



 **Universität Trier**

Bernhard Baltes-Götz

Statistisches Praktikum mit IBM SPSS Statistics 22 für Windows

2016 (Rev. 160520)

Herausgeber: Zentrum für Informations-, Medien- und Kommunikationstechnologie (ZIMK)
an der Universität Trier
Universitätsring 15
D-54286 Trier
WWW: zimk.uni-trier.de
E-Mail: zimk@uni-trier.de

Autor: Bernhard Baltes-Götz
E-Mail: baltes@uni-trier.de

Copyright © 2016; ZIMK

Vorwort

Das seit Jahrzehnten bewährte und ständig aktualisierte Statistikprogramm **SPSS** (*Statistical Package for the Social Sciences*) trägt seit der Übernahme des Herstellers durch die Firma IBM den Namen **IBM SPSS Statistics**. Wir verwenden im Manuskript den kompakten Namen **SPSS** und reden dabei über ein weitgehend komplettes und relativ leicht zu bedienendes Statistikprogramm, das in den Geo-, Wirtschafts- und Sozialwissenschaften stark verbreitet ist und alle wichtigen Betriebssysteme für Arbeitsplatzrechner unterstützt (Linux, Mac OS X, Windows).

Im Vergleich zu alternativen Statistikprogrammen mit einem vergleichbaren breiten Einsatzspektrum (z.B. R, SAS, Stata) sind vor allem die folgenden Pluspunkte von SPSS zu nennen:

- Einfache Bedienung
- Gute Unterstützung durch die Statistikliteratur und frei verfügbare Anleitungen
- Gute Erweiterbarkeit und entsprechend zahlreich vorhandene Lösungen (Makros, Extensions, etc.)

Robert A. Muenchen vergleicht auf einer populären Webseite die wichtigsten Statistikprogramme bzgl. diverser Kriterien (z.B. Stellenangebote, Nutzung in Forschungsartikeln).¹ In der Kategorie *Number of Scholarly Articles* war SPSS im Jahr 2014 einsame Spitze, was Herr Muenchen so erklärt:

SPSS is by far the most dominant package, perhaps due to its balance between power and ease-of-use.

Die freie Statistik-Programmiersprache R muss nicht als *Konkurrenz* zu SPSS, sondern kann ebenso gut als *Ergänzung* zu SPSS angesehen werden. Über eine Erweiterungslösung der Firma IBM kann man in SPSS die mit R entwickelten Funktionen nutzen, so dass ein funktionales Gespann aus SPSS und R entsteht (siehe Baltes-Götz 2016a).

Im vorliegenden Manuskript wird ein Einblick in die statistische Datenanalyse mit der SPSS-Version 22 für Windows vermittelt. Wesentliche Teile des Manuskripts sind wegen der weitgehend konsistenten Bedienungslogik auch für andere SPSS-Versionen ab 16 unter Windows oder alternativen Betriebssystemen verwendbar.

Das Manuskript dient primär als Begleitlektüre zum Kurs *Statistisches Praktikum mit SPSS*, den das *Zentrum für Informations-, Medien- und Kommunikationstechnologie (ZIMK)* an der Universität Trier anbietet, kann jedoch auch im Selbststudium verwendet werden.

Zielgruppe und Voraussetzungen

Der Kurs ist konzipiert für Personen, die *in wesentlichem Umfang* bei Forschungsarbeiten mit SPSS mitwirken wollen (z.B. im Rahmen einer eigenen Studie oder als Mitglied in einem Forschungsteam). Wer lediglich einfache Teilaufgaben zu erledigen hat (z.B. wenige Auswertungen mit einer bereits vorhandenen und fehlerbereinigten SPSS-Datendatei), sollte eventuell die vom ZIMK ebenfalls angebotene zweistündige SPSS-Kurzeinführung besuchen oder das zugehörige Manuskript lesen.²

¹ <http://r4stats.com/articles/popularity/>

² Es ist als PDF-Dokument auf dem Webserver der Universität Trier an derselben Stelle zu finden wie die aktuelle Ausgabe des vorliegenden Manuskripts (siehe unten).

Im Kurs wird eine *methodologische Grundausbildung* (empirische Forschung, Statistik) vorausgesetzt, wie sie üblicherweise in den Studiengängen empirisch-statistisch forschender Disziplinen vermittelt wird. Begriffe aus der univariaten Verteilungsanalyse (z.B. Mittelwert, Median, Varianz) sollten ebenso geläufig sein wie einfache Verfahren der Zusammenhangsanalyse (z.B. t-Test, lineare Regression).

Kursinhalte und Lernziele

Im Sinne einer *praxisnahen und projektorientierten Ausbildung* wird im Kurs bzw. Manuskript eine vollständige empirische Studie von der ersten Idee über die Untersuchungsplanung, sowie die Kodierung, Erhebung, Erfassung, Kontrolle, Korrektur und Modifikation der Daten bis zur statistischen Auswertung und zur Verwertung der Ergebnisse durchgeführt. Alle methodologischen Entscheidungen im Demonstrationsprojekt werden sorgfältig begründet (z.B. die Auswahl der statistischen Verfahren).

Wir konzentrieren uns darauf, in anderen Veranstaltungen (z.B. zur empirischen Forschung oder Statistik) erlernte Begriffe und Methoden *mit dem EDV-Werkzeug SPSS in der Praxis anzuwenden*. Zwar werden im Kursverlauf viele methodologische Themen (z.B. Verteilungsanalyse, Konfidenzintervall, Logik von Signifikanztests) in knapper Form erläutert, doch kann dabei eher vorhandenes Wissen aufgefrischt und vertieft als neues erworben werden. Insbesondere kann die Anwendung und Diskussion der vielfältigen *statistischen Modelle bzw. Auswertungsmethoden nur exemplarisch* stattfinden. Eine gründliche Behandlung ist nur bei wenigen, besonders häufig eingesetzten Verfahren möglich (z.B. bei der Kreuztabellenanalyse).¹

Insgesamt sollten mit dem Kurs bzw. Manuskript u.a. die folgenden Lernziele erreicht werden:

- **Zentrale Denk- und Arbeitsweisen der statistisch-empirischen Forschung nachvollziehbar machen**
- **Wichtige Techniken für das rationelle Arbeiten mit SPSS vermitteln**

Zwar werden auch in EDV-handwerklicher Sicht die SPSS-Optionen nicht annähernd vollständig behandelt, doch sollten Sie nach dem Kurs mit den erworbenen Grundkenntnissen und unter Verwendung der aufgezeigten Informationsmöglichkeiten selbständig und erfolgreich mit SPSS arbeiten können.

¹ Zu vielen Auswertungsmethoden bietet das ZIMK spezielle Kurse an, in denen die wesentlichen methodologischen Grundlagen und natürlich die praktische Durchführung mit SPSS erläutert werden. Informationen über das ZIMK-Kursprogramm finden Sie z.B. auf dem WWW-Server der Universität Trier von der Startseite (<http://www.uni-trier.de/>) ausgehend über:

[IT-Services \(ZIMK\)](#) > [Services für Studierende](#) > [Kursangebot](#)

Zu den meisten Kursen sind ausführliche Manuskripte entstanden, die Sie auf dem Webserver der Universität Trier folgendermaßen finden:

[IT-Services \(ZIMK\)](#) > [Downloads & Broschüren](#) > [Statistik](#)

Dateien zum Kurs bzw. Manuskript

Die aktuelle Version dieses Manuskripts ist als PDF-Dokument zusammen mit den im Kurs benutzen Dateien auf dem Webserver der Universität Trier von der Startseite (<http://www.uni-trier.de/>) ausgehend folgendermaßen zu finden:

[IT-Services \(ZIMK\)](#) > [Downloads & Broschüren](#) > [Statistik](#) >
[Statistisches Praktikum mit SPSS für Windows](#)

Leser im Selbststudium können mit den zur Verfügung gestellten Dateien fast alle Arbeitsschritte im Beispielprojekt des Kurses konkret durchführen.¹

Kritik und Verbesserungsvorschläge zum Manuskript werden dankbar entgegen genommen (z.B. unter der Mail-Adresse baltes@uni-trier.de).

Trier, im Mai 2016

Bernhard Baltes-Götz

¹ Zugunsten der guten Lesbarkeit beschränkt sich das Manuskript meist auf die männliche Form.

Inhaltsverzeichnis

Vorwort	III
Inhaltsverzeichnis	VI
1 Von der Theorie bis zu den SPSS-Variablen	1
1.1 Statistik und EDV als Hilfsmittel der empirischen Forschung	1
1.1.1 Kluge Entscheidungen trotz Unsicherheit	1
1.1.2 Statistische Aufgabenstellungen und Methoden	2
1.1.2.1 Punkt- und Intervallschätzung	2
1.1.2.2 Hypothesenprüfung	3
1.1.2.3 Modellierung	5
1.1.3 Lügen	7
1.1.4 Keine statistische Praxis ohne EDV	7
1.2 Planung und Durchführung einer empirischen Untersuchung im Überblick	7
1.2.1 Forschungsziele, Hypothesen und Modelle	7
1.2.2 Nutzung vorhandener Daten	8
1.2.3 Untersuchungsplanung	9
1.2.3.1 Untersuchungseinheiten, Population und Merkmale	9
1.2.3.2 Untersuchungsdesign	10
1.2.3.3 Operationalisierung der zu untersuchenden Merkmale	11
1.2.3.4 Empirisch prüfbare Hypothesen (über Modellparameter) formulieren	11
1.2.3.5 Statistisches Entscheidungsverfahren	12
1.2.3.6 Stichprobenrekrutierung	13
1.2.3.7 Datendeklaration und Kodierplan	13
1.2.4 Daten erfassen, prüfen und korrigieren	14
1.2.5 Datentransformation	14
1.2.6 Statistische Datenanalyse	14
1.3 Theorie und Untersuchungsplanung im Demonstrationsprojekt	15
1.3.1 Die allgemeinspsychologische KFA-Hypothese	15
1.3.2 Untersuchungsplanung	15
1.3.2.1 Untersuchungseinheiten, Population, Merkmale, Design und Operationalisierung	15
1.3.2.2 Formulierung und Illustration der empirisch prüfbaren Hypothese	16
1.3.2.3 Entscheidungsverfahren	17
1.3.2.4 Stichprobenumfangsplanung	18
1.3.3 Eine differentialpsychologische Hypothese	21
1.3.4 Demografische Merkmale	24
1.3.5 Zu Übungszwecken erhobene Merkmale	25
1.3.6 Der Fragebogen	26
1.4 Strukturierung und Kodierung der Daten	27
1.4.1 Fälle und Merkmale in SPSS	28
1.4.2 Strukturierung	29
1.4.2.1 Variablen zur Fallidentifikation	29
1.4.2.2 Abgeleitete Variablen gehören nicht in den Kodierplan	29
1.4.2.3 Mehrfachwahlfragen	30
1.4.2.3.1 Vollständige Sets aus dichotomen Variablen	30
1.4.2.3.2 Sparsame Sets aus kategorialen Variablen	30
1.4.2.4 Offene Fragen	32

1.4.3	Kodierung	33
1.4.3.1	Die wichtigsten Variablentypen in SPSS	33
1.4.3.2	Fehlende Werte	34
1.4.3.2.1	Benutzerdefinierte MD-Indikatoren	34
1.4.3.2.2	System-Missing (SYSMIS)	35
1.4.3.2.3	Fehlende Werte bei Zeichenfolgenvariablen	36
1.4.3.2.4	Fehlende Werte bei Mehrfachwahl-Fragen und offenen Fragen	36
1.4.3.2.5	Vereinfachung der Erfassung durch Datentransformationstechniken	37
1.4.3.3	Fehlerquellen bei der manuellen Datenerfassung minimieren	39
1.4.3.4	Variablennamen	39
1.4.3.5	Kodierplan	40
1.5	Durchführung der Studie (inklusive Datenerhebung)	42
2	Einstieg in SPSS für Windows	44
2.1	SPSS-Produkte an der Universität Trier	44
2.2	Programmstart und Benutzeroberfläche	45
2.2.1	SPSS starten	45
2.2.2	Die wichtigsten SPSS-Fenster	46
2.2.3	Was man mit SPSS so alles machen kann	47
2.3	Hilfesystem	48
2.3.1	Systematische Informationen	48
2.3.2	Gezielte Suche nach Begriffen	49
2.3.3	Kontextsensitive Hilfe zu den Dialogboxen	49
2.3.4	Lernprogramm	49
2.3.5	Statistik-Assistent	49
2.4	Weitere Informationsquellen	50
2.4.1	Handbücher und Manuskripte	50
2.4.2	SPSS im Internet	51
2.4.3	ZIMK - Service-Punkte	51
2.5	SPSS für Windows beenden	51
3	Datenerfassung und SPSS-Dateneditor	52
3.1	Methoden zur Datenerfassung	52
3.1.1	Online-Datenerhebung	52
3.1.2	Manuelle Verfahren	54
3.1.2.1	Datenerfassung nach einer Papier-gestützten Datenerhebung	54
3.1.2.2	Interviews mit sofortiger Datenerfassung	55
3.2	Erfassung mit dem SPSS-Dateneditor	55
3.2.1	Dateneditor, Datenblatt und Arbeitsdatei	56
3.2.2	Variablen definieren	57
3.2.2.1	Das Datenfenster-Registerblatt Variablenansicht	57
3.2.2.2	Die SPSS-Variablenattribute	58
3.2.2.3	Variablendefinition durchführen	61
3.2.2.4	Variablen einfügen, löschen oder verschieben	64
3.2.2.4.1	Variablen einfügen	64
3.2.2.4.2	Variablen löschen	64
3.2.2.4.3	Variablen verschieben	65
3.2.2.5	Attribute auf andere Variablen übertragen	65
3.2.2.5.1	Variablendeklaration vervielfältigen	65
3.2.2.5.2	Alle Attribute einer Variablen auf andere Variablen übertragen	67
3.2.2.5.3	Einzelne Attribute einer Variablen auf andere Variablen übertragen	67
3.2.2.5.4	Übung	68
3.2.2.6	Numerische Kodierung auch bei nominalskalierten Merkmalen	68

3.2.2.7	Benutzerdefinierte MD-Indikatoren	68
3.2.2.8	Übung	69
3.2.3	Sichern eines Datenblatts als SPSS-Datendatei	69
3.2.4	Rohdatendatei, Transformationsprogramm und Fertigdatendatei	72
3.2.5	Dateneingabe	73
3.2.6	Daten korrigieren	74
3.2.6.1	Wert einer Zelle ändern	74
3.2.6.2	Einen Fall einfügen	75
3.2.6.3	Einen Fall löschen	75
3.2.6.4	Fälle verschieben	75
3.2.7	Weitere Möglichkeiten des Dateneditors	75
3.2.8	Übung	76
4	Univariate Verteilungs- und Fehleranalysen	77
4.1	Fehlerhafte Werte aufspüren	77
4.1.1	Suche nach unzulässigen Werten	78
4.1.2	Einzelprüfung aller Werte	79
4.2	Öffnen von Datendateien	80
4.2.1	SPSS-Datendateien	80
4.2.2	Andere Formate	80
4.3	Verteilungsanalysen für kategoriale Variablen	81
4.4	Arbeiten mit dem Ausgabefenster (Teil I)	86
4.4.1	Arbeiten im Navigationsbereich	86
4.4.1.1	Fokus positionieren	86
4.4.1.2	Ausgabeblocke bzw. Teilausgaben aus- oder einblenden	87
4.4.1.3	Ausgabeblocke oder Teilausgaben markieren	87
4.4.1.4	Ausgabeblocke oder Teilausgaben löschen oder verschieben	87
4.4.2	Viewer-Dokumente drucken	87
4.4.3	Ausgaben sichern und öffnen	88
4.4.4	Objekte via Zwischenablage in andere Anwendungen übertragen	88
4.4.5	Ausgaben exportieren	90
4.4.6	Mehrere Ausgabefenster verwenden	91
4.4.7	Übung	92
4.5	Verteilungsanalysen für metrische Merkmale	92
4.5.1	Lagemaße	93
4.5.2	Streuungsmaße	94
4.5.3	Schiefe und Wölbung	95
4.5.3.1	Schiefe	95
4.5.3.2	Wölbung (Kurtosis)	97
4.5.3.3	Übung	97
4.5.4	Diskussion ausgewählter Ergebnisse	98
4.5.5	Median und andere Perzentile aus gruppierten Daten	100
4.6	Übung	101
4.7	Suche nach Daten	102
4.8	Populationsanteil einer Kategorie und Vertrauensintervall	104
4.8.1	Vertrauensintervall verstehen und näherungsweise berechnen	105
4.8.2	Jeffreys-Vertrauensintervall von SPSS berechnen lassen	107
4.8.2.1	Anforderung	107
4.8.2.2	Handhabung der Modellviewer-Ergebnisanzeige	110
4.8.2.3	Modelviewer abschalten	112
4.8.3	Stichprobenumfang für eine gewünschte Präzision berechnen	112

5	Speichern der SPSS-Kommandos zu wichtigen Anweisungsfolgen	116	
5.1			Zur Motivation 116
5.2	Dialogunterstützte Erstellung von SPSS-Programmen	118	
5.3	Arbeiten mit dem Syntax-Fenster	123	
5.4	Elementare Regeln zur SPSS-Syntax	124	
6	Datentransformation	127	
6.1	Vorbemerkungen	127	
6.1.1	Transformationsprogramm	127	
6.1.2	Datensicherheit	128	
6.1.3	Initialisierung neuer numerischer Variablen	130	
6.2	Alte Werte einer Variablen auf neue abbilden (Umkodieren)	130	
6.2.1	Das praktische Vorgehen am Beispiel einer Gruppenbildung	130	
6.2.2	Technische Details	133	
6.2.3	Übungen	135	
6.2.4	Visuelles Klassieren	136	
6.3	Zur Rolle des EXECUTE-Kommandos	139	
6.4	Berechnung von Variablen nach mathematischen Formeln	140	
6.4.1	Beispiel	141	
6.4.2	Technische Details	143	
6.4.2.1	Numerische Funktionen	143	
6.4.2.2	Regeln für die Bildung numerischer Ausdrücke	146	
6.4.2.3	Sonstige Hinweise	147	
6.4.3	Übungen	147	
6.5	Bedingte Datentransformation	149	
6.5.1	Beispiel	149	
6.5.2	Bedingungen formulieren	152	
6.5.2.1	Vergleich	152	
6.5.2.2	Logischer Ausdruck	152	
6.5.2.3	Regeln für die Auswertung logischer Ausdrücke	153	
6.5.3	Übung	154	
6.6	Häufigkeit bestimmter Werte bei einem Fall ermitteln	155	
6.7	Erstellung der Fertigdatendatei mit dem Transformationsprogramm	157	
6.7.1	Transformationsprogramm vervollständigen	157	
6.7.2	Transformationsprogramm ausführen	161	
7	Hypothesentests	164	
7.1	Grundprinzipien am Beispiel des Einstichproben - t-Tests	164	
7.1.1	Gerichtete Hypothese über den KFA-Effekt	164	
7.1.2	Voraussetzungen für den Einstichproben - t-Tests	164	
7.1.3	Teststatistik	165	
7.1.3.1	Anforderungen	165	
7.1.3.2	Die Prüfgröße zum Einstichproben - t-Test	165	
7.1.4	Entscheidungsregel	166	
7.1.5	Kritischer Wert und Ablehnungsbereich	167	
7.1.6	Akzeptiertes Risiko erster Art	168	
7.1.7	Faktoren mit Einfluss auf das Risiko zweiter Art	168	
7.1.8	Zweiseitiges Testproblem	170	
7.1.9	Einseitige Überschreitungswahrscheinlichkeit aus der zweiseitigen bestimmen	171	

7.2	Teststatistik und Annahmen im Modell der bivariaten linearen Regression	171
7.2.1	Teststatistik	171
7.2.2	Annahmen	172
7.2.2.1	Linearität	173
7.2.2.2	Normalität der Residuen	173
7.2.2.3	Varianzhomogenität der Residuen	174
7.2.2.4	Unkorreliertheit der Residuen	174
8	Gründliche Verteilungsanalyse für metrische Variablen	175
8.1	Diagnose von Ausreißern	175
8.2	Die SPSS-Prozedur zur explorativen Datenanalyse	176
8.3	Ausreißer- und Normalverteilungsbeurteilung für AERGZ	178
8.4	Nichtparametrische Testalternativen	180
8.5	Ausreißerbeurteilung für LOT, AERGAM und BMI	181
8.6	Vertrauensintervalle für Lageparameter	182
8.6.1	Normalverteilungs-Vertrauensintervall für das arithmetische Mittel	182
8.6.2	Bootstrapping-Vertrauensintervall für das getrimmte Mittel	184
9	Prüfung der zentralen Projekt-Hypothesen	189
9.1	Prüfung der differentialpsychologischen Hypothese	189
9.1.1	Regression von AERGAM auf LOT	189
9.1.2	Methodologische Anmerkungen	192
9.1.2.1	Explorative Analysen im Anschluss an einen „gescheiterten“ Hypothesentest	192
9.1.2.2	Post hoc - Poweranalyse	193
9.1.2.3	Fehlende Werte	194
9.2	Übung	195
9.3	Vorzeichentest zur KFA-Hypothese	197
9.4	Arbeiten mit dem Ausgabefenster (Teil II)	200
9.4.1	Pivot-Editor starten	200
9.4.2	Dimensionen verschieben	203
9.4.3	Gruppierungen	204
9.4.4	Kategorien aus- bzw. einblenden	206
9.4.5	Zellen modifizieren	207
9.4.5.1	Text editieren	207
9.4.5.2	Zellen zur weiteren Bearbeitung markieren	208
9.4.5.3	Zelleneigenschaften	208
9.4.5.4	Spaltenbreite	208
9.4.6	Tabellenvorlagen	209
10	T-Test für unabhängige Stichproben	210
10.1	T-Test anfordern	210
10.2	Interpretation	211
10.3	Prüfung der Voraussetzungen	211
10.4	Empirische Effektstärke	213
10.5	Grafische Veranschaulichung	214

