanzen 1. Ordnung aufweisen, zu analysieren, um ein räumliches Nachbarschaftskriterium mit kleinerem Radius bestimmen und die räumlichen Prozesse genauer abbilden zu können. Folglich würde sich auch die Wahrscheinlichkeit des Nachweises von lokalen räum-

lichen Autokorrelationen mit angemessenen Verfahren erhöhen. Ebenso interessant wäre es auch räumliche Autokorrelationen weiter über die Zeit zu analysieren. Durch eine räumliche Analyse der Jahressuizidraten von europäischen Ländern aus denselben Jahrgängen könnten mögliche räumliche Veränderungen über die Zeit hinweg nachgewiesen werden. Eine weitere Option wäre es lineare Regressionsmodelle mit raumbezogenen Risikofaktoren zu verwenden und zu analysieren, welche für die „Public Health“ und Epidemiologie eine bedeutende Rolle spielen könnten. Wünschenswert wäre zudem die erweiterte Verwendung der in dieser Arbeit beschriebenen geostatistischen Verfahren zur räumlichen Analyse von raumbezogenen Datensätzen in anderen Teilgebieten der psychologischen Forschung, welche über die Fragestellungen der Suizidforschung hinausgehen.

Zusammenfassung

In dieser Arbeit werden die Einflüsse und Auswirkungen von räumlichen Autokorrelationen („spatial autocorrelation“) auf die Schätzungen der Parameter und Modellanpassungen linearer Regressionsmodelle dargestellt und anhand von drei psychologischen Studien mit europäischen Suizidraten illustriert. Für die Überprüfung auf räumliche Autokorrelationen der raumbezogenen Daten werden grafische und statistische Methoden beschrieben und demonstriert. Es wird auf die Bedeutsamkeit des räumlichen Nachbarschaftskriteriums, welches die räumlichen Nachbarschaften zwischen den Datenpunkten definiert, für die Entdeckung räumlicher Autokorrelationen mittels räumlicher Autokorrelationskoeffizienten, wie beispielsweise Moran's I oder Geary's C , und die darauf basierende räumlich gewichtete Nachbarschaftsmatrix eingegangen. Zwei räumlich simultan autoregressive Modelle – das räumlich verzogene Regressionsmodell („spatial lag model“) und das räumlich fehlerbezogene Regressionsmodell („spatial error model“) – werden beschrieben und für die linearen Regressionsmodelle mit signifikant nachgewiesenen räumlichen Autokorrelationen geschätzt. In weiterer Folge werden die Modellanpassungen der linearen und räumlichen Regressionsmodelle anhand des Akaike's Informationskriterium (AIC) miteinander verglichen. Trotz signifikanter räumlicher Autokorrelationen der linearen Regressionsmodelle, erzielen weder die räumlich simultan autoregressiven Modelle eine Verbesserung der Modellanpassungen, noch sind signifikante räumliche Autokorrelationskoeffizienten nachzuweisen. Signifikante Einflüsse durch die nachgewiesenen räumlichen Autokorrelationen auf die Modellanpassungen und Schätzungen der Parameter der linearen Regressionsmodelle werden daher nicht angenommen. Der Interaktionsterm der linearen Regressionsmodelle, bestehend aus quadriertem Breiten- und einfachem Längengrad, kann nach der Exklusion von Island aus den Datensätzen bis auf einen Fall für alle linearen Regressionsmodelle signifikante Anteile an den Suizidraten der Frauen und Männer erklären. Demzufolge ist der Interaktionsterm für die Vorhersage der Suizidraten anhand der geografischen Koordinaten von besonderer Relevanz. Abschließend werden standardisierte Überprüfungen auf räumliche Autokorrelationen, Modellanpassungsversuche mit räumlich simultan autoregressiven Modellen bei räumlichen Autokorrelationen, sowie Modelanpassungsvergleiche anhand des AIC für zukünftige psychologische Studien mit raumbezogenen Daten dringend empfohlen.

Abstract

In this study the impacts and effects of spatial autocorrelation on the estimation of parameters and the goodness of fit of linear regression models are illustrated for three psychological studies with European suicide rates. For testing spatial autocorrelation in the spatial data graphical and statistical methods are described and illustrated. The definition of spatial neighbourhoods which determines the spatial connectivity between two data points is crucial for the detection and tests of spatial autocorrelation, for example Moran's I and Geary's C , and furthermore for the spatial weight matrix which results from this definition. Two spatial simultaneous autoregressive models – the spatial lag model and the spatial error model – are described and estimated for each linear regression model with significant spatial autocorrelation. Afterwards the goodness of fit of the linear and spatial regression models are compared with the Akaike's information criterion (AIC). Despite significant spatial autocorrelation for the linear regression models, the spatial simultaneous autoregressive models neither achieve a better goodness of fit nor can significant spatial autocorrelation be found in the models. Hence significant effects of the proven spatial autocorrelation on the goodness of fit and on the estimation of parameters of the linear regression models cannot be assumed. The interaction term of the linear regression models, which consists of the squared latitude and single longitude, explains for all models but one significant parts of the suicide rates for women and men. Therefore this term is of particular importance for predicting suicide rates with latitude and longitude. Finally standardized testing for spatial autocorrelation, spatial simultaneous autoregressive models in case of spatial autocorrelation and the comparison of the AIC for spatial and linear regression models are highly recommended for future psychological studies with spatial data.

