



Master Thesis

im Rahmen des

Universitätslehrganges „Geographical Information Science & Systems“
(UNIGIS MSc) am Interfakultären Fachbereich für GeoInformatik (Z_GIS)
der Paris Lodron-Universität Salzburg

zum Thema

„Räumliche Analyse der Agglomeration im filialisierten, österreichischen Einzelhandel“

vorgelegt von

Julian Jany BSc

104978, UNIGIS MSc Jahrgang 2018

Betreuer/in:

Dr. Christian Neuwirth

Zur Erlangung des Grades

„Master of Science (Geographical Information Science & Systems) – MSc(GIS)“

Salzburg, 18.01.2020

Eidesstattliche Erklärung

Ich erkläre hiermit eidesstattlich, dass ich die vorliegende Arbeit selbständig verfasst und keine anderen als die angegebenen Quellen und Hilfsmittel verwendet habe. Alle Stellen, die wörtlich oder inhaltlich den angegebenen Quellen entnommen wurden, sind als solche kenntlich gemacht. Die vorliegende Arbeit wurde bisher in gleicher oder ähnlicher Form noch nicht als Bachelor-/ Master-/ Diplomarbeit/ Dissertation eingereicht.

18.01.2020

Ort, Datum

Unterschrift

Danksagung

An dieser Stelle möchte ich mich bei Dr. Christian Neuwirth für die stets freundliche und enorm hilfreiche Betreuung der vorliegenden Arbeit bedanken. Für die im Verlauf von 2019 durchgeführten Analysen wurde mir sehr oft ein neuer Blickwinkel auf die Ergebnisse eröffnet, wodurch die Interpretation deutlich erleichtert wurde.

Zusätzlich bedanke ich mich natürlich auch beim kompletten UNIGIS-Team für die rasche und professionelle Bearbeitung meiner vielen Anfragen.

Nicht zuletzt möchte ich mich auch bei meinen UNIGIS-Studienkollegen für den interessanten Austausch und bei meinem privaten Umfeld für die laufende Unterstützung bedanken.

Kurzfassung

Im österreichischen Einzelhandel gibt es eine enorme Sättigung von Händlern aus fast allen Bereichen. Einer Erhebung der RegioData Research aus dem Jahr 2017 zufolge, hat Österreich sogar die höchste (Einzelhandels-)Verkaufsfläche pro Person in ganz Europa mit 1,67m², dicht gefolgt von Belgien mit 1,64m²/pP. Die Flächen mit hoher potenzieller Kundenfrequenz und trotzdem hohem Abstand zur branchengleichen Konkurrenz wurden somit bereits identifiziert und genutzt (Kunc and Križan, 2018). In einer weniger stark übersättigten Landschaft als Österreich, würden sich konkurrierende Unternehmen, der Theorie der zentralen Orte nach, so lange und weit aus dem Weg gehen, bis ein sinnvolles Equilibrium zwischen potenziellem Marktanteil und örtlicher Distanz zur gesamten Konkurrenz erreicht ist (Berry and Parr, 1988). Da in Westeuropa jedoch bereits eine Sättigung bzw. ein Equilibrium überschritten wurde, gibt es sogar einen Rückgang im stationären Einzelhandel (Kunc and Križan, 2018).

Neben der generellen Übersättigung haben sich die Raumordnungsgesetze in Österreich in den letzten Jahren immer weiter zu Ungunsten des Einzelhandels entwickelt. Um der Schwächung von Stadt- und Ortszentren zu begegnen, wurden Zonierungsvorschriften laufend restriktiver und zusätzlich in den Bundesländern unübersichtlich heterogen. (Mayerhofer *et al.*, 2018). Eine Möglichkeit der Übersättigung und den harten Zonierungsbeschränkungen zu begegnen ist Agglomeration, auch in Nähe der eigenen Konkurrenz. Das oft kooperative, örtliche Zusammenwachsen bzw. „Clustering“ von Einzelhändlern bietet für Unternehmen verschiedene Vorteile, aber auch das Risiko schrumpfender Marktanteile bei Angebotsüberschneidungen. Firmen können von maximierter Effizienz durch Synergien und Ressourcenteilung profitieren. Neben gemeinsamen Marketingmaßnahmen können auch Parkflächen gemeinsam genutzt werden, wodurch sich die gesamte Kundenfrequenz erhöht etc. (Christoph Teller *et al.*, 2016).

Um die Vorteile der Agglomeration zu nutzen und die entstehenden Nachteile möglichst gering zu halten, muss versucht werden, das facettenreiche Phänomen Agglomeration zu verstehen und zu analysieren. Ziel dieser Arbeit soll es sein, Agglomerationsintensität- und Muster in Österreich aufzudecken und verschiedene Möglichkeiten der Analyse vorzustellen. Neben etablierten Herangehensweisen werden neue (Kombinations-)Methoden vorgestellt. Es soll gezeigt werden, dass ein tieferes Verständnis der Agglomeration dem gesamten Einzelhandel dienlich sein könnte, etwa als erweiternder Faktor neben herkömmlichen Indikatoren bei der Planung neuer Standorte.

Abstract

There is an enormous saturation of retailers of almost all sectors in the Austrian retail Market. According to a 2017 survey by RegioData Research, Austria even has the highest (retail) sales-area per capita in all of Europe at 1.67m²/per person, closely followed by Belgium with 1.64m²/pP. Areas with potentially high customer-frequency and sufficient distance to competitors of the same sector have thus already been identified and used (Kunc and Križan, 2018). In a less saturated landscape than Austria competing companies would avoid each other as far as possible until a meaningful equilibrium between potential market share and local distance to the overall competition would be achieved, according to the theory of central locations (Berry and Parr, 1988). However, as saturation or equilibrium has already been exceeded in Western Europe, there is even a decline in stationary retail (Kunc and Križan, 2018).

In addition to general oversaturation, spatial planning laws in Austria have increasingly developed to disadvantage for retail in recent years. In order to counteract the weakening of city and town centres, zoning regulations have become increasingly restrictive and, in addition, have become unclearly heterogeneous over the Austrian provinces (Bundesländer). (Mayrhofer et al., 2018). One way to counteract oversaturation and increasing zoning restrictions is agglomeration, even in close proximity to own competitors. The often cooperative, local merging or "clustering" of retailers offers various advantages for companies, but also the risk of shrinking market shares caused by overlaps in choice of products. Companies can benefit from maximized efficiency through synergies and resource sharing. In addition to joint marketing activities, parking spaces can be shared, which increases the overall customer frequency, etc. (Christoph Teller et al., 2016).

In order to make use of the advantages of agglomeration and to keep the resulting disadvantages at a low level, it is necessary to understand and analyse the multifaceted phenomenon of agglomeration. The aim of this paper is to uncover agglomeration intensity- and patterns in Austria and to present different corresponding methodologies. Besides already established approaches, new (combinations of) methods are presented. It will be shown that a deeper understanding of agglomeration could be useful for the entire retail trade, for example as an additional factor to conventional indicators for planning new facilities.

Inhaltsverzeichnis

Eidesstattliche Erklärung	2
Danksagung	3
Kurzfassung	4
Abstract	5
Inhaltsverzeichnis	6
Abbildungsverzeichnis	8
1. Einleitung & Strukturbeschreibung	11
2. Geschichte der Agglomerationsanalyse und Forschungsstand	13
2.1 Eigenschaften, Vor- und Nachteile der Agglomeration	15
2.2 Ausgangssituation und Marktlage	16
2.2.1 International	17
2.2.2 Österreich.....	18
3. Agglomerationsanalyse durch Methodenkombination	22
3.1 Ausgangsdaten.....	22
3.2 Analyse der Clusteringintensität.....	25
3.2.1 Pointcloud-Centers	25
3.2.1.1 Methodenbeschreibung	26
3.2.1.2 Einschränkungen und Einsatzmöglichkeiten	28
3.2.2 Ripley's K-Function im Branchenvergleich.....	29
3.2.2.1 Methodenbeschreibung	29
3.2.2.2 Einschränkungen und Einsatzmöglichkeiten	34
3.2.3 Average Nearest Neighbor im Branchen- und zonalen Vergleich	35
3.2.3.1 Methodenbeschreibung	35
3.2.3.2 Einschränkungen und Einsatzmöglichkeiten	38
3.3 Musteranalyse.....	39
3.3.1 Service Areas	39
3.3.1.1 Methodenbeschreibung	39
3.3.1.2 Einschränkungen und Einsatzmöglichkeiten	41
3.3.2 Nearest Neighbor in Kombination mit Chi-Quadrat-Tests zur Analyse einseitiger bzw. zweiseitiger Branchenabhängigkeit.....	42
3.3.2.1 Methodenbeschreibung	42
3.3.2.2 Einschränkungen und Einsatzmöglichkeiten	44
3.3.3 Branchenmix.....	45
3.3.3.1 Methodenbeschreibung	45
3.3.3.2 Einschränkungen und Einsatzmöglichkeiten	47

3.3.4	Branchenmix auf Basis von Service-Areas „Local Cluster“	48
3.3.4.1	Methodenbeschreibung	48
3.3.4.2	Einschränkungen und Einsatzmöglichkeiten	48
3.4	MAUP – Eine allgemeine Einschränkung in der Agglomerationsanalyse...	49
3.5	Möglichkeit der Methodenkombination	51
4.	Ergebnisse.....	52
4.1	Österreichweite Agglomerationsmuster der einzelnen Branchen	52
4.1.1	Österreichweite Clusteringintensität der verschiedenen Branchen	52
4.1.2	Österreichweite Abhängigkeitsmuster auf Basis von Einzugsgebieten.....	56
4.1.3	Österreichweite Abhängigkeitsmuster auf Basis von Nachbarschaft.....	57
4.2	Interzonale Vergleiche.....	62
4.2.1	Interzonaler Vergleich von politischen Zonierungen	62
4.2.2	Interzonaler Vergleich von selbstdefinierten Zonierungen	66
4.2.3	Mustervergleich auf Basis von politischen Zonierungen	69
4.2.3.1	Bezirksebene	69
4.2.3.2	Gemeindeebene.....	72
4.2.3.3	Zählsprengelebene	74
4.2.4	Musteranalyse auf Basis von Einzugsgebieten „Local Cluster“	77
5.	Methodenkombination in Anwendungsfällen	78
6.	Diskussion.....	83
7.	Ausblick	85
8.	Literaturverzeichnis	86
9.	Anhang.....	89
9.1	Weitere Ripley’s K-Analysen für noch nicht abgebildete Kategorien/Branchen	89
9.2	Weitere Ergebnisse der Service-Area-Analyse	91
9.3	Weitere Ergebnisse der Average-Nearest-Neighbor Analyse	92
9.3.1	Für Bezirk Salzburg.....	92
9.3.2	Multisprengelel – Wien City	93
9.4	Weitere Ergebnisse der Branchenmix-Analyse.....	94

Abbildungsverzeichnis

Abbildung 1: Deloitte - Global Powers of Retailing 2019 – Quelle: Deloitte.....	17
Abbildung 2: Verkaufsfläche pro Person in 2016 in ausgewählten Ländern (m ²) - Quelle: RegioData Research 2017	18
Abbildung 3: Anzahl der Geschäfte im stationären Einzelhandel, 2007-2017 (und Veränderung gegenüber Vorjahr) Quelle: KMU Forschung Austria.....	19
Abbildung 4: Anzahl der Geschäfte in ausgewählten Einzelhandelsbranchen, 2017 (inkl. Veränderung zum Vorjahr) Bezogen auf Jahresbeginn des Folgejahres - Quelle: KMU Forschung Austria.....	19
Abbildung 5: Anzahl der FMA in Österreich 2006-2016 - Quelle: Standort+Markt 20	20
Abbildung 6: Zahl der Einzelhandelsgeschäfte und Verkaufsfläche, 2017 - in den Top 22 Geschäftsstraßen (GS), Einkaufs und Fachmarktzentren (EKZ&FMZ) und Fachmarkttagglomerationen (FMA) – Quelle: Standort+Markt	20
Abbildung 7: Übersicht erfasster Einzelhändler	23
Abbildung 8: Erfasste Einzelhändler nach Kategorie - WGS84.....	25
Abbildung 9: Darstellung des geografischen Zentrums der Punktwolke „Lebensmittelhändler“ im Bezirk Salzburg Stadt	26
Abbildung 10: Bezirk Salzburg Stadt - Pointcloud-Centers	27
Abbildung 11: Ripley's K-Funktion auf verschiedenen Distanzkreisen - Quelle: Jeff Gillian, Leandro Gonzalez	29
Abbildung 12: Punkt und Distanzband am Rande eines Untersuchungsgebiets – Quelle: Clusterseer	30
Abbildung 13: Berechnung der K-Funktion - Quelle: ESRI.....	30
Abbildung 14: Beispielhafte Darstellung des Ergebnisses einer Ripley's-K Analyse - Quelle: ESRI.....	31
Abbildung 15: Ergebnis einer Ripley's K-Analyse für die Kategorie LH	31
Abbildung 16: Ripley's K-Funktion am Beispiel von Lebensmittelhändlern Visualisierung von ArcGIS-Analyseergebnissen in MS Excel.....	32
Abbildung 17: Ripley's K-Funktion am Beispiel von Lebensmittelhändlern Visualisierung von CrimeStat-Analyseergebnissen.....	33
Abbildung 18: Visualisierung der auf die Nulllinie normalisierten L(d)-Werte verschiedener Ripley's K-Analysen	34
Abbildung 19: CSR-Muster im Vergleich zu Clustering- und gleichverteilten Mustern - Quelle: Boots and Getis 1988.....	35
Abbildung 20: Berechnung des Z-Wertes bei einer Average-Nearest-Neighbor- Analyse - Quelle: Boots and Getis, 1988.....	36
Abbildung 21: Average-Nearest Neighbor-Analyse der Kategorie Mode-Sport- Schuhe in Graz mit der Software ArcGIS.....	37
Abbildung 22: Average-Nearest Neighbor-Analyse der Kategorie Lebensmittelhändler in Graz mit der Software ArcGIS.....	37
Abbildung 23: Netzwerk-Distanz gegen eine gerade Linie - Quelle: O'Neill et al.	40
Abbildung 24: Isochrone Flächen einer Minute "Gehzeit" rund um Lebensmittelhändler.....	40

Abbildung 25: Verteilung der Kategorien in ganz Österreich	42
Abbildung 26: Verteilung der "Nächsten Nachbarn" zu Lebensmittelhändlern.....	43
Abbildung 27: Berechnung des Chi-Quadrat Anpassungstests - Quelle: Schwarz 2018 43	
Abbildung 28: Abweichung von Erwartungswerten in der Kategorie Lebensmittelhändler inkl. Chi-Quadrat-Anpassungstest	44
Abbildung 29: Datengrundlage für eine Branchenmix-Analyse ohne erweiterte Sortierungskriterien (Gemeindenname Punkt-Gesamtanzahl je Kategorie)	46
Abbildung 30: Top 20-Auswertung der Verteilung von Einzelhändlern in Form eines gestapelten Balkendiagramms mit Absolutwerten	46
Abbildung 31: Branchenmix der Top 20 Gemeinden nach Bevölkerungszahl	47
Abbildung 32: Einfluss der Maßstabs-Zonierung auf die Wahrnehmung eines Phänomens (empirisches Beispiel) - Quelle: Madelin et al., 2009	49
Abbildung 33: Einfluss der Zonierung auf die Wahrnehmung eines Phänomens (theoretisches Beispiel) - Quelle: Madelin et al., 2009.....	50
Abbildung 34: Ripley's K-Function am Beispiel von Lebensmittelhändlern Visualisierung von ArcGIS-Analyseergebnissen in MS Excel.....	52
Abbildung 35: Ripley's K-Function der Kategorie Kosmetiker - Österreichweit ...	53
Abbildung 36: Ripley's K-Analyse für Baumärkte - Österreichweit.....	54
Abbildung 37: Ripley's K-Analyse - normalisierte Beobachtungswerte (DiffK) der einzelnen Kategorien/Branchen - Österreichweit	55
Abbildung 38: Auszug der 1-Min Gehzeit-Einzugsgebiete rund um Lebensmittelhändler auf Basis des österr. Straßennetzes – Salzburg und Umgebung	56
Abbildung 39: Gesamtverteilung aller Punkte, sowie Verteilungen der nächsten Nachbarn (NN) je Kategorie	58
Abbildung 40: Häufigkeitsverteilungen der nächsten Nachbarn zur fokalen Kategorie im Vergleich mit Erwartungswerten inkl. prozentueller Abweichung und Chi-Quadrat-Test für die Kategorien: Baumärkte, Elektromärkte, Kosmetiker, Lebensmittelhändler und Möbelhändler.....	59
Abbildung 41: Häufigkeitsverteilungen der nächsten Nachbarn zur fokalen Kategorie im Vergleich mit Erwartungswerten inkl. prozentueller Abweichung und Chi-Quadrat-Test für die Kategorien: Mode-Sport-Schuhe und Sonstige.....	60
Abbildung 42: Verteilung von Lebensmittelhändlern im Bezirk Salzburg Stadt	62
Abbildung 43: ANN-Analyse der Lebensmittelhändler im Bezirk Salzburg Stadt.	63
Abbildung 44: ANN für Kosmetiker in Salzburg.....	64
Abbildung 45: ANN für Mode-Sport-Schuhe in Salzburg	64
Abbildung 46: Verteilung von Lebensmittelhändlern im Bezirk Graz Stadt	65
Abbildung 47: ANN für Lebensmittelhändler in Graz	65
Abbildung 48: ANN der Kosmetiker in Graz	66
Abbildung 49: ANN der Kategorie Mode-Sport-Schuhe in Graz	66
Abbildung 50: Übersicht Händler in Multisprengel entlang Mariahilferstraße.....	67
Abbildung 51: Lebensmittelhändler-ANN in Multisprengel - Mariahilfer Straße ..	67
Abbildung 52: Kosmetiker-ANN in Multisprengel - Mariahilfer Straße	68

Abbildung 53: Mode-Sport-Schuhe-ANN in Multisprengel - Mariahilfer Straße ..	68
Abbildung 54: Branchenmix - Top 20 nach Punktzahl.....	69
Abbildung 55: Branchemix - Top 20 Bezirke nach Bevölkerungzahl.....	70
Abbildung 56: Branchemix - Top 20 Bezirke nach Bevölkerungszahl	71
Abbildung 57: Durchschnitt der in Abb. 56 gezeigten Verteilung der Top 20 Bezirke nach Bevölkerungszahl.....	71
Abbildung 58: Branchenmix der Top 20 Gemeinden in Österreich nach Anzahl der Händler 72	
Abbildung 59: Branchenmix der Top 20 Gemeinden nach Bevölkerung	73
Abbildung 60: Durchschitt der Verteilung der Top 20 Gemeinden nach Bevölkerungszahl.....	73
Abbildung 61: Branchenmix der Top 20 Zählsprengel nach Punktezahl.....	74
Abbildung 62: Branchenmix der Top 20 Sprengel nach Bevölkerungszahl (mind. 10 Punkte) 75	
Abbildung 63: Durchschitt der Verteilung der Top 20 Sprengel nach Bevölkerungszahl (mind. 10 Punkte).....	75
Abbildung 64: Branchenzusammensetzung der jeweiligen Kategorien innerhalb von 1-min Einzugsgebieten rund um Lebensmittelhändler in ganz Österreich ..	77
Abbildung 65: Ripley's K-Analyse im Branchenvergleich für ganz Österreich.....	78
Abbildung 66: Branchenmix von Gemeinden mit ähnlichen Bevölkerungszahlen zu Bergheim bei Salzburg - absolut.....	79
Abbildung 67: Branchenmix von Gemeinden mit ähnlichen Bevölkerungszahlen zu Bergheim bei Salzburg - absolut.....	79
Abbildung 68: Durchschnittlicher Branchenmix von Gemeinden mit ähnlicher Bevölkerungszahl: Bergheim bei Salzburg.....	80
Abbildung 69: Branchenmix in 1-min Einzugsgebieten (Service-Areas) um Lebensmittelhändler im Salzburger Flachgau.....	81
Abbildung 70: NN-Chi-Quadrat Analyse für Lebensmittelhändler und Baumärkte in Österreich	81
Abbildung 71: Average-Nearest-Neighbor Resultate für Lebensmittelhändler im Salzburger Flachgau.....	82
Abbildung 72: Ripley's K-Analyse für Möbelhäuser - österreichweit	89
Abbildung 73: Ripley's K-Analyse für Elektromärkte - österreichweit	89
Abbildung 74: Ripley's K-Analyse für Mode-Sport-Schuhe - österreichweit.....	90
Abbildung 75: Ripley's K-Analyse für Sonstige - österreichweit.....	90
Abbildung 76: Baumärkte.....	92
Abbildung 77: Kategorie Sonstige.....	92
Abbildung 78: Elektromärkte	92
Abbildung 79: Übersicht Händler in Multisprengel: Wien City.....	93
Abbildung 80: Lebensmittelhändler	93
Abbildung 81: Kosmetiker.....	93
Abbildung 82: Branchemix der Top 20 Bezirke nach Bevölkerung	94
Abbildung 83: Branchenmix der Top 20 Gemeinden nach Bevölkerungszahl - prozentuell.....	95

1. Einleitung & Strukturbeschreibung

In der vorliegenden Arbeit soll gezeigt werden, dass das Phänomen der Agglomeration auf verschiedenen Betrachtungsebenen und über verschiedene Branchen vielfältig ausgeprägt ist und aus diesem Grund mit unterschiedlichen Werkzeugen bzw. mit deren Kombination analysiert werden sollte.

Um die unterschiedlichen Herangehensweisen nachvollziehbar zu machen, wird im ersten Schritt ein Abriss zur Geschichte der Agglomerations- bzw. Clusterforschung vorgestellt. Im nächsten Teil der Arbeit folgt eine Beschreibung der aktuellen Marktsituation für den internationalen und den spezifischen österreichischen Markt, anhand welcher deutlich werden soll, weshalb die Agglomerationsforschung auch in Österreich noch intensiver betrieben werden sollte.

Direkt im Anschluss wird eine Übersicht bzw. Erklärung zu den verwendeten Forschungsmethoden gegeben, welche teilweise für die Anwendungsfälle dieser Arbeit in spezialisierter Form verwendet wurden, etwa um Vergleichbarkeit in den Analyseergebnissen zu ermöglichen. Auch die Einschränkungen bzw. im Kontext der Agglomerationsforschung empfehlenswerten Anwendungsgebiete der Methoden werden dabei jeweils näher beleuchtet.

Nach der Beschreibung der für die Analysen benötigten Werkzeuge bzw. Methoden, wird die Möglichkeit deren Kombination für reale Anwendungsfälle besprochen, wobei zusätzlich auf das MAUP („modifiable areal unit problem“), welches für einige Erhebungsmethoden relevant ist, eingegangen wird.

Nach der (kombinierten) Methodenvorstellung werden einzelne Ergebnisse der jeweiligen Analysen vorgestellt, einige davon wurden in den Anhang verlegt, um den Lesefluss zu erleichtern. In den letzten beiden Kapiteln wird besprochen, welcher Mehrwert durch die Analyse mit verschiedenen Methoden bzw. durch deren Kombination für Forschung und Wirtschaft erzielt werden kann.

Mit den beschriebenen Methoden soll zum einen geklärt werden, ob ein statistisch signifikantes, brancheninternes Clustering der einzelnen Branchen bzw. Kategorien nachweisbar ist und wie dieses in Folge visualisiert werden kann. Zusätzlich soll erhoben werden, ob Abweichungen in Hinsicht auf Clusteringintensität zwischen den Branchen auf verschiedenen Maßstäben feststellbar ist. Ein weiteres Ziel der Erhebungen soll der Nach-

weis von einseitigen bzw. zweiseitigen Abhängigkeitsbeziehungen in direkter Nachbarschaft zwischen den Branchen sein. Zuletzt soll auch geprüft werden, ob die Zusammensetzung von Branchen über verschiedene Zonierungen, sowie auf verschiedenen Betrachtungsebenen visualisiert und verglichen werden kann, bzw. ob Muster in den Zusammensetzungen feststellbar sind.

Im nachfolgenden ersten Kapitel der Arbeit wird nun der Überblick zu früheren Agglomerationsanalysen bzw. zum Forschungsstand gegeben. Die Entstehung von Agglomerationsräumen, also Flächen mit erhöhtem Händlerclustering bzw. die Analyse dieser Agglomerationen ist in der Welt der Wissenschaft keinesfalls eine Neuheit, so wurde das Phänomen bereits vor fast einem Jahrhundert diskutiert.

2. Geschichte der Agglomerationsanalyse und Forschungsstand

Bereits im Jahr 1929 präsentiert Harold Hotelling im Paper „Stability in Competition“ sein „principle of minimum differentiation“, welches die Agglomeration branchengleicher Händler erklären sollte. Die mittlerweile überholte Theorie beobachtete die Häufung von Eiscremehändlern im Umkreis von Stränden, ging dabei jedoch von zu starren bzw. unflexiblen Ausgangsbedingungen aus (Brown, 1989). Seiner Theorie nach würden sich mehrere Einzelhändler in unmittelbarer Nähe zueinander im Marktzentrum eines gewählten Einzugsgebietes in einer Art des gegenseitigen Überspringens („leap-frogging“) ansiedeln. Hotelling unterstellte einen flachen und linearen Markt mit unelastischer, gleichbleibender Nachfrage. In den folgenden Jahren wurden konträre Theorien aufgestellt, in welchen gleichmäßige Verteilungsmuster von Händlern mit äquidistanten Abständen im zweidimensionalen Raum vorgeschlagen wurden. (Brown, 1989) Beispiele hierfür wären etwa in den Arbeiten von Christaller, welche bis heute einflussreiche Grundlagentheorien bilden.

Christaller postulierte ein hierarchisches Modell zentraler Orte, bei welchem eine flächendeckende Versorgung dispers verteilter Bevölkerung optimal sichergestellt wird. Die zwei Haupteigenschaften der Theorie sind, dass je größer die Reichweite einer zentralen Funktion ist, desto geringer die Anzahl der Zentren des Funktionsangebotes, sowie, dass jedes größere Zentrum über alle zentralen Funktionen verfügt, die auch in kleineren Zentren erfüllt werden. Die Modelle von Christaller gehen also von einer relativ gleichmäßigen, hierarchischen Verteilung (einem Equilibrium) von „Märkten“ über die Fläche aus. Zwar kann durch dieses Modell ein grundlegendes Prinzip von Städtesystemen erkannt und erklärt werden, jedoch scheitert das Modell an höher verdichteten Gebieten. So logisch die Theorie erscheinen mag, kann sie die Realitätserfahrungen nur selten passend beschreiben (Deiters, 1996). Märkte im Allgemeinen und Agglomerationen im Speziellen können aufgrund von komplexen Zusammensetzungen, Zonierungsrestriktionen, topographischen Bedingungen uvm. nicht grundsätzlich auf einzelne, deterministische Theorien zurückgeführt werden, jedoch kann man versuchen, Muster zu identifizieren und zu vergleichen.

Die Bildung von Agglomerationsräumen blieb, trotz der Schwierigkeit diese eindeutig erklären zu können, auch weiterhin ein häufig beobachtbares Phänomen und wurde in den folgenden Jahrzehnten auf verschiedene Arten untersucht und beschrieben. Zwischen

1965 und 1979 wurde häufig die Dichte pro Rastereinheit (Häufigkeit auf Rasterflächen) herangezogen. So analysierte Rogers 1965 in Stockholm, welche Händler (Mode, Möbel, Lebensmittel etc.) das stärkste, und welche das schwächste Clustering aufwiesen (Rogers, 1965). Mit derselben Technik analysierten auch Lee und Koutsopoulos 1976 in Denver das Clustering von Supermärkten untereinander (Lee and Koutsopoulos, 1976).

1979 wurden in diesem Kontext von Lee erstmals Punktmuster als solche untersucht und eine sogenannte „Nearest-Neighbor-Analysis“ oder „Average-Nearest-Neighbor-Analysis“ (ANN) durchgeführt (Lee, 1979). Bei dieser Analyse wird der mittlere Abstand zu den nächsten Nachbarn ermittelt und mit Erwartungswerten verglichen. Weicht das Ergebnis stark von der Erwartung ab, ist das Clustering (oder auch die Gleichverteilung) signifikant, bzw. nicht zufällig. Ähnliche Ansätze, sowie Kombinationen aus diesen wurden in den folgenden Jahren noch sehr häufig durchgeführt, etwa von Fischer und Harrington, sowie von Jensen, Boisson und Larralde. (Fischer and Harrington, 1996; Jensen *et al.*, 2005) Die ANN-Analyse wurde nicht für derartige Erhebungen im Einzelhandel entwickelt, eignet sich jedoch für die Analyse der Agglomerationsmuster durchaus als beschreibender Teilfaktor. Im weiteren Verlauf dieser Arbeit wird die ANN näher vorgestellt und auf den österreichischen Einzelhandel angewandt.

Neben der ANN gibt es mittlerweile noch weitere Möglichkeiten der modernen Geoinformatik, Punktmuster und deren Clusteringeigenschaften zu analysieren. 2013 wird von Krider und Putler die Ripley's K-Function in diesem Kontext angewandt (Krider and Putler, 2013). Diese Funktion ist etwas komplexer als die ANN-Analyse und analysiert die Menge an Punkten innerhalb verschiedener Distanzkreise und vergleicht diese mit Simulationen (etwa einer Poisson-Verteilung). Durch diese Art der Analyse in den Städten Vancouver und Calgary konnten interessante Agglomerationsmuster aufgedeckt werden, wobei Krider und Putler selbst in der eigenen Erhebung die Vielzahl an Kategorien und geringe Zahl an verglichenen Städten kritisierten. Eine ähnliche Analyse mit der Ripley's K-Function wird ebenfalls in dieser Arbeit vorgestellt und auf den österreichischen Markt angewandt. Hierbei wird eine abweichende Methodik zum Branchenvergleich und durch eine österreichweite Betrachtung eine höhere Zahl an Städten und Gemeinden herangezogen.