11	Diagrammerstellung am Beispiel des Streudiagramms	216
11.1	Streudiagramm anfordern	217
11.1.1	Diagrammerstellung	217
11.1.2	Dialogbox Einfaches Streudiagramm	220
11.1.3	Auswahl der Diagrammtafelvorlage	221
11.2	Streudiagramm per Diagrammeditor modifizieren	223
11.2.1	Eigenschaftsfenster	224
11.2.2	Markieren von gruppierten Objekten	225
11.2.3	Menüs und Symbolleisten	226
11.2.4	Beschriftungen	229
11.3	Diagramme verwenden	229
11.4	Übung	230
12	Fälle auswählen	232
12.1	Auswahl über eine Bedingung	232
12.2	Bericht anfordern	234
13	Analyse von Kreuztabellen	236
13.1	Untersuchungsplanung	236
13.2	Beschreibung der bivariaten Häufigkeitsverteilung	240
13.3	Die Unabhängigkeits- bzw. Homogenitätshypothese	246
13.4	Testverfahren	246
13.4.1	Asymptotische χ^2 - Tests	246
13.4.2	Schätzung der Effektstärke	251
13.4.3	Einzelvergleiche der Spaltenanteile	251
13.4.4	Exakte Tests	252
13.4.5	Besonderheiten bei (2 $\times$ 2) - Tabellen	256
13.4.5.1	Ein klarer Fall für den exakten Test von Fisher	256
13.4.5.2	Gerichtete Hypothesen	256
13.4.5.3	Kontinuitätskorrektur nach Yates	257
14	Fälle gewichten	258
14.1	Beispiel	258
14.2	Übung	259
15	Auswertung von Mehrfachwahlfragen	260
15.1	Mehrfachantwortsets definieren	260
15.2	Häufigkeitstabellen für Mehrfachantwortsets	262
15.3	Kreuztabellen für Mehrfachantwortsets	266
15.4	Ein sparsames Set kategorialer Variablen expandieren	268
16	Datendateien im Textformat einlesen	270
16.1	Import von separierten Textdaten	270
16.2	Import von positionierten Textdaten (feste Breite)	275
16.3	Überprüfung der revidierten differentialpsychologischen Hypothese	280

17	Einstellungen modifizieren	282
17.1	Allgemein	282
17.2	Sprache	283
17.3	Ausgabe	283
17.4	Dateispeicherorte	284
18	Anhang	285
18.1	Weitere Hinweise zur SPSS-Kommandosprache	285
18.1.1	Hilfsmittel für das Arbeiten mit der SPSS-Kommandosprache	285
18.1.2	Interpretation von Syntaxdiagrammen	287
18.1.3	Aufbau von SPSS-Programmen	287
18.1.4	Aufbau eines einzelnen SPSS-Kommandos	289
18.1.5	Regeln für Variablenlisten	290
18.1.5.1	Abkürzende Spezifikation einer Serie von Variablen	290
18.1.5.2	Der Platzhalter varlist	290
	Literaturverzeichnis	291
	Stichwortregister	295

1 Von der Theorie bis zu den SPSS-Variablen

In diesem Kurs starten wir *nicht* mit fertigen Datendateien, um diese zu öffnen, eventuell noch leicht zu modifizieren und dann diverse statistische Analysemethoden auf die enthaltenen Variablen anzuwenden. Stattdessen nehmen wir den gesamten Prozess der statistisch-empirischen Forschung in den Blick, starten in einem Demonstrationsprojekt mit Überlegungen zum theoretischen Hintergrund, leiten daraus eine Untersuchungsplanung ab, organisieren die Datenerhebung bzw. -erfassung und führen alle weiteren Arbeitsschritte bis zum Ergebnisbericht durch (siehe Überblick in Abschnitt 1.2). Am Ende von Kapitel 1 wird als Zwischenergebnis feststehen, welche Informationen im Demonstrationsprojekt erhoben und welche SPSS-Variablen daraus erstellt werden sollen.

1.1 Statistik und EDV als Hilfsmittel der empirischen Forschung

Erfahrungswissenschaften bemühen sich um allgemeingültige Aussagen beschreibender, erklärender oder prognostizierender Art. Viele Wissenschaftsdisziplinen (z.B. Geo-, Sozial- oder Wirtschaftswissenschaften, Biologie, Medizin) können kaum mit *deterministischen* Gesetzen (z.B. Hebelgesetz der Mechanik) rechnen und benötigen daher eine Technologie zur Erforschung **probabilistischer Gesetze**.

Eine beispielhafte Forschungsfrage aus dem Bereich der Medizin könnte lauten:

Erhöht sich durch Rauchen das Risiko, an Lungenkrebs zu erkranken?

1.1.1 Kluge Entscheidungen trotz Unsicherheit

Wie wir wissen, hat das Rauchen auch bei gleicher Dosierung keinesfalls für alle Personen dieselben negativen Folgen. Die Frage nach dem Effekt des Rauchens auf die Entstehung von Lungenkrebs ist anhand von wenigen Einzelbeobachtungen (z.B. bei einem steinalten Kettenraucher) *nicht* zu klären. In einer solchen, durch **Unsicherheit** geprägten Situation können statistische Methoden dabei helfen, rationale Entscheidungen zu treffen, denn Wallis & Roberts (1956, S. 1) stellen treffend fest:

Statistics is a body of methods for making wise decisions in the face of uncertainty.

Bevor die Statistik im Rahmen eines Forschungsprojekts ihren Nutzen entfalten kann, ist eine **Untersuchungsplanung** vorzunehmen. Insbesondere ist die wichtige Entscheidung zwischen einem Experiment und einer Beobachtungsstudie zu treffen. Im Raucherbeispiel kann aus ethischen Gründen mit Menschen nur eine **Beobachtungsstudie** durchgeführt werden.

Eine grundlegende Strategie der statistisch arbeitenden Forschung, um bei einer empirischen Studie trotz Unsicherheit zu guten Entscheidungen zu kommen, besteht darin, zu einer Fragestellung **hinreichend viele repräsentative** und **unabhängige** Untersuchungseinheiten zu rekrutieren, um aus dieser **Stichprobe** Informationen über die zugrunde liegende **Population** der potentiellen Untersuchungseinheiten zu gewinnen und die Unsicherheit auf ein akzeptables Maß zu reduzieren. Im Kurs werden Sie genauer erfahren, wann eine Stichprobe hinreichend groß und das verbleibende Maß an Unsicherheit akzeptabel klein ist.

Zur Untersuchung der Raucherproblematik wird man vielleicht 400 im Idealfall zufällig ausgewählte Erwachsene im Alter von 50 bis 70 Jahren (**Untersuchungseinheiten**, **Merkmalsträger**, **Fälle**) auf Tabakkonsum und das Vorliegen einer Lungenkrebserkrankung untersuchen, so dass

bei vereinfachender Dichotomisierung die beiden **Merkmale** *Raucher* und *Lungenkrebs* (jeweils mit den Ausprägungen *Ja* und *Nein*) resultieren, z.B. mit der folgenden Stichprobenverteilung:

		Raucher		
		Ja	Nein	Gesamt
Lungenkrebs	Ja	30	30	60
	Nein	70	270	340
	Gesamt	100	300	400

1.1.2 Statistische Aufgabenstellungen und Methoden

Anschließend wird skizziert, welche Aufgabenstellungen sich mit statistischen Forschungsmethoden bearbeiten lassen.

1.1.2.1 Punkt- und Intervallschätzung

Im medizinischen Anwendungsbeispiel interessieren u.a. zwei Wahrscheinlichkeiten:

Wie groß ist die Wahrscheinlichkeit, an Lungenkrebs zu erkranken, bei Rauchern bzw. Nichtrauchern?

Um z.B. die Lungenkrebswahrscheinlichkeit für Raucher (also einen **Populationsparameter**) anhand der obigen Stichprobendaten zu schätzen, verwendet man die relative Häufigkeit von Lungenkrebs in der Raucherteilstichprobe (= 0,3).

In der Regel wird man sich nicht auf eine **Punktschätzung** beschränken, sondern zusätzlich auch eine **Intervallschätzung** vornehmen. Dabei wird aus den Stichprobendaten für den fraglichen Populationsparameter ein **Vertrauensintervall** (synonym: **Konfidenzintervall**) ermittelt, das seinen wahren Wert mit einer gewünschten Wahrscheinlichkeit (z.B.: 0,95) enthält. Obige Daten liefern für die 100 Raucher das 95% - Vertrauensintervall [0,212; 0,395].¹

Für die 300 Nichtraucher resultiert für das Lungenkrebsrisiko die Punktschätzung 0,10 mit dem Vertrauensintervall [0,070; 0,138], das aufgrund der größeren Teilstichprobe kleiner (präziser) ausfällt.

Den Konfidenzintervallen wird in der methodologischen Literatur immer mehr Bedeutung zugemessen. Viele Autoren halten sie für erheblich informativer und wichtiger als die in Abschnitt 1.1.2.2 beschriebenen Hypothesentests (siehe z.B. Brandstätter 1999).

Von Wahlprognosen sind Vertrauensintervalle sehr geläufig. Die Forschungsgruppe Wahlen beschreibt am 10.03.2016 die Genauigkeit ihrer Prognosen zu drei Landtagswahlen im März 2016 so:²

¹ Wie man dieses Vertrauensintervall mit SPSS ermittelt, ist in Abschnitt 4.8 zu erfahren.

² http://www.forschungsgruppe.de/Aktuelles/PB-Extra_Bawue__RIP__SaAn/ (abgerufen am 10.03.2016)

Die Interviews wurden in der Zeit vom 07. bis 10. März 2016 unter 1.711 (Baden-Württemberg), 1.693 (Rheinland-Pfalz) bzw. 1.096 (Sachsen-Anhalt) zufällig ausgewählten Wahlberechtigten telefonisch erhoben. Die Befragung ist jeweils repräsentativ für die dortige wahlberechtigte Bevölkerung. Der Fehlerbereich beträgt bei einem Anteilswert von 40 Prozent gut +/- drei Prozentpunkte und bei einem Anteilswert von 10 Prozent gut +/- zwei Prozentpunkte

Bei einem dichotomen Merkmal ist mit *einer* Wahrscheinlichkeit die gesamte Verteilung beschrieben. Hat ein nominalskaliertes Merkmal k (> 2) Ausprägungen, ist seine Verteilung durch die Wahrscheinlichkeiten von $(k - 1)$ Kategorien bestimmt, so dass $(k - 1)$ Parameter zu schätzen sind. Bei einem metrischen Merkmal sind in der Regel *viele* Ausprägungen vorhanden, und entsprechend viele Einzelwahrscheinlichkeiten liefern keine kompakte Beschreibung der Verteilung. In dieser Situation beschränkt man sich darauf, wichtige *Momente* der Verteilung zu schätzen, z.B. den Mittelwert als Maß der zentralen Tendenz und die Standardabweichung als Dispersionsmaß.

Neben den gerade angesprochenen **Verteilungsparametern** sind in der empirischen Forschung oft **Modellparameter** (z.B. Regressionskoeffizienten) zu schätzen, was auch in unserem Kurs bzw. Demonstrationsprojekt geschehen wird.

1.1.2.2 Hypothesenprüfung

Bei vielen Forschungsprojekten steht die Prüfung von vorab (z.B. aufgrund von vorherigen, eher explorativ ausgerichteten Studien) formulierten Hypothesen in Vordergrund, wobei oft neben der Wissenschaft auch die Öffentlichkeit und die Politik am Ergebnis interessiert sind. Einige Beispiele:

- Erhöht sich durch Beweidung von Wiesenflächen die pflanzliche Artenvielfalt?
- Steigt mit der Entscheidungsbefugnis eines Mitarbeiters seine Arbeitszufriedenheit?
- Hat das Ausmaß an sozialer Ungleichheit in einer Gesellschaft einen negativen Effekt auf das Bruttoinlandsprodukt?

Im aktuell betrachteten medizinischen Beispiel ist u.a. die folgende Frage zu klären:

Ist bei Rauchern das Lungenkrebsrisiko höher als bei Nichtrauchern?

Hier ist eine Entscheidung zwischen *zwei komplementären* Hypothesen zu treffen:

- **Nullhypothese (H_0)**
Durch die Nullhypothese werden in der Regel Populationsverhältnisse beschrieben, die man als falsch zurückweisen möchte.
Im Beispiel: Das Lungenkrebsrisiko ist bei Rauchern *nicht* höher als bei Nichtrauchern.
- **Alternativhypothese (H_1)**
Durch die Alternativhypothese werden in der Regel Populationsverhältnisse beschrieben, die man belegen möchte.
Im Beispiel: Das Lungenkrebsrisiko ist bei Rauchern erhöht.

Kann die Nullhypothese aufgrund ihrer geringen Plausibilität gegeben die beobachteten Daten verworfen werden, gewinnt die Alternativhypothese. Ansonsten wird die Nullhypothese beibehalten.

In den meisten Anwendungsfällen, sollte wie im medizinischen Beispiel ein *gerichtetes* Hypothesenpaar formuliert werden, um einen vorhandenen Unterschied bzw. Effekt mit möglichst hoher Wahrscheinlichkeit entdecken zu können.

Die Testentscheidung läuft so ab:

- 1) Für eine Prüfgröße (Teststatistik) T , die indikativ ist für Abweichungen der wahren Populationsverteilung von der Nullhypothesenbehauptung, wird die Stichprobenrealisation T_{emp} ermittelt.
- 2) Man bestimmt die sogenannte Überschreitungswahrscheinlichkeit p , bei gültiger Nullhypothese den Wert T_{emp} oder eine der Nullhypothese noch stärker widersprechende Ausprägung der Prüfgröße zu erhalten.
- 3) Man vergleicht die Überschreitungswahrscheinlichkeit p mit der akzeptierten Irrtumswahrscheinlichkeit erster Art (mit dem α -Fehlerrisiko, z.B. 0,05):
 - Bei $p < \alpha$ wird die Nullhypothese abgelehnt, und man entscheidet sich für die H_1 .
 - Bei $p \geq \alpha$ wird die Nullhypothese beibehalten, womit sie aber nicht bewiesen ist.

Bei einem korrekt durchgeführten Hypothesentest zeigt sich die oben versprochene Weisheit der statistischen Methodologie in der Realisation der folgenden Ziele:

- Eine *wahre* Nullhypothese wird nur mit der zuvor akzeptierten Irrtumswahrscheinlichkeit erster Art (α -Fehlerrisiko) fälschlicherweise verworfen.
- Eine *falsche* Nullhypothese wird mit einer möglichst großen Wahrscheinlichkeit verworfen (hohe Teststärke, kleine Irrtumswahrscheinlichkeit zweiter Art, geringes β -Fehlerrisiko).

Das eben nur kurz skizzierte binäre Entscheidungskonzept von Neyman und Pearson wird in Abschnitt 7.1 ausführlich behandelt.

Auch zur Klärung der Frage, welche *Stichprobengröße erforderlich* ist, um einen Populationseffekt bestimmter Größe (z.B. Risiko(Raucher) = 0,3 und Risiko(Nichtraucher) = 0,1) durch einen statistischen Test zum α -Fehlerrisiko 0,05 mit einer Wahrscheinlichkeit von 0,95 (d.h. bei einem β -Fehlerrisiko von 0,05) entdecken zu können, stehen statistische Methoden bereit (siehe Abschnitt 1.3).

Im Raucherbeispiel wird übrigens die Nullhypothese aufgrund der oben präsentierten Stichprobendaten deutlich verworfen. Eine Stichprobenumfangskalkulation ergibt, dass bei der eben beschriebenen Effektlage (mit den Risiken 0,3 und 0,1) sowie einem Stichprobenanteil der Raucher von 0,25 bereits 244 Fälle genügen (61 Raucher und 183 Nichtraucher), um mit der gerichteten Variante des exakten Tests von Fisher zum Niveau $\alpha = 0,05$ den vorhandenen Effekt mit der Wahrscheinlichkeit 0,95 entdecken zu können (vgl. Abschnitt 13.4.5.1). Allerdings ist die Stichprobengröße von 400 keine sinnlose Übertreibung, weil z.B. das 95% - Vertrauensintervall zum Lungenkrebsrisiko bei Rauchern ([0,212; 0,395]) aufgrund der relativ kleinen Raucherteilstichprobe für die meisten praktischen Zwecke zu ungenau ist. Man sollte also bei der Stichprobenumfangplanung nicht ausschließlich die Power von zentralen Hypothesentests berücksichtigen, sondern auch die benötigte Präzision von kritischen Vertrauensintervallen (vgl. Abschnitt 4.8.3).

1.1.2.3 Modellierung

Die zu schätzenden bzw. auf Signifikanz zu prüfenden Parameter stammen oft aus einem *mathematischen Modell*, das auf ein *empirisches System* angewendet wird. Im Raucherbeispiel kommt ein extrem einfaches Modell mit binomialverteilten (dichotomen) Merkmalen zu Einsatz, das kaum als Modell in Erscheinung tritt. Daher betrachten wir an dieser Stelle noch das häufig verwendete Modell der *linearen Regression*, das in seiner einfachsten Form ein zu erklärendes metrisches Kriterium Y , einen Regressor X und ein normalverteiltes Residuum ε enthält:


$$Y = \beta_0 + \beta_1 X + \varepsilon, \varepsilon \sim N(0, \sigma^2)$$

Als Modellparameter treten der Ordinatenabschnitt β_0 und der Steigungskoeffizient β_1 , die gemeinsam eine Regressionsgerade festlegen, sowie die Varianz σ^2 des Residuums auf. Mit der Formel

$$\varepsilon \sim N(0, \sigma^2)$$

wird die Annahme formuliert, das Residuum ε folge einer Normalverteilung mit dem Mittelwert 0 und der (für alle Beobachtungen identischen) Varianz σ^2 .

Das Modell eignet sich z.B. dazu, den Einfluss der Körpergröße von Personen auf deren Körpergewicht zu beschreiben. Im folgenden Streudiagramm ist die gemeinsame empirische Verteilung der beiden Merkmale in einer Stichprobe mit 95 Männern zu sehen:¹



Offenbar ist im Beispiel die von den beiden Modellparametern β_0 und β_1 definierte Regressionsgerade gut geeignet, den erwarteten Y -Wert für eine gegebene X -Ausprägung vorherzusagen. Die empirischen Residuen (Abstände der Kriteriumswerte von der Regressionsgeraden in Y -Richtung) pendeln relativ varianzhomogen um die Modellprognose, so dass wir von einem gülti-

¹ In diesem Beispiel hat die Beschränkung auf eine „Männergesellschaft“ statistische bzw. didaktische Gründe: In der Gesamtpopulation (mit Frauen und Männern) wird die Regression von Gewicht auf Größe nach einer im Kursverlauf noch zu prüfenden ernährungsphysiologischen Hypothese vom Geschlecht moderiert. Weil Frauen und Männer im Mittel unterschiedlich robust gebaut sind, wächst das Gewicht eventuell unterschiedlich schnell mit der Größe. Um diese Verhältnisse korrekt zu modellieren, ist ein relativ anspruchsvolles Modell mit Interaktionsterm erforderlich (siehe z.B. Baltes-Götz 2015b), das zum aktuellen Abschnitt nicht gut passen würde.


gen Modell ausgehen dürfen.¹ Unter dieser Voraussetzung sind die Punktschätzung, das Konfidenzintervall und der Signifikanztest zum Steigungsparameter β_1 von zentralem Interesse. Bei einem gerichteten (einseitigen) Signifikanztest ist das folgende Entscheidungsproblem zu klären:

$$H_0: \beta_1 \leq 0 \text{ versus } H_1: \beta_1 > 0$$

Bei den meisten Fragestellungen sind *mehrere* Einflussgrößen zu untersuchen und z.B. in ein *multiple* lineares Regressionsmodell aufzunehmen:

$$Y = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \beta_3 X_3 + \varepsilon, \varepsilon \sim N(0, \sigma^2)$$

Ein typisches *Forschungsprojekt* wird zudem nicht bei der Untersuchung *eines* Kriteriums stehen bleiben, sondern nach einem Modell zur Beschreibung und Erklärung eines komplexen empirischen Systems suchen. Man kann z.B. versuchen, das Zusammenwirken aller relevanten Komponenten durch ein aus mehreren Gleichungen bestehendes Pfad- oder Strukturgleichungsmodell zu erfassen. Dabei sind mehrere Parameterschätzungen und Hypothesentests beteiligt. Das folgende Pfadmodell zu den Bedingungen der beruflichen Ambitionen von Kindern (Kerchoff 1974) enthält ein Kriterium (berufliche Ambitionen des Kindes), einen *Mediator* (Schulleistung des Kindes) sowie drei exogene Regressoren (Intelligenz des Kindes, Bildung des Vaters, Beruf des Vaters):²



Das Pfadmodell besteht aus zwei Regressionsgleichungen:

- Die Schulleistung des Kindes wird zurückgeführt auf seine Intelligenz und die Bildung des Vaters.
- Die berufliche Ambition des Kindes wird erklärt durch seine Schulleistung und den Beruf des Vaters.

Ein Forschungsprojekt mit dem Ziel eines allgemeingültigen Modells wird stets eingestehen müssen, eine *vereinfachte* Sicht zu liefern, was beim Statistiker George E. P. Box zur desillusionierten, aber keinesfalls resignierten Einsicht geführt hat (Box 1979, S. 202):

All models are wrong but some are useful.

¹ Eine Beurteilung der Residuen auf Normalverteilung ersparen wir uns an dieser Stelle (vgl. Abschnitt 9.1.1).

² In diesem Beispiel ist die völlige Fixierung auf väterliche Karrieremerkmale wohl der im letzten Jahrtausend noch mangelhaften Emanzipation anzulasten.

1.1.3 Lügen

Viel bekannter als die oben zitierte Aussage von Wallis & Roberts (1956) zum Wesen der Statistik ist leider die folgende, Mark Twain zugeschriebene Charakterisierung (Griffith 2010, S. 9):

Es gibt Lügen, verdammte Lügen und Statistik.

In dieser Formulierung kommt die reale Gefahr zum Ausdruck, dass Menschen bei der Anwendung statistischer Methoden auf komplexe, durch Unsicherheit geprägte Sachverhalte aufgrund unredlicher Motive oder durch Unvermögen scheitern können. Dabei resultieren fehlerhafte Forschungsergebnisse, die wiederum zu falschen Entscheidungen führen können. Dieser Gefahr ist durch statistische Sachkompetenz und ein gesundes Misstrauen zu begegnen.