Anhänge

Anhang 1: Beispiel für Codeschema der räumlichen Analyse in Studie 1 mit „R“

Die am Anfang mit „#“ gekennzeichneten Zeilen entsprechen Kommentaren, welche in R nicht als mathematische Kommandos interpretiert werden, sondern nur die folgenden Kommandos erklären sollen dienen.

```
# Arbeitsbereich definieren
```

```
setwd("...")
```

```
# Kontrolle: Arbeitsbereich anzeigen
```

```
getwd()
```

```
#Pakete für räumliche Auswertung installieren und laden
```

```
install.packages("spdep")
```

```
install.packages("ncf")
```

```
library(spdep)
```

```
library(ncf)
```

```
# tabulatorgetrennte Daten (am besten aus einem Textfile) mit Variablennamen einlesen und anzeigen
```

```
data <- read.table("...", header=T, sep="\t")
```

```
data
```

```
# Matrix aus Koordinaten erstellen
```

```
coords<-cbind(data$longitude,data$latitude)
```

```
coords<-as.matrix(coords)
```

```
# Räumliche Nachbarn anhand der Koordinaten mit einem Radius von 700 Kilometern definieren und räumlich gewichtete Nachbarschaftsmatrix erstellen und anzeigen
```

```
nb700<-dnearneigh(coords,0,700,longlat = TRUE)
```

```
nb700.w<-nb2listw(nb700, glist=NULL, style="W", zero.policy=TRUE)
```

```

nb700
nb700.w

# Längen- und Breitengrad als Vektoren

long <- c(data$longitude)
lat <- c(data$latitude)

# Interaktionsterm als Vektor

lat2long <- lat^2 * long

# Suizidraten der Frauen als Vektor

suif <- c(data$sui_f)

# Suizidraten der Männer als Vektor

suim <- c(data$sui_m)

# Lineares Regressionsmodell nur mit Interaktionsterm für Frauen und Zusammenfassung

ols.fem <- lm(suif ~ lat2long)
summary(ols.fem)

# Residuen und räumliches Korrelogramm für Frauen berechnen

res.ols.fem <- residuals(ols.fem)
cor.ols.res.fem <- correlog(long,lat,z=residuals(ols.fem),na.rm=T, increment=1, resamp=1)

# Lineares Regressionsmodell nur mit Interaktionsterm für Männer und Zusammenfassung

ols.men <- lm(suim ~ lat2long)
summary(ols.men)

```

```

# Residuen und räumliches Korrelogramm für Männer berechnen

res.ols.men <- residuals(ols.men)
cor.ols.res.men<-correlog(long,lat,z=residuals(ols.men),na.rm=T, increment=1, resamp=1)

# Zeichne Residuen der Frauen und Männer in ein räumliches Korrelogramm (mit Überschrift
und Legenden)

plot(cor.ols.res.men$correlation[1:10], type="b", pch=1, cex=1.2, lwd=1.5,ylim=c(-1,1.5),
xlab="Distanzklassen", ylab="Moran's I", cex.lab=1.5, cex.axis=1.2)
abline(h=0)
abline(h=1)
points(cor.ols.res.fem$correlation[1:10], pch=2, cex=1.2)
lines(cor.ols.res.fem$correlation[1:10], lwd=1.5)
legend(x=5, y=1.4, legend=c("Residuen der Männer"), pch=c(1), bty="n", cex=1.2)
legend(x=5, y=1.2, legend=c("Residuen der Frauen"), pch=c(2), bty="n", cex=1.2)

# Moran's I für lineares Regressionsmodell der Frauen

ols.moran.fem <- lm.morantest(ols.fem, listw=nb700.w)
ols.moran.fem

# Moran's I für lineares Regressionsmodell der Männer

ols.moran.men <- lm.morantest(ols.men, listw=nb700.w)
ols.moran.men

# Das räumlich verzogene Regressionsmodell
# Das räumlich verzogene Regressionsmodell für Frauen (Methode Monte Carlo)

slm.nb700.w.fem <- lagsarlm(suif ~ lat2long,listw=nb700.w, type="lag", method="MC")
summary(slm.nb700.w.fem)

# Residuen des räumlich verzogenen Regressionsmodells und Korrelogramm für Frauen
berechnen

res.slm.nb700.w.fem <- residuals(slm.nb700.w.fem)