In der jüngeren Vergangenheit gab es auch Versuche, die Abhängigkeit unterschiedlicher Branchen zueinander innerhalb von Agglomerationsräumen zu analysieren. Hierfür wurde 2016 von Nilsson und Smirnov ein neuer Ansatz vorgestellt. Bei deren Erhebung

wurde versucht, die Anzahl der Punkte einer Branchen-Punktewolke A innerhalb eines gewissen Einzugsbereichs um die Punkte der Branchen-Punktewolke B herum zu analysieren (Nilsson and Smirnov, 2016). Dieser Ansatz ist zwar für die Analyse der Branchenverteilung innerhalb der Agglomerationsräume durchaus interessant, jedoch technisch nur schwer umzusetzen (ein speziell angepasstes Voronoi-Diagramm muss erstellt werden). Ein ähnliches Ergebnis bietet die Analyse von Einzugsgebieten rund um Punktewolken, die mit sogenannten Service-Areas innerhalb von ArcGIS erstellt werden können. Hierbei wird anhand des Verkehrsnetzes eine „durchschnittliche Geh-/ oder Fahrzeit“ weg von den fokalen Punkten (=Händlern) erhoben. Im Anschluss wird ein Polygon über den Distanzraum z.B. „1-Min Gehzeit“ gebildet. Entfallen viele Punkte der zweiten Kategorie in diese gebildeten Polygone, könnte man eine Abhängigkeit unterstellen. Leider sind diese Ansätze sehr anfällig auf die Menge an Punkten je Branche, weshalb auf diese Methode nur kurz am österreichischen Beispiel eingegangen wird.

2.1 Eigenschaften, Vor- und Nachteile der Agglomeration

Agglomeration ist für die Händler ein durchaus ambivalentes Phänomen. Sie wirkt sich auf verschiedene Arten auf die Kooperations- und Konkurrenzsituation aus. Blickt man oberflächlich auf das Clusteringverhalten, kommen dem Betrachter möglicherweise zuerst die offensichtlichen Nachteile für Händler in den Sinn, wie etwa dem Umsatzverlust durch Angebotsüberschneidungen mit der Konkurrenz. Bei näherer Betrachtung der Agglomerationsräume werden jedoch auch die Vorteile, sowohl für die Händler, als auch für die Konsumenten deutlich. Aus Kundensicht hat man in Agglomerationsräumen die Möglichkeit, spezielle Anforderungen in einem heterogenen Angebot zu bedienen, die Möglichkeit Preise über verschiedene Händler zu vergleichen und auch das stärker werdende Bedürfnis nach Unterhaltung während des Einkaufs zu stillen. Aus Händlersicht gibt es Vorteile, wie die gemeinsame, effiziente Nutzung von Infrastruktur, erleichterte Ressourcenzugänglichkeit und ein stark vermindertes Risiko bei der Standortwahl. (Kridler and Putler, 2013).

Auch die beiden Fachtermini „Multi-Purpose-Shopping“ (Mehrzweckkäufe) und „Spillover-Effekte“ (Übertragungseffekte) müssen im Kontext der Agglomeration besprochen werden. „Multi-Purpose-Shopping“ beschreibt aus Kundensicht die Möglichkeit mit einem Einkauf mehrere Bedürfnisse befriedigen zu können. Hiermit ist jedoch

nicht nur die bereits erwähnte Möglichkeit zur Wahl aus einem heterogenen Angebot eines einzelnen Segments gemeint, sondern auch die Möglichkeit zum bedarfsdeckenden Einkauf aus allen Kategorien. Agglomerationsräume erleichtern das „Multi-Purpose-Shopping“ enorm. Ist ein Händler in einer Agglomerationszone besonders erfolgreich, hat demnach eine hohe „Leistung“ oder „Performance“, kann dieser als Lockmittel für den gesamten Agglomerationsraum wirken und sogenannte „Spillover-Effekte“ auf andere Händler haben. So kaufen Kunden mit erhöhter Wahrscheinlichkeit auch bei anderen Händlern im Agglomerationsraum ein.

Agglomerationsräume können aus zwei verschiedenen Gründen entstehen: Zum einen können diese im Zeitverlauf an stark frequentierten Orten wachsen (wie etwa Innenstadtbereiche), oder zum anderen gezielt angelegt werden (etwa Einkaufszentren). Beide Formen haben verschiedene Eigenschaften, bieten den Kunden und Händlern jedoch sehr ähnliche Vor- und Nachteile. Sinnvoll ist es in beiden Varianten, ein aktives, gemeinsames Management einzusetzen, das ein kollektives Marketing über den gesamten Agglomerationsraum erlaubt. Spillover-Effekte können mit gemeinsamen Strategien noch verstärkt werden und es ist möglich, noch besser auf das Unterhaltungsbedürfnis der Kunden einzugehen. Ist der Agglomerationsraum als solcher erfolgreich, generiert dieser eine erhöhte Besucherfrequenz und hat somit positive Spillover-Effekte auf einzelne Händler innerhalb des Agglomerationsraumes (Christoph Teller *et al.*, 2016). Natürlich muss jeder Händler je nach Angebot und Sortiment entscheiden, ob die erwähnten Vorteile von Agglomerationsräumen die potenziellen Umsatzeinbußen durch Angebotsüberschneidungen aufwiegen können. Insgesamt ist es als Händler auch bei ähnlichen Grundsortimenten möglich, sich durch andere Faktoren wie Preiszusammensetzung und (zeitlich begrenzten) Spezialangeboten gegenüber der Konkurrenz zu differenzieren und somit gemeinsam die Anforderungen eines „Multi-Purpose“-Einkaufs zu decken.

2.2 Ausgangssituation und Marktlage

Da nun beschrieben wurde, wie Agglomerationsräume in der Vergangenheit und Gegenwart analysiert wurden und aus welchen Gründen deren Entstehung auch aus Händler-sicht durchaus sinnvoll sein kann, soll nun darauf eingegangen werden, wie sich der Markt für Einzelhändler in den letzten Jahrzehnten, sowohl international, als auch in Österreich verändert hat.

2.2.1 International

Die weltweite und auch die europäische Einzelhändler-Landschaft wird in steigendem Ausmaß durch filialisierten Einzelhandel geprägt, wobei sich immer größere Flächen auf eine immer geringer werdende Zahl von wachsenden Großunternehmen konzentriert (Marktkonzentration). Weltweit gesehen ist die Firma Wal Mart mit weitem Abstand der größte Wettbewerbsteilnehmer und nur zwei der Top 10 Firmen im Einzelhandel haben den Hauptsitz nicht in den USA:

Global Powers of Retailing Top 250, FY2017

FY2017 Retail revenue rank	Name of company	Country of origin	FY2017 Retail revenue (US\$M)	FY2017 Parent company/group revenue ¹ (US\$M)	FY2017 Parent company/group net income ¹ (US\$M)	Dominant operational format	# Countries of operation	FY2012-2017 Retail revenue CAGR ²
1	Wal-Mart Stores, Inc.	US	500,343	500,343	10,523	Hypermarket/Supercenter/Superstore	29	1.3%
2	Costco Wholesale Corporation	US	129,025	129,025	2,714	Cash & Carry/Warehouse Club	12	5.4%
3	The Kroger Co.	US	118,982	122,662	1,889	Supermarket	1	4.2%
4	Amazon.com, Inc.	US	118,573	177,866	3,033	Non-Store	14	18.0%
5	Schwarz Group	Germany	111,766	111,766	n/a	Discount Store	30	7.5%
6	The Home Depot, Inc.	US	100,904	100,904	8,630	Home Improvement	4	6.2%
7	Walgreens Boots Alliance, Inc.	US	99,115	118,214**	4,101	Drug Store/Pharmacy	10	6.7%
8	Aldi Einkauf GmbH & Co. oHG	Germany	98,287 ^e	98,287 ^e	n/a	Discount Store	18	7.2%
9	CVS Health Corporation	US	79,398	184,765	n/a	Drug Store/Pharmacy	3	4.5%
10	Tesco PLC	UK	73,961	75,338	1,123	Hypermarket/Supercenter/Superstore	8	-2.4%

Abbildung 1: Deloitte - Global Powers of Retailing 2019 – Quelle: Deloitte

Der Trend der Marktkonzentration ist besonders in Europa spürbar, so wird dieser durch Marktsättigung, staatliche Zonierungsvorschriften und Preise pro m² Verkaufsraum verstärkt. (Cliquet, 2006). Kleinere, aber auch große Unternehmen können sich somit immer seltener den teuren und restriktiven Anforderungen stellen. Diese Entwicklung sorgt gepaart mit dem Vormarsch des Onlinehandels für einen Rückgang im stationären Einzelhandel, trotz gleichzeitigen Marktwachstums im Handel. Der Rückgang an Händlern in Europa wird in Folge mit wachsenden Flächen der stärksten Vertreter kompensiert. Man spricht hier von einem Strukturwandel im europäischen Einzelhandelsmarkt.

In einigen Ländern führten die Entwicklungen der letzten Jahrzehnte zu einer enormen (Über-)Sättigung, die sich beispielsweise am Verhältnis von Einzelhandelsfläche pro Einwohner visualisieren lässt. Österreich liegt hierbei an der Spitze. (Kunc and Križan, 2018)

Country	Retail area (m ²)	Country	Retail area (m ²)
Austria	1.67	Czech Republic	1.04
Belgium	1.64	Italy	1.03
Netherlands	1.61	Hungary	1.02
Switzerland	1.47	Slovakia	1.01
Germany	1.44	Poland	0.95
Sweden	1.27	Greece	0.74
France	1.23	Bulgaria	0.74
Spain	1.12	Romania	0.70
Croatia	1.10	Ukraine	0.44
Great Britain	1.09		

Abbildung 2: Verkaufsfläche pro Person in 2016 in ausgewählten Ländern (m²) - Quelle: RegioData Research 2017

2.2.2 Österreich

Die enorme Dichte sorgt in Österreich tatsächlich nicht nur bei der Zahl an Händlern für einen Rückgang, sondern auch bei der Verkaufsfläche. Die „Strukturanalyse im stationären Einzelhandel“ der KMU Forschung Austria beschreibt die Lage in Österreich ausführlich. Seit 2013 sanken die Verkaufsflächen und haben sich erst 2017 wieder stabilisiert. Die Konzentration sorgt darüber hinaus in den letzten Jahren für einen enormen Filialisierungsgrad (Anteil von Einzelhandelsketten zu Einzelhändlern insgesamt) von 40%. In den Agglomerationsräumen der Einkaufs- oder Fachmarktzentren, welche in den letzten Jahren immer beliebter wurden, liegt der Filialisierungsgrad sogar bei 83%. Die starken Veränderungen in der Händlerlandschaft werden von der KMU-Forschung Austria als Strukturwandel im Einzelhandel bezeichnet. In Österreich hat sich dieser Wandel in der jüngsten Vergangenheit zwar leicht verlangsamt, ist jedoch immer noch merklich. Betrachtet man die Daten im Zeitverlauf, wird die Veränderung besonders deutlich:




Abbildung 3: Anzahl der Geschäfte im stationären Einzelhandel, 2007-2017 (und Veränderung gegenüber Vorjahr) Quelle: KMU Forschung Austria

Durch den Strukturwandel hat sich die Einzelhändlerlandschaft in Österreich nachwirkend verändert und wurde vor allem durch die Top-Vertreter geprägt. Die Verteilung sieht lt. Strukturanalyse 2018 der KMU-Forschung Austria folgendermaßen aus:

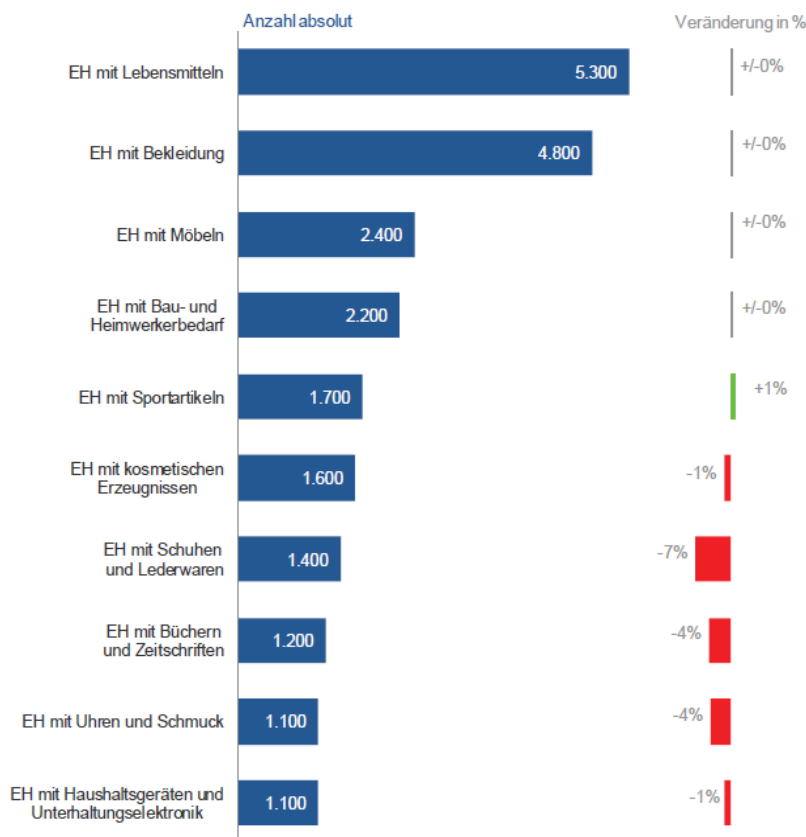


Abbildung 4: Anzahl der Geschäfte in ausgewählten Einzelhandelsbranchen, 2017 (inkl. Veränderung zum Vorjahr) Bezogen auf Jahresbeginn des Folgejahres - Quelle: KMU Forschung Austria

Während sich der Strukturwandel zwar langsam abschwächt, gewinnen Agglomerationsräume immer weiter an Bedeutung. Während Toplagen in Stadtzentren lt. Standort+Markt weiterhin äußerst beliebt sind, könnte die Beliebtheit von B- und C-Lagen abnehmen und für steigende Leerstandsdaten sorgen. Mitunter verantwortlich dafür sind die immer beliebteren Agglomerationen der Einkaufs- und Fachmarkzentren, welche laufend wachsende Flächen beanspruchen. Neben den Einkaufs- und Fachmarkzentren sind vor allem auch die Fachmarkttagglomerationen zu erwähnen, welche Österreichs Einzelhandelslandschaft stark mitprägen. Hierbei sind Agglomerationen von mind. 4 Fachmärkten mit einer Verkaufsfläche von je mind. 150 m² in nächster Nähe zueinander und zusammen mind. 4000m² Verkaufsfläche gemeint. Diese „FMA“ haben einen enorm hohen Filialisierungsgrad von 97% und erfreuen sich ebenfalls nach wie vor wachsender Beliebtheit.




Abbildung 5: Anzahl der FMA in Österreich 2006-2016 - Quelle: Standort+Markt

Diese Agglomerationsräume haben darüber hinaus noch sehr viel Verkaufsfläche und stehen sogar im Vergleich mit Einkaufs- und Fachmarkzentren heraus:




Abbildung 6: Zahl der Einzelhandelsgeschäfte und Verkaufsfläche, 2017 - in den Top 22 Geschäftsstraßen (GS), Einkaufs und Fachmarkzentren (EKZ&FMZ) und Fachmarkttagglomerationen (FMA) – Quelle: Standort+Markt

Fachmarkt- und Einkaufszentren beschreiben hierbei im Kontrast zu Fachmarkttagglomerationen gemeinsame Einkaufsflächen verschiedener Händler „unter einem Dach“. Fachmarkttagglomerationen haben somit auch mehr als das Dreifache der gesamten Verkaufsfläche der Top 22 Geschäftsstraßen in Österreich. (Gittenberger *et al.*, 2018)

Agglomerationsräume gewinnen laufend an Bedeutung und bilden immer größere Teile der gesamten Einzelhandelslandschaft, während der Filialisierungsgrad in allen Kategorien weiter voranschreitet. Eine ganzheitliche Untersuchung der Agglomerationsintensität filialisierter Einzelhändler und eine Identifikation der gebildeten Muster wird somit in steigendem Ausmaß notwendig. Die Ergebnisse solcher Analysen bzw. der Vergleich dieser, kann somit ein weiterer Impuls bzw. Faktor für die Standortwahl werden.

3. Agglomerationsanalyse durch Methodenkombination

Aufgrund der komplizierter werdenden Marktlage und den gesetzlichen Vorschriften, die Händler oftmals zur Bildung von Agglomerationsräumen zwingen, sowie den Vorteilen die Agglomerationsräume für Händler haben können, ist es nötig die Clustering-Muster besser zu verstehen.

Da das Wesen der Agglomeration als solches nun äußerst komplex ist, soll in dieser Arbeit versucht werden, die Agglomeration anhand verschiedener Methoden zu analysieren und vergleichbar zu machen, um im Handel und der Regionalplanung neue Impulse zu schaffen. Um solche Analysen zu ermöglichen, war es im ersten Schritt notwendig eine umfangreiche Datengrundlage zu erheben.

3.1 Ausgangsdaten

Eine derartige Datengrundlage konnte mithilfe von online öffentlich zugänglichen Daten erhoben werden. Diese Daten wurden aus verschiedenen Filialfindern zusammengetragen und enthalten eine große Zahl von filialiserten Einzelhändlern in ganz Österreich.

Da diese von den Händlern selbst im Internet zur Verfügung gestellt werden, ist die Güte der Ausgangsdaten (Adressdaten) sichergestellt. Im Zeitraum zwischen Mai und Juni 2019 wurden vom Autor dieser Arbeit Adressdaten zusammengetragen. Es handelt sich demnach um eine Momentaufnahme und nicht um eine dynamische Betrachtung der Marktlage. Nach der Erhebung der großen Zahl an Adressdaten, wurden diese mit der Software QGIS 3 über die Erweiterung MMQGIS geocodiert. Als Geocoding-API wurde dabei der Google-Dienst Google Maps verwendet. Nach der Verarbeitung und einigen kleineren Korrekturen, konnten insgesamt 10.171 Einzelhändler geocodiert werden.

Die bereits in Abbildung 4 gezeigten, am öftesten vorkommenden Einzelhandelsvertreter werden für die folgenden Analysen in einer leicht abweichenden Aufteilung nach Sortimentsähnlichkeit bzw. Überschneidung kategorisiert. Dabei wurden folgende Kategorien gebildet: „Baumärkte“, „Elektromärkte“, „Kosmetiker“, „Lebensmittelhändler“, „Mode-Sport-Schuhhändler“, „Möbelhäuser“ und „Sonstige“.

Zu den „Baumärkten“ zählen Unternehmen, die mit Baustoffen, Heimwerkerbedarf und ähnlichem handeln. „Elektromärkte“ umfassen alle Elektronikhändler, ob Weißware oder Unterhaltungselektronik. Zu der Kategorie „Kosmetik“ gehören Drogerien und Parfümerien. Unter den „Lebensmittelhändlern“ finden sich sowohl Vollsortiment-Anbieter, als

auch Discounter. „Mode-Sport-Schuhe“ umfassen Modehändler für Kleidung, Schuhe aber auch spezialisierte Frauen, Herren oder auch Kindermodenhändler. Der Einzelhandel mit Sportartikeln wurde ebenfalls zu dieser Kategorie hinzugezählt, da sich das Sortiment sehr oft überschneidet. „Möbelhändler“ beinhalten hier nur die großen Anbieter mit >10 Filialen in Österreich und auch ein branchenverwandtes Bettenfachgeschäft. In der Kategorie „Sonstige“ wurden jene filialisierten Unternehmen verortet, die ebenfalls typischerweise in Agglomerationsräumen vorzufinden, jedoch niemals alleine anzutreffen sind, Händler die folglich ganz besonders stark vom „Spillover-Effekt“ profitieren. Zu diesen zählen Optiker, Buchhändler, Spielzeughändler uvm. Eine Übersicht der erfassten Händler ist in folgender Tabelle zu finden:

Bau	Elektro	Kosmetik	Lebensmittel	Mode-Sport-Schuhe	Möbel	Sonstige
Bauhaus	Conrad	Bipa	Adeg	Bershka	Dänisches	Action
Hagebau	Electronic-	dm	Billa	C&A	Bettenlager	Fielmann
Hornbach	Partner	Marionnaud	Hofer	Deichmann	Ikea	Fressnapf
Lagerhaus	Expert	Müller	Lidl	Esprit	Kika	Morawa
Obi	Hartlauer		Maximarkt	Fussl	Leiner	Pagro
WH	Libro		Merkur	Gigasport	Möbelix	Pearle
	Media-Markt		Mpreis	Hervis	Mömax	Smyths Toys
	Saturn		Nah und Frisch	H&M	XXXLutz	Tedi
	Red Zac		Penny	Humanic		Thalia
			Spar	Intersport		
			Sutterlüty	kik		
			Unimarkt	Mango		
				Marco Polo		
				New Yorker		
				NKD		
				Orsay		
				Peek und Cloppenburg		
				Pimkie		
				s Oliver		
				Sport 2000		
				Sports Direct		
				Takko		
				Vero Moda		
				Zara		

Abbildung 7: Übersicht erfasster Einzelhändler

Den Löwenanteil der Daten wird, wie Abbildung 4 bereits vermuten lässt, durch die Kategorie Lebensmittelhändler gebildet, gefolgt von Mode-Sport-Schuhhändlern und Kosmetikern. Die Daten setzen sich folgendermaßen zusammen:

- Baumärkte - **683**
- Elektromärkte - **881**
- Kosmetik - **1.171**
- Lebensmittelhändler - **4.331**
- Möbelhäuser - **258**
- Mode, Sport, Schuhe - **2.200**
- Sonstige – **647**

Mit den gebildeten Kategorien ist es nun möglich Clusteringverhalten, sowohl innerhalb von Kategorien, als auch untereinander zu analysieren. Es soll in Folge geprüft werden wie stark die einzelnen Kategorien clustern, welche Clusteringmuster die einzelnen Kategorien auf verschiedenen Maßstäben bilden und welche Kombinationen ungewöhnlich häufig gebildet werden.

Um Unterschiede zwischen den Betrachtungsmaßstäben zu verdeutlichen, wurden verschiedene politische Zonierungsvarianten verwendet: Österreichische Bezirke, Gemeinden und Zählsprenkel. In der folgenden Abbildung sind alle erfassten Einzelhändler vor dem Hintergrund der österreichischen Bezirke zu sehen:

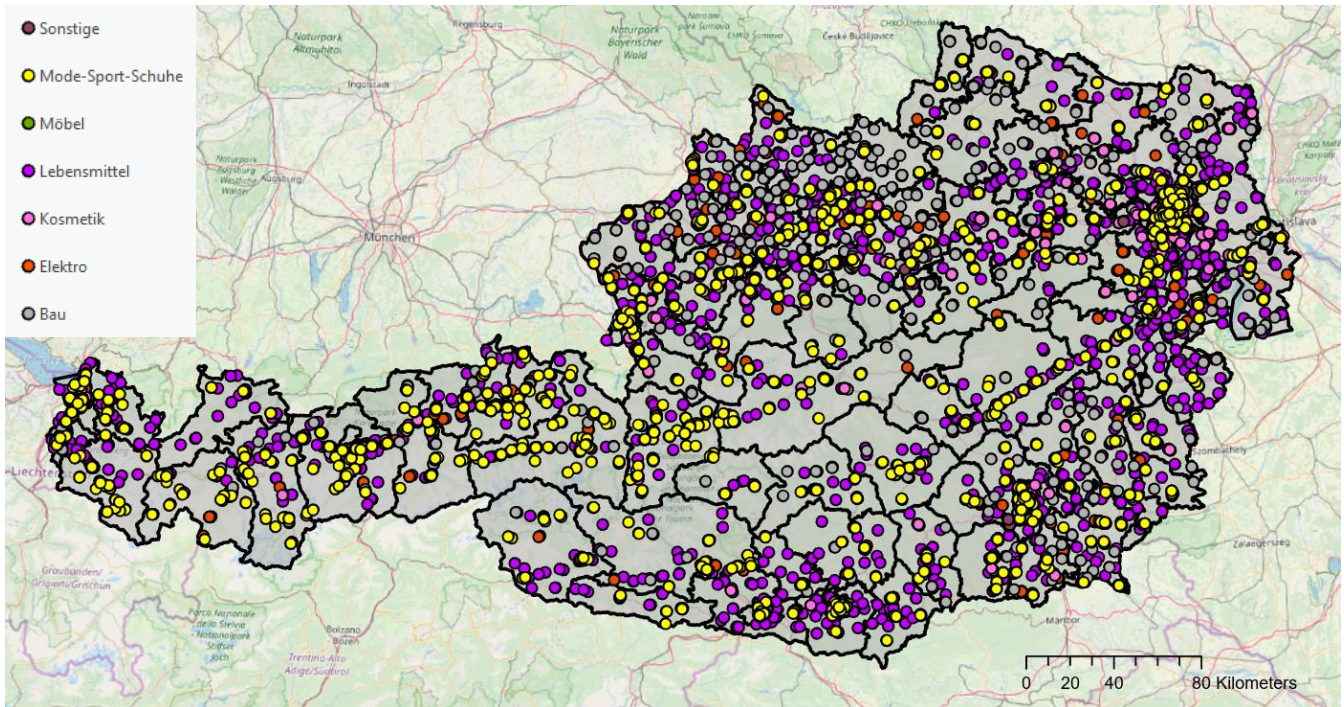


Abbildung 8: Erfasste Einzelhändler nach Kategorie - WGS84

3.2 Analyse der Clusteringintensität

In diesem Kapitel sollen drei verschiedene Methoden vorgestellt werden, mit welchen es möglich ist, das Clusteringverhalten innerhalb einzelner Kategorien/Branchen und auch zwischen Kategorien zu vergleichen.

3.2.1 Pointcloud-Centers

Die Erhebung von „Pointcloud-Centers“ stellt eine enorm simple Herangehensweise an eine Clusteranalyse dar. Die Methode bezieht sich auf die Verteilungen einer Punktwolke (in diesem Beispiel nach Branchen/Kategorien wie Lebensmittel etc.) innerhalb eines vorgegebenen Raumes.

3.2.1.1 Methodenbeschreibung

Die Pointcloud-Centers-Methode berechnet das relative Zentrum von Punktwolken. Wählt man beispielsweise Bezirke als Betrachtungsmaßstab bzw. Zonierungskriterium, ist es möglich, das Zentrum einer Punktwolke innerhalb des Bezirks abzubilden. Dabei wird der Zentroid berechnet, sozusagen der geografische Mittelwert der Populationsverteilung.

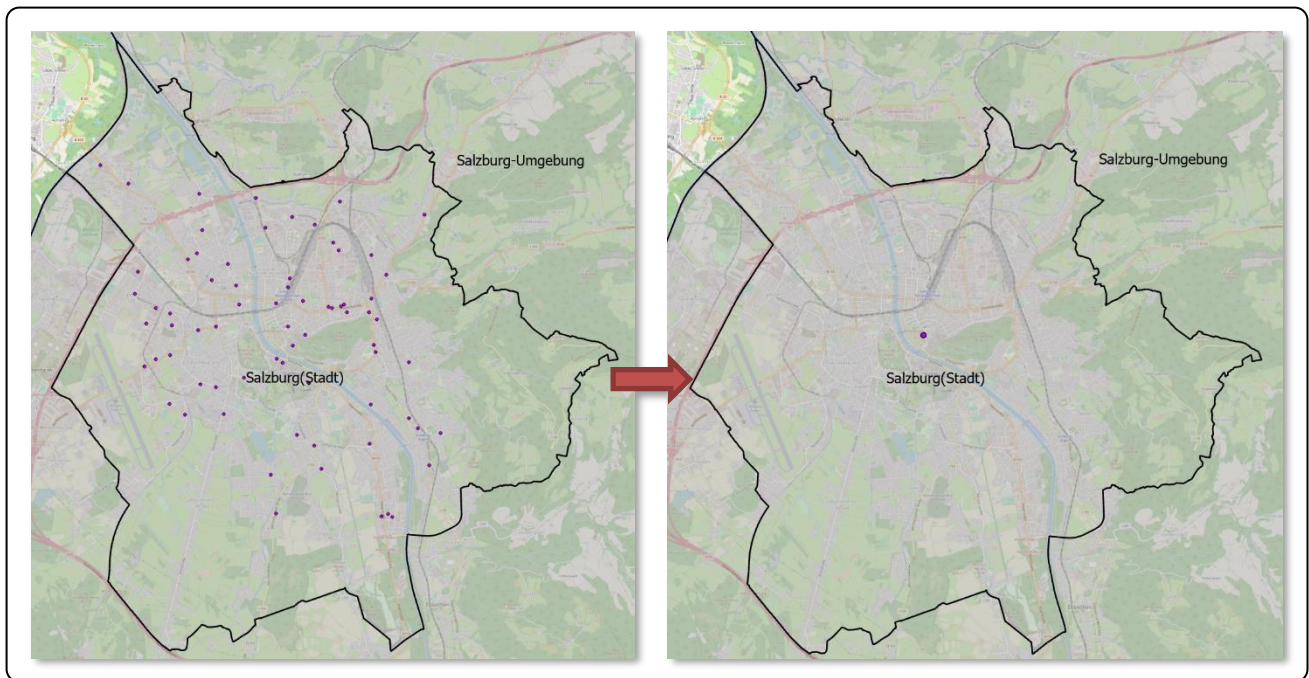


Abbildung 9: Darstellung des geografischen Zentrums der Punktwolke „Lebensmittelhändler“ im Bezirk Salzburg Stadt

Wendet man diese Methode nun auf jede der zuvor vorgestellten Kategorien an, ist es möglich, die Zentren der jeweiligen Branchen zu vergleichen und Ähnlichkeiten bzw. Unterschiede festzustellen. In der folgenden Grafik wurde diese Methode für jede der sieben Kategorien angewendet.