1.1.4 Keine statistische Praxis ohne EDV

Kehren wir kurz zum medizinischen Beispiel zurück. In einer realen Studie wird man sich nicht auf die beiden oben zur Illustration verwendeten dichotomen Merkmale (*Raucher* und *Lungenkrebs*) beschränken, sondern Dauer und Ausmaß des (aktiven und passiven) Rauchens sowie den gesundheitlichen Status der Probanden genauer untersuchen und außerdem viele zusätzliche Merkmale erheben, z.B. Alter, Geschlecht, Bildung, Beruf, Schadstoffbelastung der Wohnung (z.B. Radon-Gas in der Raumluft). Eine praktikable Auswertung solcher Datenmengen ist nur mit **EDV-Hilfe** möglich. Mit SPSS steht ein bequemes, leistungsfähiges und sehr bewährtes Analysesystem für die statistische Forschung zur Verfügung. Es bietet u.a. ...

- fast alle wichtigen statistischen Verfahren
- gute grafische Darstellungsmöglichkeiten
- eine umfangreiche Unterstützung bei der Datenverwaltung und -aufbereitung
- diverse Verfahren zur Kooperation mit anderen Programmen (z.B. Programmierschnittstellen, Datenbankzugriff)

Weil SPSS auf allen wichtigen Plattformen (Linux, Mac OS X, Windows) vertreten ist, und sein Datendateiformat weithin unterstützt wird, bestehen günstige Bedingungen für die kollegiale Kommunikation.

1.2 Planung und Durchführung einer empirischen Untersuchung im Überblick

Zunächst wollen wir uns einen Überblick über die Phasen einer empirischen Untersuchung und damit auch über unser Kursprogramm verschaffen. Dabei werden zahlreiche Aufgaben und Methoden angesprochen, über die Sie sich im Bedarfsfall in den Lehrveranstaltungen oder in der Literatur zur empirischen Forschung informieren können (siehe z.B. Bortz & Döring 2005; Eid et al. 2013; Jacob et al. 2013, Pedhazur & Pedhazur Schmelkin 1991; Schnell et al. 2008). Die anschließende Darstellung soll als Übersicht dienen und ist relativ knapp gehalten. Ihr folgt unmittelbar die konkrete Anwendung auf unsere Beispielstudie.

Weil die dargestellten Aufgaben teilweise interdependent sind, bilden sie keine strenge, bei allen empirischen Studien gleichförmig ablaufende Sequenz.

1.2.1 Forschungsziele, Hypothesen und Modelle

Am Anfang einer wissenschaftlichen Studie steht in der Regel eine längere Phase der intensiven theoretischen Auseinandersetzung mit dem Thema. Daraus ergeben sich Forschungsinteressen, die – u.a. in Abhängigkeit vom Forschungsstand – eher von **explorativer** (hypothesensuchender)

oder eher von **konfirmatorischer** (hypothesenprüfender) Natur sind. Oft werden beide Forschungsstrategien vertreten sein. Die zu prüfenden Hypothesen sollten wegen ihrer Steuerungsfunktion für spätere Schritte möglichst exakt formuliert werden. Häufig werden sich die Hypothesen auf Parameter in einem **mathematischen Modell** (z.B. in einer linearen Regressionsgleichung) beziehen.

Um eine Theorie bzw. eine Hypothesenfamilie empirisch zu prüfen oder einen Gegenstandsbereich empirisch zu explorieren, werden geeignete Daten benötigt, die aus vorhandenen Datenbeständen und/oder aus eigener Forschungstätigkeit stammen können.

1.2.2 Nutzung vorhandener Daten

Besteht zur Klärung einer empirischen Forschungsfrage die Möglichkeit zur (Sekundär-)Analyse von vorhandenen Daten, sollte diese Chance aus wirtschaftlichen Gründen genutzt werden. Wichtige Bezugsquellen für öffentlich zugängliche Datenbestände sind:

- **Allgemeine Bevölkerungsumfrage der Sozialwissenschaften (ALLBUS)**
Das GESIS-Institut für die Sozialwissenschaften befragt seit 1980 alle zwei Jahre eine repräsentative (jeweils neu gezogene) Stichprobe der erwachsenen deutschen Bevölkerung.¹ Seit 1986 geschieht dies im Rahmen des internationalen Kooperationsprogramms *International Social Survey Programme* (ISSP).
- **Sozio-oekonomisches Panel (SOEP)**
Das Deutsche Institut für Wirtschaftsforschung (DIW) führt seit 1984 eine jährliche sozio-oekonomische Befragung bei einer repräsentativen und (im Rahmen der organisatorischen Möglichkeiten) konstanten Stichprobe aus der deutschen Bevölkerung durch.²
- **Statistisches Bundesamt**
Das statistische Bundesamt bietet z.B. in der GENESIS - Online-Datenbank (*GEmeinsames NEues Statistisches Informations-System*) aggregierte Daten aus diversen Bereichen der amtlichen deutschen Statistik an (z.B. volkswirtschaftliche Indizes, Bildung).³
- **Nationales Bildungspanel (NEPS)**
Das Leibniz-Institut für Bildungsverläufe führt im NEPS-Projekt (*Nationales Bildungspanel*) sechs Panelstudien mit Startkohorten unterschiedlichen Alters durch (von Neugeborenen bis zu Erwachsenen) und stellt der wissenschaftlichen Gemeinschaft die Daten zur Verfügung.⁴

¹ <http://www.gesis.org/allbus>,
http://de.wikipedia.org/wiki/Allgemeine_Bevölkerungsumfrage_der_Sozialwissenschaften

² <http://www.diw.de/de/soep>,
http://de.wikipedia.org/wiki/Sozio-oekonomisches_Panel

³ <https://www-genesis.destatis.de/genesis/online>

⁴ <https://www.neps-data.de/>

- **General Social Survey (GSS)**

Seit 1972 wird regelmäßig eine Stichprobe der US-Amerikanischen Bevölkerung zu einer breiten Themenpalette befragt.¹ Das GSS-Trägerinstitut gehörte zu den ISSP-Gründungsmitgliedern, und die ISSP-Module sind dementsprechend in den GSS-Fragenkatalog integriert.

Weitere Details zu den genannten und zu sonstigen Datenquellen finden sich z.B. in Baur & Fromm (2011, S. 61ff) sowie bei Jacob et al. (2013, S. 237ff).

Neben den für Forschungszwecke systematisch aufgebauten Datenbeständen und den amtlichen Statistiken existieren (z.B. in Behörden oder Firmen) weitere Aufzeichnungen von Interesse für spezielle Forschungsfragen.

Bei der Suche nach statistischen Daten aus diversen Quellen hilft das Statistik-Portal **Statista**. Um den von der Universitätsbibliothek Trier abgeschlossenen Campusvertrag beim Recherchieren nutzen zu können, muss die Verbindung zur Statista-Webseite (<http://www.statista.com/>) im Campusnetz der Uni Trier bzw. bei aktiver VPN-Verbindung mit dem Campusnetz von der Homepage der Uni Trier (<http://www.uni-trier.de/>) ausgehend folgendermaßen hergestellt werden:

[Bibliothek > Digitale Medien > Datenbanken \(DBIS\) >
Fachliste > Wirtschaftswissenschaften > Statista](#)

1.2.3 Untersuchungsplanung

Ist eine komplette eigene Studie (inkl. Datenerhebung) erforderlich, sind bei der Untersuchungsplanung zahlreiche Aufgaben zu lösen.

1.2.3.1 Untersuchungseinheiten, Population und Merkmale

In der Regel ergibt sich aus der Fragestellung unmittelbar, welche Untersuchungseinheiten (Merkmalsträger) einer Studie zugrunde liegen (z.B. Personen, Volkswirtschaften, Orte, Unternehmen, Bodenproben), und welche Merkmale bei jeder Untersuchungseinheit festgestellt werden sollen.

Eng verknüpft mit der Wahl von Untersuchungseinheiten ist die Festlegung einer **Grundgesamtheit bzw. Population** von Untersuchungseinheiten, über die allgemeingültige Aussagen gewonnen werden sollen. Hier geht es um die Generalisierbarkeit der angestrebten Forschungsergebnisse (externe Validität).

Gelegentlich sind **hierarchisch geschachtelte Untersuchungseinheiten** auf mehreren Ebenen zu betrachten (siehe z.B. Baltes-Götz 2013a; Raudenbush & Bryk 2002; Snijders & Bosker 2012), wobei man auch von *Cluster-Stichproben* spricht. So hat man es etwa bei einer Studie zur Arbeitszufriedenheit und Produktivität von Arbeitnehmern aus verschiedenen Firmen in Abhängigkeit von Person- und Organisationsmerkmalen mit Untersuchungseinheiten auf *zwei* Ebenen zu tun:

- Firmen
- Arbeitnehmer

¹ <http://www3.norc.ox.ac.uk/GSS+Website/>
http://en.wikipedia.org/wiki/General_Social_Survey

Wir beschränken unsere Betrachtungen an dieser Stelle auf Studien mit zwei Ebenen und können daher bequem von der *Makro-* und der *Mikroebene* sprechen. Bei der späteren Auswertung ist zu beachten, dass traditionelle statistische Methoden (z.B. die lineare Regressionsanalyse) *unabhängige Residuen* annehmen. Die bei einer hierarchischen Datenstruktur auf der Mikroebene (im Beispiel: auf der Ebene der Arbeitnehmer) naturgemäß anzutreffende Abhängigkeit der Beobachtungen aus derselben Makroeinheit muss in speziellen Modellen berücksichtigt werden, um gültige Vertrauensintervalle und Hypothesentests zu erhalten.

Das Demonstrationsprojekt in Kurs kommt mit einer flachen Datenstruktur aus, und die Behandlung der speziellen Optionen und Probleme von Cluster-Stichproben bleibt speziellen ZIMK-Kursen bzw. Manuskripten vorbehalten.¹

1.2.3.2 Untersuchungsdesign

Man kann z.B. einen (quasi-)experimentellen Untersuchungsplan entwerfen oder eine Beobachtungsstudie konzipieren, die quer- und/oder längsschnittlich angelegt sein kann. Bei einer Beobachtungsstudie werden Merkmalsausprägungen mit den jeweils passenden Messmethoden festgestellt, doch finden keine Eingriffe in das analysierte empirische System statt. Sind die Beobachtungseinheiten Personen, werden oft Befragungen durchgeführt.

Auf dem Weg zu der im Regelfall anzustrebenden kausalen Interpretation gilt das Experiment nach wie vor als Königsweg (siehe z.B. Antonakis, et al. 2010; Eid et al. 2013, S. 56ff), doch muss man speziell in den Wirtschafts- und Sozialwissenschaften oft aus ethischen und/oder praktischen Erwägungen mit Beobachtungsdaten arbeiten.

Unter den Beobachtungsstudien bietet die **Panelstudie** relativ günstige Bedingungen für eine kausale Interpretation der Ergebnisse (siehe Brüderl 2010). Dabei werden *mehrere Untersuchungseinheiten* zu *mehreren Zeitpunkten* beobachtet. In der Regel ist die Anzahl *N* der Untersuchungseinheiten relativ groß und die Anzahl *T* der Zeitpunkte relativ klein (z.B. 5).

Bei (quasi-)experimentell manipulierten Bedingungen hat man oft die Wahl zwischen einem **Messwiederholungs- und einem Gruppierungsfaktor** (engl.: *within* - bzw. *between* - *subjects factor*). Bei einem Messwiederholungsfaktor wird jeder Fall nacheinander unter *mehreren* Be-

¹ Derzeit sind zwei Technologien zur Analyse von Cluster-Stichproben verbreitet:

- (Generalisierte) lineare gemischte Modelle
Ein *lineares gemischtes Modell* (LMM, Linear Mixed Model) erklärt für ein metrisches Kriterium mit normalverteilten Residuen die Abhängigkeit der von einem Cluster stammenden Beobachtungen durch Cluster-spezifische Zufallseffekte (siehe z.B. Baltes-Götz 2013a; Raudenbush & Bryk 2002; Snijders & Bosker 2012). Aus dem LMM entsteht das *generalisierte lineare gemischte Modell* (GLMM), wenn man ...
 - a) für die Residuen statt der Normalverteilung auch andere Verteilungen (z.B. die Binomial- oder die Poisson-Verteilung) zulässt,
 - b) als Verbindung zwischen dem erwarteten Kriteriumswert und einer Prädiktorwertekombination neben der Identität auch andere Link-Funktionen erlaubt (z.B. die Logit- oder die Logarithmusfunktion).
- GEE-Modelle (*Generalized Estimating Equations*)
Während bei einem (generalisierten) linearen gemischten Modell die Kovarianzmatrix der Beobachtungen zum Explanandum gehört und durch die Zufallseffekte im statistischen Modell erklärt werden soll, betrachtet die von Liang & Zeger (1986) eingeführte GEE-Methodologie (*Generalized Estimating Equations*) die Abhängigkeit der Beobachtungen als lästige, durch geeignete Maßnahmen zu kompensierende Störung (siehe z.B. Baltes-Götz 2015a). Ein GEE-Modell erlaubt bzgl. der Residualverteilung und der Link-Funktion dieselben Generalisierungen wie ein lineares gemischtes Modell.

dingungen beobachtet (z.B. Gedächtnisleistung in Ruhe und bei Belastung). Es resultieren entsprechend viele Messwerte, und interindividuelle Unterschiede können aus der Fehlervarianz des Analysemodells heraus gehalten werden, so dass eine günstige Teststärke bei der Beurteilung des Faktors zu erwarten ist. Allerdings sind in der Regel Übertragungen zwischen den Bedingungen zu befürchten (z.B. durch Lerneffekte), die oft durch eine Variation der Bedingungsreihenfolge neutralisiert werden können. Bei einem Gruppierungsfaktor wird jeder Fall nur unter *einer* Bedingung beobachtet, wobei eine Zufallszuordnung anzustreben ist, damit ein Experiment mit seinem kausalitätstheoretischem Interpretationsvorteil entsteht. Interindividuelle Unterschiede erschweren als Fehlervarianzquelle den Nachweis von Effekten.

Zur Prüfung einer Theorie ist eine empirische Situation zu wählen bzw. zu gestalten, die zum Anwendungsbereich der Theorie gehört (ökologische Validität).

1.2.3.3 Operationalisierung der zu untersuchenden Merkmale

Zur Operationalisierung von theoretischen Begriffen (z.B. sozioökonomischer Status, Optimismus) sind möglichst reliable und valide Messmethoden zu wählen bzw. zu entwerfen, die außerdem nicht zu aufwändig sind. Das Skalenniveau der Messmethoden muss die Voraussetzungen der geplanten statistischen Auswertungsverfahren (siehe unten) erfüllen.

Bei *quantitativen* Merkmalen (z.B. Alter) sollten die verfügbaren Informationen bei der Operationalisierung *nicht* durch eine *künstliche* und *willkürliche* Klassenbildung reduziert werden (z.B. durch Bildung der Altersklassen < 20, 21-40, 41-60, > 60). Man bewegt sich je nach Wahl der Klassengrenzen vom metrischen Messniveau mehr oder weniger weit weg in Richtung auf ordinales Niveau (mit bloßer Anordnung der Werte, ohne Bedeutung der Abstände). Häufig sind Modelle für metrische Daten einfacher und erfolgreicher als solche für ordinale Daten. Außerdem kann man mit SPSS zu einer metrischen Variablen nach Belieben klassifizierte Varianten erzeugen, wenn dies für spezielle Analysen wünschenswert erscheint. Eine Ausnahme von der Empfehlung zur Erhebung metrischer Informationen ist z.B. bei der Befragung von Personen nach ihrem Einkommen zu machen. Um bei dieser sensiblen Frage Widerstände zu vermeiden, muss man sich in der Regel auf die Erhebung von groben Einkommensklassen und damit auf ordinales Messniveau beschränken.

Bei den Überlegungen zur Operationalisierung können auch die zur Datenerhebung verfügbaren technischen Hilfsmittel eine Rolle spielen. Mit Hilfe der Computer-Technik ist eine interaktive, individualisierte und dabei auch noch ökonomische Datenerhebung möglich. Zur Steuerung experimenteller Abläufe und Messung von Reaktionszeiten kommen z.B. spezielle Rechner im Forschungslabor zum Einsatz. Für eine kontinuierliche, alltagsbegleitende Datenerfassung können oft Rechner im Taschenformat genutzt werden. Umfragen werden mittlerweile routinemäßig via Internet realisiert, wenn die zu untersuchende Population auf diesem Weg erreichbar ist (siehe Abschnitt 3.1.1).

1.2.3.4 Empirisch prüfbare Hypothesen (über Modellparameter) formulieren

Aus einer in theoretischen Begriffen formulierten Hypothese ergibt sich im Verlauf der Untersuchungsplanung durch zahlreiche Konkretisierungen und Operationalisierungen eine in empirischen Begriffen formulierte und damit statistisch prüfbare Hypothese.

Von einfachen Fällen abgesehen, werden sich die zu prüfenden Hypothesen einer Studie auf Parameter eines mathematischen Modells beziehen, das also spätestens jetzt explizit zu formulieren ist.

Oft hat man die Wahl zwischen einer **gerichteten** und einer **ungerichteten Hypothesenformulierung**. Über den Steigungsparameter β_1 der bivariaten linearen Regression mit dem Kriterium Y und dem Regressor X (vgl. Abschnitt 1.1)

$$Y = \beta_0 + \beta_1 X + \varepsilon$$

behauptet eine *gerichtete* Alternativhypothese z.B.

$$H_1: \beta_1 > 0$$

Dem steht die folgende Aussage der *ungerichteten* Alternativhypothese gegenüber:

$$H_1: \beta_1 \neq 0$$

Für die mangelnde Bereitschaft, sich auf eine Richtung festzulegen, wird man durch eine geringere Power beim Signifikanztest bestraft. Die Chance, einen vorhandenen Effekt zu entdecken, ist also geringer. Immerhin ist man berechtigt, nach einem signifikanten Ergebnis beim zweiseitigen Test doch noch eine Richtungsaussage zu machen.¹

Selbstverständlich kann gelegentlich auch eine ungerichtete Hypothesenformulierung angemessen sein, weil z.B. theoretisches Vorwissen fehlt.

Manchmal ist eine gerichtete Formulierung unmöglich, z.B. beim Vergleich der Frauenanteile in den sechs Fachbereichen der Universität Trier (siehe Kapitel 13). Hier kommt nur die „zweiseitige“ Alternativhypothesebehauptung ungleicher Frauenanteile in Frage.

1.2.3.5 Statistisches Entscheidungsverfahren

Für jede Hypothese ist ein statistisches Entscheidungsverfahren zu wählen, dessen Voraussetzungen an Skalenniveau und Verteilungsverhalten der beteiligten Merkmale (voraussichtlich) erfüllt sind.

In der wirtschafts- und sozialwissenschaftlichen Forschung ist es verbreitete Praxis, Antworten auf einer 5-stufigen Skala als intervallskaliert zu behandeln, obwohl das Messniveau irgendwo zwischen der ordinalen und der metrischen Stufe angesiedelt ist. Häufig wird aus einer Anzahl solcher Items ein Mittelwert berechnet und in der statistischen Analyse zur Messung des intendierten latenten Merkmals verwendet. Aus den Einschätzungen vieler Methodiker und aus Simulationsergebnissen kann man schließen, dass spätestens für Item-Mittelwerte das metrische Messniveau beansprucht werden kann (vgl. Warner 2013, S. 6ff).

Im Rahmen einer konfirmatorischen Studie ist zu jedem Hypothesentest das akzeptierte Fehlerisiko erster Art (α -Fehler) festzulegen, also das Risiko, eine gültige Nullhypothese fälschlich zu verwerfen, wobei z.B. die 5% - Konvention übernommen werden kann.

¹ Dies garantiert ein mathematischer Satz über den so genannten *Abschlusstest*.

1.2.3.6 Stichprobenrekrutierung

Es ist zu überlegen, wie eine *repräsentative* und zur Durchführung der geplanten Auswertungsverfahren *hinreichend große Stichprobe* aus der (möglichst präzise definierten) Population rekrutiert werden kann. *Alle* Fälle in der Population zu untersuchen, ist in der Regel weder bezahlbar, noch erforderlich. Die Methoden der Inferenzstatistik machen es möglich, mit kontrollierter Irrtumswahrscheinlichkeit von Stichprobenergebnissen auf Populationsverhältnisse zu schließen.

Bei ausgeprägt konfirmatorisch angelegten Studien ist bei der Stichprobenumfangsplanung insbesondere das **Fehlerisiko zweiter Art** (der β -Fehler) zu berücksichtigen, also das Risiko, einen vorhandenen Effekt zu übersehen.

Das Ideal einer streng zufallsgesteuerten Stichprobengewinnung, wobei aus einer klar definierten Population jedes Mitglied dieselbe Chance hat, in die Stichprobe zu gelangen, kann nur selten realisiert werden. Oft wird eine **Bequemlichkeitsstichprobe** (engl. *convenience sample*) verwendet, in die bevorzugt leicht (bei minimalen Kosten) erreichbare Untersuchungseinheiten geraten (z.B. Personen in der Reichweite von (digitalen) sozialen Netzwerken oder Patienten in der Praxis eines forschenden Mediziners). In diesem Fall ist die externe Validität (Generalisierbarkeit) der Forschungsergebnisse in Frage gestellt. Z.B. dürfte ein erheblicher Teil der psychologischen Forschung mit Studierenden aus den Anfangssemestern ausgeführt werden, wobei in Bezug auf Alter, Bildung und andere soziodemografische Merkmal große Segmente der Population ausgeschlossen sind (Warner 2013, S. 4). Die Leser von Forschungsberichten müssen durch eine gründliche Beschreibung der Stichprobe und der Rekrutierungsprozedur informiert werden.

Bei der Erforschung von *Merkmalszusammenhängen* (z.B. Effekt von Selbstvertrauen auf die Bereitschaft zur Unterstützung von Gewaltopfern) kann man hoffen, aus einer Stichprobe mit mangelnder Repräsentativität Ergebnisse zu gewinnen, die auch für die Gesamtbevölkerung von Relevanz sind. Wenn *univariate Verteilungseigenschaften* in einer exakt definierten Population untersucht werden sollen (z.B. Parteienpräferenzen, Arbeitslosenrate), dann *muss* eine strikte Zufallsauswahl oder eine stratifizierte Zufallsauswahl mit Gewichtungungsverfahren zum Einsatz kommen, damit verwertbare Forschungsergebnisse resultieren.

1.2.3.7 Datendeklaration und Kodierplan

Wer ganz sicher gehen will, dass die bei seiner Studie erhobenen Informationen sicher und bequem in die EDV übernommen werden können, sollte die Daten schon in der Planungsphase gegenüber der zuständigen Software deklarieren.