```

```
cor.slm.nb700.w.fem <- correlog(long, lat, z=residuals(slm.nb700.w.fem ), na.rm=T, increment=1, resamp=1)
```

```
# Das räumlich verzogene Regressionsmodell für Männer (Methode Monte Carlo)
```

```
slm.nb700.w.men <- lagsarlm(suim ~ lat2long,listw=nb700.w, type="lag", method="MC")  
summary(slm.nb700.w.men)
```

```
# Residuen des räumlich verzogenen Regressionsmodells und Korrelogramm für Männer berechnen
```

```
res.slm.nb700.w.men <- residuals(slm.nb700.w.men)  
cor.slm.nb700.w.men <- correlog(long, lat, z=residuals(slm.nb700.w.men ), na.rm=T, increment=1, resamp=1)
```

```
# Zeichne ein räumliches Korrelogramm: Vergleich der Residuen lineares Regressionsmodell vs. räumlich verzogenen Regressionsmodell für Männer
```

```
plot(cor.slm.nb700.w.men$correlation[1:10], type="b", pch=1, cex=1.2, lwd=1.5,ylim=c(-1,1.5), xlab="Distanzklassen", ylab="Moran's I", cex.lab=1.5, cex.axis=1.2)
```

```
abline(h=0)
```

```
abline(h=1)
```

```
points(cor.ols.res.men$correlation[1:10], pch=2, cex=1.2)
```

```
lines(cor.ols.res.men$correlation[1:10], lwd=1.5)
```

```
legend(x=5, y=1.6, legend=c("Residuen des räumlich \nverzogenen Modells"), pch=c(1), bty="n", cex=1.2)
```

```
legend(x=5, y=1, legend=c("Residuen des linearen \nRegressionsmodells"), pch=c(2), bty="n", cex=1.2)
```

```
# Zeichne ein räumliches Korrelogramm: Vergleich der Residuen lineares Regressionsmodell vs. räumlich verzogenen Regressionsmodell für Frauen
```

```
plot(cor.slm.nb700.w.fem$correlation[1:10], type="b", pch=1, cex=1.2, lwd=1.5,ylim=c(-1,1.5), xlab="Distanzklassen", ylab="Moran's I", cex.lab=1.5, cex.axis=1.2)
```

```
abline(h=0)
```

```
abline(h=1)
```

```
points(cor.ols.res.fem$correlation[1:10], pch=2, cex=1.2)
```

```

lines(cor.ols.res.fem$correlation[1:10], lwd=1.5)
legend(x=5, y=1.6, legend=c("Residuen des räumlich \nverzogenen Modells"), pch=c(1),
      bty="n", cex=1.2)
legend(x=5, y=1, legend=c("Residuen des linearen \nRegressionsmodells"), pch=c(2),
      bty="n", cex=1.2)

# Das räumlich fehlerbezogene Regressionsmodell
# Räumlich fehlerbezogenes Regressionsmodell für Männer (Methode Monte Carlo)

sem.nb700.w.men <- errorsarlm(suim ~ lat2long,listw=nb700.w,method="MC")
summary(sem.nb700.w.men)

# Residuen des räumlich fehlerbezogenes Regressionsmodell und räumliches Korrelogramm
für Männer

res.sem.nb700.w.men <- residuals(sem.nb700.w.men)
cor.sem.nb700.w.men <- correlog(long, lat, z=residuals(sem.nb700.w.men), na.rm=T, incre-
ment=1, resamp=1)

# Räumlich fehlerbezogenes Regressionsmodell für Frauen (Methode Monte Carlo)

sem.nb700.w.fem <- errorsarlm(suif ~ lat2long,listw=nb700.w,method="MC")
summary(sem.nb700.w.fem)

# Residuen des räumlich fehlerbezogenes Regressionsmodell und räumliches Korrelogramm
für Frauen

res.sem.nb700.w.fem <- residuals(sem.nb700.w.fem)
cor.sem.nb700.w.fem <- correlog(long, lat, z=residuals(sem.nb700.w.fem), na.rm=T, incre-
ment=1, resamp=1)

# Zeichne räumliches Korrelogramm: Vergleich der Residuen räumlich fehlerbezogenes
Regressionsmodell vs. lineares Regressionsmodell für Männer

plot(cor.sem.nb700.w.men$correlation[1:10], type="b", pch=1, cex=1.2, lwd=1.5,ylim=c(-
1,1.5), xlab="Distanzklassen", ylab="Moran's I", cex.lab=1.5, cex.axis=1.2)
abline(h=0)