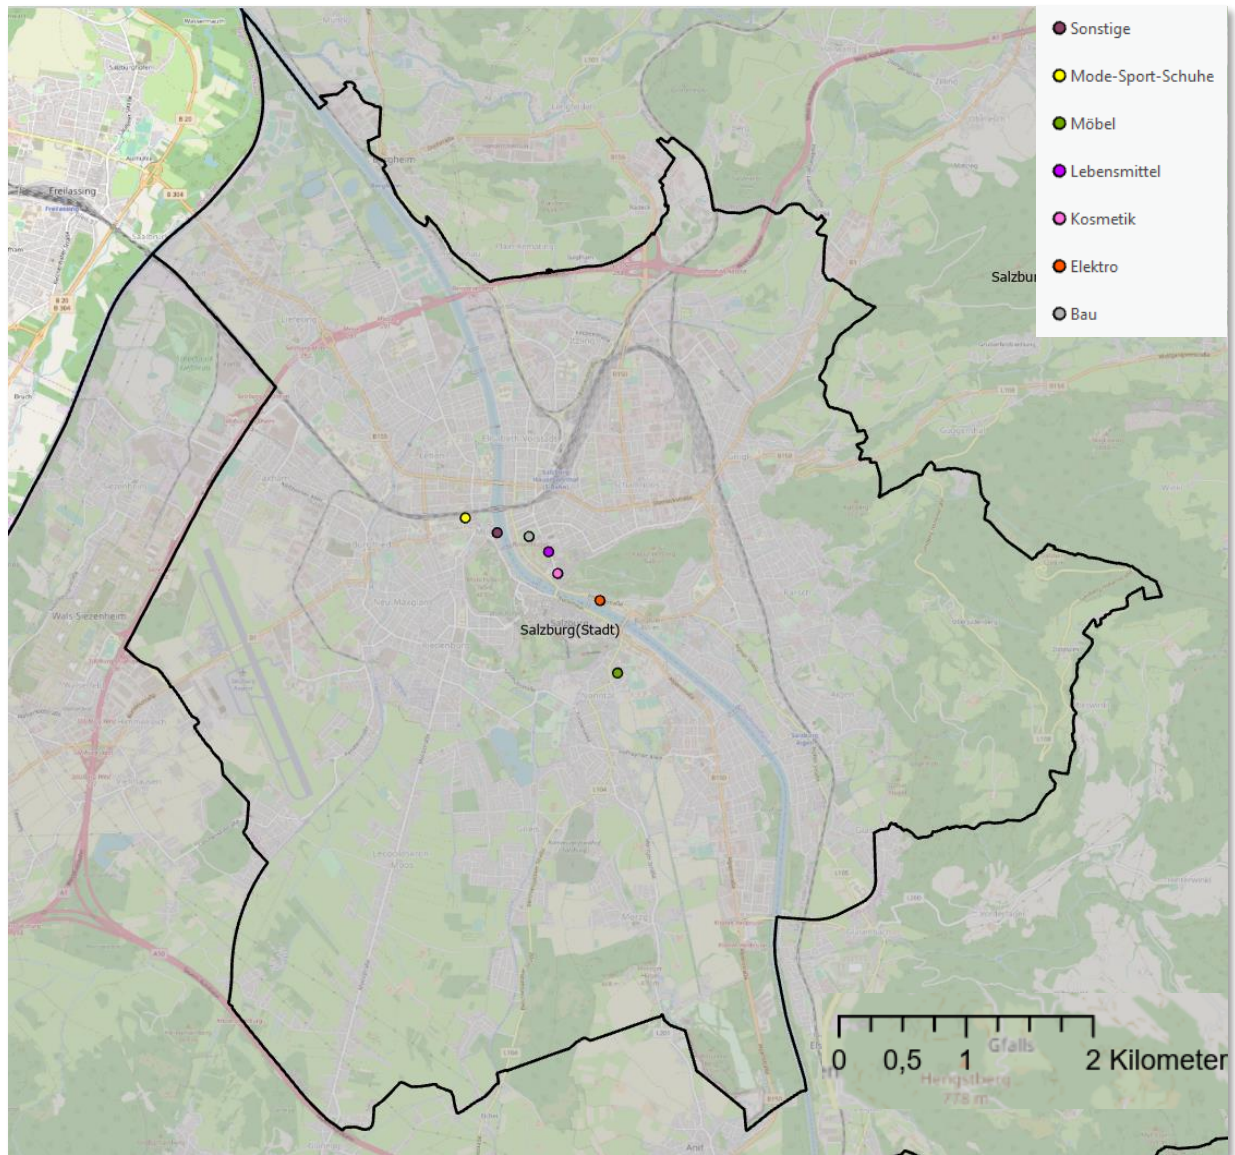


Abbildung 10: Bezirk Salzburg Stadt - Pointcloud-Centers

Es ist sehr leicht zu erkennen, dass die jeweiligen Zentren der Punktwolken nicht sehr weit auseinander liegen und somit eine ähnliche Verteilung der Punktwolken implizieren.

3.2.1.2 Einschränkungen und Einsatzmöglichkeiten

Die offensichtlichste Einschränkung dieser Methode wurde im Laufe der Erhebungen des Autors der vorliegenden Arbeit sehr deutlich. Da für jeden Maßstab nur ein Mittelwert gebildet wird, ist die Auswertung sehr anfällig auf Punkte, die weit außen an den Rändern liegen, ähnlich der Anfälligkeit des Mittelwerts auf Ausreißer in der klassischen Statistik. Neben der genannten Schwäche, in Hinblick auf weiter entfernte Punkte innerhalb des Untersuchungsgebiets, wird die Analyse auch sehr stark durch die Wahl des Untersuchungsgebietes selbst und die Anzahl an Punkten innerhalb dieser geprägt. Liegen beispielsweise stark unregelmäßige politische Zonierungen oder ungewöhnliche topografische Verhältnisse vor, die dafür sorgen, dass sich Punkte nur in grenznahen Ecken des Untersuchungsgebietes sammeln, kann es sogar passieren, dass sich die Punktzentren außerhalb dieses Gebiets befinden.

Grundsätzlich wäre es mit dieser Methode möglich, eine interzonal unverhältnismäßig häufig vorkommende Nähe verschiedener Branchen/Kategorien untereinander festzustellen. Für diese Erhebung müssten die Vergleichs-Untersuchungsgebiete jedoch sehr klein (etwa Zählsprengelebene in großen Städten um den Einfluss von Grenz-Ausreißern zu minimieren) und die Punktdichten der Kategorien sehr hoch sein, um sinnvolle Rückschlüsse ziehen zu können.

Aufgrund der erwähnten Einschränkungen kann die Methode zwar für Clustering-Analysen in Betracht gezogen werden, jedoch nur, wenn in der Datengrundlage vorab beschriebene Kriterien erfüllt werden. Für die vorliegende Arbeit wurde die beschriebene Methode auf verschiedenen Ebenen (Gemeinden, Sprengel, Bezirke etc.) getestet und auf die Aussagekraft untersucht. Wegen der Beschaffenheit der vorliegenden Datengrundlage wurde diese Methode nicht in den Forschungsergebnissen inkludiert, sollte jedoch unter anderen Umständen trotzdem für Agglomerationsforschung in Betracht gezogen werden.

3.2.2 Ripley's K-Function im Branchenvergleich

Die bereits im Kapitel 1.1 erwähnte Ripley's K-Function stellt für die vorliegende Forschungsarbeit eine der zentralen Analysemethoden dar und wurde auf verschiedenen Ebenen mehrmals getestet. Als Erweiterung zur klassischen Ripley's-K-Analyse wird in dieser Arbeit ein Branchenvergleich (Kategorievergleich) der Analyseergebnisse durchgeführt.

3.2.2.1 Methodenbeschreibung

Ripley's K-Function ist eine Methode zur Analyse zweidimensionaler Punktmuster. Sie kann zu Testzwecken, zur Zusammenfassung, Schätzung und zur Erkennung von Mustern herangezogen werden. Das Ergebnis einer Ripley's K-Analyse beschreibt die Eigenschaften von Punktmustern über verschiedene Distanzbänder bzw. Kreise. Durch die gleichzeitige Betrachtung der Punktmuster auf verschiedenen Distanzniveaus hebt sich die Funktion von ähnlichen Methoden wie der Nearest-Neighbor-Analyse ab. Punktmuster können sich auf verschiedenen Betrachtungsmaßstäben unterschiedlich verhalten, etwa Clustering im Großen und eine „Meidung“ auf kleinem Maßstab. Die Ripley's K-Function wird häufig für ökologische Untersuchungen herangezogen, etwa für die Analyse von Bäumen oder von Nistplätzen verschiedener Tiere. (Dixon, 2014) Die Funktion ist neben den genannten Einsatzmöglichkeiten jedoch auch für die Analyse der geografischen Verteilung von Einzelhändlern überaus geeignet, da sich diese auf verschiedenen Betrachtungsniveaus stark unterschiedlich verhalten. Die Erhebung auf den verschiedenen Distanzbändern wird in folgender Grafik mit blauen Kreisen abgebildet:




Abbildung 11: Ripley's K-Function auf verschiedenen Distanzkreisen - Quelle: Jeff Gillian, Leandro Gonzalez

Die Funktion zählt die Nachbarn eines Punktes und vergleicht diese Anzahl in Folge mit einem Erwartungswert. Die Erwartung wäre ein zufälliger „random“ Wert. Weicht das Ergebnis positiv ab, liegt ein Clustering vor, weicht es jedoch negativ ab, impliziert dies eine disperse Verteilung. (Gillan and Gonzalez, 2012) Für die Berechnung via ArcGIS wird folgende Formel herangezogen:

The K-Function is given as:

$$L(d) = \sqrt{\frac{A \sum_{i=1}^n \sum_{j=1, j \neq i}^n k(i, j)}{\pi n(n-1)}} \quad (1)$$

where d is the distance, n is equal to the total number of features, A represents the total area of the features and $k_{i,j}$ is a weight. If there is no edge correction, then the weight will be equal to one when the distance between i and j is less than d , and will equate to zero otherwise. Using a given edge correction method will modify $k_{i,j}$ slightly.

Abbildung 13: Berechnung der K-Funktion - Quelle: ESRI

Verschiedene Formeln können dieses Problem bei dichten Datengrundlagen mit Punkten, die sich in Grenznähe befinden beheben. Da es sich bei der Datengrundlage der vorliegenden Arbeit um großflächig verteilte und selten grenznahe Punkte handelt, ergaben diese Korrekturmaßnahmen kaum bemerkbare Änderungen in den Ergebnissen.

Das Resultat der Analyse ist eine Reihe von Daten, inklusive dem Erwartungswert (=Expected Random Spatial Pattern), dem beobachteten Wert $L(d)$ (= Observed Spatial Pattern) und den beiden Grenzen des Konfidenzintervalls (= Lower und Higher Confidence Envelop). Die folgende Grafik bildet eine beispielhafte Auswertung ab:




Abbildung 12: Punkt und Distanzband am Rande eines Untersuchungsgebiets – Quelle: Clusterseer

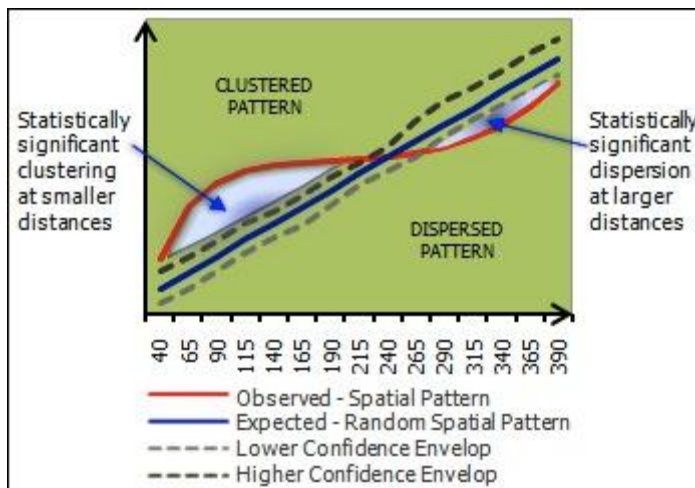


Abbildung 14: Beispielhafte Darstellung des Ergebnisses einer Ripley's-K Analyse - Quelle: ESRI

Der Erwartungswert wird, wie eingangs bereits kurz erwähnt, durch Simulationen, also zufällig verteilte Punktmuster (=Cases), etwa nach dem Poisson-Prozess erstellt. Im Fall des Poisson-Prozesses, welcher auch in den Analysen der vorliegenden Arbeit herangezogen wurde, wird eine zufällige Punktwolke mit einer gegebenen Dichte λ erstellt. (Jacquez *et al.*, 2011). Da eine einzelne Simulation eine wenig aussagekräftige Vergleichsgrundlage wäre, gibt es in ArcGIS die Möglichkeit eine Vielzahl von Simulationen als Grundlage für den Erwartungswert zu produzieren. In der vorliegenden Arbeit wurden verschiedene Anzahlen von Simulationen je Kategorie getestet, in den Ergebnissen konnte zwischen 10 und 100 Simulationen kein nennenswerter Unterschied festgestellt werden, weshalb die weniger rechenintensive Option mit 10 Simulationen gewählt wurde. In folgendem Beispiel wurde die Kategorie Lebensmittelhändler für ganz Österreich ausgewertet, dabei wurden die erwähnten 10 Simulationen durchgeführt und keine Edge-Correction verwendet. Als Distanzinkrement wurde 1km verwendet und um die Interpretation zu erleichtern, der Distanzraum von einem bis 10km herangezogen. Die Ergebnisse sind folgender Tabelle zu entnehmen (Daten in m):

ExpectedK	ObservedK	DiffK	LwConfEnv	HiConfEnv
1000	7863,612721	6863,612721	883,5280894	1045,404534
2000	13818,91517	11818,91517	1874,24611	2066,668063
3000	19175,9619	16175,9619	2941,725885	3102,249614
4000	24163,2068	20163,2068	3930,03328	4079,019231
5000	28792,71508	23792,71508	4904,518916	5030,238643
6000	32977,87298	26977,87298	5914,643876	6024,858309
7000	36816,58171	29816,58171	6899,766897	7035,014392
8000	40264,21093	32264,21093	7861,485216	8024,34756
9000	43459,858	34459,858	8844,742201	9018,913482
10000	46304,67557	36304,67557	9854,408276	9987,050285

Abbildung 15: Ergebnis einer Ripley's K-Analyse für die Kategorie LH

In folgender Grafik erkennt man den enorm schmalen Bereich des Konfidenzintervalls, innerhalb welchem sich auch der Erwartungswert findet.




Abbildung 16: Ripley's K-Funktion am Beispiel von Lebensmittelhändlern Visualisierung von ArcGIS-Analyseergebnissen in MS Excel

Diese Auswertung zeigt das starke Clustering der Kategorie „Lebensmittelhändler“, welches mit höherer Distanz immer stärker vom Erwartungswert abweicht, mehr hierzu später im Ergebniskapitel. Die Auswertung für die vorliegende Arbeit bricht die Analyse nach 10km ab, da etwa strategisches Clustering von Händlern über einer Distanz von 10km nicht mehr sinnvoll wäre.

Wegen des in fast allen Datensätzen vorkommenden, sehr kleinen Confidence-Envelopes wurde dieselbe Analyse mit dem Programm „CrimeStat“ kontrolliert (Ned Levine, 2007) und auf die gesamte Erstreckung der Datengrundlage für Lebensmittelhändler ausgeweitet (>500km). Die folgende Grafik zeigt das CrimeStat-Ergebnis.

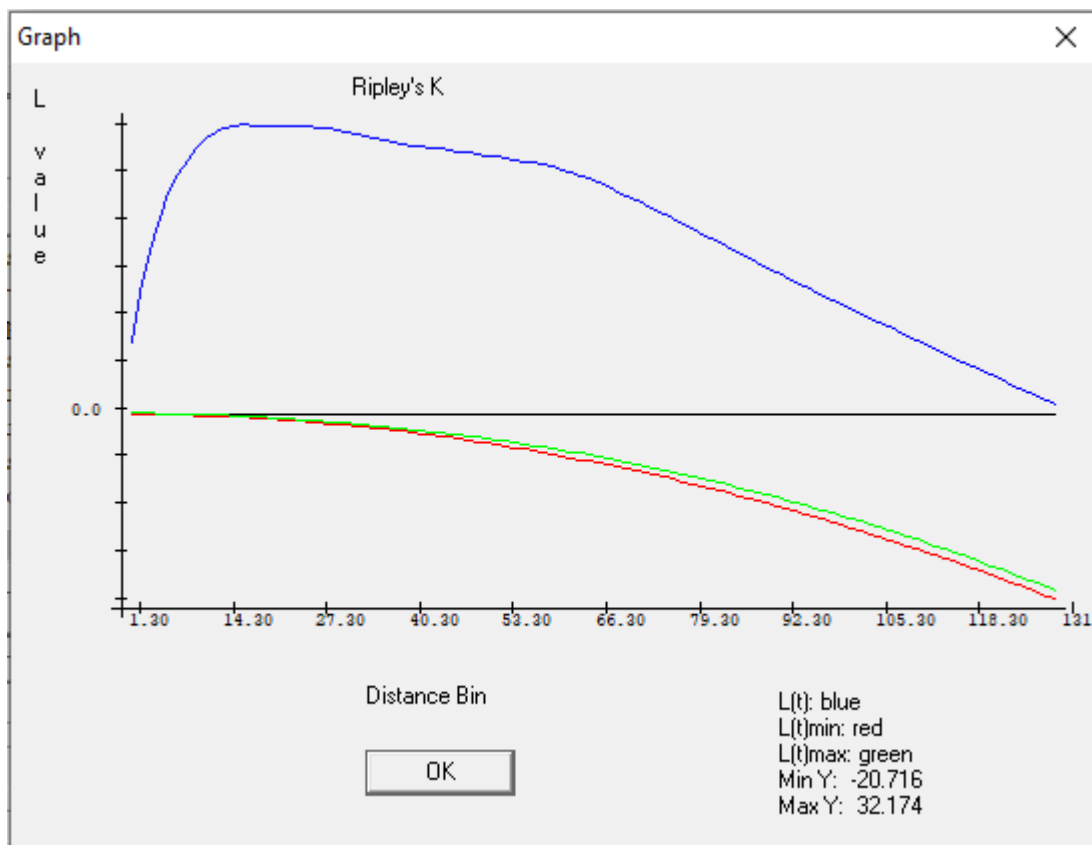


Abbildung 17: Ripley's K-Funktion am Beispiel von Lebensmittelhändlern Visualisierung von CrimeStat-Analyseergebnissen

In der Software wird die Distanz als Nulllinie dargestellt. Der Confidence-Envelope liegt wie schon in der ArcGIS-Auswertung bis 10 km an der Nulllinie. In dieser Auswertung wird auch sichtbar, dass bis zum 14. Kilometer etwa ein enorm starkes Clustering-Verhalten vorliegt, welches dann rapide nachlässt. Die Ergebniswerte im relevanten Raum von 1-10 km deckten sich mit den Ergebnissen aus ArcGIS, was die Validität der Analyse bestätigte.

Wie bereits erwähnt, dient die Ripley's K-Analyse meist zur Identifikation von ökologischen Clustering-Phänomenen und wurde somit bisher noch selten für den Vergleich verschiedener Kategorien verwendet. Für die vorliegende Arbeit hingegen ist ein kategorialer Vergleich der verschiedenen Branchen durchaus sinnvoll, weshalb die Werte in diesem Fall gegenübergestellt werden sollen. Bedingung hierfür ist die Wahl von einheitlichen Distanzinkrementen. Wertet man nun alle Kategorien wie oben beschrieben aus und stellt die Differenzen zu den jeweiligen Erwartungswerten (=die Normalisierung auf die Nulllinie) gegenüber, erhält man eine Übersicht, welche Branchen/Kategorien auf einem

bestimmten Distanzband ein stärkeres bzw. schwächeres Clusteringverhalten zeigen. Die folgende Grafik bildet diese Analyse im Raum von einem bis 10 km ab.




Abbildung 18: Visualisierung der auf die Nulllinie normalisierten $L(d)$ -Werte verschiedener Ripley's K-Analysen

Diese Form der Analyse ermöglicht einen tieferen Einblick in das Clusteringverhalten der Einzelhändler auf verschiedenen Maßstabsebenen.

3.2.2.2 Einschränkungen und Einsatzmöglichkeiten

Natürlich ist auch Ripley's K-Function für die Erhebung von Clusteringmustern von Einzelhändlern nicht omnipotent bzw. auch mit leichten Einschränkungen verbunden. Die Ergebnisse einer Ripley's-K-Analyse werden etwa durch die Anzahl von Punkten je Kategorie beeinflusst. Da jedoch für jedes Distanzband eine zur Punktzahl passende Simulation erstellt wird, die in $L(d)$ resultiert, können die jeweiligen Abweichungen durchaus verglichen werden.

Diese Methode wurde nur für die Auswertungen in ganz Österreich herangezogen, für interzonale Vergleiche eignen sich andere Methoden wie etwa Average-Nearest-Neighbour besser, da in größerem Maßstab keine Vielzahl an Distanzbändern, sondern einzelne Ausschnitte verglichen werden sollen. Die Ergebnisse der Ripley's K-Analysen dieser

Studie, geben einen übersichtlichen, ersten Einblick in das Clusteringverhalten im Einzelhandel allgemein und werden aus diesem Grund im Kapitel Ergebnisse detailliert beschrieben.

3.2.3 Average Nearest Neighbor im Branchen- und zonalen Vergleich

Die Average Nearest Neighbor-Methode ist eine sehr gebräuchliche und oft verwendete Möglichkeit zur Analyse von Punkt-Clusterings und wurde, wie bereits im Kapitel 2 kurz erwähnt, zum Thema Einzelhandels-Agglomeration sehr oft herangezogen. Diese Methode ist deutlich unkomplizierter als die zuletzt vorgestellte Ripley's K-Analyse und soll folgend kurz erklärt werden.

3.2.3.1 Methodenbeschreibung

Schon im Titel der Methode „Mittlerer nächster Nachbar“ wird diese Herangehensweise sehr gut beschrieben. Gemessen wird dabei also der Mittelwert des Abstandes der Punkte untereinander. Im nächsten Schritt werden die Werte mit jenen einer zufälligen Verteilung verglichen. Für den „Mitteldistanz“-Wert einer CSR-Verteilung (Complete Spatial Randomness), wird ähnlich wie bei den Simulationen der Ripley's K-Methode, ein Zufallsmuster nach einem planaren Poisson Punktprozess erstellt, welches folgende Bedingungen erfüllt:

1. „Jeder Ort im Untersuchungsgebiet hat dieselbe Chance auf einen Punkt (Uniformität)
2. Der Standort eines Punktes hat keinen Einfluss auf den Standort eines anderen Punktes (Unabhängigkeit)“ (Boots and Getis, 1988)

Wie ein solches, generiertes Muster aussieht, wird in folgender Grafik im Kontrast zu einem Clustering- und einem gleichverteilten Muster von Boots und Getis illustriert:




Abbildung 19: CSR-Muster im Vergleich zu Clustering- und gleichverteilten Mustern - Quelle: Boots and Getis 1988

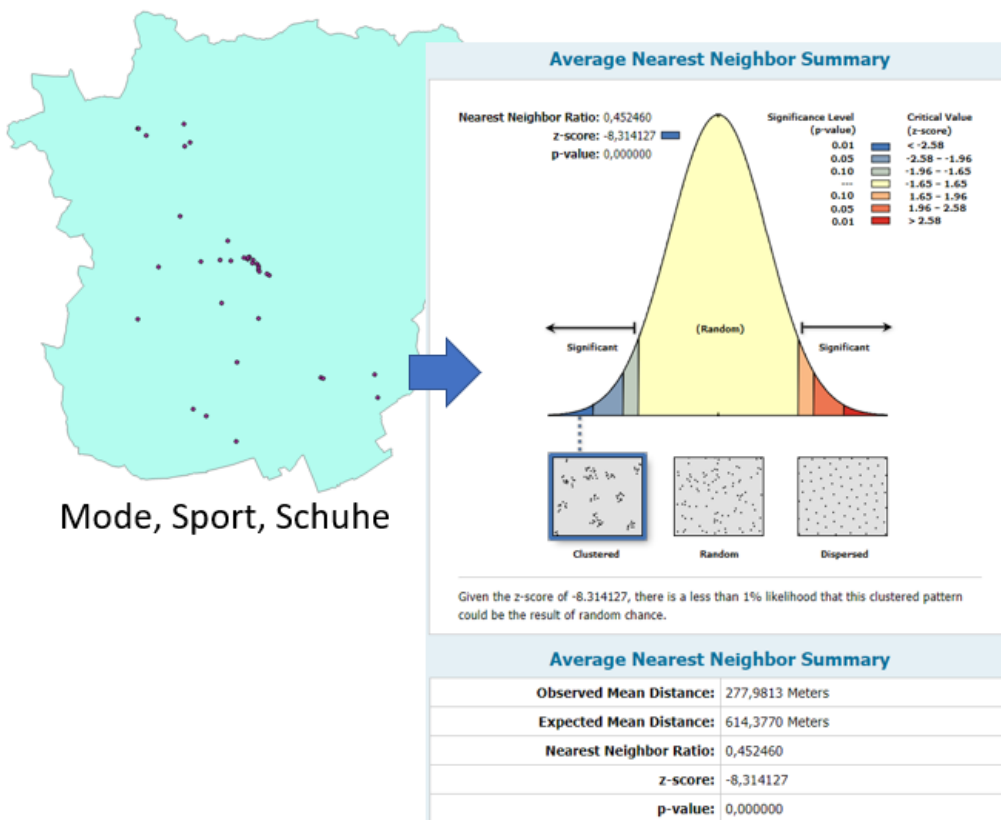
Die Nullhypothese der CSR wird via Z-Transformation (Standardnormalverteilung) getestet. Ein negativer Z-Wert in der Average-Nearest-Neighbor-Analyse deutet dabei auf Clustering hin, ein positives Ergebnis auf Dispersion. (Long, 2015)

Für die Berechnung der ANN wird nun (1) die Distanz der Punkte im Untersuchungsdatensatz zum nächsten Nachbarn (d_i) für jeden Punkt (i) berechnet, im Anschluss (2) die mittlere Distanz erhoben, daraufhin (3) ein Mitteldistanzwert einer CSR-Verteilung erhoben $E(d_i)$ und in der (4) Z-Statistik (Standardisierung) einer Standardnormalverteilung verglichen. (Boots and Getis, 1988)

$(1) \quad \sum_{i=1}^n d_i$	$(2) \quad \bar{d} = \sum_{i=1}^n d_i/n$
$(3) \quad E(d_i) = 0.5 \sqrt{A/N}$	$(4) \quad z = [\bar{d} - E(d_i)] / \sqrt{\text{var}(\bar{d})}$

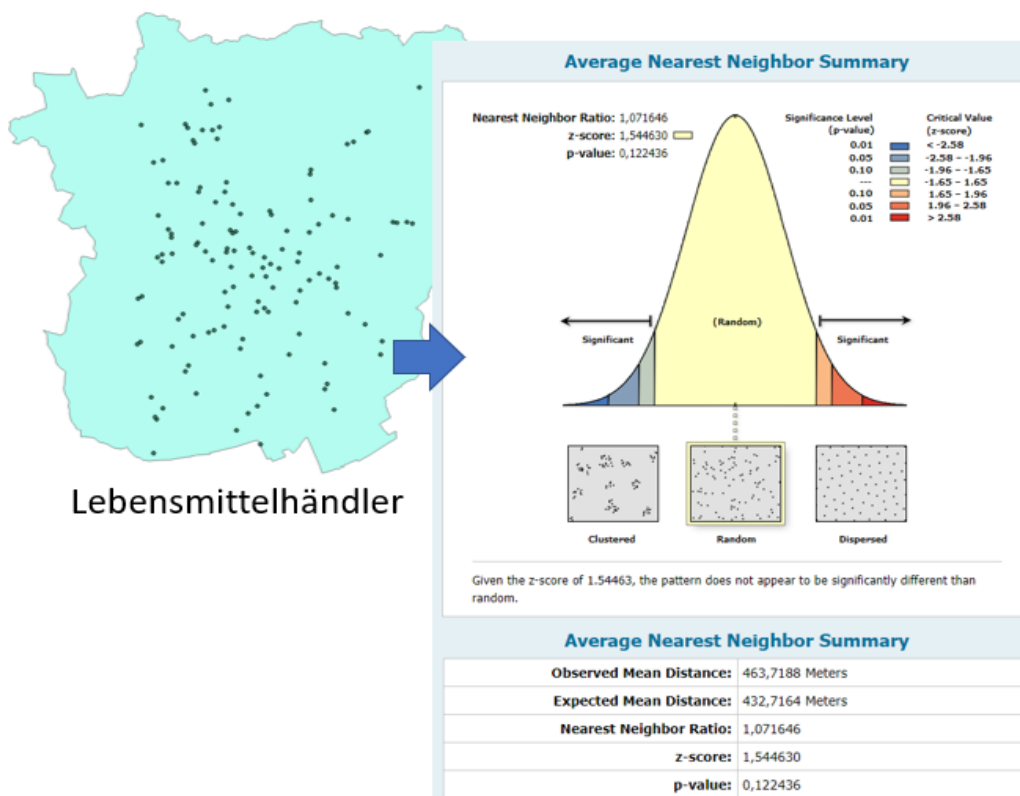
Abbildung 20: Berechnung des Z-Wertes bei einer Average-Nearest-Neighbor-Analyse - Quelle: Boots and Getis, 1988

Das Ergebnis einer solchen Analyse, welche im Programm ArcGIS vollautomatisch berechnet werden kann, wird in Abbildung 21 dargestellt. Für das Beispiel wurde die Kategorie Lebensmittelhändler, sowie Mode-Sport-Schuhe und als zonale Begrenzung Graz herangezogen. Die Fläche (etwa von Graz) dient dabei als wichtiger Faktor für spätere Vergleichbarkeit dieser Analysen. Betrachtet man das Ergebnis der Berechnung aus Graz, sind entsprechend der Ausführungen in diesem Kapitel besonders der p-Value für statistische Signifikanz ($< 0,01$ = Clustering hoch signifikant, $> 0,1$ nicht signifikant bzw. in Richtung einer dispersen Verteilung) und die Höhe/Tiefe des z-Score (je weiter unter 0 desto stärker das Clustering) relevant. Die Darstellung aus ArcGIS bietet eine Übersicht zur Signifikanz und zeigt zusätzlich mit welcher Irrtumswahrscheinlichkeit zu rechnen ist. Da in der vorliegenden Arbeit besonders die interzonale Vergleichbarkeit der Branchen relevant ist, werden die jeweiligen z-Scores im Ergebniskapitel miteinander verglichen. Diese Art der vergleichenden Analyse ist für die Average-Nearest-Neighbor-Methode eher ungewöhnlich und wurde in diesem Kontext bisher selten betrieben. Mit dieser Methode kann sowohl erhoben werden, wie stark verschiedene Branchen innerhalb einer einzelnen (Betrachtungs-)Zonierung, wie etwa einer Gemeinde, clustern und auch wie stark das Clustering im Vergleich zu anderen Zonen ist. Auch bei diesem Ansatz ist jedoch auf die folgend beschriebenen Einschränkungen zu achten.



