Markus Tausendpfund

Quantitative Datenanalyse. Eine Einführung mit R

Fakultät für
Kultur- und Sozialwissen-schaften

FernUniversität in Hagen

Das Werk ist urheberrechtlich geschützt. Die dadurch begründeten Rechte, insbesondere das Recht der Vervielfältigung und Verbreitung sowie der Übersetzung und des Nachdrucks, bleiben, auch bei nur auszugsweiser Verwertung, vorbehalten. Kein Teil des Werkes darf in irgendeiner Form (Druck, Fotokopie, Mikrofilm oder ein anderes Verfahren) ohne schriftliche Genehmigung der FernUniversität reproduziert oder unter Verwendung elektronischer Systeme verarbeitet, vervielfältigt oder verbreitet werden. Wir weisen darauf hin, dass die vorgenannten Verwertungsalternativen je nach Ausgestaltung der Nutzungsbedingungen bereits durch Einstellen in Cloud-Systeme verwirklicht sein können. Die FernUniversität bedient sich im Falle der Kenntnis von Urheberrechtsverletzungen sowohl zivil- als auch strafrechtlicher Instrumente, um ihre Rechte geltend zu machen.

Der Inhalt dieses Studienbriefs wird gedruckt auf Recyclingpapier (80 g/m^2, weiß), hergestellt aus 100 % Altpapier.

Vorwort

Die vorliegende Lerneinheit behandelt die sozialwissenschaftliche Datenanalyse, R und insbesondere die sozialwissenschaftliche Datenanalyse mit R. Dabei werden Kenntnisse vermittelt, um einfache Analysen selbstständig mit der Software R durchführen zu können.

Der Text entspricht dabei weniger einem klassischen Lehrbuch, sondern eher einem Begleitkurs für die Auseinandersetzung mit dem Programm R bzw. RStudio. In diesem Sinne soll die Lerneinheit das Interesse an sozialwissenschaftlichen Fragestellungen wecken sowie die Möglichkeiten und Grenzen der quantitativen Datenanalyse aufzeigen.

Lehrmaterial, das in erster Linie zum Selbststudium angelegt ist, profitiert insbesondere durch Rückmeldungen der Leserinnen und Leser. Deshalb möchte ich mich herzlich bei allen Personen bedanken, die mich auf Fehler und Verbesserungsmöglichkeiten hingewiesen haben. Ein besonderer Dank geht an Verena Bade, Christian Cleve, Dorothee Köstlin und Simon Stocker, die sich intensiv mit der Lerneinheit beschäftigt und mich auf Ungenauigkeiten sowie Tippfehler aufmerksam gemacht haben.

Aktuelle Ergänzungen und mögliche Korrekturen zu dieser Lerneinheit finden Sie in der Moodle-Lernumgebung des Moduls M1 „Quantitative Methoden der Sozialwissenschaften“ im BA-Studiengang „Politikwissenschaft, Verwaltungswissenschaft und Soziologie“. Dort werden auch Übungsaufgaben und Videos veröffentlicht, die die Auseinandersetzung mit den Inhalten dieser Lerneinheit fördern sollen.

Ausschließlich aus Gründen der besseren Lesbarkeit wird in dieser Lerneinheit nicht durchgängig eine geschlechterneutrale Sprache verwendet. Männliche, weibliche und genderneutrale Formen wechseln sich in dieser Lerneinheit zufallsverteilt ab. Mit den Bezeichnungen sind jeweils alle Geschlechter gemeint.