```

```

abline(h=1)
points(cor.ols.res.men$correlation[1:10], pch=2, cex=1.2)
lines(cor.ols.res.men$correlation[1:10], lwd=1.5)
legend(x=5, y=1.6, legend=c("Residuen des räumlich \nfhlerbezogenen Modells"), pch=c(1),
btty="n", cex=1.2)
legend(x=5, y=1, legend=c("Residuen des linearen \nRegressionsmodells"), pch=c(2),
btty="n", cex=1.2)

```

Zeichne räumliches Korrelogramm: Vergleich der Residuen räumlich fehlerbezogenes
Regressionsmodell vs. lineares Regressionsmodell für Frauen

```

plot(cor.sem.nb700.w.fem$correlation[1:10], type="b", pch=1, cex=1.2, lwd=1.5,ylim=c(-
1,1.5), xlab="Distanzklassen", ylab="Moran's I", cex.lab=1.5, cex.axis=1.2)
abline(h=0)
abline(h=1)
points(cor.ols.res.fem$correlation[1:10], pch=2, cex=1.2)
lines(cor.ols.res.fem$correlation[1:10], lwd=1.5)
title(main="Vergleich der Residuen des linearen und räumlich fehlerbezogenen
\nRegressionsmodells für Frauen", cex=1.5)
legend(x=5, y=1.6, legend=c("Residuen des räumlich \nfhlerbezogenen Modells"), pch=c(1),
btty="n", cex=1.2)
legend(x=5, y=1, legend=c("Residuen des linearen \nRegressionsmodells"), pch=c(2),
btty="n", cex=1.2)

```

Tabellenverzeichnis

<i>Tab. 1:</i> Räumliche Autokorrelationen der linearen Regressionsmodelle für Frauen und Männer mit Moran's I und räumlichem Nachbarschaftskriterium von 1500 Kilometern.	52
<i>Tab. 2:</i> Die drei größten Distanzen für die räumlichen Nachbarschaften 1. Ordnung.....	53
<i>Tab. 3:</i> Statistische Kennwerte und Koeffizienten der ursprünglichen und modifizierten linearen Regressionsmodelle mit und ohne Island für Frauen und Männer aus Studie 1.....	53
<i>Tab. 4:</i> Räumliche Autokorrelationen der linearen Regressionsmodelle ohne Island für Frauen und Männer mit Moran's I und räumlichem Nachbarschaftskriterium von 700 Kilometern.....	55
<i>Tab. 5:</i> Statistische Kennwerte und Koeffizienten der linearen Regressionsmodelle mit und ohne Island aus Studie 2.....	57
<i>Tab. 6:</i> Statistische Kennwerte und Koeffizienten der linearen Regressionsmodelle mit und ohne Island für Frauen, Männer und den gemittelten Gesamtwert aus Studie 3.....	60
<i>Tab. 7:</i> Räumliche Autokorrelationen der linearen Regressionsmodelle ohne Island für Männer und den Gesamtwert mit Moran's I und räumlichem Nachbarschaftskriterium von 700 Kilometern.....	62
<i>Tab. 8:</i> Vergleich der Modellanpassungen für die linearen und räumlich verzogenen Regressionsmodelle der Studien 1 und 3 anhand des AIC.....	64
<i>Tab. 9:</i> Vergleich der Modellanpassungen für die linearen und räumlich fehlerbezogenen Regressionsmodelle der Studien 1 und 3 anhand des AIC.....	68