Mode, Sport, Schuhe

Abbildung 21: Average-Nearest Neighbor-Analyse der Kategorie Mode-Sport-Schuhe in Graz mit der Software ArcGIS



Lebensmittelhändler

Abbildung 22: Average-Nearest Neighbor-Analyse der Kategorie Lebensmittelhändler in Graz mit der Software ArcGIS

3.2.3.2 Einschränkungen und Einsatzmöglichkeiten

Die größte Einschränkung, welche bei jeder Average-Nearest-Neighbor-Erhebung von enorm hoher Relevanz ist, ist ihre starke Anfälligkeit auf Verzerrungen durch die Wahl des Untersuchungsausschnittes. Schon kleine Änderungen in der Wahl des Ausschnittes können große Auswirkungen auf das Ergebnis haben. (Mitchell, 2005) Es ist daher besonders wichtig eine Fläche für die Berechnung zu hinterlegen, denn ist eine solche nicht definiert, wird das kleinste, alle Datenpunkte umfassende Rechteck herangezogen. Dieses Rechteck wird jedoch in Folge wieder stark von der Anzahl und der Verteilung der Punkte beeinflusst. Verwendet man eine fixierte Fläche, ist dieses Problem deutlich minimiert.

Vergleicht man die Ergebnisse interzonal, ist ebenfalls eine kritische Betrachtung der zu vergleichenden Untersuchungsgebiete notwendig. Ungleichmäßige politische Grenzfestlegung und topografische Gegebenheiten der Untersuchungsgebiete sind dabei zu beachten.

Generell ist auch die Anzahl von Punkten innerhalb eines Untersuchungsgebietes ein sehr großer Faktor, weshalb eine Untersuchung auf sehr hohem Maßstab wie Zählsprenkeln in punktschwachen Zonen mit ANN nicht mehr sinnvoll ist.

Diese Methode eignet sich besonders gut für den Branchenvergleich innerhalb einer fix definierten Zone im Maßstabsbereich von Bezirken bis zu Katastralgemeinden. Beachtet man die zuvor genannten Einschränkungen, ist auch der interzonale Vergleich durchaus oft anwendbar. Die ANN-Analyse mit ArcGIS gibt neben den Z-Werten aus dem Vergleich mit einer CSR auch die direkten Mitteldistanzen pro Punktwolke im Betrachtungsgebiet aus, welche ebenfalls als Subkriterien in der Standortanalyse bzw. Standortplanung betrachtet werden könnten, jedoch nur in Kombination mit anderen Faktoren.

3.3 Musteranalyse

In diesem Kapitel sollen zwei sehr spezielle Ansätze vorgestellt werden, welche es ermöglichen, die Verteilungen von Einzelhändlern zu aggregieren und vergleichbar zu machen, um interzonale Muster zu identifizieren.

3.3.1 Service Areas

Service Areas sollten in der vorliegenden Arbeit herangezogen werden, um einseitige Abhängigkeitsmuster einzelner Branchen bzw. Kategorien auf verschiedenen Maßstabsebenen zu identifizieren. Zusätzlich dienen diese zur Abbildung von Branchenzusammensetzung innerhalb bestimmter Gebiete (Kapitel [3.3.4](#)). Aus welchem Grund diese Herangehensweise jedoch im Fall der Abbildung von Abhängigkeitsbeziehungen nur für einen groben Überblick geeignet ist, soll nach einer Methodenbeschreibung folgen.

3.3.1.1 Methodenbeschreibung

Die Service-Area-Analyse ist eine Berechnung auf der Grundlage eines Verkehrsnetzes, welche in groben Zügen der Berechnung eines Buffers mit GIS-Systemen ähnelt. Als Grundlage der Berechnung in der vorliegenden Arbeit wurde das Verkehrsnetz der „Katalog Intermodales Verkehrsreferenzsystem Österreich“ von Geoland.at in ein GIS-System eingespeist. (Geoland.at, 2008)

Auf der Grundlage des Verkehrssystems wird für eine Service Area in Folge die zurückgelegte Distanz, beispielsweise Gehminuten oder auch Fahrzeit, von einem gewissen Punkt in alle Richtungen berechnet. Die Berechnung wird isotropisch (alle Richtungen) auf einer Fläche mit Linien gleicher Gehdistanz (Isochrone) abgebildet. (O'Neill *et al.*, 1992) Diese komplexe Berechnung kann nur innerhalb eines GIS-Systems sinnvoll berechnet werden, weshalb an dieser Stelle keine Formel zur Berechnung angeführt wird. In der folgenden Abbildung 23 wird jedoch leicht erkennbar, wieso die Distanz und die somit entstehende Fläche auf Basis einer Gehdistanz, stark von jener einer euklidischen Distanz (quasi der Luftlinie), abweicht.

Für die Analysen mit Service-Areas in der vorliegenden Arbeit wurde als Grundlage für die Distanzberechnungen von den einzelnen Punkten aus, eine einzelne „Gehminute“ gewählt. Die entstehende Fläche ist ein sehr kleines Polygon, welches um die einzelnen Punkte gebildet wurde. In weiterer Folge ist es möglich Berechnungen mit diesem entstandenen Einzugsbereich durchzuführen. Eine Darstellung der erstellten Flächen am

Beispiel von Lebensmittelhändlern in und um Salzburg wird in Abbildung 24 gezeigt. Flächen rund um die Lebensmittelhändler stellen dabei die Service-Areas dar.




Abbildung 23: Netzwerk-Distanz gegen eine gerade Linie - Quelle: O'Neill et al.

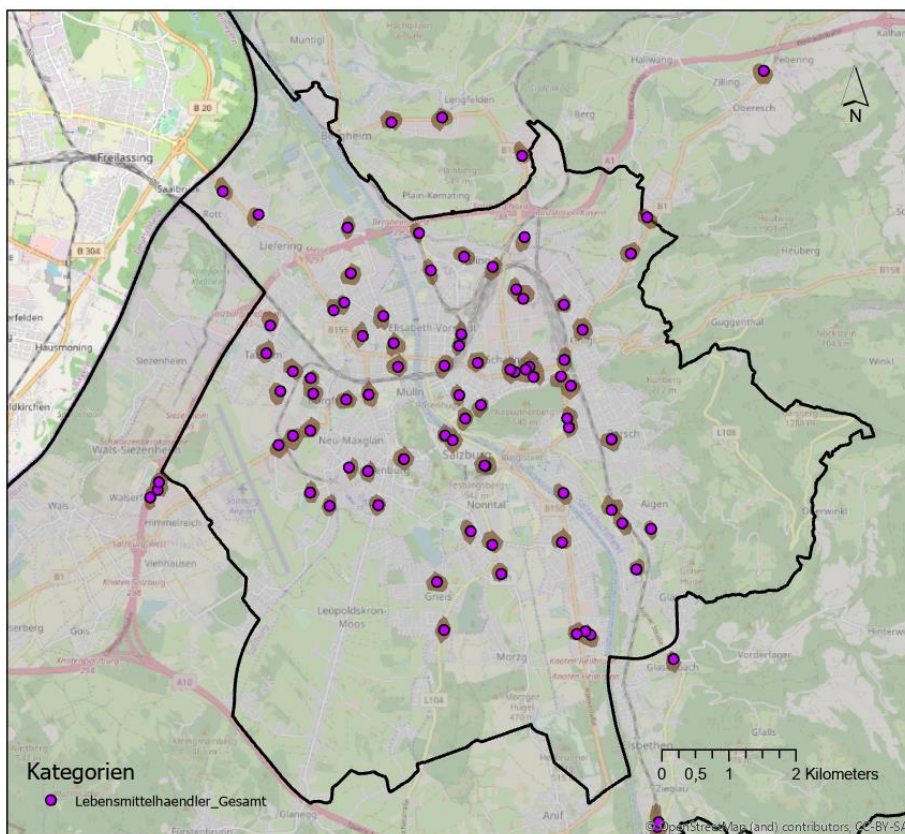


Abbildung 24: Isochrone Flächen einer Minute "Gehzeit" rund um Lebensmittelhändler

3.3.1.2 Einschränkungen und Einsatzmöglichkeiten

Zweck der erstellten Service Areas, bzw. „Einzugsgebiete einer Gehminute“ um die Punkte der jeweiligen Kategorien soll es sein, die Häufigkeit der Filialen anderer Händler innerhalb dieser kleinen Flächen zu berechnen, um mögliche einseitige Abhängigkeiten und Verteilungsmuster zu identifizieren. Die Resultate geben somit einen groben Überblick über Abhängigkeitsbeziehungen einzelner Kategorien. Wichtig ist es hierbei jedoch zu bedenken, dass die unterschiedlichen Kategorien stark abweichende Grundgesamtheiten abbilden. So hat die Kategorie „Lebensmittelhändler“ 4.331 Datenpunkte, die Kategorie „Möbelhändler“ hingegen nur 258. Durch diese erheblichen Unterschiede sind die Abhängigkeiten mit dieser Methode nicht sinnvoll prüfbar. Durch die reine Anzahl an Lebensmittelhändlern ist es deutlich wahrscheinlicher diese Kategorie innerhalb von Clustern zu finden, als Vertreter anderer Kategorien.

Trotz der genannten, verzerrenden Einschränkung kann diese Analyse als eine erste Übersicht über die Datenlandschaft herangezogen werden, etwa wie viele Händler sich in den Clustern befinden und wie kleinräumig diese sind. Im Kapitel zu den Ergebnissen wird gezeigt, wie viele Händler anderer Kategorien in den 1-Minute-Service-Areas der Lebensmittelhändler liegen. Für eine sinnvolle Analyse der einseitigen Abhängigkeiten von direkten Nachbarn der Händler, ist jedoch eine andere Form der Analyse notwendig. Eine Möglichkeit hierfür wird im folgenden Kapitel vorgestellt und stellt eine Nearest-Neighbor-Erhebung in Kombination mit einem Chi-Quadrat-Test dar.

3.3.2 Nearest Neighbor in Kombination mit Chi-Quadrat-Tests zur Analyse einseitiger bzw. zweiseitiger Branchenabhängigkeit

Diese Art der Erhebung stellt eine neue Methode dar und konnte in dieser Form nicht in der bisherigen Literatur zum Thema gefunden werden. Ziel der Erhebung ist es, einseitige Branchenabhängigkeit zu identifizieren und unregelmäßig häufige (oder seltene) Kombinationen aufzudecken. Als Grundlage wird die mengenmäßige Verteilung aller Händler in Österreich herangezogen.

3.3.2.1 Methodenbeschreibung

Um diese Berechnung zu ermöglichen, muss zuerst in ArcGIS ein sogenannter „Near-Table“ erstellt werden. Das Ergebnis dieser ArcGIS-Methode ist eine Tabelle, welche alle Punkte der betrachteten Kategorie heranzieht und in Folge deren unmittelbar nächsten Nachbarn ausgibt. Das Ergebnis der Erhebung müsste sich, bei einer gleichmäßigen Verteilung aller Händler, mit der allgemeinen Verteilung der Händler in ganz Österreich decken. Da dies jedoch sehr unwahrscheinlich ist, kann festgestellt werden, wie oft ein bestimmter Händler der nächste Nachbar einer Betrachtungskategorie ist und wie stark dieser von der „allgemeinen Verteilung“ abweicht. Die allgemeine Verteilung über ganz Österreich ist in folgender Excel-Pivot-Tabelle abzulesen.

VERTEILUNG GESAMT		
Zeilenbeschriftungen <input type="checkbox"/>	Anzahl	Prozentuell
Baumaerkte	683	6,72%
Elektromaerkte	881	8,66%
Kosmetik	1171	11,51%
Lebensmittelhaendler	4331	42,58%
Moebelhaeuser	258	2,54%
MSS	2200	21,63%
Sonstige	647	6,36%
Gesamtergebnis	10171	100,00%

Abbildung 25: Verteilung der Kategorien in ganz Österreich

Wertet man nun in Folge den besprochenen Near-Table etwa für die Kategorie Lebensmittelhändler aus, sind 4.331 nächste Nachbarn zu den eigentlichen Datenpunkten zu finden, die folgende Abbildung 26 zeigt das Ergebnis. Nun ist es das Ziel, diese Werte miteinander zu vergleichen, um eine Abweichung vom Erwartungswert, also der in Abb. 25 gezeigten Verteilung, abzubilden. Hierfür eignet sich der Chi-Quadrat-Test sehr gut, welcher untersucht, wie gut eine beobachtete Verteilung zur Erwartung passt.

NN Lebensmittelhändler		
Zeilenbeschriftungen	Anzahl von Kategorie	Prozentuell an Gesamt
Baumaerkte	399	9,21%
Elektromaerkte	332	7,67%
Kosmetik	543	12,54%
Lebensmittelhaendler	1947	44,95%
Moebelhaeuser	71	1,64%
MSS	727	16,79%
Sonstige	312	7,20%
Gesamtergebnis	4331	100,00%

Abbildung 26: Verteilung der "Nächsten Nachbarn" zu Lebensmittelhändlern

Die Form des Chi-Quadrat-Tests, welcher in dieser Untersuchung Anwendung findet, nennt sich „Chi-Quadrat-Anpassungstest“ und wird verwendet, um zu prüfen, ob sich eine beobachtete Verteilung einer kategorialen Variablen von einer theoretischen Verteilung unterscheidet. (Schwarz, 2018)

Diese Berechnung wird mit folgender Formel durchgeführt (df = Freiheitsgrade):

$$\chi^2 = \sum_{j=1}^k \frac{(h_{bj} - h_{ej})^2}{h_{ej}}$$

$$df = k - 1$$

mit

k = Anzahl zu vergleichende Kategorien

h_{bj} = beobachtete absolute Häufigkeit der Kategorie j

h_{ej} = erwartete absolute Häufigkeit der Kategorie j

Abbildung 27: Berechnung des Chi-Quadrat Anpassungstests - Quelle: Schwarz 2018

Da es im gegebenen Datensatz jeweils insgesamt 7 Kategorien (df = Kategorieanzahl-1) gibt, werden insgesamt 6 Freiheitsgrade geschrieben. Nach erster Einsicht in die Daten wurde zum Vergleich für die Signifikanz der Teststatistik 1% herangezogen. Liegt der berechnete P-Wert nun unter 1% (=0,01), kann das Ergebnis als signifikant betrachtet werden – die Nullhypothese (erwartete Häufigkeiten stimmen mit Ergebnissen annähernd überein) wird verworfen. Nähere Infos zur Methode, unter anderem wie der P-Wert berechnet werden kann, sind in den Unterlagen von Schwarz 2008 zu finden.

Die Abweichungen vom Erwartungswert pro Kategorie sind neben dem Chi-Quadrat-Wert (welcher für die Ermittlung der Signifikanz benötigt wird) auch prozentuell abbildbar, weshalb auch diese Darstellung in den Ergebnissen Anwendung findet. Eine beispielhafte Auswertung über die Verteilungen ist in folgender Abbildung zu sehen.

Häufigkeiten Lebensmittelhändler				
	erwartet	beobachtet	Abweichung %	Chi2
Anzahl LH	4331			
Baumarkt	291	399	27,06%	40,0
Elektromarkt	375	332	-12,97%	4,9
Kosmetik	498	543	8,20%	4,0
Lebensmittel	1844	1947	5,28%	5,7
Möbel	110	71	-54,94%	13,8
Mss	937	727	-28,86%	47,0
sonstige	275	312	11,71%	4,8
				120,4
				p-Wert
				1,37E-23

Abbildung 28: Abweichung von Erwartungswerten in der Kategorie Lebensmittelhändler inkl. Chi-Quadrat-Anpassungstest

Die Erwartungswerte ergeben sich in diesem Fall aus der Multiplikation der in Abbildung 25 gezeigten, prozentuellen Verteilung je Kategorie mit der Gesamtzahl der fokalen Kategorie (z.B. für Baumärkte $4.331 \cdot 6,72/100 = 291$).

3.3.2.2 Einschränkungen und Einsatzmöglichkeiten

Die wohl größte Einschränkung dieser Möglichkeit ist, dass bei der Analyse der Datenpunkte via Near-Table nur der unmittelbar nächste Nachbar herangezogen wird. Der zweitfolgende Nachbar des Punktes wird bereits nicht mehr in die Analyse miteinbezogen. Natürlich ist in einer Clusteranalyse auch jeder weitere Nachbar von großem Interesse, jedoch bilden auch direkte Paarbeziehungen bereits deutliche Muster zwischen den Kategorien ab.

Die Analyse gibt einen guten Einblick darüber, wie sich die Händlerpaare zueinander verteilen. Trotz der erwähnten Einschränkung sind die Ergebnisse somit durchaus relevant und können, besonders in Kombination mit den Ergebnissen anderer Methoden, wichtige Informationen zur Agglomeration liefern.

3.3.3 Branchenmix

Auch die Branchenmix-Analyse stellt in der folgend vorgestellten Form einen neuen Ansatz dar, versucht dabei im Gegensatz zur zuvor vorgestellten Chi-Quadrat-Erhebung in Kombination mit Nearest Neighbor jedoch, die Muster ganzheitlich abzubilden und bezieht sich dabei nicht nur auf den jeweiligen nächsten Nachbarn. Im Grunde genommen ist die Branchenmix-Übersicht eine statistische Darstellung der Verteilung der gewählten Branchen über verschiedene Zonen. Durch einen interzonalen Vergleich werden Muster und Tendenzen einzelner Branchen sichtbar. Um diese Analyse durchzuführen ist es im ersten Schritt nötig, Verteilungsstatistiken mit ArcGIS über das Tool „Summarize Within“ einzuholen.

3.3.3.1 Methodenbeschreibung

Das Geoprocessing-Werkzeug „Summarize Within“ hat die simple Funktion alle Punkte innerhalb gewisser Grenzen auszuwerten und (bei Bedarf nach Kategorie) zusammenzufassen. Die zuerst rein auf ID's basierende Auswertung muss in Folge über diverse S-Verweise innerhalb von Microsoft Excel mit verschiedenen Grunddaten wie den Bezirks-/Gemeinde-/Sprenzel-Namen, Einwohnerzahlen uvm. verbunden werden. Als Datengrundlage für Einwohnerzahlen wurden im Fall der vorliegenden Arbeit die Datenbestände von Statistik Austria mit Datenstand 01.01.2018 für Bezirke und 01.01.2019 für Gemeinden, sowie Zählsprengel herangezogen. (STATISTIK AUSTRIA, 2019)

Wurden die Daten entsprechend verbunden und angereichert, war es möglich über eine Pivot-Tabelle Summen auszuwerten, welche eine Übersicht über alle Kategorien geben. Eine Auswertung, rein sortiert nach der Anzahl an Punkten je Zone auf Betrachtungsniveau der Gemeinden, wird in Abbildung 29 in einem Balkendiagramm dargestellt und bildet die Datengrundlage zur Auswertung in Abbildung 30. Um die Interpretation zu erleichtern, wurde die Farbpalette analog zu den vorherigen Auswertungen angepasst.

In Folge sollten die entstandenen Statistiken mit einem sinnvollen Sortierungskriterium erweitert werden, um diese interzonal besser vergleichbar zu machen. Beispiele hierfür sind die erwähnte Einwohnerzahl, die Fläche (etwa in km²) der jeweiligen Zonen aus ArcGIS, oder auch einer Kombination der beiden, der Einwohnerdichte pro km². Neben Sortierungskriterien ist es auch möglich, die Auswertung um einen Wert zu erweitern, welcher Einsicht über die Abweichungen innerhalb einer Kategorie über verschiedene

Zonen der Analyse gibt. Sehr gut eignet sich hierbei der Variationskoeffizient, welcher aus dem Quotienten aus Standardabweichung und Mittelwert gebildet wird.

	Baumaerkte	Elektromaerkte	Kosmetik	Lebensmittelhaendler	Moebelhaeuser	MSS	Sonstige
Graz 292	6	14	42	127	10	63	30
Linz 193	3	19	31	86	5	35	14
Salzburg 170	3	13	27	74	4	38	11
Klagenfurt am Wörthersee 158	7	8	21	55	6	45	16
Innsbruck 150	4	7	18	66	4	42	9
Wien-Donaustadt 146	6	10	21	68	7	25	9
Wien-Floridsdorf 146	1	9	25	66	3	26	16
Wien-Favoriten 139	1	8	27	67	3	25	8
St. Pölten 113	3	7	15	36	8	30	14
Villach 103	4	5	10	39	5	26	14
Wels 94	4	7	11	28	6	28	10
Wien-Landstraße 94	2	7	22	41	3	15	4
Wien-Penzing 93	2	6	16	37	2	21	9
Wiener Neustadt 92	2	5	15	20	6	32	12
Wien-Simmering 88	1	7	15	33	2	18	12
Wien-Leopoldstadt 87		9	15	48	1	11	3
Wien-Liesing 80	2	5	16	38	1	14	4
Wien-Rudolfsheim-Fünfhaus 78		7	16	31	2	17	5
Krems an der Donau 68	2	7	9	17	4	22	7
Wien-Brigittenau 68	1	5	13	27		17	5

Abbildung 29: Datengrundlage für eine Branchenmix-Analyse ohne erweiterte Sortierungskriterien (Gemeindename | Punkt-Gesamtanzahl je Kategorie)




Abbildung 30: Top 20-Auswertung der Verteilung von Einzelhändlern in Form eines gestapelten Balkendiagramms mit Absolutwerten

Zusätzlich zur Auswertung in Absolutwerten ist es auch möglich, die Werte prozentuell auszugeben, um damit die interzonale Vergleichbarkeit noch weiter zu verbessern, dies

wird im Ergebniskapitel bzw. auch im Anhang dargestellt. Abbildung 31 zeigt nun den Branchenmix der Top 20 Gemeinden in Österreich nach Bevölkerungszahl inklusive des Variationskoeffizienten neben der jeweiligen Kategorienbeschriftung in der Legende.




Abbildung 31: Branchenmix der Top 20 Gemeinden nach Bevölkerungszahl

3.3.3.2 Einschränkungen und Einsatzmöglichkeiten

In der gezeigten Abbildung 31 wird bereits deutlich, dass der Branchenmix die Möglichkeit bietet interzonale Muster zu erkennen, da Ähnlichkeiten in den Verteilungen festzustellen sind. Je nach Sortierungskriterium und Betrachtungsniveau können unterschiedliche Zusammensetzungen beobachtet werden, die jedoch meist einem gewissen Schema folgen. Trotzdem ist auch diese Form der Agglomerationsanalyse nicht vollständig einschränkungsfrei über alle Maßstäbe und Datengrundlagen nutzbar, so muss man sich beispielsweise für interpretierbare Ergebnisse stets für einzelne Sortierungskriterien entscheiden. Da die Branchenmix-Analyse jedoch eine relativ simple Herangehensweise darstellt, welche lediglich Summen bildet und im Anschluss nach bestimmten Kriterien sortiert und vergleicht, ist sie nicht so enorm anfällig auf die Wahl der Zonierungen, wie

die zuvor vorgestellten, auf Nähe basierten Auswertungen. Die Methode eignet sich sehr gut für den Vergleich über verschiedene Zonen und Kategorien.

3.3.4 Branchenmix auf Basis von Service-Areas „Local Cluster“

Da politische Zonierungen oft wie erwähnt willkürliche Züge annehmen bzw. durch topografische oder eben politische Umstände geformt sind, können die Branchenzusammensetzungen mit Service-Areas, welche vollautomatisch erstellt werden, ebenfalls ein wirtschaftlich relevantes Bild ergeben, da diese auf Infrastruktur beruhen. Diese Form der Analyse sollte als Erweiterung zu den bisherigen Ansätzen fungieren.

3.3.4.1 Methodenbeschreibung

Um die Verteilung zu erheben, müssen die Daten innerhalb der Einzugsgebiete, wie im Kapitel [3.3.3](#) zum Thema Branchenmix bereits erklärt, via Summarize Within und der Pivot-Funktion aus Microsoft Excel zusammengefasst werden. Um den Informationsgehalt zu erhöhen, muss in der Erhebung jeweils ein Punkt der fokalen Kategorie im Einzugsgebiet abgezogen werden, welcher für die Bildung des jeweiligen Einzugsgebiets verantwortlich ist.

3.3.4.2 Einschränkungen und Einsatzmöglichkeiten

In Hinsicht auf Branchenzusammensetzung innerhalb der gebildeten Zonen, kommt die zuvor genannte Einschränkung von Service-Areas für Abhängigkeiten, welche durch Punktzahl der einzelnen Kategorien verursacht wurde, nicht zu tragen, da keine direkten Beziehungsmuster, sondern Verteilungen gezeigt werden sollen. Trotzdem ist zu beachten, dass die gebildeten Flächen sehr unregelmäßig sind und auf Straßendaten basieren, wodurch die Ergebnisse der Erhebung maßgeblich geprägt werden.

Sowohl die Ergebnisse des Branchenmix auf Basis von politischen Zonierungen, als auch jene auf Basis von Service-Areas können in der Praxis mit firmenspezifischen Einzugsgebieten durchgeführt und in Folge mit Umsatzdaten angereichert werden, wodurch „erfolgreiche Zusammensetzungen“ sichtbar und interzonal vergleichbar gemacht werden könnten.

3.4 MAUP – Eine allgemeine Einschränkung in der Agglomerationsanalyse

Werden Zonierungseinheiten nicht automatisiert erstellt, sondern durch politische Umstände oder andere Maßnahmen gesetzt, können Ergebnisse stark verzerrt werden, weshalb für einige der zuvor vorgestellten Analysen das „MAUP“- modifiable areal unit problem, also das Problem der veränderbaren Gebietseinheit stets zu beachten ist.

Das „modifiable areal unit problem“ sollte als Einschränkung der Agglomerationsanalyse und auch vieler anderer GIS-Unterstützter Erhebungen betrachtet werden. Es beschreibt die mögliche Anfälligkeit von kartografischen Analysen gegenüber der Definition der untersuchten Raumeinheiten, welche zu starken Verzerrungen und Fehlinterpretationen führen kann. Das Problem manifestiert sich dabei auf zwei Arten: Maßstab bzw. Betrachtungsebene (verschachtelte Grenzsetzungen – Bundesländer, Bezirke, Gemeinden etc.) und die Art der Gliederung pro Ebene bzw. Niveau.

Eine Auswertung auf Betrachtungsniveau A kann demnach stark konträr zur Auswertung auf Betrachtungsniveau B sein, was unter anderem auf die unterschiedliche Aggregation von Werten zurückzuführen ist. Die räumliche Betrachtungsebene wirkt wie ein Filter bei der Betrachtung von Phänomenen, was in der folgenden Darstellung auf verschiedenen NUTS-Ebenen sichtbar wird. Dieses Phänomen wird Maßstabseffekt genannt.

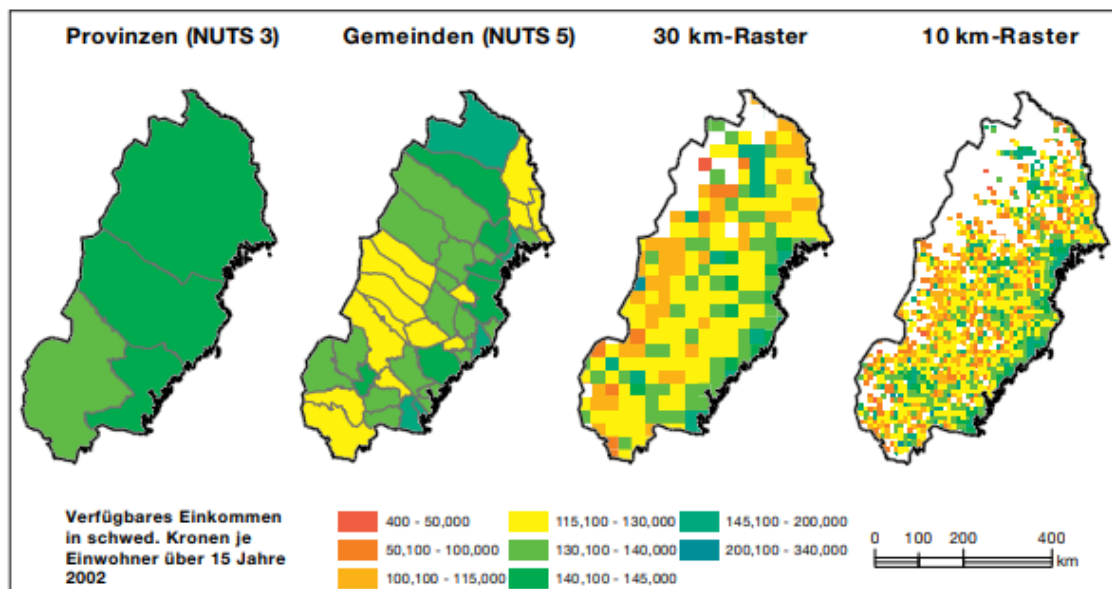


Abbildung 32: Einfluss der Maßstabs-Zonierung auf die Wahrnehmung eines Phänomens (empirisches Beispiel)

- Quelle: Madelin et al., 2009

Neben dem Betrachtungsniveau ist auch die Wahl der Zonierung stark ausschlaggebend für das Ergebnis, welches in Abbildung 33 anschaulich abgebildet wird. Eine minimale Verschiebung führt zu einer völlig anderen Auswertung und wird „Zonierungseffekt“ genannt. Trotz dieser Effekte ist das MAUP nicht ausschließlich als Problem zu betrachten, da Unterschiede in Analysen auf verschiedenen Maßstäben auch zu neuen Erkenntnissen im Zusammenhang mit dem Phänomen führen können.