Beim Entwurf eines Formulars für eine Online-Erhebung geschieht die Datendeklaration gegenüber der verwendeten Software (also *vor* der Datenerhebung). Diese Software kann in der Regel die erfassten Merkmale später in eine SPSS-Datendatei exportieren, so dass keine erneute Datendeklaration gegenüber SPSS erforderlich ist.

Auch in der heutigen Zeit werden noch viele Daten mit schriftlichen Untersuchungsdokumenten erhoben und anschließend manuell erfasst. Es kann nicht schaden, auch bei diesem Vorgehen die Daten schon vor der Erhebung gegenüber dem geplanten Erfassungsprogramm (z.B. SPSS-Dateneditor) zu deklarieren. Forschungsnovizen werden bei der Arbeit mit einem Computer-Programm, das die vorwiegend forschungslogisch und kaum durch EDV-Restriktionen diktierte Datenstruktur explizit einfordert, konzeptionelle Probleme eher entdecken als bei der schriftlichen Beschreibung des Forschungsvorhabens.

Bei den meisten Projekten können die Daten in *einer* Matrix (Tabelle) mit den Fällen als Zeilen und den Merkmalen als Spalten untergebracht werden. Gelegentlich werden *mehrere* Tabellen benötigt, z.B. bei einer Untersuchung von Mitarbeitern und Kunden einer Einzelhandelskette.

Findet eine manuelle Datenerfassung statt, ist (zumindest bei größeren Projekten) ein **Kodierplan** als genaue Arbeitsvorschrift unverzichtbar. Hier wird z.B. festgelegt, dass beim Merkmal Geschlecht die Ausprägung *weiblich* durch eine Eins und die Ausprägung *männlich* durch eine Zwei erfasst werden soll. Mit dem Abschluss der Erfassung wird der Kodierplan nicht überflüssig, sondern kann nun zur Dokumentation der entstandenen Datendatei (gegenüber einem größeren Nutzerkreis) dienen.

Nach Abschluss der Planungs- und Vorbereitungsphase kann die empirische Phase mit Datenerhebung stattfinden.

1.2.4 Daten erfassen, prüfen und korrigieren

Nach einer Datenerhebung mit einem in Papierform vorgelegten Fragebogen steht als Nächstes die Datenerfassung an. Das Eintragen der Rohdaten in eine Computer-Datei kann mit dem Dateneditor von SPSS geschehen oder mit einem speziellen Datenerfassungsprogramm. In jedem Fall ist bei der Erfassung der in der Planungsphase oder spätestens nach der Datenerhebung erstellte Kodierplan genau einzuhalten. Hier ist für jedes Merkmal festgelegt, wie seine Ausprägungen kodiert werden sollen.

Durch Fehler bei der Datenerhebung oder -erfassung können irreguläre Werte zustande kommen. Je fehleranfälliger die eingesetzten Techniken waren, desto mehr Aufwand ist bei der Datenprüfung und -korrektur angebracht.

Bei einer Online-Datenerhebung entfällt die Datenerfassung. Durch Fehler bei der Datenerhebung oder -übertragung können aber trotzdem irreguläre Werte in eine Datendatei geraten, so dass in der Regel eine Kontrolle erforderlich ist. Im Abschnitt 3.1.1 folgen weitere Informationen zur Online-Datenerhebung.

1.2.5 Datentransformation

Nach der Erfassung und Prüfung liegen bei vielen Studien die Daten immer noch nicht in auswertbarer Form vor. Vielfach müssen Variablen überarbeitet (z.B. umkodiert) oder aus Vorläufern neu berechnet werden (z.B. durch Mittelwertbildung). Solche Transformationen nehmen bei vielen Projekten einen erheblichen Umfang an, wobei sowohl akribische Fleißarbeit als auch kreative Begriffsbildung gefragt sind.

1.2.6 Statistische Datenanalyse

Nach langer Vorbereitung können mit Hilfe von SPSS z.B. die gesuchten Schätzwerte (samt Konfidenzintervallen) ermittelt und die geplanten Hypothesentests durchgeführt werden. Bei einer eher explorativen Untersuchungsanlage ist eine längere, kreative Auseinandersetzung mit den Daten erforderlich, wobei zahlreiche Datentransformationen und statistische Analysen ausgeführt werden.

1.3 Theorie und Untersuchungsplanung im Demonstrationsprojekt

Um die im Rahmen einer empirischen Studie mit SPSS zu erledigenden Arbeiten in einem realistischen Kontext üben zu können, wird im Kursverlauf eine kleine psychologische Fragebogenstudie durchgeführt.¹ Dabei werden Sie alle Phasen der empirischen Forschung kennen lernen und die erforderlichen Arbeiten zum großen Teil selbständig durchführen. Als Beispiel wurde u.a. deshalb eine Fragebogenstudie gewählt, weil die Kursteilnehmer dabei in wenigen Minuten interessante empirische Daten selbst erzeugen können. Damit ist auch die Phase der *Datenerhebung* in den Übungsablauf einbezogen, die ansonsten aus Zeitgründen ausgespart bleiben müsste.

Bezogen auf das in Abschnitt 1.2 vorgestellte Schema mit den Phasen bzw. Teilaufgaben einer empirischen Untersuchung beschäftigen wir uns nun mit dem theoretischen Hintergrund unserer Beispielstudie und mit Fragen der Untersuchungsplanung.

1.3.1 Die allgemeinspsychologische KFA-Hypothese

Nach einer Theorie von Kahneman² & Miller (1986) hängt die Stärke unserer emotionalen Reaktion auf ein positives oder negatives Ereignis u.a. davon ab, welche *alternativen* (aber nicht eingetretenen) Ereignisse wir uns vorstellen können, mit anderen Worten: welche **kontrafaktischen Alternativen** mental verfügbar sind. Wir wollen uns auf den Fall ungünstiger Ereignisse beschränken. Hierfür stellen Kahneman & Miller die folgende Hypothese auf:

Bei einem negativen Ereignis erhöht die mentale Verfügbarkeit (Vorstellbarkeit) kontrafaktischer (also positiver) Ereignisalternativen den erlebten Ärger.

Im weiteren Verlauf wollen wir unser Projekt kurz als *KFA-Studie* bezeichnen.

Weil diese Hypothese für beliebige Personen Gültigkeit beansprucht, kann sie als *allgemeinspsychologisch* bezeichnet und von *differentialpsychologischen* Hypothesen unterschieden werden, die sich mit Unterschieden zwischen Personen beschäftigen (siehe Abschnitt 1.3.3).

1.3.2 Untersuchungsplanung

1.3.2.1 Untersuchungseinheiten, Population, Merkmale, Design und Operationalisierung

Hinsichtlich des Untersuchungsdesigns haben wir uns aufgrund praktischer Erwägungen bereits auf eine **querschnittlich angelegte Fragebogenstudie** mit den Kursteilnehmern als **Untersuchungseinheiten** festgelegt. Zentrales **Merkmal** ist der Ärger über ein negatives Ereignis bei An- bzw. Abwesenheit einer kontrafaktischen (also positiven) Ereignisalternative.

Unsere Studie soll aus praktischen Gründen mit der **studentischen Stichprobe** der Kursteilnehmer durchgeführt werden. Damit können wir unter induktivistischer Perspektive die Ergebnisse günstigstenfalls auf die Population der Studierenden generalisieren. Ernsthafte Bedenken bzgl. der externen Validität (Generalisierbarkeit) unserer Ergebnisse bestehen allerdings nur dann, wenn die Besonderheiten unserer Stichprobe (z.B. bzgl. Alter und Bildungsgrad) bei einer Fragestellung von Relevanz sind (siehe Eid et al. 2013, S. 63). Dies ist bei der KFA-Hypothese

¹ Hierbei werden in stark vereinfachter Form Ideen aus einem ehemaligen Forschungsprojekt von Herrn Prof. Dr. Jochen Brandtstädter (Emeritus der Universität Trier) aufgegriffen, dem ich an dieser Stelle herzlich für die Erlaubnis und für die Überlassung von Untersuchungsmaterial danken möchte.

² Daniel Kahneman erhielt 2002 den Nobelpreis für Wirtschaft, womit vor allem seine erfolgreiche Anwendung psychologischer Erkenntnisse (u.a. zu Urteilen und Entscheidungen unter Unsicherheit) in wirtschaftswissenschaftlichen Theorien gewürdigt wurde.

kaum zu befürchten. Wir gehen also davon aus, trotz der Verwendung einer „Bequemlichkeitsstichprobe“ (vgl. Abschnitt 1.2.3.6) einen allgemeinspsychologischen Forschungsbeitrag leisten zu können.

Das Interesse am Ärger aufgrund bestimmter Situationsmerkmale bzw. Erlebnisinhalte ruft eigentlich nach der Realisation von entsprechenden experimentellen Bedingungen. Um den Aufwand eines realen Experiments zu vermeiden, verlagern wir die experimentellen Bedingungen in die Köpfe der Untersuchungsteilnehmer und bitten diese, sich in eine Geschichte einzufühlen, bei der zwei Personen objektiv denselben Schaden erleiden, jedoch in unterschiedlichem Grad eine kontrafaktische (also günstige) Alternative vor Augen haben. Dann sollen die Probanden für jeden Geschädigten angeben, wie stark sie sich in dessen Lage ärgern würden. Die genaue Instruktion ist dem unten wiedergegebenen Fragebogen (Teil 1, siehe Abschnitt 1.3.6) zu entnehmen.

Indem wir jede Person den *beiden* imaginierten Behandlungen aussetzen, also einen **Messwiederholungsfaktor** KFA verwenden, gewinnen wir jeweils *zwei* Beobachtungswerte, die eine statistische Analyse der allgemeinspsychologischen Hypothese mit relativ hoher Teststärke (kleiner Irrtumswahrscheinlichkeit zweiter Art) ermöglichen. Für jede Person wird die Differenz aus ihren beiden Ärgerwerten bestimmt, wobei individuelle Besonderheiten (z.B. generell hohe oder niedrige Ärgerneigung) verschwinden. Weil interindividuelle Unterschiede als Quelle von unaufgeklärter Merkmalsvarianz ausscheiden, kann der KFA-Effekt leichter nachgewiesen werden als bei einem Gruppierungsfaktor (siehe Cohen 1988, S. 51).

Gegen diese Vorgehensweise lässt sich einwenden, dass durch die Präsentation der *beiden* Varianten ein Kontrast künstlich induziert, zumindest jedoch verstärkt wird. Um diese **Artefaktgefahr** zu vermeiden, könnte man statt des Messwiederholungsfaktors KFA einen **Gruppierungsfaktor** verwenden und jede Person nur zu *einer* Schädigungsvariante befragen. Weil das Artefaktargument nicht zwingend und die Kursstichprobe aus organisatorischen Gründen relativ klein ist, hat das Teststärkeargument ein höheres Gewicht.

Die beiden Ärgermessungen werden durch Ratingskalen realisiert, wobei das Antwortformat der Anschaulichkeit halber an ein Thermometer mit den Ankerpunkten 0° und 100° erinnert. Wir gehen davon aus, dass die Ärgermessungen annähernd Intervallniveau besitzen.

1.3.2.2 Formulierung und Illustration der empirisch prüfbaren Hypothese

In Abschnitt 1.3.1 wurde die KFA-Hypothese noch ohne Bezug auf unsere Untersuchungsplanung formuliert. Jetzt nehmen wir eine Konkretisierung vor durch ...

- Verwendung von direkt beobachtbaren Begriffen
- Bezug auf Verteilungsparameter (Erwartungs- bzw. Mittelwert)

Zu Beginn von Kapitel 1 wurde betont, dass unsere Hypothesen in der Regel *probabilistischer* Natur sind. Auch bei einer allgemeinspsychologischen Hypothese wird man kaum auf einer Gültigkeit für *alle* Personen einer Population bestehen (womöglich sogar mit derselben Effektstärke). Die konkretisierte Hypothese sollte über die im statistischen Entscheidungsverfahren (siehe unten) tatsächlich analysierten Modell- bzw. Verteilungsparameter reden.

Außerdem soll hier der Klarheit halber (in einer für Forschungsberichte kaum zu empfehlenden Ausführlichkeit) dargelegt werden, dass bei einem inferenzstatistischen Entscheidungsverfahren *zwei* konkurrierende und komplementäre Hypothesen beteiligt sind:


Nullhypothese (H_0)	Die Untersuchungsteilnehmer erleben in der Rolle des Geschädigten mit hochgradig verfügbarer kontrafaktischer, also positiver Ereignisalternative im Mittel <i>nicht</i> mehr Ärger als in der Rolle des Geschädigten mit „weit entfernter“ kontrafaktischer Alternative.
Alternativhypothese (H_1) ¹	Die Untersuchungsteilnehmer erleben in der Rolle des Geschädigten mit hochgradig verfügbarer kontrafaktischer Alternative im Mittel mehr Ärger.

In den Hypothesen werden die Erwartungs- bzw. Mittelwerte von zwei Merkmalen verglichen:

- Ärgerausprägung in der Situation mit „weit entfernter“ kontrafaktischer Alternative
- Ärgerausprägung in der Situation mit hochgradig verfügbarer kontrafaktischer Alternative

Zur Vereinfachung der Ausdrucksweise sprechen wir ab jetzt vereinfachend über die Situationen *ohne* bzw. *mit* KFA.

Das folgende Diagramm zeigt die Verteilungen des Ärgers aus der Situation *ohne* (blau) bzw. *mit* KFA (rot) im Sinne unserer Alternativhypothese:



Zur Veranschaulichung der Alternativhypothese wird hier für beide Ärgervarianten eine spezielle eingipflige Verteilungsform, nämlich die Normalverteilung, verwendet. Allerdings ist in den Hypothesen *keine* Aussage über die Verteilungsform enthalten.

Mit dem Symbol μ_o für den Erwartungswert (Populationsmittelwert) des Ärgers ohne KFA und dem Symbol μ_M für den Erwartungswert des Ärgers mit KFA kann unser allgemeinspsychologisches KFA-Testproblem kompakt so formuliert werden:

$$H_0 : \mu_M \leq \mu_o \quad \text{versus} \quad H_1 : \mu_M > \mu_o$$

1.3.2.3 Entscheidungsverfahren

Wir wollen das eben beschriebene Entscheidungsproblem mit einem **t-Test für verbundene** (alias: **abhängige**) **Stichproben** lösen, weil dieses Verfahren sehr gut dazu in der Lage ist, einen vorhandenen Effekt nachzuweisen (hohe Teststärke), sofern seine Verteilungsvoraussetzung erfüllt ist.

¹ Hier handelt es sich um einen statistischen Terminus, der nur zufällig mit unserer allgemeinspsychologischen Hypothese den Wortbestandteil *alternativ* gemeinsam hat.

Diese Voraussetzung betrifft die *Differenz* der beiden Ärgerausprägungen, die in der Population normalverteilt sein muss (siehe Abschnitt 7.1). Ist diese Bedingung *nicht* erfüllt, ist der t-Test für verbundene Stichproben unzulässig und besitzt außerdem in der Regel *keine* gute Teststärke (Entdeckungswahrscheinlichkeit). Wir werden die Normalverteilungsannahme für die Ärgerdifferenz mit den Daten unserer Stichprobe überprüfen und bei ungünstigem Testergebnis ein alternatives Entscheidungsverfahren wählen.

Da gerichtete Hypothesen vorliegen, ist **einseitig** zu testen. Dabei wird eine Irrtumswahrscheinlichkeit erster Art in Höhe von $\alpha = 0,05$ akzeptiert.

Es wäre unzulässig und im Hinblick auf die Teststärke vor allem auch ineffizient, anstatt des t-Tests für abhängige Stichproben einen t-Test für *unabhängige* Stichproben durchzuführen, und dabei die beiden von einer Person stammenden Ärgermessungen als unabhängig zu betrachten. Enthalten z.B. die Variablen $X_i^{(O)}$ bzw. $X_i^{(M)}$ den von Person i gelieferten Ärger in der Situation ohne bzw. mit KFA, dann enthalten beide Variablen denselben Personeneffekt (z.B. die generelle Ärgerneigung und die aktuelle Stimmung von Person i). Liegt z.B. $X_i^{(O)}$ bei einer leicht erregbaren Person i über μ_O , dann liegt erwartungsgemäß auch $X_i^{(M)}$ über μ_M . Die beiden Residuen (Abweichungen vom Populationserwartungswert) sind also korreliert, und die Unabhängigkeitsannahme des t-Tests für unabhängige Stichproben ist verletzt.

Beim t-Test für verbundene Stichproben wird für jede Person die Differenz aus den Variablen $X_i^{(O)}$ und $X_i^{(M)}$ gebildet. Es ist also pro Person nur noch *ein* Wert im Spiel, so dass die Abhängigkeitsproblematik verschwindet. Außerdem verschwinden durch die Differenzbildung auch die für unaufgeklärte Varianz sorgenden interindividuellen Unterschiede, so dass die Chancen steigen, einen Mittelwertsunterschied im Sinne der Alternativhypothese ($\mu_M > \mu_O$) in den Stichprobendaten zu entdecken.

1.3.2.4 Stichprobenumfangsplanung

Da aus statistischer Sicht eine Stichprobe nie zu groß sein kann, sollen nach Möglichkeit *alle* Kursteilnehmer als Probanden gewonnen werden. Es ist aus praktischen Gründen nicht möglich, weitere Untersuchungsteilnehmer zu rekrutieren. Der Übung halber soll aber trotzdem an dieser Stelle eine β -Fehler - basierte Kalkulation des **Stichprobenumfangs** vorgenommen werden. Vor allem bei hohen Kosten pro Untersuchungseinheit möchte man wissen, wie groß die Stichprobe sein muss, damit ein angenommener Populationseffekt mit einer gewünschten Wahrscheinlichkeit zu einem signifikanten Testergebnis führt. Diese Entdeckungswahrscheinlichkeit (engl. *Power*) ist das Komplement des β -Fehlerrisikos, d.h.

$$\text{Power} = 1 - \beta\text{-Fehlerrisiko}$$

Die Firma IBM SPSS unterstützt solche Berechnungen im Zusatzprogramm **SamplePower**, das auf den Pool-PCs der Universität Trier nicht zur Verfügung steht. Stattdessen verwenden wir das exzellente Power-Analyse - Programm **G*Power 3.1** (Faul et al. 2007, 2009), das für Mac OS X und Windows kostenlos über folgende Webseite zu beziehen ist:

<http://www.psych.uni-duesseldorf.de/abteilungen/aap/gpower3/>


Auf den Pool-PCs der Universität Trier unter dem Betriebssystem Windows lässt sich G*Power 3.1 über die folgende Programmgruppe starten

Start > Alle Programme > Statistik > GPower

Zur Planung des Stichprobenumfangs für den t-Test zur KFA-Hypothese wählen wir in G*Power folgende Problembeschreibung:

- **Test family:** **t-Tests**
- **Statistical test:** **Means: Difference between two dependent means**
- **Type of power analysis:** **A priori**

und öffnen über den Schalter **Determine** ein Zusatzfenster, um die Effektstärke in der Population aufgrund theoretischer Annahmen und/oder bisheriger empirischer Befunde festlegen zu können:



Unsere KFA-Hypothese handelt vom *Ärgerzuwachs* aufgrund einer mental leicht verfügbaren positiven Alternative zum negativen Ereignis und kann über die *Differenz* der beiden Ärgermessungen beurteilt werden. Wir verwenden in G*Power 3.1 diese Sichtweise (**From differences**), um die **Effektstärke** d_z bequem festlegen zu können.

Beim geplanten t-Test für abhängige Stichproben und auch bei der nun anstehenden Stichprobenumfangsplanung wird für den *Ärgerzuwachs* eine Normalverteilung in der Population angenommen (siehe Abschnitt 7.1).

Die Effektstärke ist (wie beim letztlich zugrunde liegenden Einstichproben - t-Test) folgendermaßen definiert (vgl. Cohen 1988, S. 48; Faul et al. 2007, S. 182; Wentura 2004, S. 4):

$$d_z := \frac{\mu_d}{\sigma_d}$$

Darin sind:

- μ_d Mittlere Ärgerdifferenz in der Population
- σ_d Standardabweichung der Ärgerdifferenz in der Population

Indem man den Abstand des Lageparameters μ_d von der Nullhypothesenbehauptung in *Standardabweichungseinheiten* angibt, erhält man einen Effektstärkeindex mit guter Vergleichbarkeit. Werden z.B. in zwei Studien zum selben theoretischen Konstrukt Messverfahren (Operationalisierungen) mit unterschiedlichen Standardabweichungen eingesetzt, sind die beiden erzielten Effektstärken durch die Verwendung der obigen Definition trotzdem vergleichbar.¹

Zur Beurteilung von d_z -Werten hat Cohen (1988, S. 40) den folgenden Vorschlag gemacht:²

- kleiner Effekt: $d_z = 0,2$
- mittlerer Effekt: $d_z = 0,5$
- großer Effekt: $d_z = 0,8$

Für die Beispielstudie lässt sich eine konkrete Effektstärke begründen, so dass wir nicht auf die oft zu beobachtende Annahme einer *mittleren* Effektstärke zurückgreifen müssen. Beim Ärgerzuwachs wird ein Erwartungswert von 20 angenommen bzw. als theoretisch relevant und „entdeckungswürdig“ eingestuft. Als Ärgerzuwachs-Standardabweichung (Nebenparameter der KFA-Hypothese) vermuten wir aufgrund bisheriger Studien ebenfalls einen Wert von ca. 20. Mit dem Schalter

Calculate and transfer to main window

befördern wir die resultierende, sehr große Effektstärke von 1,0 in das G*Power-Hauptfenster.

Dort wählen wir ...

- einen gerichteten Test (**Tail(s): One**)
- ein akzeptiertes α -Fehlerrisiko (**α err prob**) der Größe 0,05
Bei der Eingabe ist zu beachten, dass G*Power nur den *Punkt* als Dezimaltrennzeichen akzeptiert.
- eine gewünschte Teststärke (**Power**) von 0,95, also ein β -Fehlerrisiko von 0,05

Nach einem Mausklick auf den Hauptfensterschalter


Calculate

erhalten wir das beruhigende Ergebnis, dass lediglich 13 Fällen erforderlich sind. Sofern ein Effekt von der angenommenen (oder einer größeren) Stärke vorhanden ist, werden wir ihn mit großer Wahrscheinlichkeit entdecken, weil an der Kursstudie in der Regel ca. 30 Fälle teilnehmen.