Abbildungsverzeichnis

<i>Abb. 1:</i> Darstellungen im Gittermodell von (a) positiven räumlichen Autokorrelationen, (b) negativen räumlichen Autokorrelationen und (c) einer zufälligen Verteilung räumlicher Datenpunkte in Anlehnung an Lo und Yeung (2002).....	12
<i>Abb. 2:</i> Modellhafte Darstellung eines räumlichen Moran's I -Korrelogramm. Die räumlichen Autokorrelationen schwächen mit größer werdender Entfernung ab und treffen den Erwartungswert von Moran's I in der fünften Distanzklasse.....	24
<i>Abb. 3:</i> Darstellung der räumlichen Nachbarschaftskriterien (a) Turm („rook“), (b) Läufer („bishop“) und (c) Königin („queen“) im geordneten Gittermodell für räumliche Nachbarschaften 1. Ordnung.	28
<i>Abb. 4:</i> Räumliches Korrelogramm von Residuen des linearen Regressionsmodells für Frauen und Männer nach Voracek, Fisher und Marušič (2003) mit einem Nachbarschaftskriterium von 1500 Kilometern.....	50
<i>Abb. 5:</i> Verteilung der Suizidraten der europäischen Landeshauptstädte für (a) Frauen und (b) Männern aus der Studie 1 mit angepasster Normalverteilungskurve.	51
<i>Abb. 6:</i> Histogramm der Distanzen 1. Ordnung zwischen europäischen Hauptstädten ohne Island in Kilometer mit markiertem Median und unterem Quartil (25% der kleinsten Distanzen).	54
<i>Abb. 7:</i> Räumliche Korrelogramme von Residuen der modifizierten linearen Regressionsmodelle für Frauen und Männer ohne Island und einem Nachbarschaftskriterium von 700 Kilometern.....	56
<i>Abb. 8:</i> Histogramm der Distanzen 1. Ordnung zwischen europäischen Hauptstädten und dem westlich europäischen Teil Russlands mit angepasster Normalverteilungskurve, Median und unterem Quartil (25% der kleinsten Distanzen).	58
<i>Abb. 9:</i> Räumliches Korrelogramm von Residuen des linearen Regressionsmodells nach Voracek, Loibl und Kandrychyn (2007) ohne Island und einem Nachbarschaftskriterium von 700 Kilometern.....	59
<i>Abb. 10:</i> Räumliche Korrelogramme von Residuen der linearen Regressionsmodelle für Männer und den Gesamtwert ohne Island und einem Nachbarschaftskriterium von 700 Kilometern.	61
<i>Abb. 11:</i> Räumliche Korrelogramme von Residuen der linearen und räumlich verzogenen Regressionsmodelle für (a) Frauen und (b) Männer aus Studie 1 und (c) Männer aus Studie 3 ohne Island mit einem Nachbarschaftskriterium von 700 Kilometern.	66

Abb. 12: Räumliche Korrelogramme von Residuen der linearen und räumlich fehlerbezogenen Regressionsmodelle für (a) Frauen und (b) Männer aus Studie 1 und (c) Männer aus Studie 3 ohne Island mit einem Nachbarschaftskriterium von 700 Kilometern. 70

Literaturverzeichnis

- Anselin, L. (1980). Estimation methods for spatial autoregressive structures. *Regional Science Dissertation and Monograph Series*, 8, 263-273.
- Anselin, L. (1988). *Spatial econometrics: Methods and models*. Dordrecht: Kluwer.
- Anselin, L. (2001). Spatial econometrics. In B. H. Baltagi (Ed.), *A companion to theoretical econometrics* (pp. 310-330), Malden: Blackwell Publishing.
- Anselin, L. (2002). Under the hood issues in the specification and interpretation of spatial regression models. *Agricultural Economics*, 27, 247-267.
- Anselin, L., & Bera, A. K. (1998). Spatial dependence in linear regression models with an introduction to spatial econometrics. In A. Ullah, & D. E. Giles (Eds.), *Handbook of applied economic statistics* (pp. 237-289). New York: Dekker.
- Anselin, L., & Florax, R. (1995). Small sample properties of tests for spatial dependence in regression models: Some further results. In L. Anselin & R. Florax (Eds.), *New directions in spatial econometrics* (pp. 21-74). Berlin: Springer.
- Anselin, L., & Rey, S. (1991). Properties of tests for spatial dependence in linear regression models. *Geographical Analysis*, 23, 112-131.
- Berry, W. D. (1993). *Understanding regression assumptions*. Newbury Park, CA: Sage.
- Besag, J. (1974). Spatial interaction and the statistical analysis of lattice systems. *Journal of the Royal Statistical Society. Series B (Methodological)*, 36, 192-236.
- Besag, J., & Newell, J. (1991). The detection of clusters in rare diseases. *Journal of the Royal Statistical Society. Series A (Statistics in Society)*, 154, 143-155.
- Bivand, R. (2011). *spdep: Spatial dependence: weighting schemes, statistics and models* (0.5-43). Zugriff am 28. Dezember 2011 unter <http://CRAN.R-project.org/package=spdep>
- Bivand, R. S., Pebesma, E. J., & Gómez-Rubio, V. (2008). *Applied spatial data analysis with R*. New York: Springer.
- Bjornstad, O. N. (2009). *nfc: Spatial nonparametric covariance functions* (1.1-3.). Zugriff am 28. Dezember 2011 unter <http://CRAN.R-project.org/package=nfc>
- Bortz, J., & Döring, N. (2006). *Forschungsmethoden und Evaluation für Human- und Sozialwissenschaftler* (4. überarb. Aufl.). Heidelberg: Springer.
- Bortz, J., & Schuster, C. (2010). *Statistik für Human- und Sozialwissenschaftler* (7. Aufl.). Berlin: Springer.
- Cliff, A. D., & Ord, J. K. (1969). The problem of spatial autocorrelation. *London Papers in Regional Science*, 1, 25-55.
- Cliff, A. D., & Ord, K. (1971). Evaluating the percentage points of a spatial autocorrelation coefficient. *Geographical Analysis*, 3, 51-62.