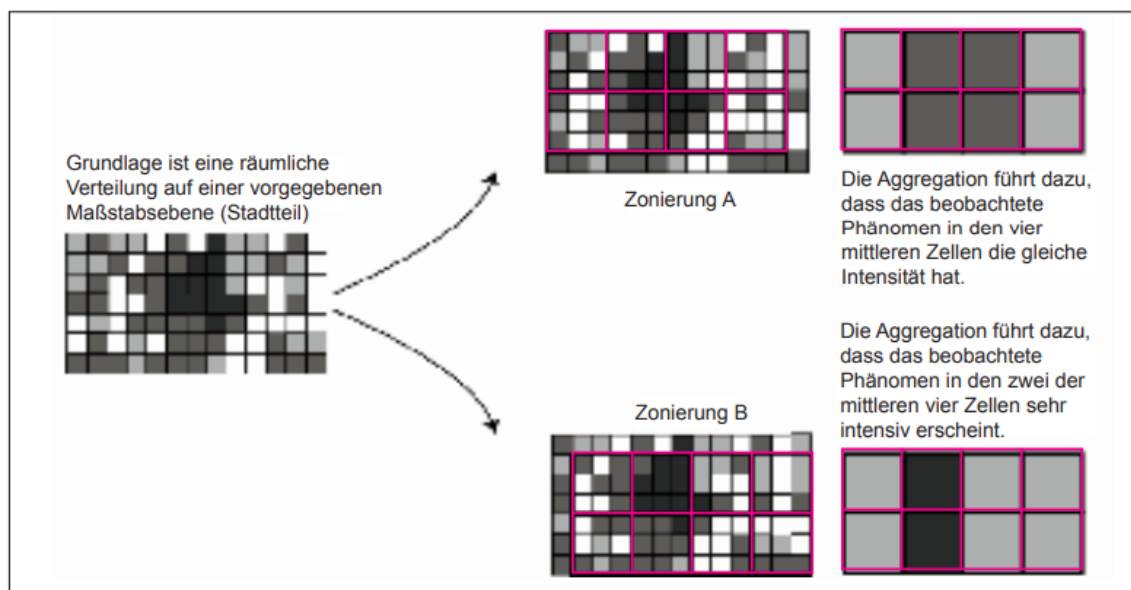


Abbildung 33: Einfluss der Zonierung auf die Wahrnehmung eines Phänomens (theoretisches Beispiel) - Quelle: Madelin et al., 2009

Das Hauptproblem besteht bei MAUP darin, dass es keine einzelne „wahre Kartendarstellung“ gibt. Karten auf unterschiedlichen Niveaus und Zonierungen widersprechen sich nicht, sie ergänzen sich. (Madelin *et al.*, 2009) Das MAUP ist folglich stets im Hinterkopf zu behalten, teilweise um mögliche Auffälligkeiten in Ergebnissen zu erklären und auch um Fehler bei Interpretationen zu vermeiden. Durch MAUP werden die Ergebnisse zwar „verzerrt“ aber nicht „verfälscht“.

Im Fall der vorliegenden Forschung kommt das MAUP besonders bei Average-Nearest-Neighbor-Analysen zu tragen, da hier teilweise frei definierte Zonierungen hergestellt wurden (etwa Zählsprengel entlang berühmter Einkaufsstraßen als Ausgangsbasis für Analysen), die jedoch im Kategorienvergleich innerhalb der definierten Zonierung wieder an Relevanz gewinnen. Bei der nicht verwendeten Pointcloud-Centers-Analyse käme das MAUP am stärksten zu tragen, da die Zonierungsform eine der Hauptkriterien dargestellt hätte.

Die zuletzt vorgestellte Branchenmix-Analyse kann ebenfalls durch das MAUP beeinflusst werden, jedoch wurden hierbei im Gegensatz zum MAUP bei den erstellten ANN-Analysen keine frei definierten Zonierungen herangezogen, sondern ausschließlich strikt getrennte, politische Grenzsetzungen. Die unterschiedlichen Niveaus von Zonierungen (Gemeinden, Katastralgemeinden, Sprengel etc.) sorgen durchaus für starke Abweichungen in den Resultaten, jedoch sind diese auch als Teile der Ergebnisse pro Zone erwünscht.

Bei der Ripley's K-Analyse im Branchenvergleich kommt das MAUP kaum bzw. nicht zu tragen, da diese in der vorliegenden Arbeit nur auf ganz Österreich für einen Gesamtüberblick herangezogen wurde. Wäre die Analyse jedoch auch auf kleineren Niveaus für interzonale Vergleiche herangezogen worden, müsste das MAUP beachtet werden.

Die Service-Areas-Analyse und die Nearest-Neighbor in Kombination mit Chi-Quadrat-Analyse bleiben durch das MAUP fast unbeeinflusst.

3.5 Möglichkeit der Methodenkombination

Während alle beschriebenen Methoden teilweise stärkere, teilweise schwächere Einschränkungen aufweisen, kann durch ihre Kombination auf verschiedenen Ebenen ein komplexes Phänomen wie Agglomeration besser beschrieben werden. So soll die Ripley's K-Analyse eine allgemeine Übersicht über das Clusteringverhalten (über verschiedene Distanzbänder) der einzelnen Kategorien geben, welche mit den Service-Area-Erhebungen kombiniert werden kann, um einen Überblick über die Forschungslandschaft und die einzelnen Kategorien bzw. erste Hinweise zu deren Beziehung zu gewinnen. Die Beziehungsmuster der Kategorien werden in weiterer Folge mit Nearest Neighbor in Kombination mit Chi-Quadrat ermittelt und bilden so zusammen mit den Intensitätserhebungen eine Branchenübersicht der Agglomeration für Österreich.

Betrachtet man in weiterer Folge kleinere Ausschnitte wie Bezirke, Gemeinden oder Sprengel, kommt die ANN-Analyse im interzonalen Vergleich zu tragen, welche kleinräumige Vergleiche von Clusteringintensitäten erlaubt. Diese Ergebnisse können dann nachfolgend mit dem Branchenmix kombiniert werden um Agglomerationsmuster noch besser erklären zu können. Die entstandenen Ergebnisse formen ein vielschichtiges Bild der Agglomerationsmuster, welches bei richtiger Interpretation neue Erkenntnisse und Anregungen für die Standortanalyse und Standortsuche bieten kann. Die Ergebnisse werden mit den entsprechenden Illustrationen in den folgenden Kapiteln dargestellt.

4. Ergebnisse

Der folgende vierte Abschnitt der Arbeit teilt die Ergebnisse in zwei Kapitel: „Österreichweite Agglomerationsmuster der einzelnen Branchen“ und „Interzonale Vergleiche“. In den jeweiligen Kapiteln finden sich Unterkapitel, in welchen die zuvor beschriebenen Methoden angewandt werden.

4.1 Österreichweite Agglomerationsmuster der einzelnen Branchen

Wie zuvor bereits erwähnt, werden die unterschiedlichen Methoden für die Beleuchtung verschiedener Aspekte der Agglomeration bzw. auf verschiedenen Betrachtungsniveaus angewandt. Für einen Gesamtüberblick werden zuerst die Ergebnisse der Erhebung via Ripley’s K-Analyse innerhalb einzelner Branchen (z.B. LH zu LH) vorgestellt.

4.1.1 Österreichweite Clusteringintensität der verschiedenen Branchen

Die Analyse wurde wie im Kapitel 3.2.2 erwähnt, auf die Maximaldistanz von 10km eingestellt, da Clusteringstrategien in einem höheren Radius kaum vorstellbar sind. Das bedeutet, dass der L(d)-Wert, also die Clusteringintensität bis zu einer Distanz von 10.000m erhoben wird. Wobei diese Distanzkreise für alle Punkte in der Datengrundlage berechnet werden, wodurch die Erhebung ein österreichweites Ergebnis abbildet. Die folgenden Analyseergebnisse wirken auf den ersten Blick zueinander ähnlich, vergleicht man die Werte der einzelnen Kategorien jedoch auf einem einzelnen Graphen, werden die Unterschiede im Clusteringverhalten schnell sichtbar.

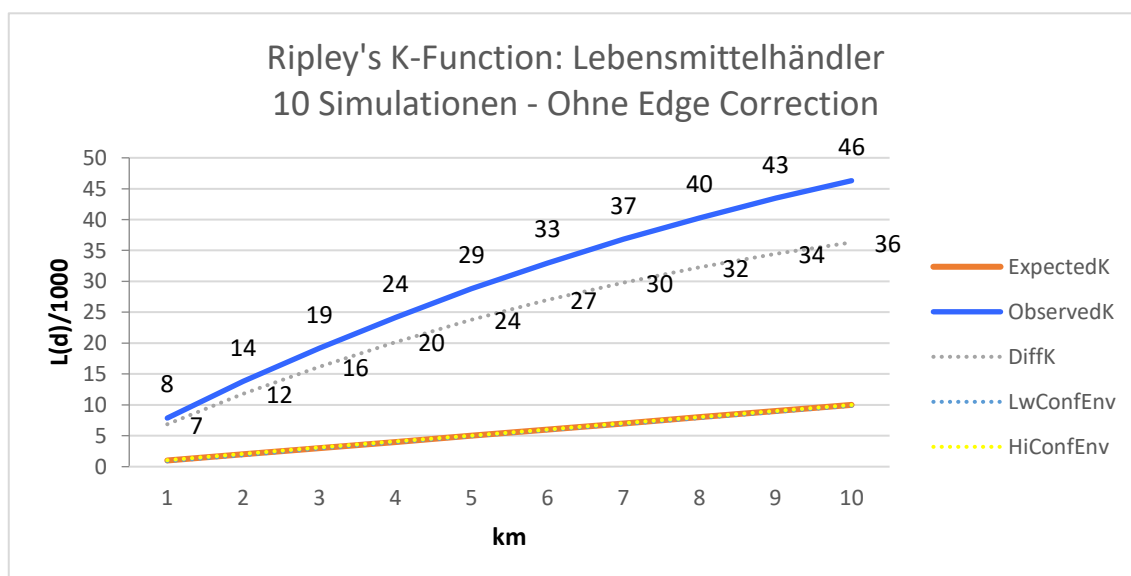


Abbildung 34: Ripley’s K-Function am Beispiel von Lebensmittelhändlern Visualisierung von ArcGIS-Analyseergebnissen in MS Excel

Der in Abbildung 34 gezeigte Graph bildet das Clusteringverhalten von Lebensmittelhändlern in Distanzbändern ab und zeigt, dass diese auf jedem Niveau stark über den Erwartungen clustern. Je größer der Betrachtungslevel, bzw. Distanzkreis, desto stärker ist bei Lebensmittelhändlern ein Clustering weit über den Erwartungswerten zu identifizieren. Diese, ebenso wie die folgenden Ergebnisdarstellungen (Analyseeinstellungen auf „10 Simulationen“ sowie „ohne Edge-Correction“ wurde weiterhin beibehalten) zeigen, dass Einzelhändler in Österreich allgemein sehr stark clustern. Die Maße wurden um den Faktor 1000 (sowohl $L(d)$ als auch m) dividiert, um km abzubilden, wobei die Abweichungen unbeeinflusst abgebildet werden können.

Ein sehr ähnliches Bild zeigt sich am Graphen der Erhebung von Kosmetikern, also Drogerien und Parfümerien in Abbildung 35.

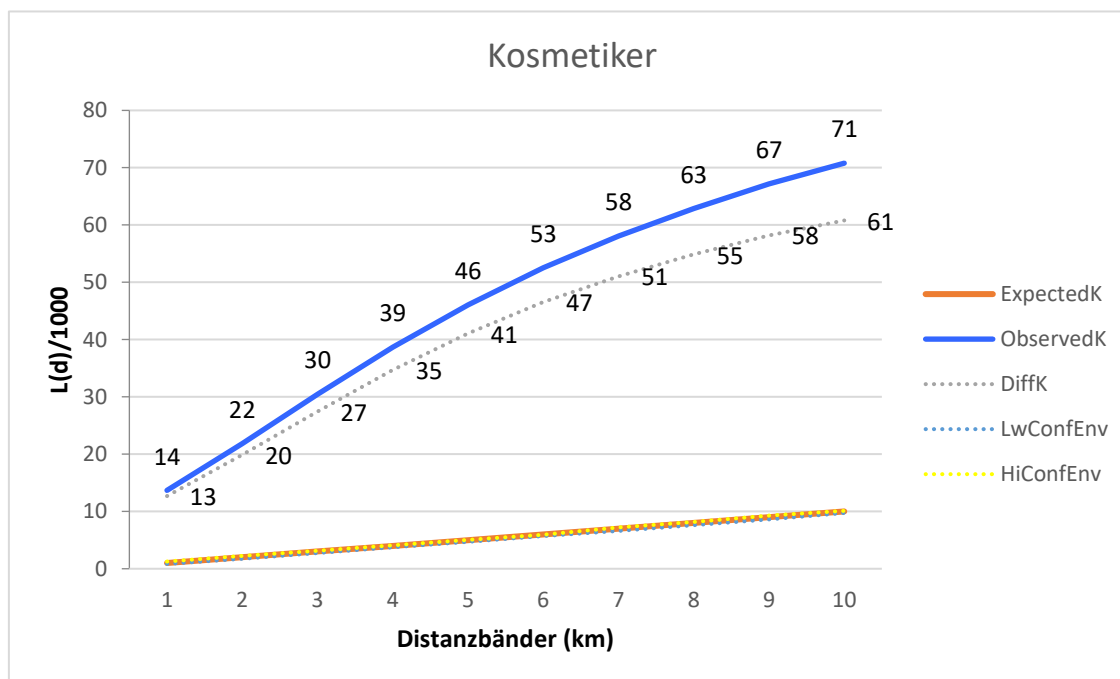


Abbildung 35: Ripley's K-Function der Kategorie Kosmetiker - Österreichweit

Der „Confidence-Envelope“ ist auch hier sehr schmal um den eigentlichen Erwartungswert, also die gedachte „Nulllinie“ zu finden und der $L(d)$ -Wert weicht enorm weit von diesem ab. Die Differenz, also die Normalisierung zur Nulllinie „DiffK“ ist in der Grafik, wie bereits bei Abbildung 18 und 32 als punktierte, graue Linie unter dem Beobachtungswert „ObservedK“ in blau zu finden. Auffällig im Kontrast zum Ergebnis der Lebensmittelhändler ist, dass der $L(d)$ -Wert, also die Clusteringintensität noch höher ist und folglich noch stärker von den Erwartungswerten abweicht, wobei das Verlaufsmuster über die Distanzbänder gleichzeitig sehr gut vergleichbar zu jenem der LH bleibt.

Während der Großteil der Ergebnisse der restlichen Kategorien bzw. Branchen einen ähnlichen Verlauf abbilden (weitere Ergebnisse sind im Anhang der Arbeit zu finden), gibt es jedoch auch deutliche Ausnahmen, wie sie in Abbildung 36 am Beispiel von Baumärkten sichtbar sind.




Abbildung 36: Ripley's K-Analyse für Baumärkte - Österreichweit

Die beobachteten Werte, liegen zwar erneut über dem Erwartungswert, bzw. dem „Confidence-Envelope“, jedoch wesentlich geringer als die zuvor gezeigten Beispiele mit deutlich niedrigeren $L(d)$ -Werten. Die auf die Nulllinie normalisierte DiffK-Linie, zeigt das gleichmäßige, verhältnismäßig schwache Clustering über alle Distanzbänder.

Das im Einzelhandel insgesamt deutlich beobachtbare Clustering innerhalb der einzelnen Kategorien über alle Distanzbänder, kann mit der Ripley's K-Analyse effektiv abgebildet werden. Die Graphen zeigen bereits in der jeweils kategoriell separierten Ausgabe ein gewisses Verhalten der Einzelhändler auf unterschiedlichen Maßstäben. Kombiniert man nun die Beobachtungswerte, bzw. deren Normalisierung zur Nulllinie „DiffK“ in einen einzelnen Graphen, werden die Unterschiede in den Ergebnissen noch wesentlich deutlicher. Durch die kombinierte Darstellung der normalisierten Beobachtungswerte, ist es möglich die Clusteringintensität innerhalb der Branchen mit anderen Branchen bzw. Kategorien zu vergleichen. Die folgende Abbildung 37 zeigt das Ergebnis der Erhebung bzw. Kombination und formt ein erstes Bild darüber, wie stark das „Intra-Branchen“-Clustering in Österreich ist. Es zeigt ein erstes, österreichweites Agglomerationsmuster.

Ripley's K - Ergebnisse norm. Beobachtungswerte

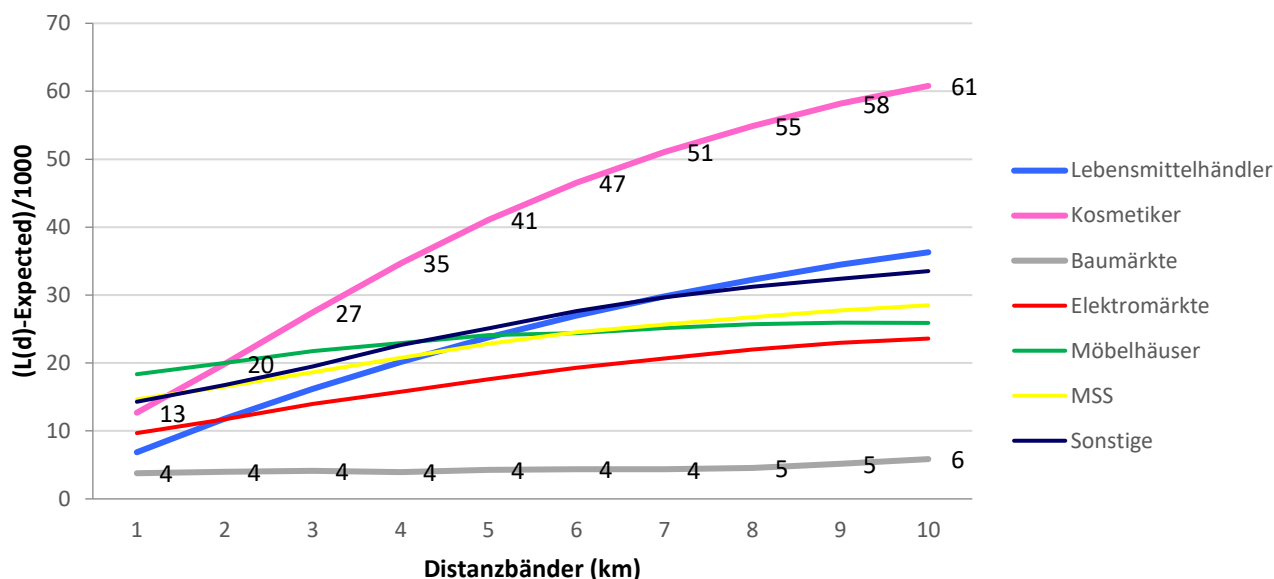


Abbildung 37: Ripley's K-Analyse - normalisierte Beobachtungswerte (DiffK) der einzelnen Kategorien/Branchen - Österreich

Im besonders interessanten, kleinen Distanzband von einem Kilometer sind Möbelhäuser am stärksten zueinander geclustert, gefolgt von Händlern aus der Kategorie Mode-Sport-Schuhe und Sonstige, welche kleinräumig ein sehr ähnliches Clusteringverhalten aufweisen. Erst nach Kosmetikern und sogar Elektrohändlern, folgen die Lebensmittelhändler, welche sich hier gegenseitig am wenigsten untereinander anziehen. Nur Baumärkte zeigen ein noch schwächeres Clustering auf hohem Maßstab als Lebensmittelhändler.

Kosmetiker holen in höheren Distanzbändern bzw. Kreisen schnell auf und weisen bereits ab etwa 2km die höchsten Intra-Branchen-Clustering-Werte auf. Im weiteren Verlauf bleibt die Kategorie weitab „ungeschlagen“ und zeigt ein enormes Clustering auf allen Bändern. Während Lebensmittelhändler im kleineren 1km-Kreis noch eine deutliche Distanzierungsstrategie zur branchengleichen Konkurrenz aufweisen, überholen auch diese die anderen Kategorien im Verlauf bis zum 10km-Kreis, was auf deren hohe Anzahl und dadurch Vorkommen innerhalb der Analysekreise zurückzuführen ist.

Während die Ripley's K-Analyse nun einen sehr guten, jedoch auch groben Einblick in das Intra-Branchen-Clustering in ganz Österreich gibt, bietet sie keine Möglichkeit das Verhalten der Einzelhändler zueinander abzubilden. Um den Informationsgehalt der ös-

terreichweiten Clusteringanalyse weiter zu erhöhen, können diese Ergebnisse nun mit jenen der Service-Areas-Analyse und besonders der NN-Chi-Quadrat-Analyse erweitert werden.

4.1.2 Österreichweite Abhängigkeitsmuster auf Basis von Einzugsgebieten

Die Service-Area-Analyse ist stark durch die Anzahl der einzelnen Kategorien beeinflussbar und deshalb nur für einen groben Datenüberblick über das Inter-Branchen-Clustering verwendbar. Die in Abbildung 24 beispielhaft gezeigten 1-Min Einzugsgebiete um die gewählten Kategorien beinhalten oft eine große Anzahl an Punkten der anderen Kategorien. Trotz einer Verzerrung durch die jeweils gegebene Anzahl an Punkten, können Beziehungstendenzen erahnt werden, welche zwar unzuverlässiger als jene der NN-Chi-Quadrat-Analyse sind, jedoch alle Nachbarn der direkten Umgebung miteinbeziehen.

Die folgende Abbildung zeigt die kleinflächigen Einzugsgebiete einer Minute Gehzeit rund um Lebensmittelhändler im Bereich von Salzburg bzw. Salzburg Umgebung.

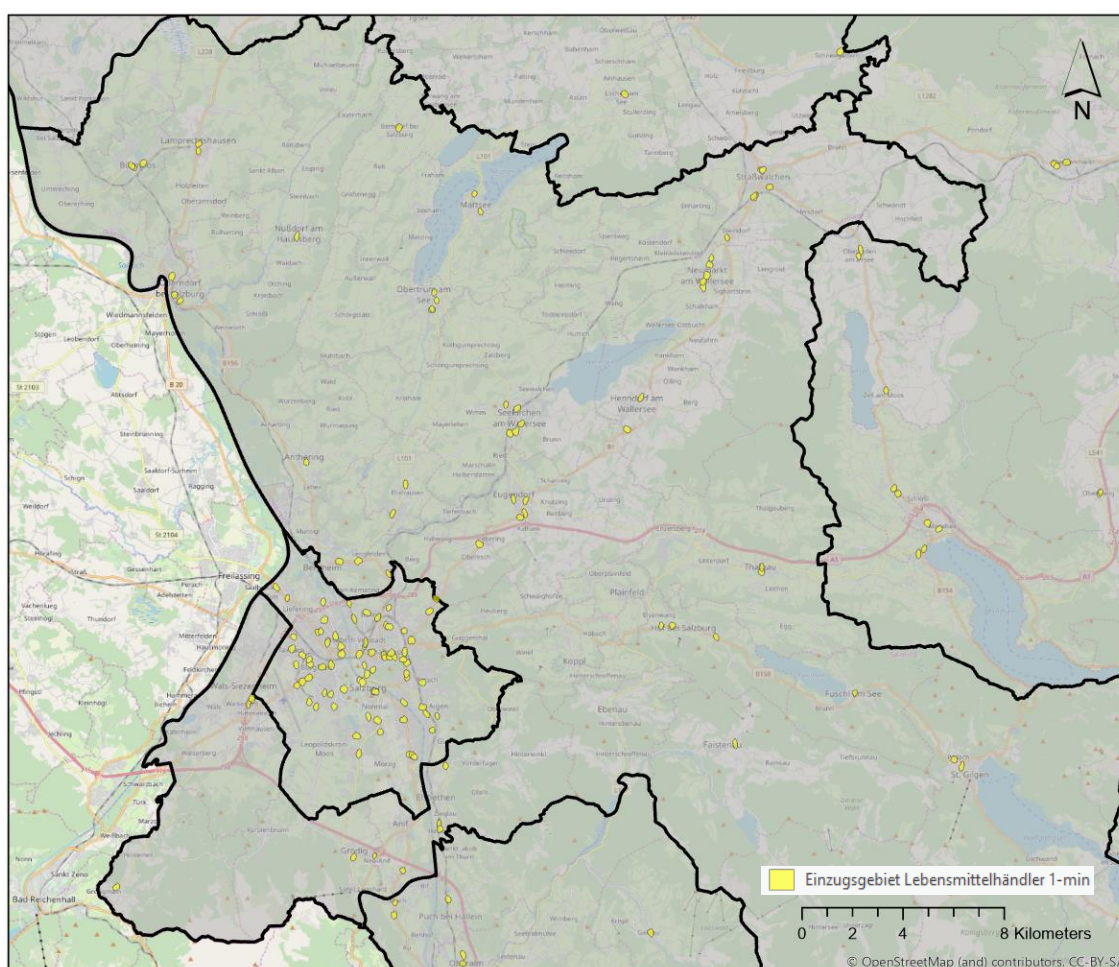


Abbildung 38: Auszug der 1-Min Gehzeit-Einzugsgebiete rund um Lebensmittelhändler auf Basis des österr. Straßennetzes – Salzburg und Umgebung

Da in sehr vielen Einzelhändler-Agglomerationsflächen zumindest ein Lebensmittelhändler vorhanden ist, bilden diese kleinen Einzugsgebiete eine sinnvolle Grundlage für eine allgemeine Dateneinsicht. Innerhalb der gezeigten Flächen, die sich entsprechend über die Grenzen des gezeigten Ausschnittes über ganz Österreich verteilen, befinden sich 17% aller Baumärkte, 26% der Möbelhändler, 42% der Elektromärkte 56% der Punkte aus der Kategorie Mode-Sport-Schuhe, 60% der Märkte aus der Kategorie Sonstige und sogar 70% aller Kosmetiker.

Zieht man die Analyse von der anderen Seite auf und analysiert die 1-Min-Einzugsgebiete von Punkten aus der Kategorie Kosmetik, erhält man ein deutlich anderes Bild. So sind nur 20% der Lebensmittelhändler innerhalb der Service-Areas von Kosmetikern. Weitere Analyseergebnisse der Service-Areas-Methode sind im Anhang zu finden.

Diese Analyse würde Kosmetikern und Märkten aus der Kategorie Sonstige eine einseitige Abhängigkeit unterstellen, würde man die Verzerrung durch Punktzahl außer Acht lassen. Während eine direkte Abhängigkeit einzelner Kategorien durch die genannte Verzerrung noch nicht eindeutig nachgewiesen kann, wird trotzdem im Fall einiger Händler deutlich, dass diesen eine überzufällige Nähe zu anderen Kategorien vorliegt. Ob jedoch eine unmittelbare Nähe im Sinn von direkten Nachbarn als Strategie herangezogen wird, kann jedoch erst mit der im Kapitel [3.3.2](#) besprochenen Analyse gezeigt werden.

4.1.3 Österreichweite Abhängigkeitsmuster auf Basis von Nachbarschaft

Die Nearest Neighbor-Analyse in Kombination mit einem Chi-Quadrat Abhängigkeitstest, welche im Kapitel [3.3.2](#) erklärt wird, stellt die Abweichungen einer beobachteten Verteilung der nächsten Nachbarn zu den Erwartungswerten (= Prozentanteil an Gesamtverteilung der Kategorie * Anzahl der Punkte in Kategorie) dar. Die bereits in Abbildung 25 gezeigte Gesamtverteilung wird auf der folgenden Abbildung 39 erneut dargestellt und um die Verteilungen der nächsten Nachbarn aller Kategorien erweitert. Bereits in dieser Ansicht wird sichtbar, dass es deutliche Unterschiede der kategoriellen Verteilungen zur Gesamtverteilung gibt, diese Abweichungen sollen dann in weiterer Folge näher beschrieben werden.