Um die Ergebnisse der Stichprobenumfangskalkulation mit G*Power in einen Projektbericht zu übernehmen, wechselt man zur Registerkarte mit dem **Protocol of power analysis**:

¹ Das gilt allerdings nur, wenn beide Studien in derselben Population durchgeführt werden. Beim Vergleich von Effektstärken aus verschiedenen Populationen mit unterschiedlichen Varianzen ist das Standardisieren eher ungünstig (siehe z.B. Eid et al. 2013, S. 216f).

² Nach diesem Vorschlag werden d_z -Werte genauso beurteilt wie d -Werte aus dem Vergleich von zwei unabhängigen Stichproben. Allerdings müssen d_z -Werte vor der Verwendung von Cohens Power-Tabellen für d -Werte nach folgender Formel in d -Werte transformiert werden: $d = d_z \sqrt{2}$ (siehe Cohen 1988, S. 46). Hier artikuliert sich die (bei gleicher Effektstärke) höhere Power des t-Tests für abhängige Stichproben gegenüber seinem Pendant für unabhängige Stichproben. Eid et al. (2013, S. 353) interpretieren Cohen (1988) allerdings anders und werten z.B. schon den d_z -Wert $\frac{0,2}{\sqrt{2}} \approx 0,14$ als kleinen Effekt.



Man kann das Protokoll in eine RTF-Datei (*Rich-Text-Format*) sichern (Schalter **Save**), drucken (Schalter **Print**) oder die markierten Bestandteile mit der Tastenkombination **Strg+C** in die Windows-Zwischenablage befördern, um den formatierten Text anschließend in ein Zieldokumentenfenster einzufügen (z.B. mit der Tastenkombination **Strg+V**).

1.3.3 Eine differentialpsychologische Hypothese

Neben der im Fokus stehenden KFA-Hypothese soll in unserer Studie noch die folgende, auf Überlegungen von Scheier & Carver (1985) zurückgehende Hypothese überprüft werden:

Der durch ein negatives Ereignis ausgelöste Ärger wird durch dispositionellen Optimismus gedämpft.

Begründung: Dispositioneller Optimismus führt zur Verwendung günstiger Bewältigungsstrategien (z.B. positive Reinterpretation von negativen Erfahrungen).

Während die allgemeinspsychologische KFA-Hypothese für eine beliebig aus der Allgemeinbevölkerung herausgegriffene Person einen Effekt postuliert, geht es hier um Differentialpsychologie, also um Verhaltens- bzw. Erlebensunterschiede in Folge von relativ stabilen Personmerkmalen.

Als Quasieignis soll der schon zur Prüfung der allgemeinspsychologischen Hypothese verwendete imaginierte Schadensfall dienen (Fragebogenteil 1, siehe Abschnitt 1.3.6). Das arithmetische Mittel der für beide Situationsvarianten angegebenen Ärgerausprägungen soll als Ärgermaß dienen. Zur Erfassung von dispositionellem Optimismus wird der von Scheier & Carver (1985) entwickelte *Life Orientation Test* (LOT) eingesetzt (siehe Fragebogenteil 2). Wie aus den Antworten auf die zwölf Fragen dieses Tests ein Optimismus-Messwert zu ermitteln ist, wird später erläutert. Wir gehen jedenfalls davon aus, dass diese Messmethode annähernd Intervallniveau besitzt.

Nach dieser **Operationalisierung** der theoretischen Begriffe kann die folgende **empirisch prüfbare Alternativhypothese** formuliert werden:


Je höher der LOT-Wert einer Person, desto weniger Ärger (Mittel aus beiden Situationsvarianten) berichtet sie für den imaginierten Schadensfall.

Die Nullhypothese ergibt sich durch Negation der Alternativhypothese und muss daher nicht notiert werden.

Weil die Messungen zum Ärger und zum Optimismus (hoffentlich) Intervallskalenniveau besitzen, kann die differentialpsychologische Hypothese mit einer **einfachen (bivariaten) linearen Regressionsanalyse** geprüft werden, sofern deren Modell- und Verteilungsvoraussetzungen erfüllt sind (siehe Abschnitt 7.2). Bei der bivariaten linearen Regression kann man tatsächlich von einem *Modell* sprechen. Die Modellgleichung für ein zu erklärendes Kriterium Y , einen Regressor X und ein Residuum ε war schon in Abschnitt 1.1 zu sehen:

$$Y = \beta_0 + \beta_1 X + \varepsilon, \varepsilon \sim N(0, \sigma^2)$$

Als Modellparameter treten der Ordinatenabschnitt β_0 und der Steigungskoeffizient β_1 , die gemeinsam eine Regressionsgerade festlegen, sowie die Varianz des Residuums auf. Dabei ist β_0 der Schnittpunkt der Regressionsgeraden mit der Y-Achse (Ordinatenabschnitt) und β_1 die Steigung der Regressionsgeraden. Unserer differentialpsychologischen Alternativhypothese entspricht eine Regressionsgerade mit negativer Steigung, weil wir eine Ärgerreduktion bei zunehmendem Optimismus erwarten. Für jede Ausprägung x des Regressors befindet sich die modellgemäße Erwartung $E_x(Y)$ auf der Regressionsgeraden:



Zur Interpretation des Koeffizienten β_1 : Erhöht man X um eine Einheit, so sinkt modellgemäß der Erwartungswert $E_x(Y)$ um β_1 Einheiten.

Die statistisch zu prüfende Alternativhypothese lässt sich im Rahmen dieses Modells sehr präzise formulieren:


In der linearen Regression von Ärger (Mittel aus beiden Situationsvarianten) auf den LOT-Testwert ergibt sich ein negativer Steigungskoeffizient (β_1).

Die Hypothese ist *gerichtet (einseitig)* formuliert und soll bei einem α -Fehler – Risiko von 0,05 mit dem t-Test zum Regressionskoeffizienten β_1 geprüft werden.

Zur Berechnung der erforderlichen Stichprobengröße wählen wir im Teststärkenanalyseprogramm G*Power 3.1 (vgl. Abschnitt 1.3.2):

- **Test family:** **t-Tests**
- **Statistical test:** **Linear multiple regression: Fixed model, single regression coefficient**
- **Type of power analysis:** **A priori**

Für den geplanten einseitigen t-Test mit einem α -Fehler – Risiko von 0,05 in einem Modell mit *einem* Prädiktor wählen wir die von Cohen (1988, S. 56) als Standardwert empfohlene Power (Entdeckungswahrscheinlichkeit) von 0,8 (entspricht einem β -Fehlerrisiko von 0,2):




Das von G*Power verwendete Effektstärkemaß f^2 steht bei einer bivariaten Regression in folgender Beziehung zur quadrierten Korrelation ρ^2 zwischen Kriterium und Regressor in der Population:

$$f^2 = \frac{\rho^2}{1 - \rho^2}$$

Die quadrierte Korrelation ρ^2 bezeichnet man auch als *Determinationskoeffizienten*, weil sie den vom Regressor erklärten Anteil der Kriteriumsvarianz quantifiziert.

Wie das folgende Diagramm zeigt, stehen ρ^2 und f^2 im interessanten Wertebereich von 0 bis 0,5 fast in einer linearen Beziehung zueinander:



Wir nehmen einen Determinationskoeffizienten von 0,09 (also eine LOT-Ärger - Korrelation von -0,3) und damit eine Effektstärke von ca. 0,1 an:

$$\frac{0,09}{1 - 0,09} = \frac{0,09}{0,91} \approx 0,1$$

In G*Power öffnen wir mit dem Schalter **Determine** das Seitenfenster zur Effektstärkenspezifikation, wählen dort die Option **Direct**, tragen im Textfeld **Partial R²** den Wert 0,09 ein und übernehmen den resultierenden f^2 -Wert mit dem Schalter **Calculate and transfer to main window**. Beachten Sie bitte, dass G*Power als Dezimaltrennzeichen einen Punkt verlangt.

Wie nach einem Klick auf den Hauptfensterschalter **Calculate** zu erfahren ist, resultiert aus unserer Problembeschreibung ein erforderlicher Stichprobenumfang von 64 Fällen. Weil die Kursstichprobe in der Regel kleiner ist, stehen unsere Chancen, einen Effekt von der vermuteten Stärke zu entdecken, also eher schlecht. Bei einer gewünschten Power von 0,95 (β -Fehler 0,05) werden sogar 111 Fälle benötigt. In einem realen Forschungsprojekt zur Klärung der differentialpsychologischen Hypothese müsste der Stichprobenumfang folglich erhöht werden.

Bei einem *zweiseitigen* Test werden bei der oben angenommenen Effektstärke und $\alpha = \beta = 0,05$ bereits 134 Fälle benötigt. Wer den Unterschied zwischen gerichteten und ungerichteten Hypothesen ignoriert und mit dem bei EDV-Programmen üblicherweise voreingestellten zweiseitigen Test arbeitet, verliert also bei identischem Stichprobenumfang in erheblichem Umfang an Teststärke.

Zur Beurteilung der Effektstärke im Model der bivariaten linearen Regression nennt Cohen (1988, S. 77ff) folgende Orientierungswerte:

Effektstärke in der Population	ρ^2	f^2
klein	0,01	0,01
mittel	0,09	0,10
groß	0,25	0,33

Damit ein *großer* Effekt bei einseitiger Testung zum α -Niveau 0,05 mit einer Wahrscheinlichkeit von 0,8 zu einem signifikanten Ergebnis führt, sind nur 21 Fälle erforderlich, so dass für die differentialpsychologische Hypothese auch in der relativ kleinen Kursstichprobe noch Anlass zur Hoffnung besteht.

Bei der Stichprobenumfangsplanung ist es oft schwierig, eine begründete Effektstärke anzugeben. Ein häufig gewählter Ausweg besteht darin, von einer mittleren Effektstärke auszugehen.

Wird ein Regressor aus einem *multiplen* linearen Regressionsmodell (mit zwei oder mehr Regressoren) betrachtet, geht statt der oben betrachteten quadrierten Korrelation ρ^2 die quadrierte *partielle* Korrelation zwischen dem betrachteten Regressor und dem Kriterium bei Kontrolle der restlichen Regressoren in die Effektstärkenberechnung ein (siehe **Determine** - Seitenfenster in G*Power).

1.3.4 Demografische Merkmale

Auf die Erfassung demografischer Merkmale (siehe Fragebogenteil 4 in Abschnitt 1.3.6) kann man in keiner Studie mit Personen als Untersuchungseinheiten verzichten, auch wenn sich keine expliziten Hypothesen darauf beziehen. Man benötigt sie auf jeden Fall zur Beschreibung der

Stichprobe, damit sich später die Leser von Berichten ein Urteil über die Interpretier- bzw. Generalisierbarkeit der Ergebnisse bilden können. Wir werden darüber hinaus einige demografische Merkmale auf Zusammenhänge mit unseren zentralen Projektvariablen untersuchen. Insofern finden sich auch in unserem überwiegend konfirmatorisch (hypothesenprüfend) angelegten Projekt einige explorative Elemente.

Wie Jacob et al. (2013, S. 138) plausibel begründen, sollten demografische Fragen *nicht* am Anfang einer Befragung stehen:

- Die Auskunftspersonen werden zunächst mit relativ langweiligen Aufgaben behelligt und erfahren den Zweck der Befragung verspätet.
- Manche demografische Fragen (etwa nach Bildung oder Einkommen) können als heikel erlebt werden. Dies kann die Teilnahmemotivation reduzieren und/oder das Antwortverhalten beeinflussen.

Damit ist das Ende eines Fragebogens in der Regel der angemessene Ort für demografische Fragen.

Anmerkungen zu einigen Erhebungstechniken im Beispielfragebogen:

- Beim Geschlecht wurde die Residualkategorie *Keine Angabe* aufgenommen, um Fälle von Inter- bzw. Transsexualität zu berücksichtigen.
- Statt nach dem Alter wird nach dem Geburtsjahr gefragt, weil manche Auskunftspersonen diese Information leichter und genauer liefern können.
- Nach der (generell meist relevanten) Bildung zu fragen, wäre in der diesbezüglich sehr homogenen Kursstichprobe eine Vergeudung von Befragungszeit.
- Indem die Probanden (allesamt Studierende an der Universität Trier) auch nach ihrem primären Fachbereich befragt werden, lassen sich Geschlechtsunterschiede bei der Studienfachpräferenz untersuchen. Diese Fragestellung werden wir in Kapitel 13 als Anwendungsbeispiel für die Kreuztabellenanalyse verwenden.

Über Standards zur Erfassung von soziodemografischen Daten informieren z.B. Jacob et al. (2013, S. 151ff) und das statistische Bundesamt (2010).

1.3.5 Zu Übungszwecken erhobene Merkmale

Rein zu Übungszwecken und ohne inhaltlichen Bezug zu den oben beschriebenen Hypothesen sollen zusätzlich folgende Informationen erhoben werden:

- Motive zur Kursteilnahme (siehe Fragebogenteil 3 in Abschnitt 1.3.6)
Mit diesen Merkmalen lässt sich üben, wie die aus Mehrfachwahlfragen und offenen Fragen resultierenden Informationen deklariert, erfasst und analysiert werden können.
- Größe und Gewicht (siehe Fragebogenteil 4 in Abschnitt 1.3.6)
Mit diesen Merkmalen lassen sich manche statistische und grafische Verfahren gut demonstrieren.

1.3.6 Der Fragebogen

1) Fragen zur Reaktion in ärgerlichen Situationen

Versetzen Sie sich bitte möglichst gut in folgende Situation:

Herr Meier und Herr Schulze waren mit demselben Taxi auf dem Weg zum Flughafen. Sie sollten zur selben Zeit, aber mit verschiedenen Maschinen abfliegen. Durch einen Stau kommen sie erst eine halbe Stunde nach der planmäßigen Abflugzeit am Flughafen an.

Herr Meier erfährt, dass seine Maschine pünktlich vor einer halben Stunde gestartet ist.

Herr Schulze erfährt, dass seine Maschine Verspätung hatte und erst vor zwei Minuten gestartet ist.

Wie sehr würden Sie sich **ärgern**, wenn Sie in der Situation von ...

Herrn Meier wären?	0	10	20	30	40	50	60	70	80	90	100
Herrn Schulze wären?	0	10	20	30	40	50	60	70	80	90	100

Betrachten Sie bitte die Antwortskala als "Ärgerthermometer".

2) Aussagen zur Selbsteinschätzung

Teilen Sie bitte für die folgenden Selbstbeschreibungen durch Ankreuzen einer Antwortkategorie mit, inwiefern die Aussagen auf Sie persönlich zutreffen.

	völlig falsch	falsch	unent- schieden	stimmt	stimmt genau
1. Auch in unsicheren Zeiten rechne ich im Allgemeinen damit, dass sich alles zum Besten wendet.	☐	☐	☐	☐	☐
2. Ich kann mich leicht entspannen.	☐	☐	☐	☐	☐
3. Wenn etwas schief gehen kann, dann passiert es mir auch.	☐	☐	☐	☐	☐
4. Bei allem sehe ich stets die negative Seite.	☐	☐	☐	☐	☐
5. Ich blicke kaum einmal mit Zuversicht in die Zukunft.	☐	☐	☐	☐	☐
6. Ich bin gern mit Freunden zusammen.	☐	☐	☐	☐	☐
7. Ich muss mich immer mit etwas beschäftigen.	☐	☐	☐	☐	☐
8. Ich habe stets die Hoffnung, dass die Dinge in meinem Sinne gehen.	☐	☐	☐	☐	☐
9. Die Dinge laufen immer so, wie ich es mir wünsche.	☐	☐	☐	☐	☐
10. Ich bin nicht leicht aus der Ruhe zu bringen.	☐	☐	☐	☐	☐
11. Ich glaube an den sprichwörtlichen "Silberstreifen am Horizont".	☐	☐	☐	☐	☐
12. Dass mir einmal etwas Gutes widerfährt, damit rechne ich kaum.	☐	☐	☐	☐	☐

3) Ihre Motive für die Teilnahme am SPSS-Kurs

- a) Kreuzen Sie bitte in der folgenden Liste möglicher Motive für die Teilnahme am SPSS-Kurs alle für Sie zutreffenden Aussagen an und/oder nennen Sie Ihre sonstigen Motive.

Ich möchte SPSS kennen lernen, ...

- ☐ um eine eigene empirische Studie damit auszuwerten.
- ☐ weil in vielen Stellenanzeigen SPSS-Kenntnisse verlangt werden.
- ☐ weil ich mich um eine Stelle als EDV-Hilfskraft in der Forschung bewerben will (HIWI-Job).
- ☐ weil ich mich für EDV interessiere und ein modernes Programm kennen lernen möchte.
- ☐ weil ich mich für Statistik interessiere und mit Auswertungsverfahren experimentieren möchte.
- ☐ Andere Motive: _____

- b) Möchten Sie im Kurs bestimmte statistische Methoden besonders gerne üben? Ja ☐ Nein ☐

Wenn „Ja“, welche? _____

4) Angaben zur Person

Geschlecht	Frau ☐ Mann ☐ Keine Angabe ☐
Geburtsjahr	__ __ __ __
Primärer Fachbereich	☐ I ☐ II ☐ III ☐ IV ☐ V ☐ VI ☐ VII
Körpergröße	__, __ __ m
Körpergewicht	__ __ __ kg

1.4 Strukturierung und Kodierung der Daten

Wir werden die mit unserem Fragebogen erhobenen Informationen später manuell mit dem SPSS-Dateneditor erfassen und erstellen daher einen **Kodierplan** mit genauen Handlungsanweisungen für die Erfassung. Dabei müssen wir uns auch mit den Voraussetzungen beschäftigen, die SPSS für die Aufnahme unserer Daten bereitstellt. Diese sind in erster Linie durch die Logik der empirischen Forschung und nur in geringem Ausmaß durch EDV-Restriktionen festgelegt.

Bei der Online-Erhebung wird kein Kodierplan als Arbeitsvorschrift für Datenerfasser benötigt, jedoch kann auch hier eine Dokumentation der Daten nützlich sein (z.B. für die Kooperation in einer Arbeitsgruppe). Die in Abschnitt 1.4 behandelten Festlegungen werden bei der Online-Erhebung teilweise bei der Projektdeklaration gegenüber dem zuständigen Programm geregelt und teilweise von dieser Software entschieden. Bei manchen Aufgaben sind aber Urteilsvermögen und Handarbeit eines Menschen durch keine Software zu ersetzen, z.B. bei der Behandlung der Antworten auf offene Fragen (siehe Abschnitt 1.4.2.4). Insgesamt kann der Abschnitt 1.4 auch solchen Lesern zur Lektüre empfohlen werden, die zu einer Online-Erhebung tendieren.

1.4.1 Fälle und Merkmale in SPSS

Wir haben oben bereits daran erinnert, dass in einer empirischen Studie bei den einbezogenen **Fällen** bzw. **Untersuchungseinheiten** die Ausprägungen etlicher **Merkmale** festgestellt werden. Nun wollen wir uns ansehen, wie die Merkmalsausprägungen der Fälle im SPSS-System gespeichert werden. Die ganz konkrete Demonstration von KFA-Beispieldaten im **SPSS-Dateneditorfenster** wird das Verständnis der anschließenden, wieder eher allgemein-methodologisch geprägten, Ausführungen unterstützen. U.a. werden dabei auch einige zentrale Begriffe des SPSS-Systems erläutert:

a) Variable

Der Begriff *Variable* wird in der Literatur zur statistischen Datenanalyse häufig synonym zum Begriff *Merkmal* gebraucht. Wir wollen ihn SPSS-konform in einer etwas technischeren Bedeutung verwenden: Schreibt man für ein Merkmal die Ausprägungen aller Fälle in der Stichprobe untereinander, so entsteht ein Spaltenvektor, und einen solchen Spaltenvektor wollen wir als *Variable* bezeichnen. Genau genommen gehören zu einer SPSS-Variablen auch noch etliche Attribute, vor allem ein Name.

Zwar resultieren Variablen meist (wie eben beschrieben) aus jeweils *einem* Merkmal, doch kann z.B. das Bemühen um eine rationelle Datenerfassung zu Ausnahmen führen. In Kürze wird eine Technik vorgeschlagen, die zur Erfassung von 100 Merkmalen mit Hilfe von sieben Variablen führt.

b) Datenmatrix und Dateneditor

Schreibt man alle Variablen eines Projekts nebeneinander, so entsteht eine (Fälle $\times$ Variablen) - **Datenmatrix** (Datentabelle). Sie kann in einem Fenster des **SPSS-Dateneditors** aufgebaut und auch dort während der Auswertungsarbeit ständig eingesehen oder modifiziert werden. Die folgende Abbildung zeigt ein Dateneditorfenster mit den KFA-Beispieldaten aus einem früheren statistischen Praktikum:

	fnr	aergo	aergm	lot1	lot2	lot3	lot4	lot5	lot6	lot7	lot8	lot9	lot10	lot11	lot12	motiv1	motiv2	motiv3	motiv4	motiv5
1	1	5	8	4	2	4	5	4	5	3	4	4	3	4	4	1	0	0	0	0
2	2	5	8	4	3	5	4	4	4	3	4	2	3	4	4	1	0	0	0	0
3	3	4	8	4	2	3	4	4	4	5	4	3	1	3	4	0	0	0	0	0
4	4	6	2	4	4	4	5	4	5	3	3	2	4	4	4	1	0	0	0	0
5	5	8	8	3	1	4	4	4	5	5	4	3	4	4	5	1	0	0	0	0
6	6	8	10	2	2	4	5	4	5	1	4	4	3	3	5	0	0	0	1	0
7	7	6	8	3	3	3	2	3	4	3	3	2	2	3	4	1	0	0	0	1
8	8	5	6	4	3	3	3	5	5	3	4	4	2	4	5	1	0	0	0	1
9	9	4	4	3	3	4	4	5	5	2	3	2	3	4	5	0	0	1	0	0
10	10	6	10	4	2	4	5	5	5	4	3	4	2	5	5	1	0	0	0	0
11	11	2	6	4	2	3	2	4	5	4	4	3	2	3	5	1	0	0	0	0
12	12	10	10	4	3	2	4	4	5	3	3	2	4	3	3	1	0	0	1	0
13	13	8	10	3	2	2	2	.	5	3	4	2	2	4	3	.	.	.	.	.
14	14	3	5	4	2	4	1	5	4	3	3	4	4	4	5	1	0	0	0	0

Weil die zugrunde liegende Stichprobe im Manuskript häufig zur Demonstration dient, wird sie als *Manuskriptstichprobe* bezeichnet.