- Cliff, A., & Ord, K. (1972). Testing for spatial autocorrelation among regression residuals. *Geographical Analysis*, 4, 267-284.
- Cliff, A., & Ord, J. K. (1973). *Spatial autocorrelation*. London: Pion.
- Cliff, A., & Ord, J. K. (1981). *Spatial processes: Models and applications*. London: Pion.
- Cressie, N. A. C. (1993). *Statistics for spatial data*. New York: Wiley.
- Dacey M. F. (1968). A review on measures of contiguity for two and k-color maps. In B. J. L. Berry & D. F. Marble (Eds.), *Spatial analysis: A reader in statistical geography* (pp. 479-495). Englewood Cliffs: Prentice-Hall.
- Diniz-Filho, J. A. F., Bini, L. M., & Hawkins, B. A. (2003). Spatial autocorrelation and red herrings in geographical ecology. *Global Ecology and Biogeography*, 12, 53-64.
- Doreian, P. (1980). Linear models with spatially distributed data: Spatial disturbances or spatial effects? *Sociological Methods & Research*, 9, 29-40.
- Dormann, C.F., McPherson, J. M., Araujo, M. B., Bivand, R., Bolliger, J., Carl, G., ...Wilson, R. (2007). Methods to account for spatial autocorrelation in the analysis of species distributional data: a review. *Ecography*, 30, 609-628.
- Dungan, J. L., Perry, J. N., Dale, M. R. T., Legendre, P., Citron-Pousty, S., Fortin, M.-J., ... Rosenberg, M. S. (2002). A balanced view of scale in spatial statistical analysis. *Ecography*, 25, 626-640.
- Durbin, J., & Watson, G. S. (1950). Testing for serial correlation in least squares regression: I. *Biometrika*, 37, 409-428.
- Durbin, J., & Watson, G. S. (1951a). Corrections to part I: Testing for serial correlation in least squares regression: I. *Biometrika*, 38, 177-178.
- Durbin, J., & Watson, G. S. (1951b). Testing for serial correlation in least squares regression: II. *Biometrika*, 38, 159-179.
- Field, A. P. (2005). *Discovering statistics using SPSS* (2nd ed.). London: Sage.
- Fortin, M.-J., & Dale, M. R. (2005). *Spatial analysis: A guide for ecologists*. Cambridge, UK: Cambridge University Press.
- Fortin, M.-J., Dale, M. R., & ver Hoef, J. (2002). Spatial analysis in ecology. In A. H. El-Shaarawi, & W. W. Piegorsch (Eds.), *Encyclopedia of environmetrics* (pp. 2051-2058). Chichester, UK: Wiley.
- Fotheringham, S. A., Brunsdon, C., & Charlton, M. (2000). *Quantitative geography: Perspectives on spatial data analysis*. London: Sage.
- Fotheringham, S. A., Brunsdon, C., & Charlton, M. (2002). *Geographically weighted regression: The analysis of spatially varying relationships*. West Sussex, UK: Wiley.
- Geary, R. C. (1954). The contiguity ratio and statistical mapping. *The incorporated statistician*, 5, 115-145.
- Getis, A. (2009). Spatial weights matrices. *Geographical Analysis*, 41, 404-410.