Die vorliegende Lerneinheit ist kein „Endprodukt“. Die regelmäßige Aktualisierung stellt eine Daueraufgabe dar. Deshalb freue ich mich sehr über alle Hinweise und Anregungen zur weiteren Verbesserung der Lerneinheit. Sie erreichen mich unter der E-Mail-Adresse Markus.Tausendpfund@fernuni-hagen.de

Hagen, im Dezember 2022

Markus Tausendpfund

Inhaltsverzeichnis

Abbildungsverzeichnis VII
Tabellenverzeichnis VIII
1 Einführung 9
1.1 Sozialwissenschaftlicher Forschungsprozess 9
1.2 Quantitative Datenanalyse 11
1.3 Warum R? 12
1.4 Struktur der Lerneinheit 14
2 R und RStudio kennenlernen 14
2.1 Installation 15
2.1.1 R 15
2.1.2 RStudio 16
2.1.3 Pakete 20
2.1.4 Aktualisierungen 20
2.2 Ein erster Überblick 20
2.2.1 Console 21
2.2.2 Skripte 22
2.2.3 Befehle 24
2.2.4 Objekte 25
2.2.5 Vektoren 26
2.2.6 Tabellen 27
2.2.7 Erste Analysen 28
2.2.8 Fehlende Werte 30
2.2.9 Hilfe 31
3 Arbeiten mit R 32
3.1 Pakete installieren und laden 32
3.2 Daten laden 34
3.3 Daten importieren 35
3.3.1 Excel 36
3.3.2 SPSS 36
3.4 Objekttypen 37
3.5 Datenstrukturen 41
4 Beispieldatensatz 42
4.1 Daten und Pakete 42

4.2 Beispieldatensatz kennenlernen ... 42
4.3 Pipe-Operator ... 43
4.4 Datenmanagement mit dplyr ... 44
4.4.1 Variablen auswählen ... 44
4.4.2 Variablen umbenennen ... 45
4.4.3 Variablen filtern ... 46
4.4.4 Variablen verändern ... 46
4.4.5 Einfache Berechnungen ... 47
4.4.6 Weitere Optionen ... 48
4.5 Datenaufbereitung mit sjmisc ... 48
4.5.1 Variablenwerte ändern ... 48
4.5.2 Variablen zusammenfassen ... 51
4.5.3 Werte zählen ... 53
4.5.4 Weitere Optionen ... 53
4.6 Labels konvertieren ... 54
5 Univariate Datenanalyse ... 56
5.1 Daten und Pakete ... 56
5.2 Häufigkeitstabellen ... 56
5.3 Lagemaße ... 58
5.4 Streuungsmaße ... 59
5.5 Formmaße ... 60
5.6 Kompakte Übersichten ... 62
6 Bivariate Datenanalyse ... 63
6.1 Daten und Pakete ... 63
6.2 Univariate Statistiken nach Gruppen ... 63
6.3 Kreuztabellen ... 64
6.4 Zusammenhangsmaße ... 67
6.4.1 Nominalskalierte Merkmale ... 68
6.4.2 Ordinalskalierte Merkmale ... 71
6.4.3 Metrische Merkmale ... 73
7 Multivariate Datenanalyse ... 76
7.1 Einführung ... 76
7.2 Lineare Regression ... 78
7.2.1 Das Grundmodell ... 78

7.2.2 Daten und Pakete ... 86
7.2.3 Lineare Regression mit R ... 86
7.2.4 Interpretation der Ergebnisse ... 89
7.2.5 Weitere Möglichkeiten ... 92
7.2.6 Anwendungsvoraussetzungen ... 98
7.2.7 Praktische Hinweise ... 99
7.3 Logistische Regression ... 101
7.3.1 Das Grundmodell ... 101
7.3.2 Daten und Pakete ... 107
7.3.3 Logistische Regression mit R ... 108
7.3.4 Interpretation der Ergebnisse ... 109
7.3.5 Weitere Möglichkeiten ... 112
7.3.6 Praktische Hinweise ... 117
8 Inferenzstatistik ... 119
8.1 Daten und Pakete ... 119
8.2 Konfidenzintervalle ... 120
8.3 Mittelwertvergleiche (t-Test) ... 121
9 Grafiken ... 127
9.1 Einführung ... 127
9.2 Ausgewählte Diagramme ... 129
9.2.1 Säulen- und Balkendiagramm ... 129
9.2.2 Kreisdiagramm ... 131
9.2.3 Histogramm ... 132
9.2.4 Boxplot ... 133
9.2.5 Streudiagramm ... 135
9.2.6 Liniendiagramm ... 137
9.3 Weitere Pakete ... 138
Pakete im Überblick ... 139
Beispieldatensatz im Überblick ... 141
Literaturverzeichnis ... 145