Jede Variable, d.h. jede Spalte der Datenmatrix, besitzt einen eindeutigen **Variablennamen**, über den sie bei der Anforderung von Analysen und Diagrammen angesprochen werden kann.

Nachdem Sie einen exemplarischen Eindruck vom *Ziel* der Strukturierungs- und Kodierungsbemühungen gewonnen haben, werden wir nun einige Details behandeln und einen Kodierplan für unser Projekt erstellen. Dabei soll u.a. angestrebt werden, den Aufwand und die Fehlergefahr bei der manuellen Datenerfassung möglichst gering zu halten.

1.4.2 Strukturierung

Welche SPSS-Variablen im oben besprochenen Sinn sollen zur Aufnahme der mit unserem Fragebogen erfassten Informationen definiert werden? Obwohl die Antwort auf diese Frage trivial zu sein scheint, sind doch zu einigen Themen kurze Erläuterungen angebracht.

1.4.2.1 Variablen zur Fallidentifikation

Über die empirischen Variablen hinaus sollten in die Datenmatrix stets organisatorische Variablen zur Fallidentifikation aufgenommen werden, was u.a. folgende Vorteile bietet:

- In der Regel besteht für die Identifikationsvariablen Eindeutigkeitszwang, so dass Dubletten (doppelt vorhandene Fälle) leicht identifiziert werden können.
- Sind zu den Fällen schriftliche oder sonstige Untersuchungsdokumente vorhanden, sollten diese eindeutig mit den Daten im Rechner verknüpft sein. Eine solche Korrespondenz ist für eventuelle spätere Kontrollen oder Korrekturen der Daten erforderlich.

Meist verwendet man zur Fallidentifikation eine *einzelne* Variable, die z.B. FNR (für *Fallnummer*) genannt werden kann. Natürlich muss die Fallidentifikation ggf. auch auf den schriftlichen oder sonstigen Untersuchungsdokumenten eingetragen werden. Bei personbezogenen Daten wählt man aus Datenschutzgründen zur Fallidentifikation z.B. eine zufällig vergebene Nummer ohne jeden Bezug zu den Personalien.

Möglicherweise erscheint Ihnen bei der Erfassung schriftlicher Untersuchungsdokumente das Eintippen einer Identifikationsvariablen überflüssig, weil im SPSS-Dateneditor (siehe Abbildung in Abschnitt 1.4.1) die Zeilen bzw. Fälle ohnehin fortlaufend nummeriert sind. Die Nummern der Datenfensterzeilen stellen jedoch die gewünschte Korrespondenz zwischen den Datensätzen im Rechner und den nummerierten schriftlichen (oder sonstigen) Untersuchungsdokumenten *nicht zuverlässig* her. Die Nummerierung der Datenfensterzeilen kann sich nämlich leicht ändern, z.B. wenn ein Sortieren der Fälle nötig wird, oder wenn Fälle gelöscht oder eingefügt werden.

1.4.2.2 Abgeleitete Variablen gehören nicht in den Kodierplan

Häufig sind in einem Forschungsprojekt nicht nur die direkt erfassten *Rohvariablen* von Interesse, sondern auch darauf aufbauende Variablen. Im KFA-Projekt soll etwa der Optimismus der Untersuchungsteilnehmer durch ihre mittlere Antwort auf die Fragen im Life Orientation Test (LOT) geschätzt werden. SPSS verfügt über leistungsfähige Dialogboxen bzw. Befehle zur Berechnung neuer Variablen aus bereits vorhandenen, so dass derartige Routinearbeiten keinesfalls bei der Datenerfassung (z.B. per Taschenrechner) erledigt werden sollten. Freilich müssen nach diesem Vorschlag *alle* Ausgangsvariablen erfasst werden, was aber vielfach ohnehin erforderlich ist (z.B. zur Überprüfung messtechnischer Eigenschaften der Ausgangsvariablen per Faktoren- und/oder Reliabilitätsanalyse). Erfassen Sie also ausschließlich Rohvariablen, und führen Sie alle

erforderlichen Transformationen später mit SPSS-Techniken durch. Wir werden uns im weiteren Kursverlauf mit den SPSS-Transformationsmethoden ausführlich beschäftigen.


1.4.2.3 Mehrfachwahlfragen

Im Teil 3a unseres Fragebogens teilen die Untersuchungsteilnehmer für fünf konkrete Motive und eine Restkategorie mit, ob sie bei ihrer Entscheidung für die Kursteilnahme relevant waren. Damit erfahren wir von jeder Person sechs eigenständige Merkmalsausprägungen und benötigen (ohne Komprimierungsverfahren, siehe unten) folglich in der SPSS-Datenmatrix sechs Variablen, um die Antworten aufzunehmen, die wir z.B. durch die Zahlen Eins (für ein markiertes Motiv) und Null (für ein *nicht* markiertes Motiv) kodieren können.

Beim Umgang mit einer Mehrfachwahlfrage müssen Sie sich vor allem vor dem aussichtslosen Versuch hüten, die Informationen zu allen Merkmalen in *eine* Variable zu verpacken. Dies käme dem unsinnigen Versuch gleich, für jede Person *mehrere* Werte (z.B. Zahlen) in *eine* Zelle der SPSS-Datenmatrix einzutragen. So absurd das eben beschriebene Ziel dem Leser (hoffentlich) erscheinen mag, geistert es doch durch manche Köpfe und führt nicht selten zu Beratungsanfragen.

1.4.2.3.1 Vollständige Sets aus dichotomen Variablen

In unserem Beispiel aus dem Fragebogenteil 3a führt also eine Mehrfachwahlfrage zu sechs dichotomen SPSS-Variablen, die jeweils die Information darüber enthalten, ob ein bestimmtes Motiv (bzw. ein sonstiges Motiv) vorlag oder nicht. Das folgende Datenfenster zeigt die sechs Variablen, hier mit den Namen MOTIV1 bis MOTIV5 und ANDERE, bei einem Fall mit dem Antwortmuster (1,0,0,0,1,0):



Wir werden in Kapitel 15 ein so genanntes **Mehrfachantwortset** bestehend aus diesen sechs Variablen definieren und mit seiner Hilfe eine gemeinsame Auswertung der Variablen vornehmen. An dieser Stelle müssen Sie jedoch unbedingt akzeptieren, dass wir es mit *sechs* Merkmalen bzw. Variablen zu tun haben, die eine gewisse inhaltliche Verwandtschaft und ein gemeinsames dichotomes Format besitzen.

1.4.2.3.2 Sparsame Sets aus kategorialen Variablen


Das im letzten Abschnitt beschriebene Standardverfahren zur Übersetzung einer Mehrfachwahlfrage in SPSS-Variablen ist angemessen, sofern nicht zu viele Antwortmöglichkeiten im Spiel sind. Wenn Sie aber z.B. bei einer touristischen Umfrage eine Liste mit 100 möglichen Freizeitaktivitäten präsentieren, dann führt das Schema zur Definition von 100 SPSS-Variablen. Unter der Annahme, dass jeder einzelne Untersuchungsteilnehmer maximal sieben Optionen wählen wird, ist das Schema bei der Datenerfassung mit dem SPSS-Dateneditor recht unpraktisch. Für

solche Situationen bietet sich ein alternatives Vorgehen an, das im eben konstruierten Freizeitbeispiel lediglich sieben Variablen bzw. Spalten in der SPSS-Datenmatrix benötigt.

Auch dieses Komprimierungsverfahren soll an unserem Motivbeispiel demonstriert werden, obwohl es hier (bei nur sechs Antwortmöglichkeiten) definitiv ungeeignet ist. Unter der Annahme, dass pro Person maximal zwei verschiedene Motive zur Kursteilnahme zutreffen werden, definiert man die beiden SPSS-Variablen MOTIVA und MOTIVB, die jeweils folgende Werte annehmen können:

- 1 für das Motiv *Eigene empirische Studie*
- 2 für das Motiv *Orientierung am Arbeitsmarkt*
- 3 für das Motiv *Bewerbung als EDV-Hilfskraft*
- 4 für das Motiv *Interesse an der EDV*
- 5 für das Motiv *Interesse an Statistik*
- 6 für andere Motive

Mit den Variablen MOTIVA und MOTIVB stehen für jede Person zwei Möglichkeiten zur Verfügung, um die Nummern von angekreuzten Motiven zu erfassen. Das Antwortmuster (1,0,0,0,1,0) wird folgendermaßen übertragen:



Im Prinzip kann man im Beispiel die beiden Werte Eins und Fünf auch in umgekehrter Reihenfolge eintragen (MOTIVA = 5, MOTIVB = 1). Wesentlich ist nur, dass die Nummer jedes angekreuzten Motivs bei MOTIVA oder MOTIVB als Wert auftritt. Von einer Person, die zwei Motive angekreuzt hat, wissen wir *nicht*, welchem Motiv sie die größte Bedeutung beimisst. Daher können auch die resultierenden Variablen eine solche subjektive Ranginformation nicht enthalten. Allerdings wird man beim Erfassen der Systematik halber so vorgehen, dass in MOTIVA die Nummer des ersten angekreuzten Motivs landet usw. (bei Anordnung von oben nach unten).

Wir sparen vier Variablen ein, wobei kein Informationsverlust eintritt, wenn tatsächlich pro Person maximal zwei Motive angekreuzt werden. Erweist sich ein sparsames Set während der Erfassung als unterdimensioniert, kann es bei Verwendung des SPSS-Dateneditors problemlos erweitert werden (z.B. um die Variable MOTIVC).

Auch bei der komprimierten Informationsanordnung kann man mit SPSS nach erfolgter Datenerfassung z.B. für jedes Motiv ermitteln, wie viel Prozent der Kursteilnehmer es angekreuzt haben. Vor einer solchen Auswertung ist wiederum ein Mehrfachantwortset zu definieren, diesmal bestehend aus den beiden Variablen MOTIVA und MOTIVB. Bei manchen Auswertungen ist es aber erforderlich, über Transformationsanweisungen aus dem sparsamen kategorialen Set das vollständige dichotome Set (mit *einer* Variablen pro Merkmal) herzustellen (siehe Abschnitt 15.4).

1.4.2.4 Offene Fragen

Offene Fragen bewirken vielfältige und unstrukturierte Antworten. Der übliche Weg zur Systematisierung und Erfassung besteht darin, eine **Kategorienliste** zu entwickeln, die möglichst kurz ist und trotzdem alle Antworten der Teilnehmer gut repräsentiert. Anschließend kann man bei jedem Fall die vorhandenen bzw. fehlenden Nennungen von Listenelementen analog zu den Antworten für die Items einer Mehrfachwahlfrage behandeln. Jedem Element der Kategorienliste entspricht ein dichotomes Merkmal.

Im Fall unseres Fragebogenteils 3b ist also durch Inspektion der ausgefüllten Fragebögen aller Teilnehmer eine Liste mit speziell gewünschten statistischen Auswertungsverfahren zu erstellen, z.B. mit dem Ergebnis:

Lineare Regressionsanalyse
Kreuztabellenanalyse
Faktorenanalyse
Logistische Regressionsanalyse

Zur Übernahme der Daten in SPSS-Variablen wird man bei einer relativ kurzen Kategorienliste ein vollständiges Set mit dichotomen Variablen verwenden, ansonsten ein sparsames Set mit kategorialen Variablen (siehe Abschnitt 1.4.2.3). Aus der obigen vierelementigen Liste mit speziellen methodischen Interessen entsteht also ein vollständiges Set mit dichotomen Variablen, z.B. mit den Namen:

LINREG	für die lineare Regressionsanalyse
KT	für die Kreuztabellenanalyse
FAKT	für die Faktorenanalyse
LOGREG	für die logistische Regressionsanalyse

Als Wert für die Variable LINREG ist bei der sich anbietenden (0/1)-Kodierung eine 1 einzutragen, wenn ein Fall auf die offene Frage hin die lineare Regressionsanalyse angegeben und damit sein Interesse an dieser Methode signalisiert hat. Anderenfalls wird eine 0 notiert, die aber *nicht* als explizit bekundetes Desinteresse an der linearen Regressionsanalyse zu interpretieren ist.

Beim Erstellen einer Kategorienliste sind zu enge Kategorien (mit geringer Wahlfrequenz, z.B.: *Spearman's Rangkorrelation*) ebenso ungeeignet wie zu breite Kategorien (mit geringem Informationsgehalt, z.B.: *Mittelwertsvergleiche*). Vielfach wird man aber mit einer Restkategorie arbeiten (z.B.: *Sonstige Methoden*), um bei vertretbarem Aufwand möglichst alle Äußerungen berücksichtigen zu können.

Das beschriebene Vorgehen erfordert zum Erstellen der Kategorienliste eine (speziell bei großen Stichproben) lästige Vorauswertung der Fragebögen, die sich mit folgendem Trick vermeiden lässt: Man verwendet eine **dynamisch wachsende Kategorienliste** in Verbindung mit einem sparsamen Set kategorialer Variablen. In unserem Beispiel kann man sich über ein sparsames Set mit den drei Variablen METH1 bis METH3 darauf vorbereiten, für jeden Fall maximal drei spezielle Auswertungsinteressen festzuhalten. Die Kategorienliste wird erst während der Datenerfassung entwickelt, indem man bei jedem Fall entscheidet, welche bereits definierten oder neu in die Liste aufzunehmenden Kategorien er im Fragebogenteil 3b angesprochen hat. Die Liste kann dynamisch um beliebig viele Kategorien erweitert werden, weil die drei Variablen beliebig viele verschiedene Kategoriennummern als Werte aufnehmen können. Selbstverständlich müssen die neu aufgenommenen Kategorien mit den vergebenen Nummern sorgfältig dokumentiert werden.

Für die simultane Datenerfassung durch *mehrere* Personen sind dynamisch wachsende Kategorienlisten allerdings weniger geeignet.

Mit dem bislang vorgeschlagenen Verfahren lassen sich aus den Antworten auf eine offene Frage nur *dichotome* Merkmale extrahieren. Um ein *ordinales* Merkmal zu gewinnen, kann man eine Serie von Kategorien als Stufen dieses Merkmals festlegen und bei jedem Fall schlussendlich die höchste aufgetretene Stufe als Merkmals- bzw. Variablenausprägung festhalten.

Offene Fragen sind sicher sinnvoll, weil sie Informationen zutage fördern können, an die bei der Untersuchungsplanung niemand gedacht hat. Gelegentlich sind die Antworten jedoch so spärlich oder so schlecht strukturierbar, dass eine *statistische* Analyse nicht lohnend erscheint. So werden erfahrungsgemäß im Teil 3a des Beispielfragebogens kaum individuelle Motive zur Kursteilnahme angegeben, und wir ignorieren diese offene Frage im weiteren Projektverlauf.

Bilden bei einer Studie längere Textpassagen (z.B. transkribierte Interviews) einen wesentlichen Bestandteil des empirischen Datenmaterials, dann sollte die Erstellung und Anwendung eines Kategoriensystems durch eine Spezialsoftware aus dem Bereich der **qualitativen Datenanalyse** unterstützt werden:

- Angehörige der Universität Trier im Besitz einer SPSS-Einzelplatzlizenz (vgl. Abschnitt 2.1) können zu diesem Zweck das Programm **Text Analytics for Surveys** nutzen.¹
- Auf einigen Pool-PCs an der Universität Trier steht das Programm **MAXQDA** zur Verfügung.²

1.4.3 Kodierung

Für jedes erhobene Merkmal muss festgelegt werden, wie die einzelnen Ausprägungen kodiert werden sollen. Dabei ist eine Kodierung durch einfach aufgebaute Werte anzustreben (z.B. durch positive, ganze Zahlen). Bei den Überlegungen zur Kodierung müssen wir berücksichtigen, welche Variablentypen von SPSS unterstützt werden.

1.4.3.1 Die wichtigsten Variablentypen in SPSS

An dieser Stelle beschränken wir uns auf die wichtigsten Variablentypen, mit denen die meisten Projekte auskommen:

- **Numerische Variablen**

Werte: Zahlen
Z.B. geeignet für die Merkmale: - Geburtsjahr
- Größe
- Gewicht

- **Eingeschränkt numerische Variablen**

Die so genannten *eingeschränkt numerischen Variablen* respektieren führende Nullen und erlauben trotzdem numerische Funktionen.

Werte: Nichtnegative ganze Zahlen, die links bis zu einer definierten Länge mit Nullen aufgefüllt werden

Z.B. geeignet für das Merkmal: Postleitzahl des Wohnorts, z.B.: 01067

¹ <http://public.dhe.ibm.com/common/ssi/ecm/en/ytd03122usen/YTD03122USEN.PDF>

² <http://www.maxqda.de/>

- **Zeichenfolgenvariablen (synonym: alphanumerische Variablen, String-Variablen)**

Werte: Folgen von Zeichen (Buchstaben, Ziffern, Sonderzeichen) mit einer maximalen Länge von 32767 Zeichen.

Z.B. geeignet für die Merkmale: - Familienname
- Man könnte das Merkmal Geschlecht alphanumerisch kodieren mit den Werten **f** und **m**.

- **Datumsvariablen**

Werte: Datumsangaben

Z.B. geeignet für das Merkmal: Untersuchungsdatum

Anwendungsfälle für Datumsvariablen dürften in der Regel klar erkennbar sein.

Bei Merkmalen mit **mindestens ordinalem Skalenniveau** ist offensichtlich nur die numerische Kodierung sinnvoll.

Bei Merkmalen mit **Nominalskalenniveau** hat man die Wahl zwischen numerischer und alphanumerischer Kodierung der Merkmalsausprägungen.

Beispiel Geschlecht: - numerische Kodierung: **1** für Frauen, **2** für Männer
- alphanumerische Kodierung: **f** für Frauen, **m** für Männer

Beim Arbeiten mit SPSS empfiehlt es sich, auch nominalskalierte Merkmale mit einer überschaubaren Anzahl von Ausprägungen numerisch zu kodieren, weil viele Auswertungsverfahren auch dort numerische Variablen verlangen, wo aus statistischer Sicht lediglich nominales Messniveau erforderlich ist (z.B. die Prozeduren REGRESSION, DISCRIMINANT, NPAR TESTS).

Für nominalskalierte Merkmale mit sehr vielen Ausprägungen (z.B. Herkunftsland, Autokennzeichen) können Zeichenfolgenvariablen eine gute Lösung darstellen. Außerdem werden sie benötigt, wenn ausnahmsweise mit SPSS längere Texte erfasst werden sollen (z.B. von Probanden zu einem Bild erfundene Geschichten).

Sind bei einem nominalskalierten Merkmal vorgegebene Ausprägungen zu verwenden, die eine feste Anzahl von Ziffern enthalten mit der Möglichkeit von führenden Nullen (z.B. Postleitzahlen), dann eignet sich eine eingeschränkt numerische Variable.

1.4.3.2 *Fehlende Werte*

Trotz aller Sorgfalt sind in vielen Forschungsprojekten bei manchen Fällen einige Merkmalsausprägungen unbekannt, z.B. wegen verweigerter Antworten oder nicht zutreffender Fragen. Bei der Kodierungsplanung muss für alle betroffenen Variablen festgelegt werden, welche Ersatzwerte an Stelle fehlender oder ungültiger Werte in die Zellen der Datenmatrix eingetragen werden sollen. Diese Ersatzwerte bezeichnet man häufig als *MD-Indikatoren*, wobei *MD* für *Missing Data* steht. Wir konzentrieren uns bei der anschließenden Behandlung des Themas auf reguläre (nicht eingeschränkte) numerische Variablen.

1.4.3.2.1 Benutzerdefinierte MD-Indikatoren

Grundsätzlich kann jede Zahl als MD-Indikator für eine numerische Variable vereinbart werden, z.B. der Wert 9 bei einer verweigerter Auskunft über das in fünf Stufen erfasste und durch die Werte 1 bis 5 kodierte Einkommen. Gelegentlich sind bei einer Variablen sogar *mehrere* MD-Indikatoren nötig. Wenn z.B. die Besucher einer touristischen Einrichtung per Ratingskala nach

der Zufriedenheit mit ihrer Ferienunterkunft befragt werden, kann man für die resultierende SPSS-Variable folgende Kodierungsregeln vereinbaren:

- Vorhandene Beurteilungen werden durch die Zahlen 1 bis 5 kodiert.
- Ersatzwerte für fehlende Antworten:
 - Tagesgäste haben keine Ferienunterkunft und erhalten den MD-Indikator 8 (*Frage trifft nicht zu*).
 - Liegt bei Übernachtungsgästen keine Beurteilung vor, wird der MD-Indikator 9 vergeben.

Beachten Sie bei der Verwendung von benutzerdefinierten MD-Indikatoren folgende Regeln:

- Es ist klar, dass alle MD-Indikatoren zu einer Variablen außerhalb des validen Wertebereichs liegen müssen. So wäre z.B. die Zahl 99 kein geeigneter MD-Indikator für unsere Variable Körpergewicht (gemessen in kg).
- Wählen Sie möglichst prägnante oder extreme Werte (also z.B. bei einer Variablen mit den validen Werten 1 und 2 den MD-Indikator 9). Dies bewirkt warnend auffällige Ergebnisse, falls Fälle mit fehlenden Werten nicht ordnungsgemäß von einer Analyse ausgeschlossen wurden.
- Der Einfachheit halber sollte für alle Variablen mit ähnlichem Wertebereich derselbe MD-Indikator verwendet werden.
- **Besonders wichtig: Die benutzerdefinierten MD-Indikatoren müssen dem SPSS-System unbedingt bekannt gemacht werden (siehe Abschnitt 3.2.2).**

Die für so genannte **Residualkategorien** (z.B. „Weiß nicht“, „Keine Angabe“) vergebenen Kodierungswerte müssen in der Regel (zumindest für bestimmte Auswertungen) ebenfalls als MD-Indikatoren deklariert werden.

1.4.3.2.2 System-Missing (SYSMIS)

Neben den vom Benutzer variablenspezifisch vereinbarten MD-Indikatoren verwendet SPSS für alle numerischen Variablen automatisch einen weiteren MD-Indikator, der mit *System-Missing*, *systemdefiniert fehlend* oder *SYSMIS* bezeichnet wird. Er kommt immer dann zum Einsatz, wenn SPSS auf eines der folgenden Probleme trifft:

- Im Dateneditor bzw. beim Lesen einer Datendatei (z.B. im Textformat) findet SPSS im Feld einer als numerisch definierten Variablen unzulässige Zeichen oder überhaupt keinen Eintrag.
- Beim Neuberechnen einer Variablen per Transformationsanweisung (siehe Kapitel 6) fehlt ein Argument, oder der Funktionswert ist nicht definiert (z.B. bei einer Division durch Null).