- Getis, A., & Aldstadt, J. (2004). Constructing the spatial weights matrix using a local statistic. *Geographical Analysis*, 36, 90-104.
- Getis, A. & Ord, J. K. (1992). The analysis of spatial association by use of distance statistics. *Geographical Analysis*, 24, 189-206.
- Griffith, D. A. (1987). *Spatial autocorrelation: A primer*. Washington, DC: Association of American Geographers.
- Griffith, D. A. (1996). Some guidelines for specifying the geographic weights matrix contained in spatial statistical models. In S. L. Arlinghaus (Ed.), *Practical handbook of spatial statistics* (pp. 65-82). Boca Raton, FL: CRC.
- Griffith, D. A. (2009). Spatial autocorrelation. In R. Kitchin & N. Thrift (Eds.), *International encyclopedia of human geography* (pp. 308-316). New York: Elsevier.
- Griffith, D. A. & Paelinck, J. H. P. (2011). *Non-standard spatial statistics and spatial econometrics*. Heidelberg: Springer.
- Haining, R. (1988). Estimating spatial means with an application to remotely sensed data. *Communications in Statistics: Theory and Methods*, 17, 573-597.
- Haining, R. (1990). *Spatial data analysis in the social and environmental sciences*. Cambridge, UK: Cambridge University Press.
- Haining, R. (2003). *Spatial data analysis theory and practice*. Cambridge, UK: Cambridge University Press.
- Hassall, C., & Sherratt, T. N. (2011). Statistical inference and spatial patterns in correlates of IQ. *Intelligence*, 39, 303-310.
- Jong, P. de, Sprenger, C., & van Veen, F. (1984). On extreme values of Moran's I and Geary's C. *Geographical Analysis*, 16, 17-24.
- Kelejian, H. H., & Prucha, I. R. (2001). On the asymptotic distribution of the Moran I test statistic with applications. *Journal of Econometrics*, 104, 219-257.
- Kissling, W. D. & Carl, G. (2008). Spatial autocorrelation and the selection of simultaneous autoregressive models. *Global Ecology and Biogeography*, 17, 59-71.
- Kühn, I. (2007). Incorporating spatial autocorrelation may invert observed patterns. *Diversity and Distributions*, 13, 66-69.
- Krige, D. G. (1951). A statistical approach to some basic mine valuation problems on the Witwatersrand. *Journal of the Chemical, Metallurgical and Mining Society of South Africa*, 52, 119-139.
- Legendre, P. (1993). Spatial autocorrelation: Trouble or new paradigm? *Ecology*, 74, 1659-1673.
- Legendre, P., & Fortin, M.-J. (1989). Spatial pattern and ecological analysis. *Vegetatio*, 80, 107-138.
- Legendre, P., & Legendre, L. (1998). *Numerical ecology* (2nd ed.). Amsterdam: Elsevier.

- Lennon, J. J. (2000). Red-shifts and red herrings in geographical ecology. *Ecography*, 23, 101-113.
- LeSage, J. P. (1997) Regression analysis of spatial data. *The Journal of Regional Analysis & Policy*, 27 (2), 83-94.
- Lo, C. P., & Yeung, A. K. W. (2002). *Concepts and techniques of geographic information systems*. Upper Saddle River, NJ: Prentice Hall.
- Marušič, A., & Farmer, A. (2001). Genetic risk factors as possible causes of the variation in European suicide rates. *British Journal of Psychiatry*, 179, 194-196.
- McMillen, D. P. (2003). Spatial autocorrelation or model misspecification? *International Regional Science Review*, 26, 208-217.
- Moran, P. A. P. (1950). Notes on continuous stochastic phenomena. *Biometrika*, 37, 17-23.
- Oden, N. L., & Sokal, R. R. (1986). Directional autocorrelation: An extension of spatial correlograms to two dimensions. *Systematic Zoology*, 35, 608-617.
- Ord, J. K., & Getis, A. (1995). Local spatial autocorrelation statistics: Distributional issues and an application. *Geographical Analysis*, 27, 286-306.
- Osborne P. E., Foody G. M., & Suárez-Seoane, S. (2007). Non-stationarity and local approaches to modelling the distributions of wildlife. *Diversity and Distributions*, 13, 313-323.
- Perez, S. I. , Diniz-Filho, J. A. F., Bernal, V., & Gonzalez, P. N. (2010). Spatial regression techniques for inter-population data: Studying the relationships between morphological and environmental variation. *Journal of Evolutionary Biology*, 23, 237-248.
- Pinkse, J., & Slade M.E. (1998). Contracting in space: An application of spatial statistics to discrete-choice models. *Journal of Econometrics*, 85, 125-154.
- R Development Core Team (2011). *R: A language and environment for statistical computing* (2.14.1). Vienna, Austria: R Foundation for Statistical Computing. Zugriff am 28. Dezember 2011 unter <http://cran.r-project.org/bin/windows/base/>
- Schabenberger, O., & Gotway, C. A. (2005). *Statistical methods for spatial data analysis texts in statistical science*. Boca Raton, FL: Chapman & Hall/CRC.
- Schmid, V. (2004) Bayesianische Raum-Zeit-Modellierung in der Epidemiologie. Dissertation, Fakultät für Mathematik, Informatik und Statistik, Ludwig-Maximilians-Universität, München, Deutschland.
- Schulze, P. M. (1993). Zur Messung räumlicher Autokorrelationen. *Jahrbuch für Regionalwissenschaft*, 14/15, 57-78.
- Sokal, R. R. (1986). Spatial data analysis and historical processes. In: E. Diday (Ed.), *Data analysis and informatics IV* (pp. 29-43). Amsterdam: Elsevier.
- Sokal, R. R., & Oden, N. L. (1978a). Spatial autocorrelation in biology. 1. Methodology. *Biological Journal of the Linnean Society*, 10, 199-228.