Abbildungsverzeichnis

Abbildung 1: Phasen eines quantitativen Forschungsprojekts 10
Abbildung 2: The Comprehensive R Archive Network (CRAN) 15
Abbildung 3: Startbildschirm von R 16
Abbildung 4: RStudio mit drei Fenstern 17
Abbildung 5: RStudio mit vier Fenstern 18
Abbildung 6: Global Options bei RStudio 19
Abbildung 7: Streudiagramm des Einkommens in Abhängigkeit des Alters 30
Abbildung 8: Installierte Pakete 33
Abbildung 9: „Import Dataset"-Funktion in RStudio 35
Abbildung 10: Excel-Datensatz importieren 36
Abbildung 11: SPSS-Datensatz importieren 37
Abbildung 12: Normalverteilung 61
Abbildung 13: Auswahl von regressionsanalytischen Verfahren 76
Abbildung 14: Streudiagramm von Alter und Einkommen 79
Abbildung 15: Streudiagramm von Einkommen und Alter mit Regressionsgerade 80
Abbildung 16: Empirischer und geschätzter Wert einer linearen Regression 81
Abbildung 17: Grafische Darstellung einer multiplen Regression 85
Abbildung 18: Lineare Regressionsfunktion 103
Abbildung 19: Logistische Regressionsfunktion 104
Abbildung 20: Logistische Regression (Beispieldaten) 107
Abbildung 21: Grafische Darstellung der logistischen Regression I 116
Abbildung 22: Grafische Darstellung der logistischen Regression II 117
Abbildung 23: Aussage über die Grundgesamtheit auf Basis einer Zufallsstichprobe 123
Abbildung 24: Säulen- und Balkendiagramm 130
Abbildung 25: Kreisdiagramm 131
Abbildung 26: Histogramm 132
Abbildung 27: Elemente eines Boxplots 133
Abbildung 28: Boxplots 134
Abbildung 29: Plotsymbole bei R 136
Abbildung 30: Streudiagramm 136
Abbildung 31: Liniendiagramm 137