Gerade war u.a. zu erfahren, dass man bei der Datenerfassung mit dem SPSS-Dateneditor für eine numerische Variable den Ersatzwert SYSMIS ganz einfach dadurch vereinbaren kann, dass man in die betroffene Zelle *nichts* einträgt.

Tipp: Bei der Datenerfassung mit dem SPSS-Dateneditor können Sie für numerische Variablen routinemäßig SYSMIS als MD-Indikator verwenden, bei Bedarf ergänzt durch zusätzliche benutzerdefinierte MD-Indikatoren. Man kann SYSMIS bequem dadurch vereinbaren, dass man die betroffene Zelle unverändert lässt. Eine Deklaration dieses bei numerischen Variablen generell definierten MD-Indikators ist weder nötig noch möglich und kann daher auch nicht vergessen werden.

Im Datenfenster und in der Ergebnisausgabe wird SYSMIS durch einen Punkt dargestellt (siehe Abbildung in Abschnitt 1.4.1, Variable LOT5 bei Fall 13).

1.4.3.2.3 Fehlende Werte bei Zeichenfolgenvariablen

Aus den in Abschnitt 1.4.3.1 genannten Gründen werden wir in unserer Beispielstudie keine Zeichenfolgevariablen verwenden. In anderen Studien können sie jedoch durchaus sinnvoll sein. Als Indikatoren für fehlende Werte kommen in Frage:

- **Leere Zeichenfolge**
Während bei numerischen Variablen eine leere Zelle im Dateneditor als SYSMIS interpretiert wird, ist eine leere Zeichenfolge per se ein *gültiger* Wert. Soll sie als fehlender Wert interpretiert werden, ist eine entsprechende Definition erforderlich (siehe Abschnitt 3.2.2.2). Bei Zeichenfolgenvariablen gibt es keine Entsprechung zum SYSMIS-Wert der numerischen Variablen.
- **Sonstige benutzerdefinierte Indikatoren**
SPSS erlaubt bei Zeichenfolgenvariablen benutzerdefinierte Indikatoren mit maximal 8 Zeichen. Man kann z.B. den MD-Indikator „-88“ verwenden, wenn diese Zeichenfolge als valider Wert nicht möglich ist.

1.4.3.2.4 Fehlende Werte bei Mehrfachwahl-Fragen und offenen Fragen

Nachdem der Sinn und die Verwendung von MD-Indikatoren geklärt sind, geht es nun um eine spezielle Interpretationsunsicherheit im Zusammenhang mit fehlenden Werten, die bei Mehrfachwahlfragen aus der Verwendung eines Teilnehmer-freundlichen Antwortformats resultieren kann. Im Fragebogenteil 3a zu den Motiven für die Kursteilnahme sorgt die sechste Ankreuzalternative (*Andere Motive*) durch Komplettieren der Antwortmöglichkeiten dafür, dass eine redliche Auskunftsperson mindestens eines der sechs Kästchen ankreuzen muss. Wir dürfen annehmen, dass hinter einem aufwändigen Verhalten (SPSS-Kurs besuchen) mindestens ein Motiv stehen muss.

Ohne diese Restkategorie könnten wir bei einem zu erfassenden Fragebogenexemplar mit fünf leeren Motivkästchen folgende Möglichkeiten *nicht* unterscheiden:

- Bei der Auskunftsperson trifft tatsächlich keines der fünf vorgegebenen Motive zu.
- Die Person hat den Fragebogenteil 3a nicht bearbeitet (fehlende Daten).

Ursache für die Interpretationsunsicherheit ist das vereinfachte Antwortformat, das pro Motiv nur *ein* Kästchen vorsieht, statt jeweils ein Ja- *und* ein Nein-Kästchen vorzugeben. Damit ersparen wir den Untersuchungsteilnehmern zahlreiche Nein-Markierungen. Dies ist sinnvoll, damit deren Kooperationsbereitschaft nicht überstrapaziert wird, und die Fehlerquote gering bleibt.

Bei der offenen Frage in Teil 3b wird durch die vorgeschaltete Frage, ob überhaupt spezielle Methoden gewünscht sind, dafür gesorgt, dass bei Fragebögen ohne eingetragene Methodeninteressen folgende Möglichkeiten unterschieden werden können:

- Die Person hat kein Interesse an speziellen Auswertungsmethoden.
- Die Person hat den Fragebogenteil 3b nicht bearbeitet (fehlende Daten).

Durch das Bemühen um die Unterscheidbarkeit von verneinenden und fehlenden Antworten sollte das Fragebogendesign allerdings nicht zu umständlich bzw. pedantisch geraten.

1.4.3.2.5 Vereinfachung der Erfassung durch Datentransformationstechniken

Im Zusammenhang mit dem MD-Problem bei den Variablen zu unserem Fragebogenteil 3 wage ich nun einige Vorschläge, die zwar dem Datenerfasser das Leben erleichtern, aber zugegebenermaßen die Kursteilnehmer beim ersten Entwurf eines Kodierplans durch zusätzliche Überlegungen belasten. Bei der Mehrfachwahlfrage nach den Kursmotiven haben wir geschickt durch die sechste Ankreuzalternative *Andere Motive* dafür gesorgt, dass Personen mit fehlenden Werten sicher zu identifizieren sind. Wir könnten den Erfasser per Kodierplan beauftragen:

- Schreibe bei den Variablen MOTIV1 bis MOTIV5 und ANDERE den Wert 1, wenn das zugehörige Kästchen markiert ist, sonst eine 0.
- Ist aber *keines* der sechs Kästchen markiert, dann erhalten die Variablen MOTIV1 bis MOTIV5 und ANDERE den MD-Indikator SYSMIS.

Die im zweiten Satz enthaltene Regel lässt sich mit später anzuwendenden SPSS-Transformationskommandos bequem automatisieren, so dass wir den Erfasser damit nicht belasten wollen. Damit wird die Lösung des MD-Problems zugunsten einer möglichst einfachen Erfassung in die spätere Projektphase der Datentransformation verschoben. Schlussendlich soll für die Variablen MOTIV1 bis MOTIV5 und ANDERE folgende Kodierung sichergestellt sein:

0	=	Nein
1	=	Ja
System-Missing	=	Wert unbekannt

Zur Erfassung der Informationen im Fragebogenteil 3b wollen wir eine dynamische Kategorienliste mit einem zugehörigen sparsamen Set kategorialer Variablen METH1 bis METH3 (vgl. Abschnitt 1.4.2.4) entwickeln. Der damit schon reichlich belastete Erfasser soll folgendermaßen vorgehen (bei Verwendung des SPSS-Dateneditors):

- Die Antwort auf die Frage, ob spezielle Methodenwünsche bestehen, wird konventionell durch eine Variable mit dem Namen SMG (**S**pezielle **M**ethoden **G**ewünscht) und folgender Kodierungsvorschrift erfasst:

0	=	Nein
1	=	Ja
System-Missing	=	keine Antwort

- In die Dateneditorzellen zu den Variablen METH1 bis METH3 sollen die Kategoriennummern der gewünschten Methoden eingetragen werden. Bei weniger als drei Nennungen soll in die nicht benötigten Zellen nichts eingetragen werden, was zum MD-Indikator SYSMIS führt. Diese Regel erleichtert die Erfassung und hat noch einen weiteren Vorteil: Sollte sich herausstellen, dass zusätzliche Variablen METH4 etc. benötigt werden, können

wir diese ergänzen, ohne bei bereits erfassten Fällen irgendwelche Ersatzwerte (z.B. Nullen) nachtragen zu müssen.

Bei den Variablen METH1 bis METH3 ist später mit SPSS-Transformationsanweisungen dafür zu sorgen, dass ihre Ausprägungen zuverlässig folgendermaßen interpretiert werden können:

0	=	Von der i -ten ($i = 1, \dots, 3$) Option zur Nennung einer interessierenden Methode wurde kein Gebrauch gemacht.
natürliche Zahl ≥ 1	=	Die Methode mit dieser Kategoriennummer wurde angegeben.
System-Missing	=	Wert unbekannt

Dazu müssen unter den verschiedenen Wertekonstellationen der Variablen SMG und METH1 bis METH3 folgende Anpassungen vorgenommen werden:

		Mindestens eine speziell interessierende Methode angegeben?	
		Ja	Nein
SMG	1	METH1 ... METH3: SYSMIS $\rightarrow$ 0 Bem.: Korrektes Antwortverhalten. Variablen zu nicht benutzten Optionen (gem. Kodierplan auf SYSMIS) werden auf 0 gesetzt.	SMG: 1 $\rightarrow$ SYSMIS Bem.: Irreguläres Antwortverhalten. METH1 bis METH3 behalten SYMIS. SMG wird ebenfalls auf SYMIS gesetzt.
	0	SMG: 0 $\rightarrow$ 1 METH1 ... METH3: SYSMIS $\rightarrow$ 0 Bem.: Leicht irreguläres Antwortverhalten. Wir sind großzügig und setzen SMG auf 1 sowie die Variablen zu nicht benutzten Optionen auf 0.	METH1 ... METH3: SYSMIS $\rightarrow$ 0 Bem.: Korrektes Antwortverhalten. Die Variablen zu allen Optionen (gem. Kodierplan auf SYSMIS) werden auf 0 gesetzt.
	SYSMIS	SMG: SYSMIS $\rightarrow$ 1 METH1 ... METH3: SYSMIS $\rightarrow$ 0 Bem.: Leicht irreguläres Antwortverhalten. Wir sind großzügig und setzen SMG auf 1 sowie die Variablen zu nicht benutzten Optionen auf 0.	Bem.: Irreguläres Antwortverhalten. Alle Variablen behalten den Wert SYSMIS.

Vermutlich kam beim Lesen der letzten Ausführungen wenig Freude auf. Das MD-Problem verursacht oft erheblichen Aufwand, wobei auch Ermessenentscheidungen gefragt sind. Jedenfalls sind die vorgeschlagenen Methoden zur Erfassung der Informationen aus dem Fragebogenteil 3 recht simpel und praktikabel.

1.4.3.3 Fehlerquellen bei der manuellen Datenerfassung minimieren

Wenn die Daten manuell erfasst werden, ist bei den Kodierungsvereinbarungen darauf zu achten, dass dem Erfasser keine zeitaufwändigen und fehleranfälligen Arbeiten zugemutet werden, z.B.:

- Treten gebrochene Zahlen als Werte auf (z.B. bei unserer Frage nach der Körpergröße), so kann man durch Wechsel der Maßeinheit das lästige Dezimaltrennzeichen eliminieren.
Beispiel: 1,65 m → 165 cm
- Bei bipolaren Skalen (z.B. bei unseren LOT-Fragen) empfiehlt sich eine Kodierung durch ausschließlich positive Werte z.B.:

- -	→	1
-	→	2
0	→	3
+	→	4
++	→	5

Durch die Vermeidung negativer Werte spart man Tipparbeit und macht keine Fehler durch vergessene Vorzeichen.

- Wurden einige Fragen aus messtechnischen Gründen umgepolt (negativ formuliert), was im KFA-Projekt bei einigen LOT-Fragen geschehen ist, so sollte diese Umpolung keinesfalls während der Erfassung rückgängig gemacht werden. Dies gelingt sehr viel bequemer und ohne Fehlerrisiko mit den Transformationsmöglichkeiten von SPSS (siehe Kapitel 1).


1.4.3.4 Variablennamen

Es empfiehlt sich, an dieser Stelle auch schon SPSS-Namen für die Variablen festzulegen und in den Kodierplan (siehe Abschnitt 1.4.3.5) aufzunehmen. Dabei sind die SPSS-Regeln für Variablennamen zu beachten:

- Maximal 64 Zeichen
Die frühere Beschränkung von SPSS-Variablennamen auf acht Zeichen ist seit der Version 12 überwunden, doch sollte man sich weiterhin möglichst kurz fassen. Lange Namen belegen viel Platz (z.B. in der Kopfzeile des Dateneditorfensters) und sind beim Einsatz von SPSS-Syntax (siehe z.B. Kapitel 6) recht umständlich.
- Das erste Zeichen muss ein Buchstabe sein.
- An den restlichen Positionen sind folgende Zeichen zugelassen: Buchstaben, Ziffern sowie die Symbole @, #, _ und \$. Von der zweiten bis zur vorletzten Position ist außerdem der Punkt erlaubt.
- Aus den eben genannten Regeln ergibt sich insbesondere, dass Leerzeichen in Variablennamen verboten sind.
- Die von älteren SPSS-Versionen abgelehnten Umlaute in Variablennamen werden mittlerweile akzeptiert. Seit der SPSS-Version 16 sind auch beim Übergang zu einem alternativen Betriebssystem keine Zeichensatzprobleme bei Variablennamen mehr zu befürchten. Bei Beteiligung anderer Programme sind aber weiterhin Pannen durch Umlaute in SPSS-Variablennamen möglich. Im Manuskript werden daher mit Sinne maximaler Kompatibilität Umlaute in Variablennamen vermieden.

- Die folgenden Schlüsselwörter der SPSS-Kommandosprache dürfen nicht als Variablennamen verwendet werden: ALL, AND, BY, EQ, GE, GT, LE, LT, NE, NOT, OR, TO, WITH.
- Die Groß-/Kleinschreibung ist irrelevant hinsichtlich der *Identifikation* von Variablen. Erscheint ein Variablenname in der *Ausgabe* (d.h. in Tabellen oder Diagrammen), verwendet SPSS die Schreibweise aus der Variablendefinition. Erhält eine Variable neben dem obligatorischen Namen auch die optionale *Beschriftung* (siehe unten), erscheint in der Ausgabe die Beschriftung.
In Manuskript werden SPSS-Variablennamen zur Hervorhebung in Großbuchstaben geschrieben.

Beim Versuch, einen irregulären Variablennamen zu vereinbaren, erhalten Sie im SPSS-Dateneditor eine meist informative Fehlermeldung, z.B.:



Tipps zur Benennung:

- Bilden Sie möglichst *informative* Namen wie z.B. GEBJ und FB für *Geburtsjahr* und *Fachbereich* an Stelle informationsarmer Bezeichnungen wie T4F2 (Teil 4, Frage 2) und T4F3.
- Die eben genannte Regel sollte in einem speziellen Fall relativiert werden: Bei Serien verwandter Variablen, z.B. resultierend aus den 12 Fragen des Life Orientation Tests (LOT) im Teil 2 unseres Fragebogens, ist es in der Regel schwer und wenig sinnvoll, entsprechend viele individuelle Variablennamen zu bilden. Hier ist meist eine Indexschreibweise günstiger, bei der an einen informativen Namensstamm eine fortlaufende Nummer angehängt wird, z.B. LOT1, LOT2, ...

1.4.3.5 Kodierplan

Die Festlegungen zur Strukturierung und Kodierung der Projektdaten sollten (zumindest bei größeren Projekten) in einem **Kodierplan** dokumentiert werden. Er hat zwei Funktionen:

- Während der Erfassung regelt er, wie die Daten eines Falles ins SPSS-Dateneditorfenster einzutragen bzw. mit einem anderen Programm zu erfassen sind.
- Später dient er als kompakte Beschreibung der entstandenen Datendatei.

Bei unserer KFA-Studie kann für die geplante Erfassung mit dem SPSS-Dateneditor der folgende Kodierplan verwendet werden:

Merkmal	SPSS-Var.-name	Kodierung	Bemerkungen
Fallnummer	FNR	MD-Indikator: entfällt	
Ärger als Herr Meier (ohne KFA)	AERGO	0 = 0 1 = 10 . . . 10 = 100 MD-Indikator: SYSMIS	Wir sparen uns per Division durch Zehn viel Schreibarbeit und haben dabei eine bei Intervallskalen zulässige Transformation vorgenommen.
Ärger als Herr Schulze (mit KFA)	AERGM	0 = 0 1 = 10 . . . 10 = 100 MD-Indikator: SYSMIS	
LOT-Fragen	LOT1 bis LOT12	1 = -- 2 = - 3 = o 4 = + 5 = ++ MD-Indikator: SYSMIS	
Kursmotive	MOTIV1 bis MOTIV5, ANDERE	0 = Nicht markiert 1 = Markiert	SYSMIS wird nicht vergeben! Die MD-Behandlung erfolgt später per Datentransformation.
Spezielle Methoden gewünscht?	SMG	0 = Nein 1 = Ja MD-Indikator: SYSMIS	
Gewünschte statistische Methoden	METH1 bis METH3	1 = Meth.-Kat. 1 gewünscht 2 = Meth.-Kat. 2 gewünscht . . . Bei weniger als drei Nennungen: SYSMIS-Initialisierungen belassen	Die Kategorienliste wird während der Erfassung nach Bedarf entwickelt und dokumentiert. Die MD-Behandlung erfolgt später per Datentransformation.
Geschlecht	GESCHL	1 = Frau 2 = Mann 8 = Keine Angabe MD-Indikatoren: 8, SYSMIS	
Geburtsjahr	GEBJ	vierstellige Eingabe (z.B. 1984)! MD-Indikator: SYSMIS	
Fachbereich	FB	1 = I (Pädag., Philos., Psychol.) 2 = II (Sprachen) 3 = III (Hist. und polit. Wiss.) 4 = IV (BWL, Ethnol., Inform., Mathe, Soziol., VWL, Wirtsch.- Inf.) 5 = V (Jura) 6 = VI (Geowissenschaften) 7 = VII (Theologie) MD-Indikator: SYSMIS	
Körpergröße	GROESSE	Eingabe in cm ! MD-Indikator: SYSMIS	
Körpergewicht	GEWICHT	Eingabe in kg MD-Indikator: SYSMIS	

Dieser Kodierplan ist bei der Datenerfassung einfach zu handhaben und leistet damit einen Beitrag zur Integrität der Daten.

Bei der Erfassung mit dem SPSS-Dateneditor ist es üblich und empfehlenswert, zunächst eine Variablendeklaration vorzunehmen, wobei einige Regeln des Kodierplans einfließen (vgl. Abschnitt 3.2.2). Damit stellt sich die Frage, ob man auf einen Kodierplan verzichten und das Regelwerk direkt im Deklarationsteil einer SPSS-Datendatei unterbringen kann. Allerdings enthält unser Beispiel viele Vorschriften (z.B. vierstellige Erfassung des Geburtsjahrs, Erfassung der Körpergröße in cm), die per Variablendeklaration *nicht* hinreichend klar dokumentiert werden können. Sind mehrere Personen bei der Erfassung und/oder Auswertung der Daten beteiligt, ist ein schriftlicher Kodierplan unbedingt erforderlich. Wenn die Daten jedoch nur zeitlich befristet und von *einer* Person analysiert werden, die zudem auch die Erfassung übernimmt, kann auf einen Kodierplan verzichtet werden.

1.5 Durchführung der Studie (inklusive Datenerhebung)

Bei den obigen Überlegungen zur Strukturierung und Kodierung der Daten hat sich ergeben, dass der in Abschnitt 1.3 wiedergegebene Fragebogen ohne Korrekturen eingesetzt werden kann. Damit steht der Durchführung unserer Befragung nichts mehr im Weg.

Oft ist eine Vorstudie (ein Pretest) angemessen, um den Untersuchungsplan sowie die Erfassungsinstrumente auf Schwächen zu untersuchen (z.B. schwer verständliche Frageformulierungen).

Im realen Kursverlauf haben die Teilnehmer noch im Zustand der „naiven Unbefangenheit“ (z.B. ohne Kenntnis der KFA-Theorie) die Rolle der Probanden übernommen und so ihre eigenen, von zufälligen Stichprobeneffekten gefärbten Daten produziert. Die Leser(innen) im Selbststudium werden wohl aus praktischen Gründen in der Regel auf die Durchführung einer eigenen KFA-Erhebung verzichten. Im weiteren Verlauf des Manuskripts werden die in einem früheren Kurs erhobenen Daten analysiert. Die zugehörigen Dateien können über das Internet bezogen werden (siehe Vorwort). Anschließend ist der ausgefüllte Fragebogen derjenigen Untersuchungsteilnehmerin zu sehen, die bei der zufälligen Vergabe einer Fallidentifikation (vgl. Abschnitt 1.4.2.1) die Nummer Eins erhalten hat:

1) Fragen zur Reaktion in ärgerlichen Situationen

Versetzen Sie sich bitte möglichst gut in folgende Situation:

Herr Meier und Herr Schulze waren mit demselben Taxi auf dem Weg zum Flughafen. Sie sollten zur selben Zeit, aber mit verschiedenen Maschinen abfliegen. Durch einen Stau kommen sie erst eine halbe Stunde nach der planmäßigen Abflugzeit am Flughafen an.

Herr Meier erfährt, dass seine Maschine pünktlich vor einer halben Stunde gestartet ist.

Herr Schulze erfährt, dass seine Maschine Verspätung hatte und erst vor zwei Minuten gestartet ist.

Wie sehr würden Sie sich **ärgern**, wenn Sie in der Situation von ...

Herrn Meier wären?	0	10	20	30	40	50	60	70	80	90	100
-----------------------	---	----	----	----	----	----	----	----	----	----	-----

Herrn Schulze wären?	0	10	20	30	40	50	60	70	80	90	100
-------------------------	---	----	----	----	----	----	----	----	----	----	-----

Betrachten Sie bitte die Antwortskala als "Ärgerthermometer".

2) Aussagen zur Selbsteinschätzung

Teilen Sie bitte für die folgenden Selbstbeschreibungen durch Ankreuzen einer Antwortkategorie mit, inwiefern die Aussagen auf Sie persönlich zutreffen.

	völlig falsch	falsch	unent- schieden	stimmt	stimmt genau
1. Auch in unsicheren Zeiten rechne ich im Allgemeinen damit, dass sich alles zum Besten wendet.	--	-	o	X	++
2. Ich kann mich leicht entspannen.	--	X	o	+	++
3. Wenn etwas schief gehen kann, dann passiert es mir auch.	--	X	o	+	++
4. Bei allem sehe ich stets die negative Seite.	X	-	o	+	++
5. Ich blicke kaum einmal mit Zuversicht in die Zukunft.	--	X	o	+	++
6. Ich bin gern mit Freunden zusammen.	--	-	o	+	X
7. Ich muss mich immer mit etwas beschäftigen.	--	-	X	+	++
8. Ich habe stets die Hoffnung, dass die Dinge in meinem Sinne gehen.	--	-	o	X	++
9. Die Dinge laufen immer so, wie ich es mir wünsche.	--	-	o	X	++
10. Ich bin nicht leicht aus der Ruhe zu bringen.	--	-	X	+	++
11. Ich glaube an den sprichwörtlichen "Silberstreifen am Horizont".	--	-	o	X	++
12. Dass mir einmal etwas Gutes widerfährt, damit rechne ich kaum.	--	X	o	+	++

3) Ihre Motive für die Teilnahme am SPSS-Kurs

a) Kreuzen Sie bitte in der folgenden Liste möglicher Motive für die Teilnahme am SPSS-Kurs alle für Sie zutreffenden Aussagen an und/oder nennen Sie Ihre sonstigen Motive.