VERTEILUNG GESAMT		
Zeilenbeschriftungen	Anzahl von Kategorie	Prozentuell an Gesamt
Baumaerkte	683	6,72%
Elektromaerkte	881	8,66%
Kosmetik	1171	11,51%
Lebensmittelhaendler	4331	42,58%
Moebelhaeuser	258	2,54%
MSS	2200	21,63%
Sonstige	647	6,36%
Gesamtergebnis	10171	100,00%

NN Lebensmittelhändler		
Zeilenbeschriftungen	Anzahl von Kategorie	Prozentuell an Gesamt
Baumaerkte	399	9,21%
Elektromaerkte	332	7,67%
Kosmetik	543	12,54%
Lebensmittelhaendler	1947	44,95%
Moebelhaeuser	71	1,64%
MSS	727	16,79%
Sonstige	312	7,20%
Gesamtergebnis	4331	100,00%

NN Baumärkte		
Zeilenbeschriftungen	Anzahl von Kategorie	Prozentuell an Gesamt
Baumaerkte	61	8,93%
Elektromaerkte	41	6,00%
Kosmetik	13	1,90%
Lebensmittelhaendler	437	63,98%
Moebelhaeuser	19	2,78%
MSS	72	10,54%
Sonstige	40	5,86%
Gesamtergebnis	683	100,00%

NN Möbelhändler		
Zeilenbeschriftungen	Anzahl von Kategorie	Prozentuell an Gesamt
Baumaerkte	16	6,20%
Elektromaerkte	9	3,49%
Kosmetik	15	5,81%
Lebensmittelhaendler	67	25,97%
Moebelhaeuser	75	29,07%
MSS	37	14,34%
Sonstige	39	15,12%
Gesamtergebnis	258	100,00%

NN Elektromärkte		
Zeilenbeschriftungen	Anzahl von Kategorie	Prozentuell an Gesamt
Baumaerkte	38	4,31%
Elektromaerkte	89	10,10%
Kosmetik	209	23,72%
Lebensmittelhaendler	385	43,70%
Moebelhaeuser	22	2,50%
MSS	68	7,72%
Sonstige	70	7,95%
Gesamtergebnis	881	100,00%

NN MSS		
Zeilenbeschriftungen	Anzahl von Kategorie	Prozentuell an Gesamt
Baumaerkte	17	0,77%
Elektromaerkte	137	6,23%
Kosmetik	225	10,23%
Lebensmittelhaendler	432	19,64%
Moebelhaeuser	34	1,55%
MSS	744	33,82%
Sonstige	611	27,77%
Gesamtergebnis	2200	100,00%

NN Kosmetik		
Zeilenbeschriftungen	Anzahl von Kategorie	Prozentuell an Gesamt
Baumaerkte	11	0,94%
Elektromaerkte	113	9,65%
Kosmetik	60	5,12%
Lebensmittelhaendler	414	35,35%
Moebelhaeuser	9	0,77%
MSS	337	28,78%
Sonstige	227	19,39%
Gesamtergebnis	1171	100,00%

NN Sonstige		
Zeilenbeschriftungen	Anzahl von Kategorie	Prozentuell an Gesamt
Baumaerkte	11	1,70%
Elektromaerkte	35	5,41%
Kosmetik	58	8,96%
Lebensmittelhaendler	105	16,23%
Moebelhaeuser	18	2,78%
MSS	210	32,46%
Sonstige	210	32,46%
Gesamtergebnis	647	100,00%

Abbildung 39: Gesamtverteilung aller Punkte, sowie Verteilungen der nächsten Nachbarn (NN) je Kategorie

Da diese Ansicht nur einen groben Überblick liefern kann, müssen die Ergebnisse nun direkt mit der Gesamtverteilung in Beziehung gesetzt werden, dazu werden diese zuerst in prozentueller Abweichung je Kategorie zu den Erwartungswerten (= Prozentanteil an Gesamtverteilung der Kategorie * Anzahl der Punkte in Kategorie) und in Folge mit dem Chi-Quadrat-Wert abgebildet. Die einzelnen Chi-Quadrat-Werte werden in Folge zur Bildung eines p-Wertes summiert.

Die prozentuellen Abweichungen werden zusätzlich bei der höchsten positiven Abweichung in Grün (= nächste Nachbarschaft häufiger als erwartet) bzw. bei der niedrigsten in Rot dargestellt (= nächste Nachbarschaft seltener als erwartet).

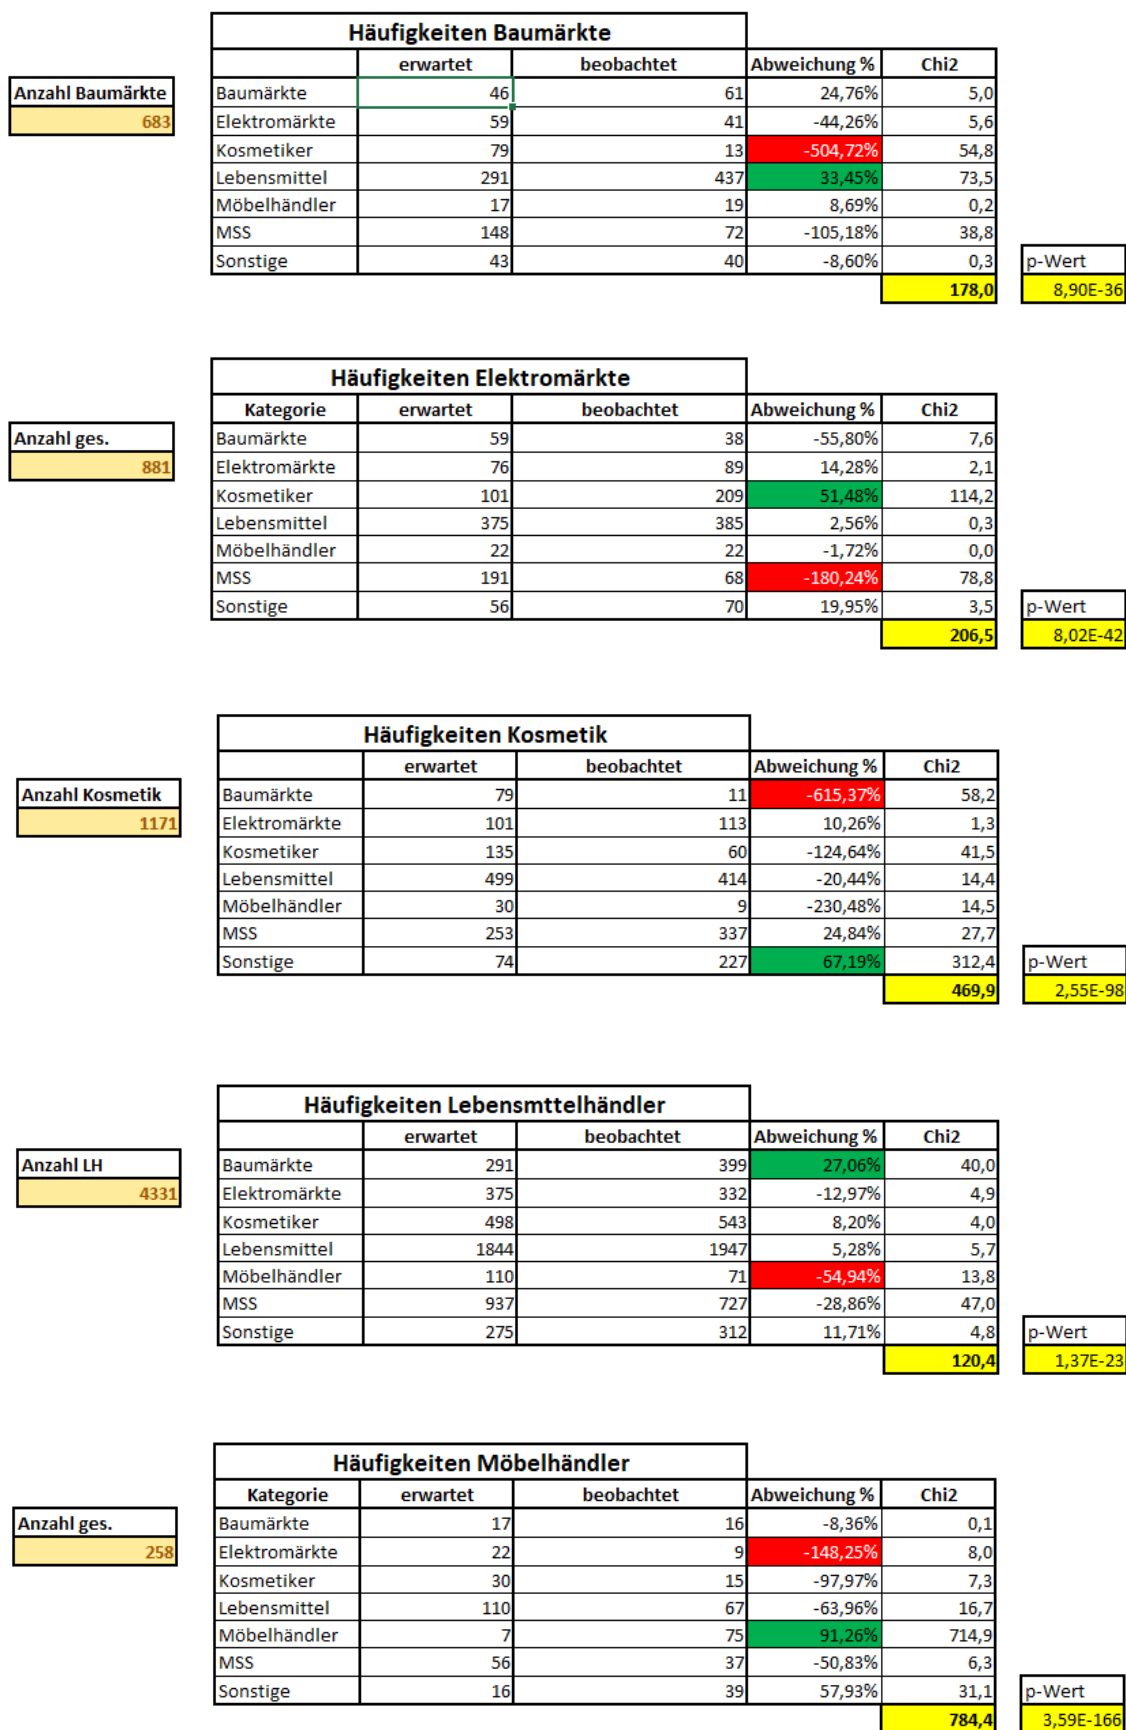


Abbildung 40: Häufigkeitsverteilungen der nächsten Nachbarn zur fokalen Kategorie im Vergleich mit Erwartungswerten inkl. prozentueller Abweichung und Chi-Quadrat-Test für die Kategorien: Baumärkte, Elektromärkte, Kosmetiker, Lebensmittelhändler und Möbelhändler

Häufigkeiten MSS				
	erwartet	beobachtet	Abweichung %	Chi2
Anzahl MSS				
2200				
Baumärkte	148	17	-769,65%	115,8
Elektromärkte	191	137	-39,07%	15,0
Kosmetiker	253	225	-12,54%	3,1
Lebensmittel	937	432	-116,84%	272,0
Möbelhändler	56	34	-64,35%	8,6
MSS	476	744	36,04%	151,1
Sonstige	140	611	77,10%	1586,0
				2151,6
				p-Wert
				0,00E+00

Häufigkeiten Sonstige				
	erwartet	beobachtet	Abweichung %	Chi2
Anzahl Sonstige				
647				
Baumärkte	43	11	-295,26%	24,3
Elektromärkte	56	35	-60,09%	7,9
Kosmetiker	74	58	-28,40%	3,6
Lebensmittel	275	105	-162,37%	105,5
Möbelhändler	16	18	8,70%	0,1
MSS	140	210	33,36%	35,1
Sonstige	41	210	80,41%	692,9
				869,4
				p-Wert
				1,56E-184

Abbildung 41: Häufigkeitsverteilungen der nächsten Nachbarn zur fokalen Kategorie im Vergleich mit Erwartungswerten inkl. prozentueller Abweichung und Chi-Quadrat-Test für die Kategorien: Mode-Sport-Schuhe und Sonstige

H0: „Die nächsten Nachbarn je Kategorie verteilen sich gleichmäßig über alle Kategorien“

H1: „Die nächsten Nachbarn je Kategorie verteilen sich ungleichmäßig über alle Kategorien“

Die Ergebnisse aller Kategorien sind hochsignifikant auf 1% Signifikanzniveau, wodurch H0 verworfen und H1 angenommen werden kann. Da die Nachbarn folglich nicht gleichmäßig verteilt sind, wird in dieser Analyse ein Clustering bzw. eine Meidung verschiedener Kategorien zueinander festgestellt.

In fast jeder Kategorie bzw. Branche gibt es deutliche Auffälligkeiten, welche schon durch die prozentuellen Abweichungen zu den Erwartungswerten abgebildet werden. So häufen sich in der Nähe von Lebensmittelhändlern Baumärkte über den Erwartungen und auch Kosmetiker, sowie Händler aus der Kategorie Sonstige sind vermehrt neben diesen zu finden. Im Kontrast dazu gibt es eher selten Möbelhändler in unmittelbarer Nachbarschaft von Lebensmittelhändlern. Betrachtet man die Kosmetiker, fällt im Vergleich zur Auswertung der Lebensmittelhändler auf, dass Baumärkte diese offenbar meiden und Händler aus der Kategorie Sonstige eher neben diesen zu finden sind. In der Kategorie Sonstige wiederum sind Kosmetiker nicht die gefragtesten Nachbarn, sondern eher an-

dere Händler aus eben dieser Kategorie, während auch diese Baumärkte meiden. Betrachtet man nun die Baumärkte sind auch dort diese Tendenzen zu sehen, „Sonstige“ werden leicht gemieden, Kosmetiker stark gemieden und Lebensmittelhändler eher bevorzugt. Eine weitere leichte Auffälligkeit ist die Bevorzugung der Nachbarschaft von Möbelhändlern durch weitere Möbelhändler. Für planerische Zwecke könnte diese Form der Analyse bei der Wahl der direkten Nachbarschaft als Anhaltspunkt dienen.

4.2 Interzonale Vergleiche

Die bisher besprochenen Erhebungsmethoden bilden das Verhalten von Einzelhändlern über ganz Österreich ab und zeigen, wie sehr Branchen mit sich selbst und mit anderen Branchen clustern. Sollen jedoch spezielle Regionen in Hinsicht auf Clustering und Verteilungsmuster untersucht bzw. verglichen werden, sind andere Herangehensweisen empfehlenswert, welche nach der großflächigen Erhebung durchgeführt werden sollten.

4.2.1 Interzonaler Vergleich von politischen Zonierungen

Average-Nearest-Neighbor macht auf kleinen, dicht durch Einzelhändler besiedelten Regionen das Intra-Branchen-Clusteringverhalten sichtbar und vergleichbar. Im Folgenden werden verschiedene Beispiele aus unterschiedlichen Regionen präsentiert und über mehrere Kategorien verglichen.

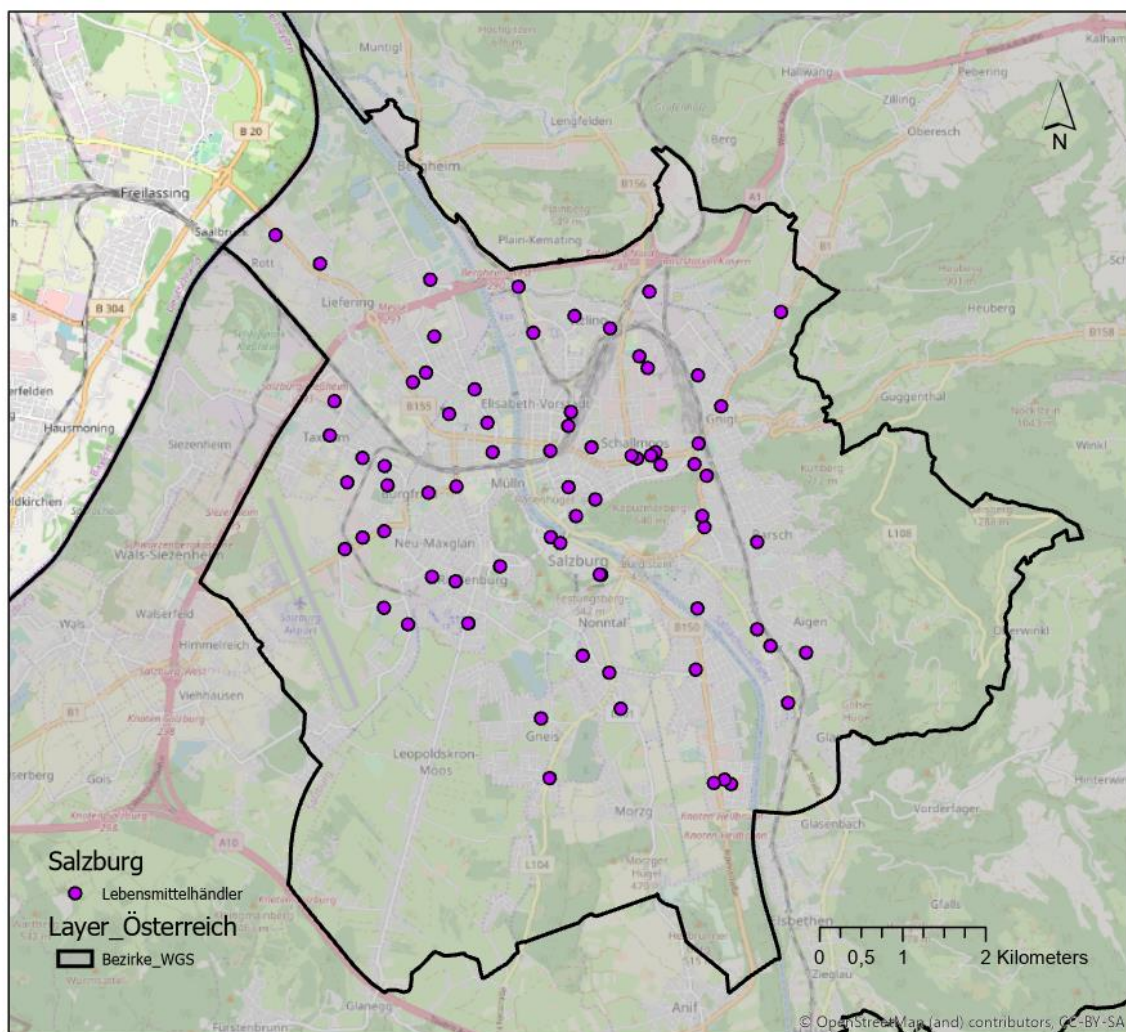


Abbildung 42: Verteilung von Lebensmittelhändlern im Bezirk Salzburg Stadt

Auf der gezeigten Abbildung sind die Lebensmittelhändler im Bezirk Salzburg Stadt abgebildet. In Folge wird eine ANN-Analyse auf dieses Gebiet auch für alle anderen Kategorien neben Lebensmittelhändlern durchgeführt, ohne erneut die Verteilung auf einer Karte abzubilden. Die Ergebnisse werden für das erste Beispiel anhand der kompletten Auswertung inkl. Normalverteilungskurve dargestellt, in weiterer Folge werden diese nicht mehr zusätzlich abgebildet.

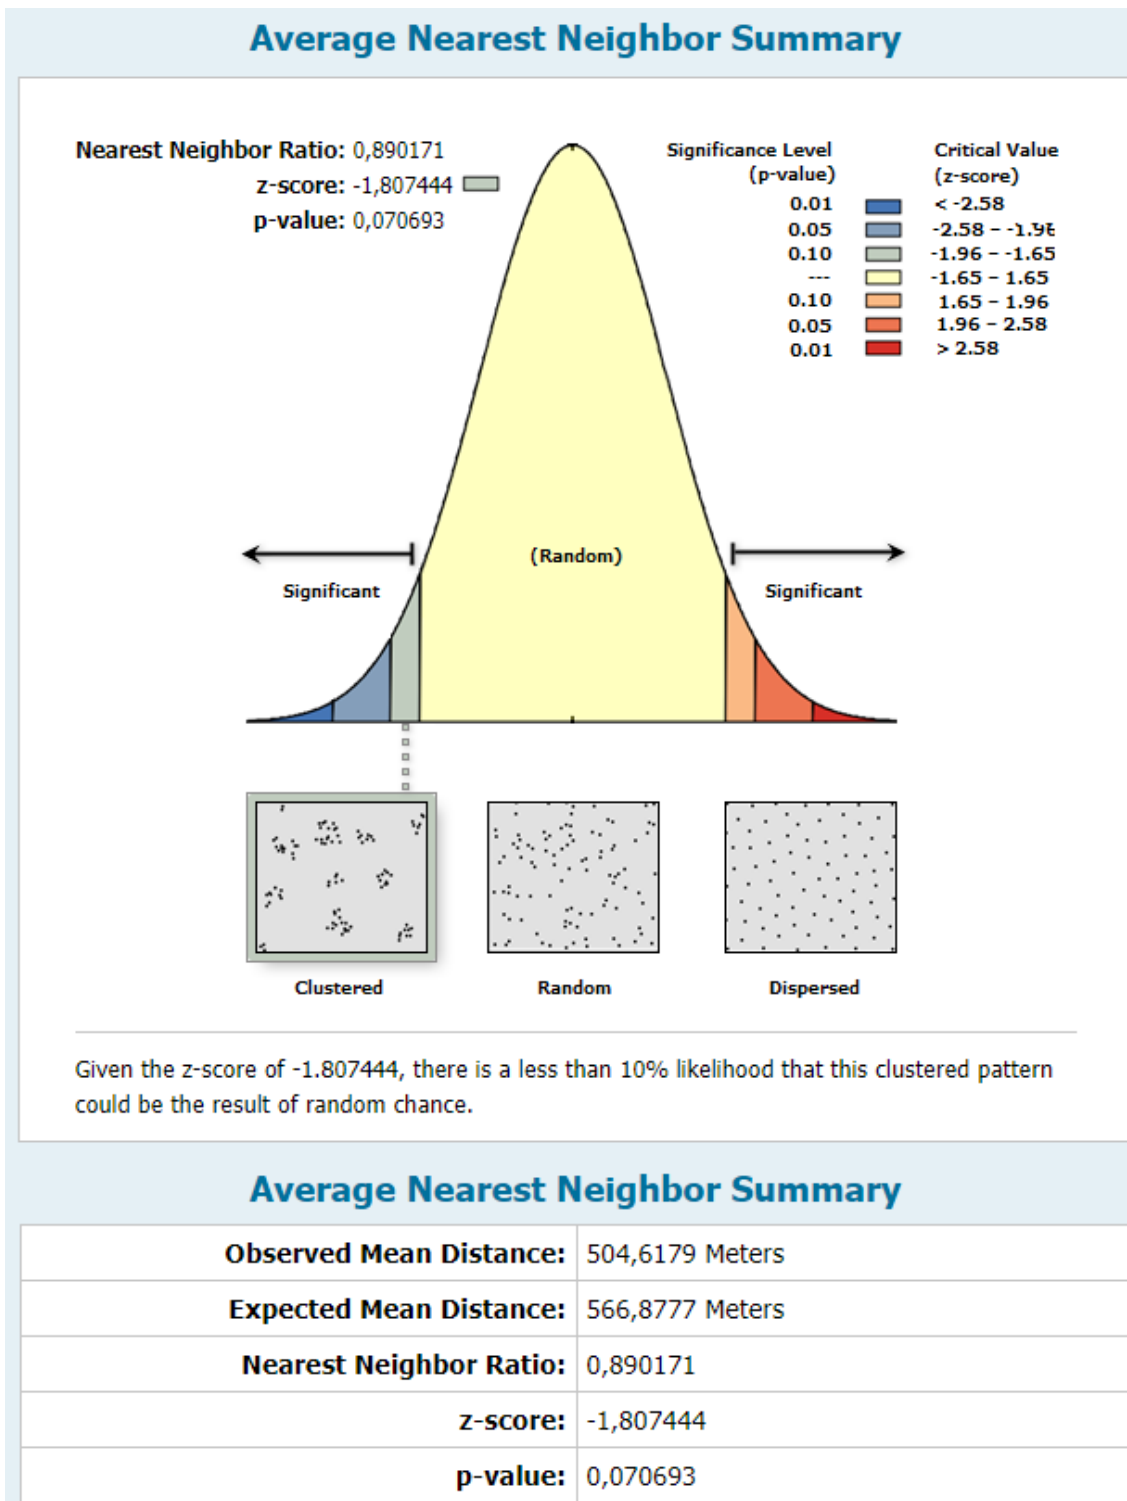


Abbildung 43: ANN-Analyse der Lebensmittelhändler im Bezirk Salzburg Stadt

Dass die Lebensmittelhändler ein eher schwaches Clustering auf hohem Maßstab haben, wurde bereits durch die Ripley's K-Analyse sichtbar. Auch die Ergebnisse der NN-Chi-Quadrat-Analyse zeigen, dass Lebensmittelhändler sich als nächste Nachbarn zwar nicht meiden, jedoch auch deutlich seltener an sich selbst, als an anderen Kategorien siedeln.

Durch die ANN-Analyse wird das Meidungsverhalten bzw. geringe Clustering (Clustered in Richtung Random mit einem p-Wert von 0,07 - nicht sehr signifikant) innerhalb der Kategorie sichtbar, der Z-score nimmt hier „nur“ einen Wert von nur -1,8 an. Die Skala der Signifikanzniveaus im oberen, rechten Bereich von Abbildung 43 ist für alle folgenden Auswertungen eine Interpretationshilfe zur statistischen Signifikanz.

Analysiert man im gleichen Ausschnitt andere Kategorien, kommt man auf folgende Ergebnisse:

Observed Mean Distance:	526,8953 Meters
Expected Mean Distance:	938,4764 Meters
Nearest Neighbor Ratio:	0,561437
z-score:	-4,359581
p-value:	0,000013

Abbildung 44: ANN für Kosmetiker in Salzburg

Observed Mean Distance:	153,8384 Meters
Expected Mean Distance:	791,0673 Meters
Nearest Neighbor Ratio:	0,194469
z-score:	-9,499587
p-value:	0,000000

Abbildung 45: ANN für Mode-Sport-Schuhe in Salzburg

Weitere Ergebnisse für Salzburg sind im Anhang zu finden.

Neben dem Z-Score kann auch die beobachtete mittlere Distanz interessante Details über die Verteilungsmuster preisgeben, so ist diese bei der Kategorie mit dem stärksten Clustering (Z-Score -9,5) in Salzburg: Mode-Sport-Schuhe nur 153 Meter. Diese Art der Berechnung soll in weiterer Folge, um die Ergebnisse zu vergleichen, für eine weitere Region durchgeführt werden. Als zweites Beispiel wurde im Folgenden Graz herangezogen.

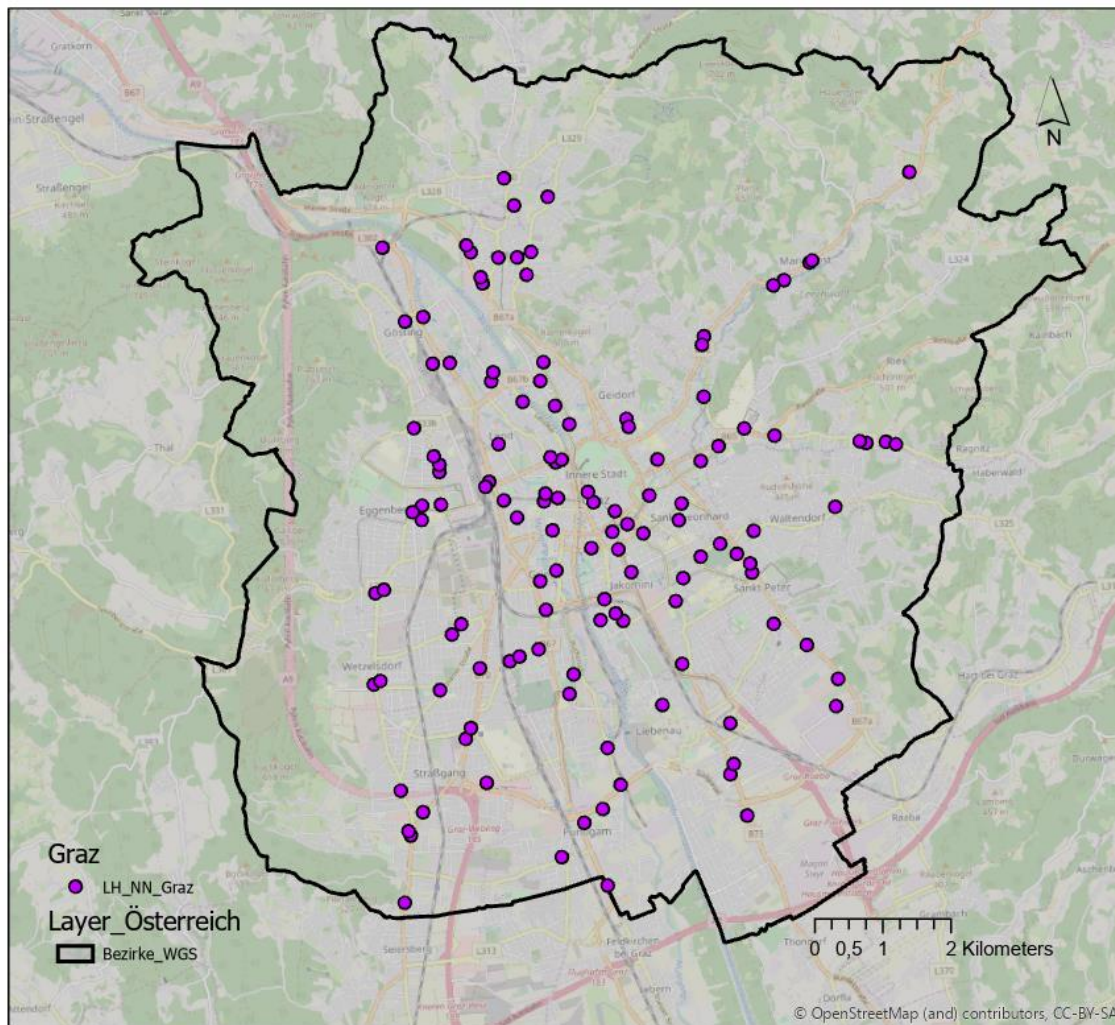


Abbildung 46: Verteilung von Lebensmittelhändlern im Bezirk Graz Stadt

Average Nearest Neighbor Summary	
Observed Mean Distance:	463,7188 Meters
Expected Mean Distance:	432,7164 Meters
Nearest Neighbor Ratio:	1,071646
z-score:	1,544630
p-value:	0,122436

Abbildung 47: ANN für Lebensmittelhändler in Graz

In Graz clustern die Lebensmittelhändler folglich sogar noch ein wenig schwächer als im Vergleichsgebiet Salzburg mit einem leicht positiven Z-Score von 1,5 ($p > 0,1$ – kein signifikantes Clustering = random). Die mittlere Distanz zwischen Lebensmittelhändlern ist dem Wert aus Salzburg erneut sehr ähnlich mit 464 zu 504m zwischen den Händlern, jedoch unterschiedlichem Z-Score.

Nun werden noch die anderen beiden, zuvor gezeigten Kategorien abgebildet.