Tabellenverzeichnis

Tabelle 1: SPSS, Stata und R im Überblick ... 13
Tabelle 2: Mathematische Funktionen in R ... 21
Tabelle 3: Logische Abfragen in R ... 22
Tabelle 4: Installieren und Laden von Paketen ... 33
Tabelle 5: Beispieldatensatz (peanuts_r) ... 34
Tabelle 6: Ausgewählte Funktionen zum Testen und Konvertieren von Objekten ... 39
Tabelle 7: Objekttypen in den Datensätzen ... 40
Tabelle 8: Ausgewählte Funktionen von dplyr ... 44
Tabelle 9: Auswahl von Filter-Möglichkeiten ... 46
Tabelle 10: Ausgewählte Möglichkeiten des rec-Arguments ... 50
Tabelle 11: Interpretation von Schiefe und Wölbung ... 62
Tabelle 12: Kreuztabelle zwischen Wahlbeteiligung und Bildung ... 66
Tabelle 13: Zusammenhangsmaße bei der bivariaten Datenanalyse ... 68
Tabelle 14: Arbeitstabelle für die Berechnung von Chi-Quadrat ... 69
Tabelle 15: Interpretation von Cramer's V ... 71
Tabelle 16: Interpretation von Spearman's Rho ... 73
Tabelle 17: Interpretation des Korrelationskoeffizienten nach Pearson ... 75
Tabelle 18: Beispieldaten für Alter und Einkommen ... 78
Tabelle 19: Bivariate Regression (Beispieldaten) ... 83
Tabelle 20: Beispieldaten für Alter, Einkommen und Berufserfahrung ... 84
Tabelle 21: Multiple Regression (Beispieldaten) ... 85
Tabelle 22: Bestimmungsfaktoren der Lebenszufriedenheit I ... 87
Tabelle 23: Bestimmungsfaktoren der Lebenszufriedenheit II ... 88
Tabelle 24: Bestimmungsfaktoren der Lebenszufriedenheit III ... 89
Tabelle 25: Bestimmungsfaktoren der Lebenszufriedenheit IV ... 93
Tabelle 26: Bestimmungsfaktoren der Lebenszufriedenheit V (standardisierte Koeffizienten) ... 94
Tabelle 27: Bestimmungsfaktoren der Lebenszufriedenheit V (mit Faktoren) ... 96
Tabelle 28: Bestimmungsfaktoren der Lebenszufriedenheit VI (Regressionstabelle mit sjPlot) ... 97
Tabelle 29: Informationen zu einer linearen Regression ... 98
Tabelle 30: Beispieldaten für Rauchen und Alter in Jahren ... 102
Tabelle 31: Bestimmungsfaktoren des Tabakkonsums ... 106
Tabelle 32: Bestimmungsfaktoren der Wahlbeteiligung ... 109
Tabelle 33: Bedeutung der Asteriske ... 111
Tabelle 34: Logistische Regressionskoeffizienten und Odds Ratio im Vergleich ... 113
Tabelle 35: t-Test der Lebenszufriedenheit in Abhängigkeit des Geschlechts ... 124
Tabelle 36: t-Test der Demokratiezufriedenheit in Abhängigkeit des politischen Interesses ... 125
Tabelle 37: Argumente beim t-Test ... 126
Tabelle 38: Argumente bei Grafikbefehlen ... 127
Tabelle 39: Pakete zur Erstellung von Grafiken ... 138
Tabelle 40: Pakete im Überblick ... 139
Tabelle 41: Beispieldatensatz im Überblick ... 141

1 Einführung

Vorschau

Die quantitative Datenanalyse ist die Phase im sozialwissenschaftlichen Forschungsprozess, in der die theoretisch entwickelten Hypothesen empirisch geprüft werden. In diesem Kapitel werden die einzelnen Phasen des Forschungsprozesses knapp skizziert, die Bedeutung der Methodenkompetenz für die Auseinandersetzung mit empirischen Studien dargelegt und Statistikprogramme vorgestellt. Die Einführung schließt mit einem Ausblick auf die weiteren Kapitel dieser Lerneinheit und verweist auf ergänzende Materialien in der Moodle-Lernumgebung.

1.1 Sozialwissenschaftlicher Forschungsprozess

In einem quantitativen Forschungsprojekt lassen sich idealtypisch mehrere Phasen unterscheiden (siehe Abbildung 1). Nach der Entscheidung für ein Forschungsthema und der Entwicklung einer Forschungsfrage (1) müssen zunächst die zentralen Konzepte der Forschungsfrage identifiziert und theoretisch geklärt werden (2). Auf dieser Grundlage können Hypothesen formuliert (3) und Operationalisierungen der Konzepte (4) entwickelt werden (ausführlicher Tausendpfund 2018).

Bedeutung des Forschungsstands

Diese Phasen eines Forschungsprojekts erfolgen in intensiver Auseinandersetzung mit der existierenden Fachliteratur. Nur wer den Forschungsstand zu seinem Forschungsthema kennt, kann eine gehaltvolle Forschungsfrage entwickeln. Die Auseinandersetzung mit der Fachliteratur ist aber auch für die Konzeptspezifikation und die Entwicklung von Hypothesen erforderlich. Schließlich ist auch bei der „Übersetzung“ theoretischer Konzepte in empirische Indikatoren ein Überblick existierender Operationalisierungen notwendig.

Bei einer Primäranalyse werden neue Daten erhoben, um die Forschungsfrage zu untersuchen. Bei einer Sekundäranalyse werden existierende Daten genutzt, um die Forschungsfrage zu bearbeiten (5). Falls für die Bearbeitung einer Forschungsfrage bereits geeignetes Datenmaterial existiert, dann können die Phasen Forschungsdesign (6), Auswahlverfahren (7) und Datenerhebung (8) „übersprungen“ werden.