- Sokal, R. R., & Oden, N. L. (1978b). Spatial autocorrelation in biology. 2. Some biological implications and four applications of evolutionary and ecological interest. *Biological Journal of the Linnean Society*, 10, 229-249.
- Sturges, H. A. (1926). The choice of a class-interval. *Journal of the American Statistical Association*, 21, 65-66.
- Tiefelsdorf, M. (2002). The saddlepoint approximation of Moran's I 's and local Moran's I_i 's reference distributions and their numerical evaluation. *Geographical Analysis*, 34, 187-206.
- Tiefelsdorf, M., Griffith, D. A., & Boots, B. (1999). A variance-stabilizing coding scheme for spatial link matrices. *Environment and Planning A*, 31, 165-180.
- Tobler, W. (1970). A computer movie simulating urban growth in the Detroit region. *Economic Geography*, 46, 234-240.
- Venables, W. N., Smith, D. A. & R Development Core Team (2011). *An introduction to R*. Zugriff am 28. Dezember 2011 unter <http://cran.r-project.org/doc/manuals/R-intro.pdf>
- Voracek, M., Fisher, M. L., & Marušič, A. (2003). The Finno-Ugrian suicide hypothesis: Variation in European suicide rates by latitude and longitude. *Perceptual and Motor Skills*, 97, 401-406.
- Voracek, M., Loibl, L. M., & Kandrychyn, S. (2007). Testing the Finno-Ugrian Suicide Hypothesis: Replication and refinement with regional suicide data from Eastern Europe. *Perceptual and Motor Skills*, 104, 985-994.
- Voracek, M., & Marušič, A. (2008). Testing the Finno-Ugrian Suicide Hypothesis: Geographic variation of elderly suicide rates across Europe. *Nordic Journal of Psychiatry*, 62, 302-308.
- Waller, L. A., & Gotway, C. A. (2004). *Applied spatial statistics for public health data*. Hoboken, NJ: Wiley.
- Ward, M. D., & Gleditsch, K. S. (2008). *Spatial regression models*. Thousand Oaks, CA: Sage.
- Yu, W., Pu, Y., Chen, G., Wang, J., Ma, J., & Han, H. (2010). The construction of spatial weight matrix based on discrete points through building a searching area for each point. *Computer Application and System Modeling (ICCA SM), International Conference*, 5, V5-250-V5-253.

Eidesstattliche Erklärung

Eidesstattliche Erklärung

Ich bestätige, die vorliegende Diplomarbeit selbst und ohne Benutzung anderer als der angegebenen Quellen verfasst zu haben. Weiter ist sie die Erste ihrer Art und liegt nicht in ähnlicher oder gleicher Form bei anderen Prüfstellen auf. Alle Inhalte, die wörtlich oder sinngemäß übernommen wurden, sind mit der jeweiligen Quelle gekennzeichnet.

Wien, März 2012

Christoph Strauß

Curriculum Vitae

Persönliche Daten

Name: Christoph Strauß
Geboren: 23.01.1985 in Göttingen (D)
Email: herr.strauss@gmail.com

Ausbildung

1991 – 1995 Grundschule Hogenkamp (Oldenburg)
1995 – 1997 Orientierungsstufe der katholischen Paulusschule (Oldenburg)
1997 – 2004 Staatlich anerkanntes Gymnasium der Liebfrauenschule Oldenburg
in christlicher Trägerschaft mit dem Abschluss
„Allgemeine Hochschulreife“ (Abitur)
2004 – 2005 Zivildienst im Arbeiter Wohlfahrt Wohn- und Pflegeheim Parkstraße
in Braunschweig
Seit 2005 Studium der Psychologie an der Universität Wien
2008 – 2009 Anamnesegruppe, Medizinische Universität Wien
Seit 2009 Schwerpunkt Klinische und Gesundheitspsychologie, Universität
Wien
Oktober 2009 Proseminar Bildungspsychologie: Fortgeschrittene Studierende als
– Januar 2010 MentorInnen für StudienanfängerInnen („Cascaded Blended Mentoring“)
Seit 2010 Diplomand an der Universität Wien im Bereich „Psychologische
Grundlagenforschung“

Praktika

Dezember 2009 Praktikum in der Lehr- und Forschungspraxis der Universität Wien
– Februar 2009
November 2010 Praktikum bei Rat auf Draht 147 als vollwertiger Berater (ORF)
– April 2011

Besondere Kenntnisse

- Sehr gute Englischkenntnisse in Sprache und Schrift
- Schul- bzw. Grundkenntnisse in Französisch in Sprache und Schrift
- Schul- bzw. Grundkenntnisse in Spanisch in Sprache und Schrift
- Sehr gute EDV-Kenntnisse (MS Office, MS Windows, SPSS, R)