Average Nearest Neighbor Summary	
Observed Mean Distance:	781,9920 Meters
Expected Mean Distance:	752,4551 Meters
Nearest Neighbor Ratio:	1,039254
z-score:	0,486677
p-value:	0,626488

Abbildung 48: ANN der Kosmetiker in Graz

Average Nearest Neighbor Summary	
Observed Mean Distance:	169,1052 Meters
Expected Mean Distance:	696,6380 Meters
Nearest Neighbor Ratio:	0,242745
z-score:	-10,140778
p-value:	0,000000

Abbildung 49: ANN der Kategorie Mode-Sport-Schuhe in Graz

Während bei Kosmetikern in Graz ein anderes Muster als in Salzburg zu entdecken ist, nämlich, dass diese in der steirischen Hauptstadt deutlich schwächer clustern (kein signifikantes Clustering mit einem p-Wert von über 0,1), ist in der Kategorie Mode-Sport-Schuhe wiederum das deutliche Clustering ($p < 0,01$) über der simulierten Erwartung abzulesen.

Natürlich kann man diese Art der Analyse nicht nur auf einem mittleren Maßstab wie Bezirken durchführen. Ist die Population hoch genug, kann die Analyse bis zum größtmöglichen Maßstab heruntergebrochen werden.

4.2.2 Interzonaler Vergleich von selbstdefinierten Zonierungen

ANN-Werte für Zählsprenkel können in der gleichen Form wie die im vorherigen Kapitel gezeigten Analysen auf Bezirksebene erhoben werden, jedoch sind diese aufgrund ihrer Größe sehr oft nur eingeschränkt vergleichbar. Von großem Interesse sind spezielle Einkaufsstraßen oder sonstige Agglomerationsgebiete, welche sich zwar meist nicht durch einzelne Sprengel, jedoch durch eine Multiauswahl von mehreren Sprengeln abbilden lassen. Man kann auf diese Weise beispielsweise alle Zählsprenkel entlang der Mariahilfer Straße in Wien analysieren und das dortige Clusteringverhalten untersuchen. Bei dieser sehr speziellen Anwendung, ist das besprochene MAUP besonders zu beachten.

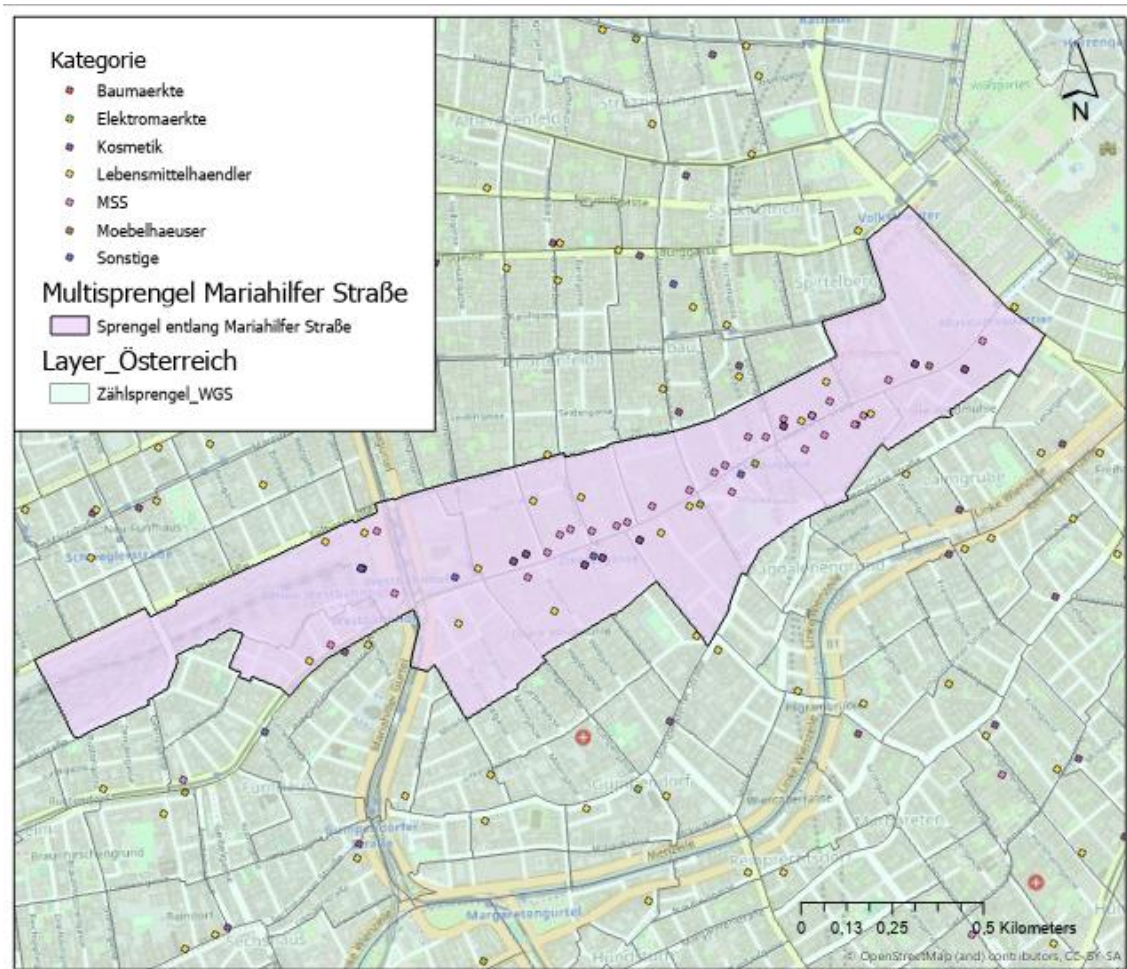


Abbildung 50: Übersicht Händler in Multisprengel entlang Mariahilferstraße

Prüft man innerhalb dieser „Multisprengel“ nun eine ANN durch, erhält man folgende Ergebnisse.

Average Nearest Neighbor Summary	
Observed Mean Distance:	201,2815 Meters
Expected Mean Distance:	209,1608 Meters
Nearest Neighbor Ratio:	0,962329
z-score:	-0,269653
p-value:	0,787428

Abbildung 51: Lebensmittelhändler-ANN in Multisprengel - Mariahilfer Straße

Auch auf so hohem Maßstab und in einer so dicht besiedelten Fläche, clustern Lebensmittelhändler nur leicht über den Erwartungen, was die Ergebnisse der Ripley's-K-Analyse weiter stützt. Das Muster wurde erneut als zufällig (Random) eingestuft und kein auffälliges Clustering beobachtet ($p > 0,1$ – in Richtung disperser Verteilung). Betrachtet man nun die anderen Kategorien, sieht das anders aus.

Average Nearest Neighbor Summary	
Observed Mean Distance:	86,3660 Meters
Expected Mean Distance:	217,0564 Meters
Nearest Neighbor Ratio:	0,397896
z-score:	-4,153114
p-value:	0,000033

Abbildung 52: Kosmetiker-ANN in Multisprengel - Mariahilfer Straße

Average Nearest Neighbor Summary	
Observed Mean Distance:	84,7957 Meters
Expected Mean Distance:	134,2162 Meters
Nearest Neighbor Ratio:	0,631785
z-score:	-4,107451
p-value:	0,000040

Abbildung 53: Mode-Sport-Schuhe-ANN in Multisprengel - Mariahilfer Straße

Sowohl Kosmetiker, als auch Modehändler clustern innerhalb der Mariahilfer Straße weit über den Erwartungswerten mit Z-Scores jeweils unter -4, $p < 0,01$ und einer mittleren Distanz zwischen 80 und 90m. Ein weiteres Multisprengel-Ergebnis für die Wiener City ist im Anhang zu finden. Auch im Fall der Wiener City clustern die Händler aus der Kategorie Mode-Sport-Schuhe am stärksten in sich selbst.

Je nach Strategie und Ziel sollten Planer diese Analyse auf unterschiedlichen Maßstäben heranziehen und vergleichen. Ist die Strategie eher in städtische, dicht besiedelte Gebiete zu siedeln, wäre die Multisprengel-Analyse ein guter Ansatz um bestehende, erfolgreiche Modelle zu prüfen und zu übertragen (erfolgreiche Modelle aus dem eigenen Bestand im Abgleich mit Umsatzdaten weisen durchschnittlich mind. 100m zur branchengleichen Konkurrenz auf, könnte dabei eine These lauten). Sind strategisch gesehen eher ländliche Gebiete relevant, sollte die Analyse auf Gemeindeniveau oder Bezirksniveau angewandt werden. Diese Form der Auswertung ist sehr gut vergleichbar und kann dann in Folge sogar noch mit dem Branchenmix kombiniert werden, um Anhaltspunkte für die Standortplanung zu finden. Mehr hierzu im Kapitel „Methodenkombination in Anwendungsfällen“.

4.2.3 Mustervergleich auf Basis von politischen Zonierungen

Der im Folgenden gezeigte Branchenmix wurde auf verschiedenen Betrachtungsniveaus erhoben und unterschieden, wobei sich zwischen den Niveaus Bezirke, Gemeinden und Zählsprengel deutliche Unterschiede in den Verteilungsmustern feststellen ließen, was bereits durch die Ripley’s K-Analyse impliziert wurde. Pro Analyse werden die Top 20 Bezirke (bzw. Gemeinden und Sprengel) mit dem dazugehörigen Variationskoeffizienten ausgegeben (neben den Kategorienamen), danach folgt jeweils die prozentuelle Betrachtung.

4.2.3.1 Bezirksebene

Im ersten Schritt der Branchenmix-Analyse wird das Ergebnis rein nach Punktzahl ausgegeben, in Abbildung 54 erkennt man bereits erste Tendenzen der Daten. In den folgenden Aufstellungen wird Wien zuerst komplett und in Folge pro Bezirk abgebildet.




Abbildung 54: Branchenmix - Top 20 nach Punktzahl

Leicht abzulesen ist dabei der starke Überhang von Lebensmittelhändlern auf Bezirksebene gefolgt von Vertretern aus den Kategorien Mode-Sport-Schuhe und Kosmetik, dies deckt sich zwar mit der Gesamtverteilung, jedoch ist es auffällig, dass die Verteilungen der verschiedenen Branchen über die Bezirke in eine regelmäßige Richtung tendieren. Da diese Betrachtung jedoch noch nicht nach einem Parameter wie Bevölkerung oder Größe des Bezirks normalisiert wurde, ist das Ergebnis noch wenig aussagekräftig, da keine Vergleichsgrundlage bereitsteht.

Führt man eine Normalisierung nach Bevölkerungszahl durch, weicht das Ergebnis in Absolutwerten (für die Top 20 in der Auswahl nach Bevölkerungszahl) bereits auf Bezirksebene von den Top 20 nach Punktzahl ab. (Die Grafik ist im Anhang mit Bevölkerungszahlen zu finden.)




Abbildung 55: Branchemix - Top 20 Bezirke nach Bevölkerungszahl

Wien und Graz bleiben wegen der hohen Bevölkerungsdichte an der Spitze, jedoch rückt der 10. Wiener Bezirk Favoriten weit nach oben.

Der Überblick über Verteilungstendenzen einzelner Branchen bleibt bei Betrachtung auf Bezirksebene ähnlich der Aufstellung nach Punktzahl, was auch die jeweiligen Variationskoeffizienten beweisen, die sich nicht merklich von der letzten Aufstellung unterscheiden. Überträgt man diese Aufstellung nach Bevölkerungszahl in eine prozentuelle Ansicht und bildet einen Mittelwert dieser (Tortendiagramm), zeigt sich folgendes Ergebnis.




Abbildung 56: Branchemix - Top 20 Bezirke nach Bevölkerungszahl





Abbildung 57: Durchschnitt der in Abb. 56 gezeigten Verteilung der Top 20 Bezirke nach Bevölkerungszahl

4.2.3.2 Gemeindeebene

Die folgenden Ergebnisse auf Gemeindeebene werden erneut zuerst nach Punktzahl und in Folge nach Bevölkerung angegeben.






Abbildung 59: Branchenmix der Top 20 Gemeinden nach Bevölkerung




Abbildung 60: Durchschnitt der Verteilung der Top 20 Gemeinden nach Bevölkerungszahl

Auffällig in dieser Auswertung ist es, dass die Variationskoeffizienten deutlich geringer sind als auf Bezirksebene und Muster dadurch besser erkennbar sind. Im Hinblick auf Untersuchungen zu Agglomerationsmustern ist demnach die Betrachtung auf Gemeindeebene, normalisiert um einen Parameter wie Bevölkerung oder auch Bevölkerungsdichte je km² die sinnvollere Variante. Im Folgenden soll nun noch die Betrachtung auf Zählsprengelebene durchgeführt werden.

4.2.3.3 Zählsprengelebene

Auf der sehr kleinen, politischen Betrachtungsebene der Zählsprengelebene werden deutliche Unterschiede zu den zuvor gezeigten Ergebnissen erwartet, da diese in den meisten Fällen sehr kleinflächig sind. Folgt man der Ripley's K-Analyse, sollte nun etwa die Kategorie Lebensmittelhändler schwächer vertreten sein als die zweitgrößte Kategorie Mode-Sport-Schuhe, da diese im kleinflächigen Bereich nicht stark clustern, was auch die ANN-Analyse auf Gemeindeebene bzw. Multisprengelebene bewiesen hat.




Abbildung 61: Branchenmix der Top 20 Zählsprengelebene nach Punktezah

Abbildung 60 bildet diese Annahme tatsächlich ab, während Lebensmittelhändler nur noch schwach vertreten sind, da sich diese auf hohem Maßstab gleichmäßiger verteilen, gibt es starke Cluster von Modehändlern, welche in punktreichen Regionen häufig vorkommen. (Es wurden Sprengel mit mind. 10 Datenpunkten gefiltert.)




Abbildung 62: Branchenmix der Top 20 Sprengel nach Bevölkerungszahl (mind. 10 Punkte)




Abbildung 63: Durchschnitt der Verteilung der Top 20 Sprengel nach Bevölkerungszahl (mind. 10 Punkte)

Hier wird deutlich, dass der Variationskoeffizient in fast jeder Kategorie im Vergleich zur Aufstellung rein nach Punkten wieder nach oben geht und die Muster demnach weniger einheitlich über verschiedene Sprengel mit ähnlichen Einwohnerzahlen sind. Die Kategorie Mode-Sport-Schuhe ist hierbei deutlich stärker vertreten als die Lebensmittelhändler, was die Erhebung in 1-4km Distanzbändern der Ripley's-K Analysen bestätigen. Für einen Überblick über das Umfeld von 1-5km Distanz, sollte eher die Branchenmix-Analyse auf Gemeindeebene herangezogen werden, da diese meist ausreichende Punkte für sinnvolle Vergleiche beinhaltet. Da auf dem Betrachtungsniveau der Sprengel häufig nur sehr wenige Punkte pro Sprengel vorkommen, ist die Aufstellung nach Punktzahl tatsächlich relevanter, als jene nach Bevölkerungszahl für eine grobe Übersicht. Jedoch ist auch diese nur eingeschränkt geeignet, da sich die Punkte nicht an Sprengeln bzw. deren Grenzen halten. Oft orientieren sich Händler an gewachsenen bzw. geplanten Clustersonen, weshalb die folgende Betrachtung auf Basis von Service-Areas sinnvoller werden kann.

4.2.4 Musteranalyse auf Basis von Einzugsgebieten „Local Cluster“

Je nach Branche kann auch die Service-Area-Analyse genutzt werden, um die branchenmäßige Zusammensetzung anderer Händler innerhalb von Service-Area-Einzugsgebieten zu prüfen. Diese Methode wurde auf die im Kapitel [3.3.4](#) besprochenen 1-Min-Einzugsgebiete für alle Lebensmittelhändler in Österreich angewandt und bildete (bereinigt) insgesamt 4811 Punkte aus allen Kategorien innerhalb dieser Zonen ab. Die Branchenverteilung zeigt sich dabei wie folgt: 136 Baumärkte, 461 Elektromärkte, 1.000 Händler der Kategorie Kosmetik, 952 weitere Lebensmittelhändler, 89 Möbelhäuser, 1573 Punkte der Kategorie Mode-Sport-Schuhe und 500 Punkte aus der Kategorie Sonstige. Abb.37 präsentiert das Ergebnis in prozentuellen Anteilen der Gesamtzahl je Kategorie.




Abbildung 64: Branchenzusammensetzung der jeweiligen Kategorien innerhalb von 1-min Einzugsgebieten rund um Lebensmittelhändler in ganz Österreich

Die Tendenzen ähneln dabei den Analysen auf Sprengelebene stark, jedoch enthalten diese neuen Service-Area-Zonen die deutlich höheren Punktzahlen und sind demnach aussagekräftiger. Natürlich ist es mit dieser Art der Analyse auch möglich, einzelne Cluster miteinander zu vergleichen und in Folge Variationskoeffizienten über ähnliche Agglomerationszonen zu bilden. Versucht man nun in Folge die Ansätze zu kombinieren, ist es möglich die Agglomeration nach verschiedenen Gesichtspunkten abzubilden.

5. Methodenkombination in Anwendungsfällen

In einem praktischen Beispiel könnte es nun die Aufgabe eines Standortplaners bzw. einer Standortplanerin sein, einen geeigneten Standort für einen Lebensmittelhändler im Umkreis der Gemeinde Bergheim im Bundesland Salzburg zu finden. Da es in dieser Gemeinde bereits Händler aus der Kategorie Vollsortiment und Discount gibt, muss man sich in diesem Fall mit der Konkurrenz arrangieren. Nun soll ermittelt werden, wie nahe man an der Konkurrenz bzw. innerhalb bestimmter Cluster siedeln kann um möglichst hohe Umsätze am Standort zu erzielen. Nachdem Faktoren wie Flächenwidmung, Leerstand bzw. Kauf- oder Mietfähigkeit festgestellt wurden, soll nun der Faktor Agglomeration bzw. Clustering geprüft werden.

Aus der Ripley's K-Analyse im Branchenvergleich hat der Planer bzw. die Planerin bereits die Information, dass eine zu knappe Siedlung an der Konkurrenz auf kleinem Raum nicht üblich ist, weshalb diese Option ausgeschlossen wird.

Ripley's K - Ergebnisse norm. Beobachtungswerte

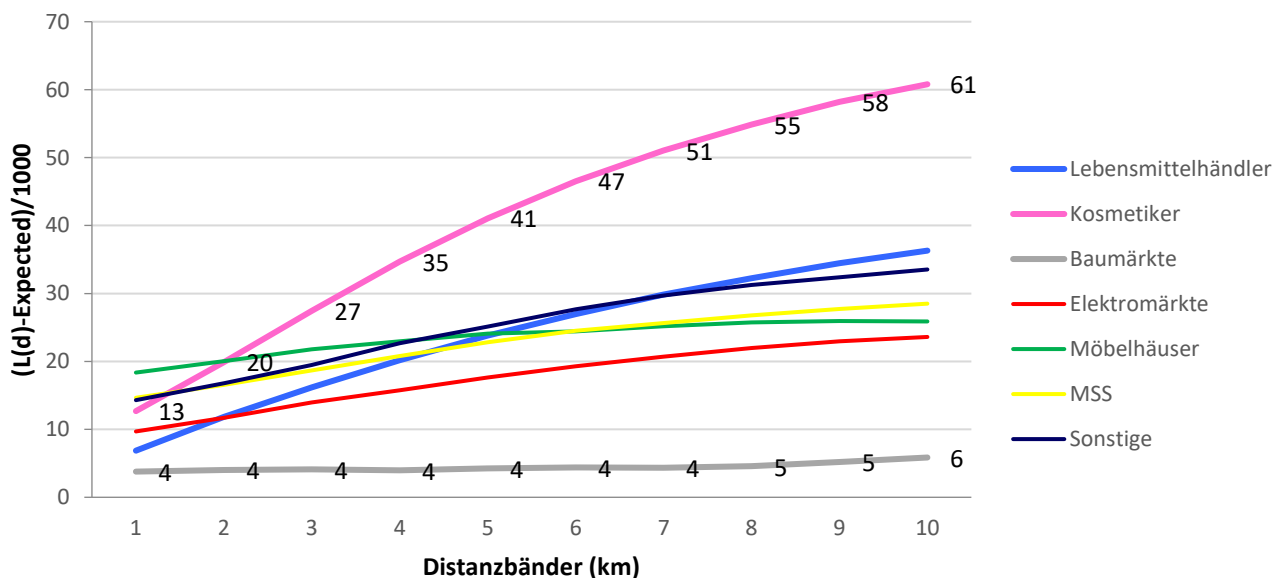


Abbildung 65: Ripley's K-Analyse im Branchenvergleich für ganz Österreich

(Auch eine Unterscheidung nach Vollsortiment und Discount wäre für eine weiterführende Analyse möglich).

Im nächsten Schritt prüft der Planer bzw. die Planerin den Branchenmix von Gemeinden mit ähnlichen Eigenschaften wie etwa der Bevölkerungszahl und bildet den mehrstufigen Branchenmix als lokalen Überblick.




Abbildung 66: Branchenmix von Gemeinden mit ähnlichen Bevölkerungszahlen zu Bergheim bei Salzburg - absolut




Abbildung 67: Branchenmix von Gemeinden mit ähnlichen Bevölkerungszahlen zu Bergheim bei Salzburg - absolut




Abbildung 68: Durchschnittlicher Branchenmix von Gemeinden mit ähnlicher Bevölkerungszahl: Bergheim bei Salzburg

Bergheim hätte im Vergleich zur Bevölkerungszahl-Gruppe nach dieser Auswertung mit 43% zu 47% im umliegenden Durchschnitt noch Potenzial für weitere Lebensmittelhändler. Die Auswertung könnte nun auf umsatzstarke Cluster nach Branchenmix verglichen und erfolgreiche Modelle könnten übertragen werden. Jedoch ist der Variationskoeffizient in der Gruppe relativ hoch, weshalb die Vergleichsgruppe wahlweise vergrößert, bzw. ein zusätzlicher Maßstab verwendet werden sollte.

Nun sollen die Service-Area-Einzugsgebiete mit 1-min Gehzeit um Lebensmittelhändler im Salzburger Flachgau (ohne Salzburg) ermittelt werden, damit ein regionalspezifischer Branchenmix festgestellt werden kann. In diesem Fall wird der „lokale Cluster“ jedoch nur mit Kategorien aus anderen Branchen verglichen.

Insgesamt gibt es im Flachgau 67 Lebensmittelhändler, demnach auch 67 1-min Einzugsgebiete. In keinem der kleinen Einzugsgebiete findet sich jeweils ein weiterer Lebensmittelhändler, was für das Ergebnis der Ripley's K-Analyse für ganz Österreich spricht. Zusätzlich zeigt sich folgende Verteilung:

Baumärkt.	Elektrom.	Kosmetik	MSS	Möbelh.	Sonstige	LH
2	5	13	12	4	4	0




Abbildung 69: Branchenmix in 1-min Einzugsgebieten (Service-Areas) um Lebensmittelhändler im Salzburger Flachgau

Die Verteilungen innerhalb der kleinen Zonen sind recht eindeutig, demnach sind Kosmetiker bzw. Vertreter der Kategorie Mode-Sport-Schuhe beliebte Nachbarn zu Lebensmittelhändlern im Salzburger Flachgau. Im Süden von Bergheim bestünde die Möglichkeit in der Nähe eines Händlers der Kategorie Mode-Sport-Schuhe und eines Baumarktes zu siedeln, weshalb dies noch weiter geprüft werden soll.

Der NN-Chi-Quadrat Test ergab, dass speziell die Kombination mit Baumärkten in Österreich durchaus üblich ist und diese auch oft als nächste Nachbarn gewählt werden.

		Häufigkeiten Lebensmittelhändler					
Anzahl LH		erwartet	beobachtet	Abweichung %	Chi2	p-Wert	
4331		Baumärkte	291	399	27,06%	40,0	1,37E-23
		Elektromärkte	375	332	-12,97%	4,9	
		Kosmetiker	498	543	8,20%	4,0	
		Lebensmittel	1844	1947	5,28%	5,7	
		Möbelhändler	110	71	-54,94%	13,8	
		MSS	937	727	-28,86%	47,0	
		Sonstige	275	312	11,71%	4,8	
						120,4	

		Häufigkeiten Baumärkte					
Anzahl Baumärkte		erwartet	beobachtet	Abweichung %	Chi2	p-Wert	
683		Baumärkte	46	61	24,76%	5,0	8,90E-36
		Elektromärkte	59	41	-44,26%	5,6	
		Kosmetiker	79	13	-504,72%	54,8	
		Lebensmittel	291	437	33,45%	73,5	
		Möbelhändler	17	19	8,69%	0,2	
		MSS	148	72	-105,18%	38,8	
		Sonstige	43	40	-8,60%	0,3	
						178,0	

Abbildung 70: NN-Chi-Quadrat Analyse für Lebensmittelhändler und Baumärkte in Österreich

Nach dieser Analyse muss noch geklärt werden, wie viel Abstand man mindestens zum Vertreter der eigenen Kategorie halten sollte, weshalb eine NN-Analyse für Lebensmittelhändler im Flachgau durchgeführt werden soll.

Observed Mean Distance:	1468,3865 Meters
Expected Mean Distance:	1936,8883 Meters
Nearest Neighbor Ratio:	0,758116
z-score:	-3,787694
p-value:	0,000152

Abbildung 71: Average-Nearest-Neighbor Resultate für Lebensmittelhändler im Salzburger Flachgau

Insgesamt halten die Lebensmittelhändler demnach weitaus mehr Abstand voneinander, als dies in Salzburg-Stadt (Abbildung 42) der Fall ist, jedoch ist hier insg. eine deutliche Clusteringtendenz zur eigenen Branche (Z-Score von -3,78) abgebildet. Insgesamt werden im Flachgau gut 1,5 km zur branchengleichen Konkurrenz eingehalten. Nun muss abgeschätzt werden, ob der Vorteil durch „beliebte Nachbarn“ oder der Abstand zur branchengleichen Konkurrenz bevorzugt wird, in Folge kann eine Entscheidung getroffen werden.

Diese vollständige Analysenkombination könnte auch für andere Gemeinden im benachbarten Umland erstellt und auf deren Eignung verglichen werden, um sich am Ende, nach Abklärung aller weiterer Faktoren, für einen Standort zu entscheiden. Zusätzlich kann die Analyse für einzelne Händler, anstelle von Kategorien durchgeführt werden. Natürlich sollten die vorgestellten Werte nur als Erweiterung zu anderen Indikatoren, wie Kaufkraft gesehen werden, jedoch sind diese in Kombination durchaus aussagekräftig und deren jeweilige Schwächen können durch die Betrachtung auf unterschiedlichen Maßstäben minimiert werden.

6. Diskussion

Es konnte festgestellt werden, dass Einzelhändler sich keineswegs zufällig über die Landschaft verteilen und eindeutige Muster sowohl innerhalb von Branchen, als auch zwischen Branchen festzustellen sind. Die vorgestellten Methoden bieten Möglichkeiten das facettenreiche Phänomen der Agglomeration näher zu beschreiben und können in Kombination als erweiternde Werkzeuge zu klassischen Methoden der modernen Standortplanung herangezogen werden. Auf jeder Ebene konnten auffällige Kombinationen und Meinungsverhalten zwischen und innerhalb der Branchen festgestellt werden.

Durch die Ripley's-K Analyse im Branchenvergleich konnte ein Einblick über das österreichweite Clusteringverhalten von filialisierten Einzelhändlern gegeben werden, welches ohne diese Erhebung nur schwer abzubilden gewesen wäre. Der Erhebung zufolge, clustern alle Branchen über den Erwartungen, jedoch einige merklich intensiver als andere. So konnte auf allen Distanzkreisen ein verhältnismäßig schwaches Clusteringverhalten von Baumärkten im Vergleich zu Modehändlern festgestellt werden. Lebensmittelhändler clustern kleinräumig verhältnismäßig schwach, auf großflächiger Betrachtung über 5km jedoch verstärkt. Diese Analyse ist sowohl auf andere Länder, als auch auf weitere Maßstabebenen übertragbar. Mit der Methode konnte die Annahme bestätigt werden, dass alle untersuchten Branchen bzw. Kategorien branchenintern deutlich über den Erwartungen clustern und dass dieses „Intra-Branchen-Clustering“ zwischen den Branchen deutlich unterschiedlich ausgeprägt ist.

Durch die Service-Area-Analysen konnte ein Einblick in die Datenlandschaft gegeben werden, während die gebildeten Zonen gleichzeitig für die Erstellung von Branchenmix-Übersichten dienen können, welche wiederum die „Local-Cluster-Analyse“ ermöglichen. Diese konnten am Beispiel von 1-min Gehzeit-Einzugsgebieten rund um Lebensmittelhändler zeigen, dass sich Händler der Kategorie Mode-Sport-Schuhe und Kosmetik deutlich häufiger in der Nähe von Lebensmittelhändlern befinden, als beispielsweise Elektromärkte, was jedoch hauptsächlich durch deren Anzahl bedingt wird. Diese Analyse kann somit einen erweiterten, benutzerdefinierten Einblick in die Nachbarschaft von fokalen Händlern bieten. Zieht man jedoch noch zusätzlich die relative Gesamtzahl der Punkte mit in Betracht, eignet sich die NN-Chi-Quadrat-Analyse als Erweiterung der genannten Erhebung, um weitere Faktoren der direkten Nachbarschaft zu prüfen.

Die NN-Chi-Quadrat-Analyse zeigte österreichweit beliebte Kombinationen bzw. populäre, unmittelbare Nachbarschaftsbeziehungen, welche flächendeckend hochsignifikant

von erwarteten Verteilungsmustern abweichen. So konnte beispielsweise, stark im Kontrast zur Local-Cluster-Erhebung eine Häufung der Kombination von Lebensmittelhändlern und Baumärkten festgestellt werden, welche mit anderen Erhebungsmethoden unsichtbar geblieben wäre. Auch das in der Ripley's K-Analyse festgestellte, intensive Intra-Branchen-Clustering von Möbelhändlern, konnte durch die NN-Chi-Quadrat-Analyse bestätigt werden, so siedeln diese stärker in direkter Nachbarschaft zueinander, als zu allen anderen Händlern der Vergleichsgruppe und meiden gleichzeitig Elektromärkte auffällig. Durch die genannte Methode wurden statistisch signifikante Häufungs- und Meidungsverhalten in einseitigen und zweiseitigen Nachbarschaftsbeziehungen zwischen Branchen in ganz Österreich aufgezeigt. Die Methode kann als Inspiration für Standortplanungen dienen und bei der Wahl für die direkte Nachbarschaft hilfreich sein. Zusätzlich können neben österreichweiter Erhebung, wie in der vorliegenden Arbeit vorgestellt, in weiteren Analysen auch kleinräumigere Analysegebiete herangezogen werden.