Die Datenaufbereitung und -analyse stellt eine Phase in einem sozialwissenschaftlichen Forschungsprojekt dar (9). In dieser Phase werden die theoretisch formulierten Hypothesen empirisch geprüft. Mittlerweile existieren zahlreiche Verfahren der Datenanalyse (für einen Überblick siehe z.B. Wolf und Best 2010a; Backhaus et al. 2021); alle Verfahren setzen jedoch eine vorherige intensive Auseinandersetzung mit dem jeweiligen Forschungsstand voraus. Mit anderen Worten: Die Datenanalyse kann die vorherige Auseinandersetzung mit dem Forschungsstand nicht ersetzen.

In Publikationen (10) werden die Forschungsergebnisse der Öffentlichkeit zugänglich gemacht.

Abbildung 1: Phasen eines quantitativen Forschungsprojekts

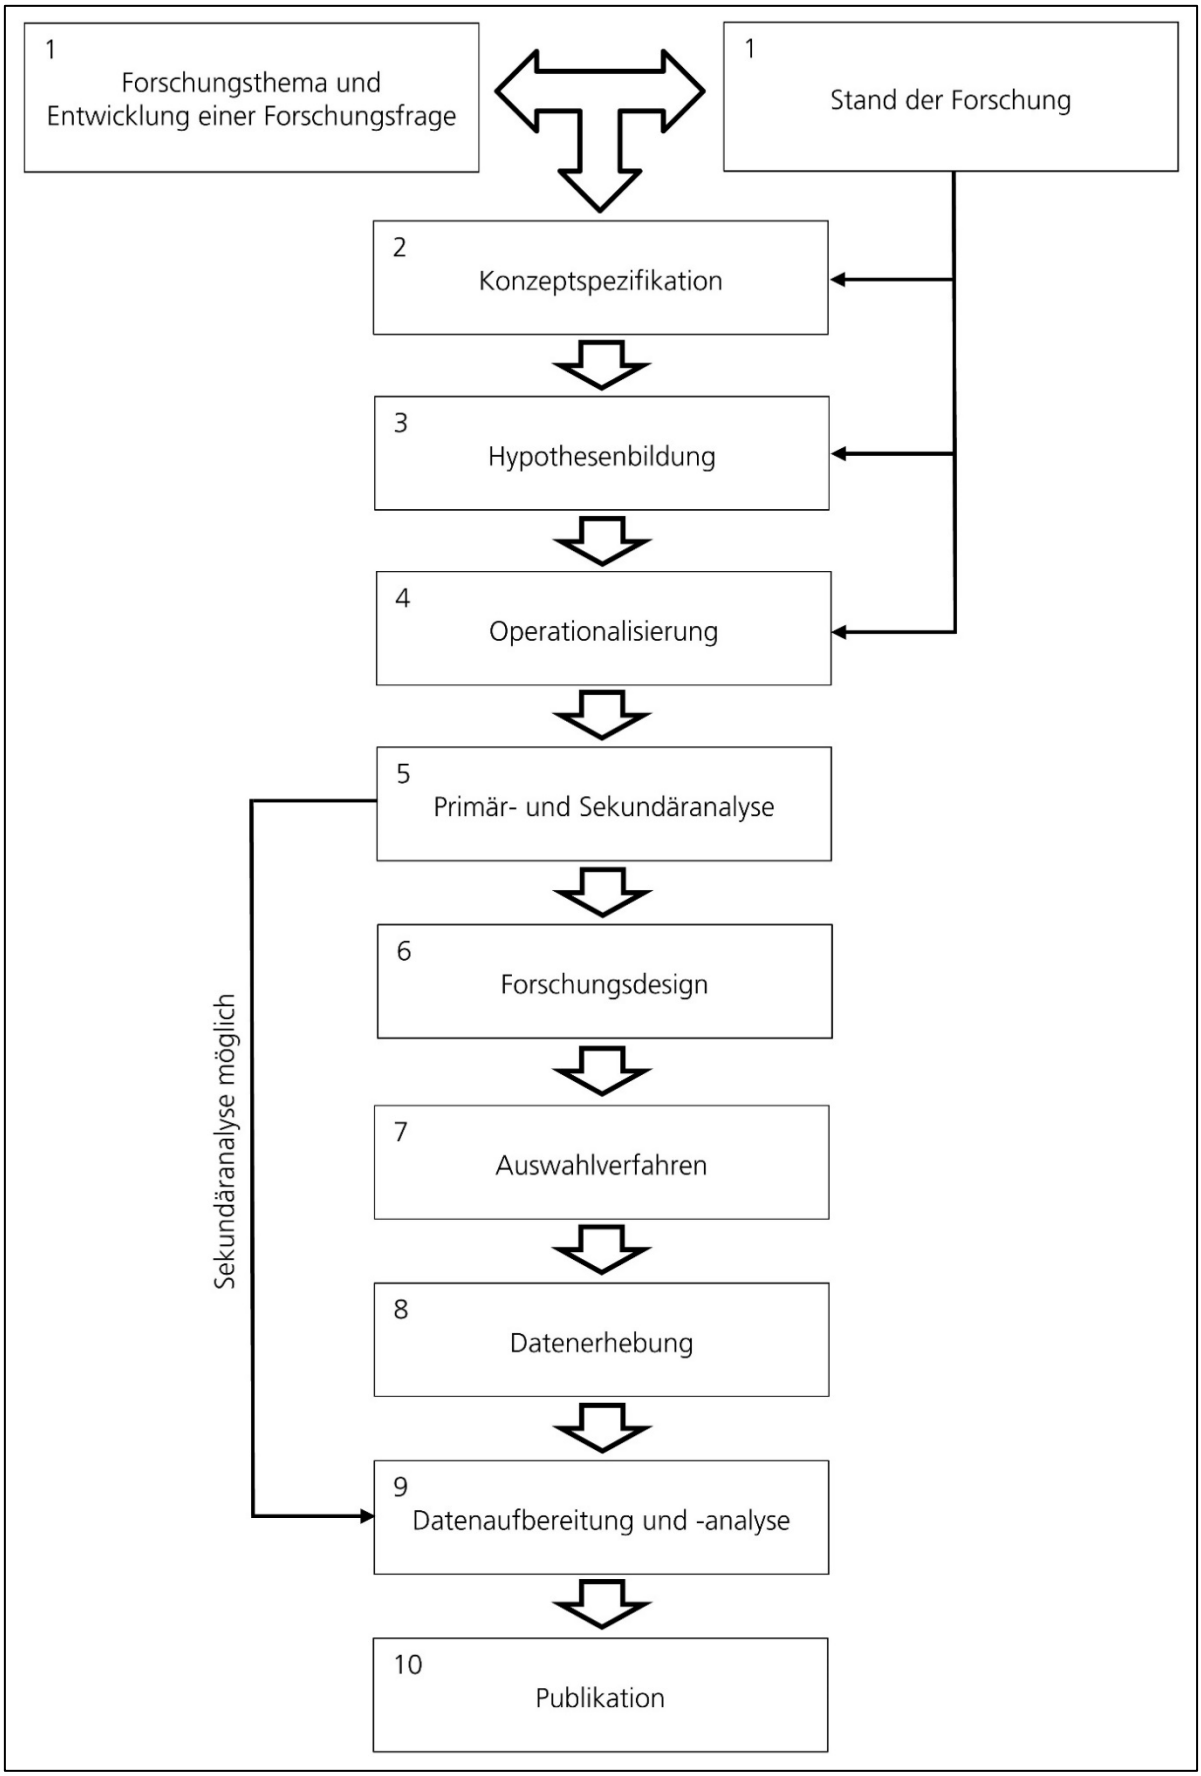

Quelle: Eigene Darstellung