Es konnte darüber hinaus gezeigt werden, dass die ANN-Analysen für wissenschaftliche Zwecke die Möglichkeit bieten, das Clusteringverhalten bzw. die Clusteringintensität verschiedener Händler zu erheben und sowohl zwischen Branchen, als auch interzonal zu vergleichen, wenn idente Rahmenbedingungen eingehalten werden. Die ANN-Analysen bieten für Planer zusätzlich die Möglichkeit zu erheben, wie sich Vertreter der eigenen (bzw. einer fokalen) bzw. auch von anderen Branchen auf großem bzw. mittlerem Maßstab verhalten und wie viel Abstand diese durchschnittlich zueinander einhalten.

Die Branchenmix-Analysen auf verschiedenen Ebenen konnten ein Bild über die Verteilung von Branchen im interzonalen Schnitt abbilden und dadurch einen Mittel- bzw. Richtwert für die Branchenverteilung bzw. Zusammensetzung visualisieren. Auch Unterschiede in der interzonalen Variation innerhalb der Branchen konnten über die Variationskoeffizienten dargestellt werden, welche bei den Beispieldaten bei Lebensmittelhändlern und Kosmetikern deutlich erhöht waren. Der äußerst simple statistische Ansatz kann auf jegliche Zonierungsform, bzw. Maßstabsebene übertragen werden, sollten ausreichend Datenpunkte für interzonale Vergleiche gegeben sein. Das Potenzial von Branchenmix-Tabellen für interzonale Vergleiche konnte im Verlauf der Arbeit dargelegt werden. Natürlich könnten und sollten die Branchenmix-Tabellen um weitere Faktoren wie Einwohnerdichte, Demographie uvm. erweitert werden.

7. Ausblick

Während die einzelnen Methoden durchaus das Potenzial bergen weitere wissenschaftliche Erkenntnisse hervorzubringen, können diese durch Kombination auch für planerische Zwecke im wirtschaftlichen Umfeld herangezogen werden.

Agglomeration wird aktuell nur bruchstückhaft bzw. in einzelnen Aspekten beleuchtet. Die vorliegende Arbeit hat gezeigt, dass Agglomeration als vielfältiges Phänomen jedoch mit verschiedenen Methoden betrachtet und verglichen werden sollte, da die einzelnen Ausprägungen auf unterschiedlichen Maßstabsebenen nicht einheitlich sind. Die in Kapitel 3 besprochenen Einschränkungen der jeweiligen Methoden sind stets zu beachten und könnten in weiterer Folge noch weiter minimiert werden. In aufbauenden Forschungen könnten die vorgestellten Werkzeuge auf andere Kategorien und auf weiteren Maßstäben angewandt bzw. mit anderen Faktoren zur Normalisierung etc. verwendet werden. Auch die Ausweitung auf öffentliche, (teil-)staatliche bzw. infrastrukturelle Kategorien könnte für zukünftige Erhebungen in Betracht gezogen werden. Insgesamt sollte das Phänomen der Agglomeration laufend weiter erforscht und kontrolliert werden, da sowohl Wirtschaft, als auch Politik in steigendem Ausmaß davon betroffen sind.

8. Literaturverzeichnis

- Berry, B.J.L. and Parr, J.B. (1988), *Market centers and retail location: Theory and applications*, Prentice Hall, Englewood Cliffs, NJ.
- Boots, B.N. and Getis, A. (1988), *Point pattern analysis, Scientific geography series*, Vol. 8, Sage, Newbury Park.
- Brown, S. (1989), "Retail Location Theory: The Legacy of Harold Hotelling", *Journal of Retailing*, Vol. 65 No. 4, p. 450.
- Christoph Teller, Andrew Alexander and Arne Floh (2016), "The impact of competition and cooperation on the performance of a retail agglomeration and its stores", *Industrial Marketing Management*, Vol. 52, pp. 6–17.
- Cliquet, G. (2006), "Retailing in Western Europe — Structures and Development Trends", in Zentes, J. (Ed.), *Handbuch Handel: Strategien - Perspektiven - Internationaler Wettbewerb*, 1. Aufl., Gabler, Wiesbaden, pp. 112–138.
- Deiters, J. (1996), "Ist das Zentrale-Orte-System als Raumordnungskonzept noch zeitgemäss? (Is the Central Place System Still Appropriate as a Spatial Planning Concept for Our Day and Age?)", *Erdkunde*, Vol. 50 No. 1, pp. 26–34.
- Dixon, P.M. (2014), "Ripley's K Function", in Balakrishnan, N. (Ed.), *Wiley StatsRef: Statistics Reference Online*, Vol. 81, Wiley, [Erscheinungsort nicht ermittelbar], p. 403.
- Fischer, J.H. and Harrington, J.E. (1996), "Product Variety and Firm Agglomeration", *The RAND Journal of Economics*, Vol. 27 No. 2, p. 281.
- Geoland.at (2008), "Katalog Intermodales Verkehrsreferenzsystem Österreich (GIP.at). Die Graphenintegrations-Plattform Österreich (GIP.at) ist das intermodale, amtliche Verkehrsreferenzsystem Österreichs.", available at: <https://www.data.gv.at/katalog/dataset/intermodales-verkehrsreferenzsystem-osterreich-gip-at-beta> (accessed 2 November 2019).
- Gillan, J. and Gonzalez, L. (2012), "Ripley's K Function and Pair Correlation Function", available at: https://wiki.landscapetoolbox.org/doku.php/spatial_analysis_methods:ripley_s_k_and_pair_correlation_function (accessed 27 October 2019).

- Gittenberger, E., Ziniel, W. and Schwarzenecker, R. (2018), *Strukturanalyse im stationären Einzelhandel 2018*, available at: <https://www.wko.at/branchen/handel/strukturanalyse-im-stationaeren-einzelhandel-2018.pdf> (accessed 21 October 2019).
- Jacquez, G., Estberg, L., Long, A., Do, E. and Rommel, B. (2011), *ClusterSeer*, BioMedware Inc.
- Jensen, P., Boisson, J. and Larralde, H. (2005), “Aggregation of retail stores”, *Physica A: Statistical Mechanics and its Applications*, Vol. 351 No. 2-4, pp. 551–570.
- Krider, R.E. and Putler, D.S. (2013), “Which Birds of a Feather Flock Together? Clustering and Avoidance Patterns of Similar Retail Outlets”, *Geographical Analysis*, Vol. 45 No. 2, pp. 123–149.
- Kunc, J. and Križan, F. (2018), “Changing European retail landscapes: New trends and challenges”, *Moravian Geographical Reports*, Vol. 26 No. 3, pp. 150–159.
- Lee, Y. (1979), “A Nearest-Neighbor Spatial-Association Measure for the Analysis of Firm Interdependence”, *Environment and Planning A: Economy and Space*, Vol. 11 No. 2, pp. 169–176.
- Lee, Y. and Koutsopoulos, K. (1976), “A locational analysis of convenience food stores in metropolitan Denver”, *The Annals of Regional Science*, Vol. 10 No. 1, pp. 104–117.
- Long, A. (2015), “The GeoMed Project. Spatial Analysis of Disease Patterns”, available at: <http://ceadserv1.nku.edu/longa//geomed/ppa/doc/NNA/NNA.htm> (accessed 1 November 2019).
- Madelin, M., Grasland, C., Mathian, H., Sanders, L. and Vincent, J.-M. (2009), *Das „MAUP“: Modifiable Areal Unit - Problem oder Fortschritt?*, available at: <https://halshs.archives-ouvertes.fr/halshs-00424589/document>.
- Mayrhofer, M., Schneider, F., Haigner, D.S., Jenewein, S. and Walkolbinger, F. (2018), *Die unsichtbaren Kosten der Raumordnung im Lebensmitteleinzelhandel: Volkswirtschaftliche Auswirkungen des Raumordnungsrechtes der österreichischen Bundesländer für Geschäftsbauten des LEH*, Wien, available at: https://www.handelsverband.at/fileadmin/content/Presse_Publikationen/presseaussendungen/201809_PK_Raumordnung/201809_Executive-Summary_Raumordnung_LEH.pdf (accessed 13 October 2019).

- Mitchell, A. (2005), *Spatial measurements & statistics / Andy Mitchell, The ESRI guide to GIS analysis, / Andy Mitchell ; Vol. 2*, ESRI Press, Redlands, Calif.
- Ned Levine (2007), *CrimeStat: A Spatial Statistics Program for the Analysis of Crime Incident Locations (v 3.1)*, Houston, TX, and the National Institute of Justice, Washington, DC. March.
- Nilsson, I.M. and Smirnov, O.A. (2016), “Clustering vs. relative location: Measuring spatial interaction between retail outlets”, *Papers in Regional Science*, Vol. 55, p. 573.
- O'Neill, W.A., Ramsey, R.D. and Chou, J. (1992), “ANALYSIS OF TRANSIT SERVICE AREAS USING GEOGRAPHIC INFORMATION SYSTEMS”.
- Rogers, A. (1965), “A Stochastic Analysis of the Spatial Clustering of Retail Establishments”, *Journal of the American Statistical Association*, Vol. 60 No. 312, p. 1094.
- Schwarz, J. (2018), “Methodenberatung. Pearson Chi-Quadrat-Test”, available at: https://www.methodenberatung.uzh.ch/de/datenanalyse_spss/unterschiede/proportionen/pearsonuntersch.html (accessed 2 November 2019).
- STATISTIK AUSTRIA (2019), “Regionale Gliederungen”, available at: https://www.statistik.at/web_de/klassifikationen/regionale_gliederungen/index.html (accessed 8 November 2019).

9. Anhang

9.1 Weitere Ripley's K-Analysen für noch nicht abgebildete Kategorien/Branchen

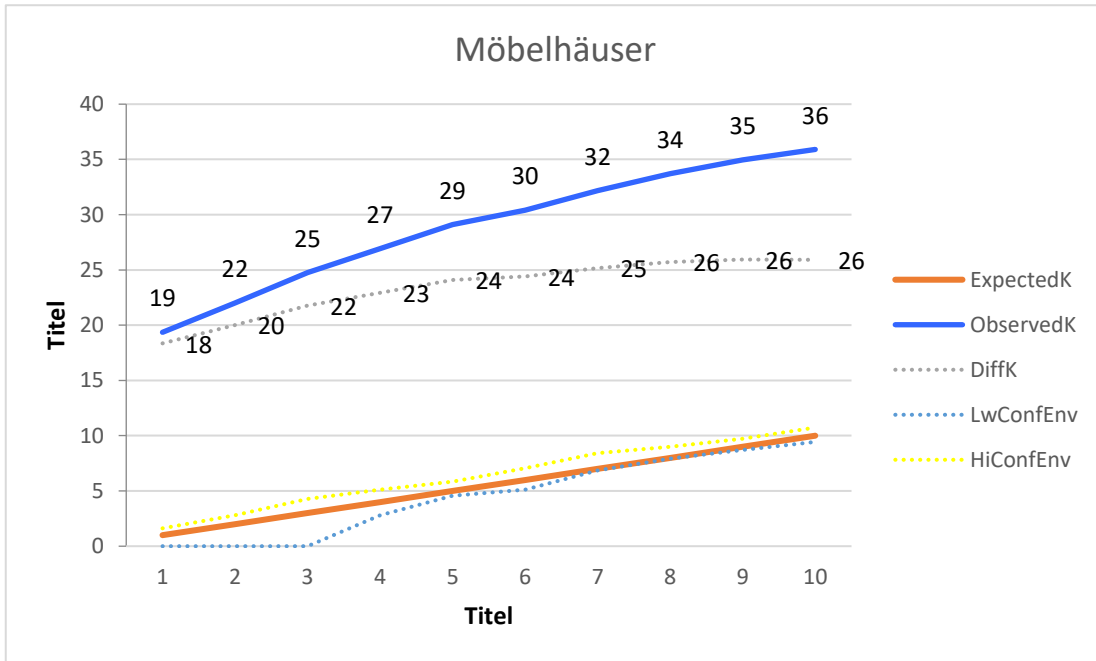


Abbildung 72: Ripley's K-Analyse für Möbelhäuser - österreichweit

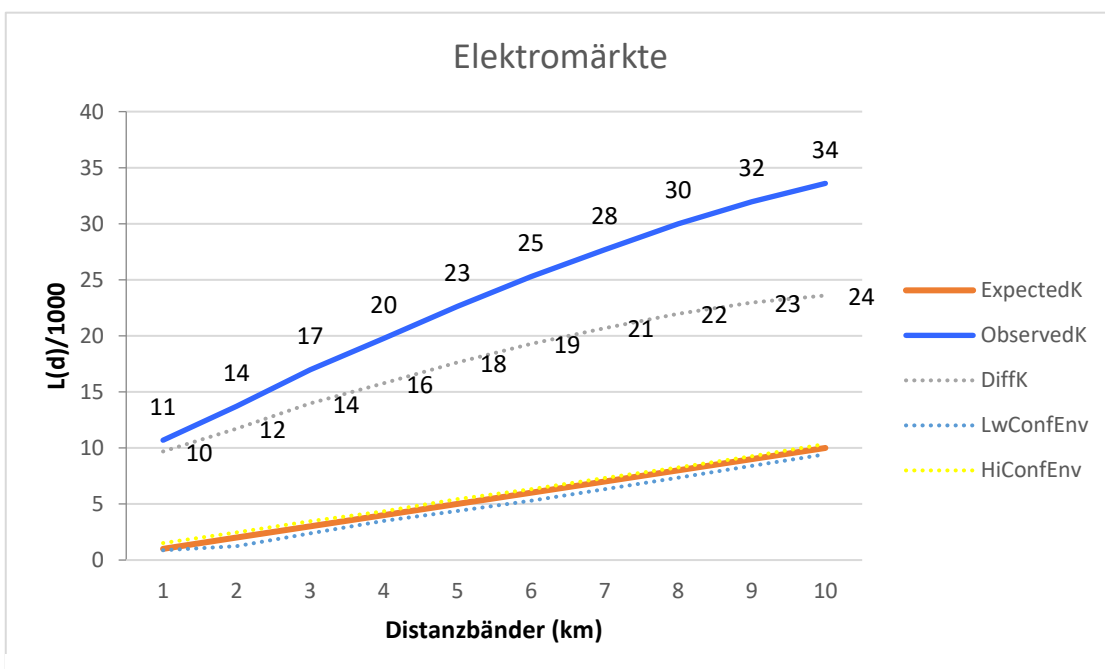


Abbildung 73: Ripley's K-Analyse für Elektromärkte - österreichweit




Abbildung 74: Ripley's K-Analyse für Mode-Sport-Schuhe - österreichweit

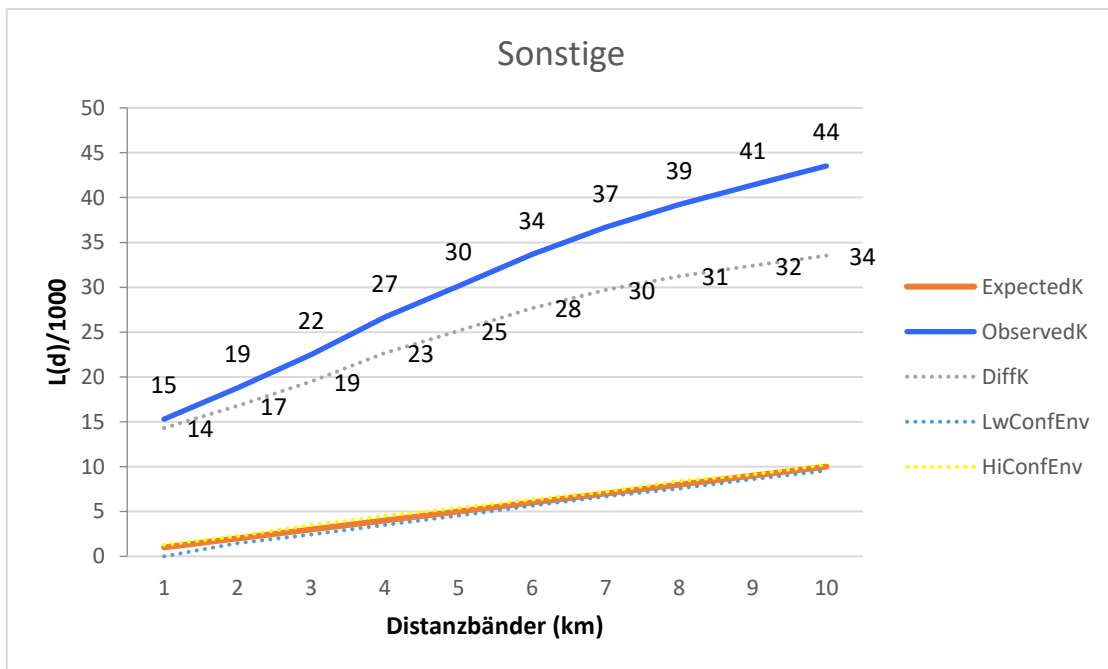


Abbildung 75: Ripley's K-Analyse für Sonstige - österreichweit

9.2 Weitere Ergebnisse der Service-Area-Analyse

Innerhalb der 1092 Einzugsgebiete mit einer Minute Gehzeit rund um Kosmetiker, fanden sich folgende Anteile der restlichen Händler: $1.237/2.200 = 56\%$ der Händler aus der Kategorie Mode, Sport Schuhe, $380/647 = 59\%$ der Händler aus der Kategorie Sonstige, lediglich $21/683 = 3\%$ der Baumärkte, $378/881 = 43\%$ der Elektromärkte, $886/4.331 = 20\%$ der Lebensmittelhändler und auch $53/258 = 20\%$ der Möbelhändler.

Sowohl im Ergebnis der Service-Area-Analyse der Lebensmittelhändler, als auch in der Analyse der Kosmetiker-Einzugsgebiete scheinen Baumärkte am geringsten von den beiden erhobenen Kategorien „abhängig“ zu sein, weshalb die Service-Areas dieser Kategorie in Folge ebenfalls beleuchtet werden sollen.

Baumärkte haben wie schon im Intra-Branchen-Clustering nun auch der Service-Area-Analyse zufolge ein Meidungsverhalten gegenüber anderen Einzelhändlern, bzw. sind sie von diesen unabhängig. Lediglich $66/22.00 = 3\%$ der Händler aus der Kategorie Mode-Sport-Schuhe, $31/647 = 5\%$ aus der Kategorie Sonstige, $26/1.171 = 2\%$ der Kosmetiker, $19/881 = 2\%$ der Elektromärkte, 3% der Lebensmittelhändler und $7/258 = 2\%$ der Möbelhäuser finden sich in deren Einzugsgebiet. Natürlich ist dieses Ergebnis stark durch die geringe Anzahl an Baumärkten gezeichnet.

9.3 Weitere Ergebnisse der Average-Nearest-Neighbor Analyse

9.3.1 Für Bezirk Salzburg

Average Nearest Neighbor Summary	
Observed Mean Distance:	2320,6989 Meters
Expected Mean Distance:	2815,4291 Meters
Nearest Neighbor Ratio:	0,824279
z-score:	-0,582258
p-value:	0,560393

Abbildung 76: Baumärkte

Average Nearest Neighbor Summary	
Observed Mean Distance:	643,6735 Meters
Expected Mean Distance:	1352,4884 Meters
Nearest Neighbor Ratio:	0,475918
z-score:	-3,614946
p-value:	0,000300

Abbildung 77: Kategorie Sonstige

Average Nearest Neighbor Summary	
Observed Mean Distance:	333,2926 Meters
Expected Mean Distance:	1470,3099 Meters
Nearest Neighbor Ratio:	0,226682
z-score:	-4,906654
p-value:	0,000001

Abbildung 78: Elektromärkte

9.3.2 Multisprengel – Wien City

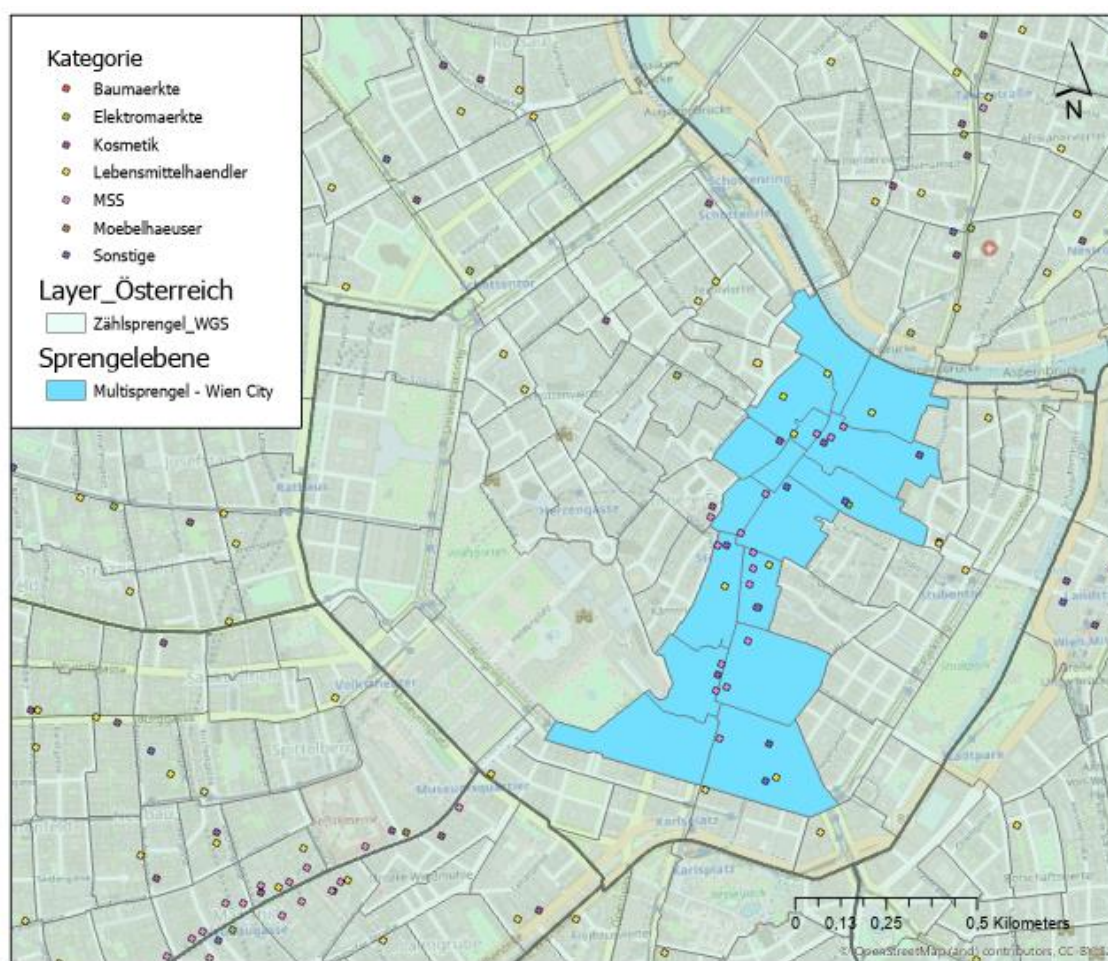


Abbildung 79: Übersicht Händler in Multisprengel: Wien City

Average Nearest Neighbor Summary

Observed Mean Distance:	284,5707 Meters
Expected Mean Distance:	209,3970 Meters
Nearest Neighbor Ratio:	1,359001
z-score:	1,817086
p-value:	0,069204

Abbildung 80: Lebensmittelhändler

Average Nearest Neighbor Summary

Observed Mean Distance:	179,9482 Meters
Expected Mean Distance:	175,1941 Meters
Nearest Neighbor Ratio:	1,027136
z-score:	0,164166
p-value:	0,869601

Abbildung 81: Kosmetiker

9.4 Weitere Ergebnisse der Branchenmix-Analyse




Abbildung 82: Branchemix der Top 20 Bezirke nach Bevölkerung

GEMEINDEEBENE: TOP 20 NACH BEVÖLKERUNG PROZENTUELL

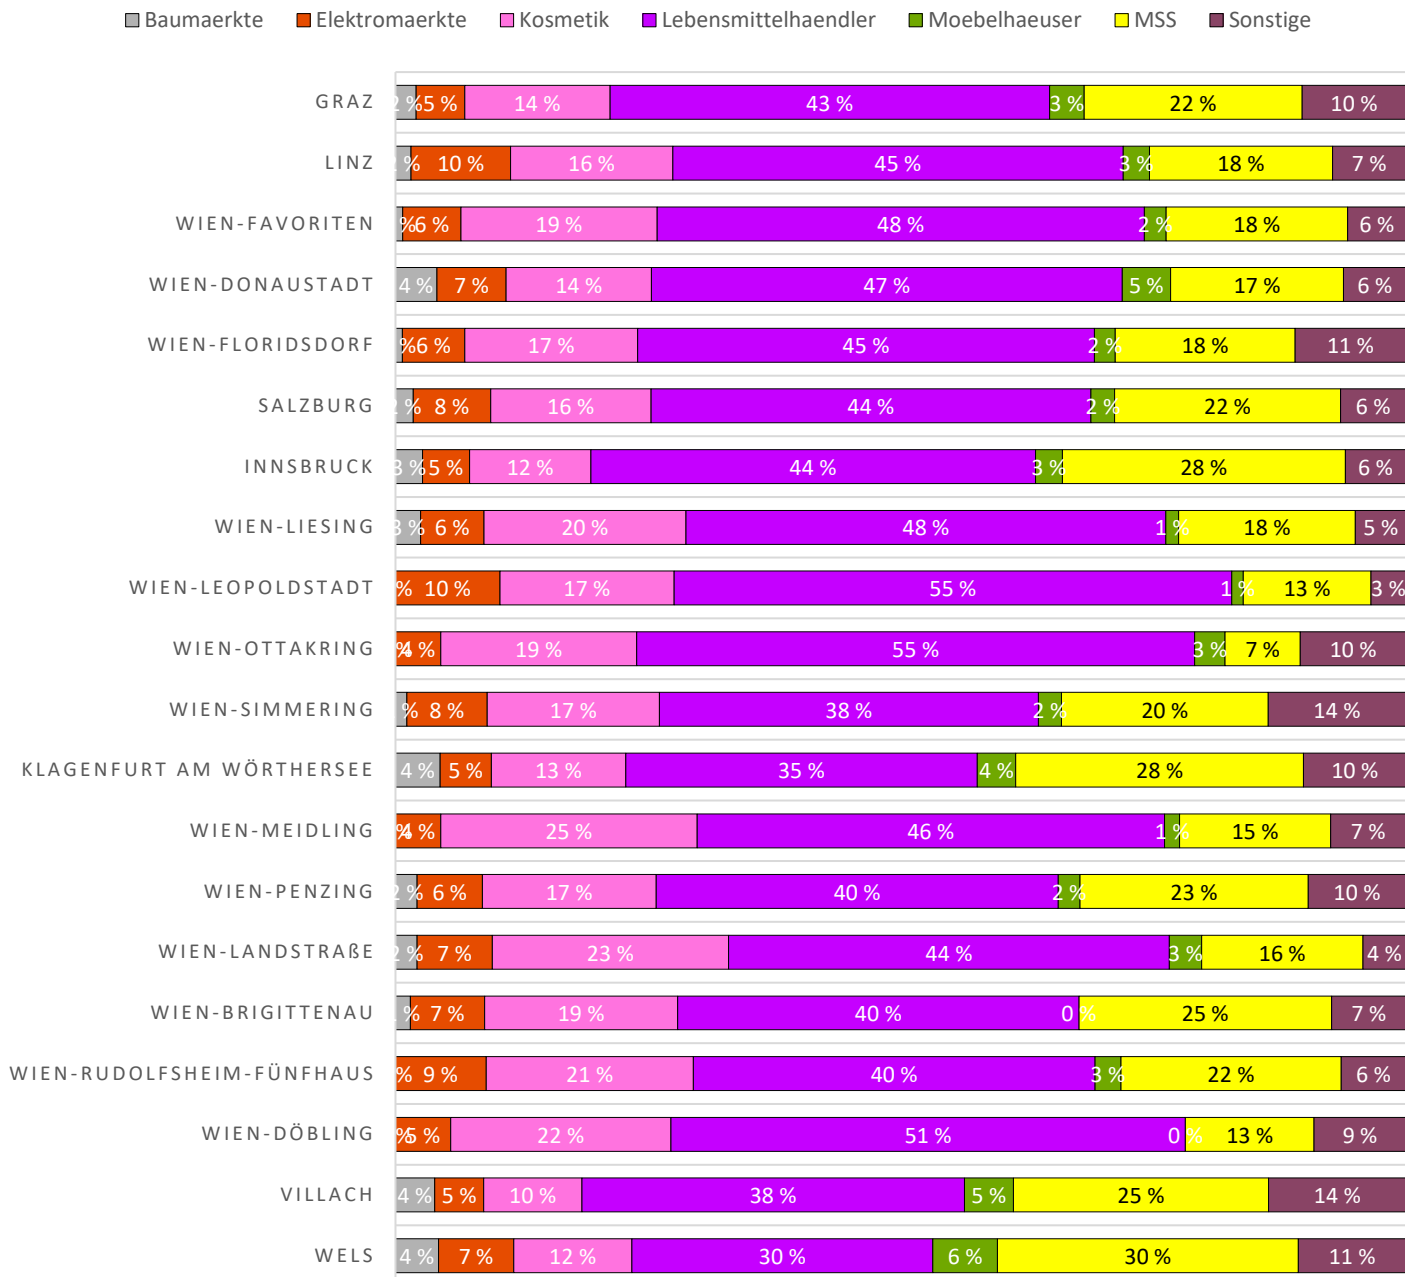


Abbildung 83: Branchenmix der Top 20 Gemeinden nach Bevölkerungszahl - prozentuell