Ich möchte SPSS kennen lernen, ...

- ☒ um eine eigene empirische Studie damit auszuwerten.
☐ weil in vielen Stellenanzeigen SPSS-Kenntnisse verlangt werden.
☐ weil ich mich um eine Stelle als EDV-Hilfskraft in der Forschung bewerben will (HIWI-Job).
☐ weil ich mich für EDV interessiere und ein modernes Programm kennen lernen möchte.
☐ weil ich mich für Statistik interessiere und mit Auswertungsverfahren experimentieren möchte.

☐ Andere Motive: _____

b) Möchten Sie im Kurs bestimmte statistische Methoden besonders gerne üben? ☒ Ja ☐ Nein

Wenn „Ja“, welche? Regression, Faktorenanalyse

4) Angaben zur Person

Geschlecht	Frau ☒ Mann ☐
Geburtsjahr	<u>1969</u>
Primärer Fachbereich	☒ I ☐ II ☐ III ☐ IV ☐ V ☐ VI ☐ VII
Körpergröße	<u>1.63</u> m
Körpergewicht	<u>51</u> kg

Diese Nummer wurde nachträglich von der Untersuchungsleitung auf den Fragebogen geschrieben.

2 Einstieg in SPSS für Windows

In den bisher dargestellten Projektphasen von der theoretischen Ausarbeitung bis zur Erstellung des Kodierplans spielte SPSS noch keine wesentliche Rolle. Die im KFA-Projekt nun anstehende Datenerfassung wollen wir jedoch mit diesem Programm bewerkstelligen, so dass an dieser Stelle einige einführende Bemerkungen zu SPSS angemessen sind. In Abschnitt 2.1 geht es um die Verfügbarkeit von SPSS an der Universität Trier (inklusive kostenloser Nutzung auf Privat-PCs), und in den Abschnitten 2.2 bis 2.5 werden im Wesentlichen einige Informationsquellen zur SPSS-Bedienung beschrieben.

2.1 SPSS-Produkte an der Universität Trier

An der Universität Trier steht SPSS für Linux, MacOS und Windows mit einer kompletten Modul-Ausstattung zur Verfügung:

Statistics Base, Regression, Advanced Statistics, Categories, Conjoint, Custom Tables, Data Preparation, Decision Trees, Exact Tests, Forecasting, Missing Values, Bootstrapping, Neural Networks, Direct Marketing, Complex Samples

Aus der SPSS-Produktfamilie sind außerdem die folgenden, nur für Windows verfügbaren Programme vorhanden:

- **Amos**
Erlaubt Strukturgleichungsanalysen (z.B. konfirmatorische Faktorenanalysen)
- **SamplePower**
Stichprobenumfangsplanung für verschiedene statistische Verfahren
- **Visualization Designer**
Erstellung von Diagrammvorlagen, die (auch) in SPSS Statistics genutzt werden können
- **Text Analytics for Surveys**
Kategorisierung und Analyse von Antworten auf offene Fragen
- **Data Collection Data Entry**
Paket aus den drei Komponenten **Author** (Erstellung von Fragebögen), **Interviewer** (Erfassen von Daten) und **Translation Utility** (Übersetzung von Texten in Data Collection - Fragebögen).

Die aufgeführten SPSS-Produkte können von Angehörigen der Universität Trier im Rahmen ihrer dienstlichen Tätigkeit bzw. Ausbildung auf folgende Weise genutzt werden:

a) ZIMK - Pool-PCs

Auf den vom ZIMK betreuten Pool-PCs unter dem Betriebssystem Windows finden Sie über

Start > Alle Programme > Statistik

und/oder über

Start > Alle Programme > Wissenschaftliche Programme

die Programmgruppe **SPSS** mit Unterverzeichnissen zu allen installierten SPSS-Produkten bzw. -Versionen.

Im Mai 2016 vorhandene Programme:

- **SPSS Statistics**
- **Amos**

b) Kostenlose Nutzung über die ZIMK-Lizenzserver (netzabhängig)

Über die Webseite

<http://www.uni-trier.de/index.php?id=25191>

steht SPSS samt Installationsanleitung für Angehörige der Universität Trier zum Herunterladen bereit. Alternativ kann in den ZIMK - Service-Punkten eine DVD erworben werden. Mit dem Download-Ergebnis oder der DVD lässt sich SPSS auf einem Rechner mit permanentem Internetzugang (an der Uni oder im Privatbereich) zur kostenlosen Nutzung der ZIMK-Lizenzserver installieren.

Für Windows-Rechner stehen neben SPSS Statistics noch einige Zusatzprogramme bereit:

- **Amos**
- **SamplePower**
- **Visualization Designer**

c) Kostenpflichtige individuelle Mietlizenz (netzunabhängig)


Für Rechner ohne permanenten Internetzugang kann in der ZIMK-Benutzerberatung eine befristete SPSS-Einzelplatzlizenz erworben werden.

Für Windows-Rechner enthält die Einzelplatzlizenz neben SPSS Statistics noch einige Zusatzprogramme:

- **Amos**
- **SamplePower**
- **Visualization Designer**
- **Text Analytics for Surveys**
- **Data Collection Data Entry**

2.2 Programmstart und Benutzeroberfläche**2.2.1 SPSS starten**

Nach erfolgreicher Anmeldung bei einem ZIMK - Pool-PC unter Windows erreichen Sie SPSS 22 über das Desktop-Symbol



oder über das Startmenü:


Start > Alle Programme > Statistik > SPSS > IBM SPSS Statistics 22

Nach einer Standardinstallation unter Windows (z.B. auf einem privaten PC) können Sie SPSS 22 so starten:


Start > Alle Programme > IBM SPSS Statistics > IBM SPSS Statistics 22

SPSS 22 kann bei Texten in Daten- und Syntaxdateien den Unicode-Zeichensatz unterstützen, sodass z.B. kyrillische oder japanische Zeichen möglich sind. Beim ersten Start erkundigt sich

SPSS 22, ob Sie mit dem Unicode oder mit der Kodierung gemäß Windows-Standard arbeiten wollen:¹



Der folgende Begrüßungsdialog erscheint bei jedem SPSS-Start, sofern Sie ihn nicht über das Kontrollkästchen in seiner unteren linken Ecke unterdrücken:²




Er ermöglicht z.B. ein bequemes Öffnen der in früheren Sitzungen benutzten Dateien.

2.2.2 Die wichtigsten SPSS-Fenster

Das zur Deklaration, Erfassung und Verwaltung von Daten dienende **Dateneditorfenster** haben Sie schon in Abschnitt 1.4.1 kennen gelernt. Angeforderte Ergebnistabellen und Diagramme erscheinen im **Ausgabefenster**, auch **IBM SPSS Statistics Viewer** genannt, z.B.:

¹ Ein Wechsel zwischen dem Unicode-Modus und der Zeichenkodierung gemäß Ländereinstellung ist nach dem Menübefehl **Bearbeiten > Optionen** auf der Registerkarte **Sprache** des **Optionen**-Dialogs möglich, sofern kein nichtleeres Dateneditorfenster geöffnet ist.

² Wenn Sie den Begrüßungsdialog im späteren Verlauf einer SPSS-Sitzung wiedersehen wollen, können Sie im Fenster des Dateneditors den Menübefehl **Datei > Begrüßungsdialogfeld** verwenden.



Die SPSS-Fenster enthalten in der Kopfzone eine Menüzeile und verschiebbare Symbolleisten, im Fußbereich eine Statuszeile mit Informationen über wichtige Programzustände.

2.2.3 Was man mit SPSS so alles machen kann

Wir sind im Moment dabei, einen ersten Eindruck vom Arbeitsplatz *SPSS Statistics* zu gewinnen. Einen guten Überblick vermitteln die Optionen in der Menüzeile des Dateneditorfensters:

- **Datei**
Hier finden Sie u.a. Befehle zum Öffnen bzw. Sichern von Daten-, Ausgabe oder Syntaxdateien sowie zum Beenden von SPSS.
- **Bearbeiten**
Über das **Bearbeiten**-Menü erreichen Sie Editorbefehle zum Ausschneiden, Kopieren, Einfügen, Löschen und Suchen von Daten sowie die **Optionen**-Dialogbox zur Anpassung von diversen SPSS-Einstellungen. Außerdem können Sie hier Modifikationen des Datenfensters rückgängig machen.
- **Ansicht**
Hier können Sie u.a. die Statuszeile sowie die Symbolleisten aus- bzw. einschalten sowie die Schriftart der angezeigten Daten festlegen.
- **Daten**
Über das **Daten**-Menü sind u.a. Dialoge zur Auswahl einer Teilstichprobe, zum Zusammenführen von SPSS-Dateien (z.B. mit Daten aus verschiedenen Stichproben) sowie zum Sortieren und Gewichten der Fälle erreichbar.
- **Transformieren**
Hier finden Sie z.B. die Befehle zum Rekodieren von Variablen oder zum Berechnen von neuen Variablen aus bereits vorhandenen.

- **Analysieren**

Dieser Menüpunkt erschließt die statistischen Auswertungsmethoden, mit denen wir letztlich unsere Forschungsfragen klären wollen.

- **Direktmarketing**

Über diesen Menüpunkt stehen Techniken zur Verbesserung von Marketingkampagnen zur Verfügung.

- **Grafik**

An dieser Stelle bietet SPSS vielfältige Möglichkeiten zur grafischen Präsentation von Datenstrukturen an.

- **Extras**

Hier finden sich diverse Funktionen (z. B. Kommentieren einer Datendatei, Installation benutzerdefinierter Dialogfelder).

- **Fenster**

Über dieses Menü sind die offenen SPSS-Fenster erreichbar.

- **Hilfe**

Die Hilfefunktion bietet neben systematischen Informationen über das SPSS-System auch ein Lernprogramm, Fallstudien (komplette Anwendungsbeispiele) und einen Statistik-Assistenten (siehe Abschnitt 2.3).


Die anderen SPSS-Fenster bieten angepasste Menüzeilen.

2.3 Hilfesystem

Bei der Arbeit mit SPSS können Sie stets auf ein mächtiges Hilfesystem zurückgreifen, dessen wichtigste Möglichkeiten in diesem Abschnitt vorgestellt werden.

2.3.1 Systematische Informationen


Nach dem Menübefehl **Hilfe > Themen** finden Sie auf der **Inhalt**-Registerkarte des folgenden Browser-Fensters Informationen über die installierten SPSS-Module in systematischer Form:



Registerkarte
Inhalt hier
aktivieren

2.3.2 Gezielte Suche nach Begriffen

Die Registerblätter **Index** und **Suchen** im Hilfefenster eignen sich für die Suche nach Informationen zu bestimmten Begriffen, z.B.:




2.3.3 Kontextsensitive Hilfe zu den Dialogboxen

In fast jeder SPSS-Dialogbox können Sie mit der Standardschaltfläche **Hilfe** Informationen zu den verfügbaren Optionen anfordern.

2.3.4 Lernprogramm

Nach **Hilfe > Lernprogramm** kann man anhand konkreter Arbeitsabläufe elementare technische Aspekte der SPSS-Bedienung kennen lernen, z.B.:



2.3.5 Statistik-Assistent

Der über **Hilfe > Statistik-Assistent** verfügbare Assistent versucht, den Anwender durch eine Sequenz von Fragen zur richtigen Statistik- bzw. Grafikdialogbox zu führen.

2.4 Weitere Informationsquellen

Neben dem umfangreichen Hilfesystem sind zu SPSS noch weitere Informationsquellen vorhanden.

2.4.1 Handbücher und Manuskripte

Es stehen u.a. zur Auswahl:

- **Programmhandbücher des Herstellers**

Mit SPSS wird eine umfangreiche Sammlung von PDF-Dokumenten zu den einzelnen Modulen und zu den statistischen Algorithmen ausgeliefert. Allein die Dokumentation der Kommandosprache, über die man die meisten Leistungen des SPSS-Systems abrufen kann (siehe unten), umfasst ca. 2.200 Seiten. Dieses PDF-Dokument ist auch im Hilfesystem verfügbar (**Hilfe > Befehlssyntax-Referenz**). Wer SPSS vom WWW-Server der Universität Trier bezieht, kann von derselben Seite auch die Handbücher herunterladen (siehe Abschnitt 2.1). Allerdings sind die mit SPSS gelieferten Handbücher keine geeignete Lektüre, wenn Sie eine statistische Methode neu erlernen wollen.

- **Sekundärliteratur**

Im Buchhandel und in wissenschaftlich orientierten Bibliotheken finden sich zahlreiche Bücher zu SPSS. Nach dem Absolvieren des vorliegenden Kurses sind für die meisten SPSS-Anwender(innen) insbesondere diejenigen Bücher von Interesse, welche die jeweils benötigten statistischen Methoden auf einem angemessenen Niveau behandeln und die konkrete Realisation mit SPSS gut unterstützen (z.B. durch eine Erläuterung der Ergebnistabellen). Leider habe ich mir aus Zeitgründen von den zahlreichen Statistik-Lehrbüchern mit SPSS-Unterstützung nur wenige Titel näher ansehen können, so dass die folgende Liste unvollständig ist:

Backhaus et al. (2008). *Multivariate Analysemethoden*

Brosius (2013). *SPSS 21*

Bühl (2012). *SPSS 20. Einführung in die moderne Datenanalyse*

Bühner & Ziegler (2009). *Statistik für Psychologen und Sozialwissenschaftler*

Cohen et al. (2003). *Applied Multiple Regression/Correlation Analysis ...*

Diehl & Staufenbiehl (2007). *Statistik mit SPSS für Windows. Version 15*

Field (2013). *Discovering Statistics Using SPSS*

Norušis (2012a). *IBM SPSS Statistics 19 Guide to Data Analysis*

Norušis (2012b). *IBM SPSS Statistics 19 Statistical Procedures Companion*

Norušis (2012c). *IBM SPSS Statistics 19 Advanced Statistical Procedures*

Rasch, Frieze, Hofmann & Naumann (2010). *Quantitative Methoden* (Band 1 und 2)

Tabachnik & Fidell (2012). *Using multivariate statistics*

Warner (2013). *Applied statistics*

Die vollständigen bibliografischen Angaben finden Sie im Literaturverzeichnis.

- Auf die [ZIMK-Manuskripte](#) zur Verwendung spezieller Analysemethoden in SPSS wurde schon im Vorwort hingewiesen.

2.4.2 SPSS im Internet

SPSS ist im Internet vielfach präsent, z.B.:

- **Die IBM-Webseite zu SPSS:** <http://www-01.ibm.com/software/analytics/spss/>
- **Die Mailing-Liste SPSSX-L@LISTSERV.UGA.EDU**

Hier werden technische und statistische Themen lebhaft diskutiert, wobei auch SPSS-Mitarbeiter zu wichtigen Fragen kompetent Stellung nehmen. Die folgende Webseite bietet ein durchsuchbares Archiv der Liste: <http://spssx-discussion.1045642.n5.nabble.com/>

2.4.3 ZIMK - Service-Punkte

Bei Problemen mit der Anwendung von SPSS-Produkten können sich Angehörige der Universität Trier an die ZIMK - Service-Punkte wenden:

Web: <http://helpdesk.uni-trier.de>
Mail: helpdesk@uni-trier.de
Tel.: 0651 - 201 - 4400
Orte: Campus I: Foyer Gebäude E (Raum 43a)
Campus II: Raum H3
Zeiten: Siehe: <http://www.uni-trier.de/index.php?id=19249>

2.5 SPSS für Windows beenden

Die Beendigung einer SPSS-Sitzung wird mit

Datei > Beenden

eingeleitet. Falls Sie während der Sitzung Dokumente erstellt bzw. verändert und noch nicht gesichert haben (z.B. im Daten- oder im Ausgabefenster), werden Sie von SPSS an das Speichern erinnert.

3 Datenerfassung und SPSS-Dateneditor

Wie bei unserer KFA-Studie liegen auch in vielen anderen Projekten nach Abschluss der Datenerhebung schriftliche Untersuchungsdokumente vor, die nun erfasst, d.h. in eine Computer-Datei übertragen werden müssen. Bevor in Abschnitt 3.2 die konkrete Erfassung der KFA-Daten mit dem SPSS-Dateneditor beschrieben wird, sollen in Abschnitt 3.1 einige alternative Erfassungsmethoden vorgestellt werden.

3.1 Methoden zur Datenerfassung

3.1.1 Online-Datenerhebung

Wenn die nötigen technischen und organisatorischen Voraussetzungen gegeben sind, sollte eine Online-Datenerhebung eingesetzt werden. Hiermit sind Verfahren gemeint, bei denen die Untersuchungsteilnehmer ihre Daten (aktiv oder passiv) direkt in eine EDV-Anlage einspeisen (z.B. Internet-Umfrage, automatische Aufzeichnung physiologischer Daten). Nach Abschluss der Datenerhebung kann sofort die Auswertung beginnen, weil die Daten automatisch in einer Datei landen, die in der Regel direkt in SPSS genutzt werden kann. Auf eine gelegentliche Kontrolle (z.B. wegen möglicher Defekte in der Aufzeichnungsapparatur) sollte man aber nicht verzichten. Die *Datenerfassung* als eigenständige Arbeitsphase entfällt bei den Online-Verfahren.

Mit der zunehmenden Normalität eines problemlosen Internet-Zugangs verbessern sich die Chancen für den Einsatz der Online-Datenerhebung bei einer Vielzahl von Untersuchungen. Hier sind erhebliche methodische und wirtschaftliche Vorteile zu erzielen:

- **Geringe Kosten**

Im Vergleich zur Datenerhebung durch schriftliche Befragung oder Interview fallen deutlich geringere Kosten an (z.B. keine Druck- und Portokosten, keine Kosten für Interviewer). Die für eine Online-Befragung erforderlichen Ressourcen (z.B. Software, Server) können bei diversen Dienstleistern zu erträglichen Kosten gemietet werden.

- **Schnelle Abwicklung**

Zur Beschleunigung tragen einige Faktoren bei:

- Es werden schnelle Internet-Kommunikationstechniken genutzt (z.B. zum Einladen der Probanden).
- Die zeitaufwändige Datenerfassung entfällt.
- Eingeladene Probanden entscheiden sich sehr schnell für oder gegen die Teilnahme an einer Online-Befragung, während ein ausgehändigter oder per Post zugestellter Fragebogen oft zu späteren Bearbeitung deponiert wird (Jacob et al 2013, S. 110).

- **Benutzerfreundliche Filterführung**

Ein Proband sieht nur die ihn betreffenden Fragen, während er bei einem Papierfragebogen ggf. die Sprunginstruktionen korrekt beachten muss.

- **Versuchspläne mit verschiedenen Bedingungen**

Die Teilnehmer können zufallsgesteuert auf Bedingungen (z.B. mit unterschiedlichen Instruktionen) verteilt werden.

- **Simulation von Interaktionen**

Es lassen sich soziale Interaktionen simulieren (z.B. Verhandlungen).

- Einbindung von **Medien** (Bilder, Video, Audio)

- Optionen zur **randomisierten Präsentation** von Fragen und/oder Items

So lassen sich Reihenfolgeeffekte neutralisieren.

- **Plausibilitätskontrollen** zur Steigerung der Datenqualität
- **Zusatzinfos** über die Auskunftspersonen (z.B. Verweildauer auf einzelnen Seiten)

Als Nachteile von Online-Umfragen sind zu nennen:

- **Schlechte Erreichbarkeit** mancher Populationen, **fragliche Repräsentativität**
Nach einer Untersuchung des statistischen Bundesamts aus dem ersten Quartal 2014 nutzten 80% der Personen ab 10 Jahren das Internet, wobei jedoch mit zunehmendem Alter die Nutzung (speziell bei Frauen) geringer ausfiel:¹
 - Von den Frauen ab 65 nutzten nur 32% das Internet.
 - Bei den Männern ab 65 waren es noch 51%.

Nach Jacob et al. (2013, S. 112) sind niedrige soziale Schichten seltener im Internet anzutreffen als gehobene. Durch Gewichtungstechniken bei der statistischen Analyse lassen sich Repräsentativitätsdefizite teilweise ausgleichen. Allerdings kommt z.B. eine Online-Umfrage kaum in Betracht, wenn die Zufriedenheit von Altersheimbewohnern untersucht werden soll.
- **Abhängigkeit von technischen Ressourcen** in der Befragungssituation (Hardware, Internet)

Über das ZIMK haben Angehörige der Universität Trier Zugriff auf das professionelle Online-Umfragesystem **Enterprise Feedback Suite Survey** (EFS Survey) der Firma **Questback**, die unter dem Namen **Unipark** günstige Lizenzbedingungen für Hochschulen bietet (siehe Baltes-Götz 2016b).

Hier ist die erste Seite der Online-Realisation des Beispielfragebogens zum Kurs zu sehen:

Statistisches Praktikum mit SPSS

20%

1) Fragen zur Reaktion in ärgerlichen Situationen

Versetzen Sie sich bitte möglichst gut in folgende Situation:

Herr Meier und Herr Schulze waren mit demselben Taxi auf dem Weg zum Flughafen. Sie sollten zur selben Zeit, aber mit verschiedenen Maschinen abfliegen. Durch einen Stau kommen sie erst eine halbe Stunde nach der planmäßigen Abflugzeit am Flughafen an.

Herr Meier erfährt, dass seine Maschine pünktlich vor einer halben Stunde gestartet ist.
Herr Schulze erfährt, dass seine Maschine Verspätung hatte und erst vor zwei Minuten gestartet ist.

Wie sehr würden Sie sich ärgern, wenn Sie in der Situation von ...

	0°	10°	20°	30°	40°	50°	60°	70°	80°	90°	100°
Herrn Meier wären?	☐	☐	☐	☐	☐	☐	☐	☐	☐	☐	☐
Herrn Schulze wären?	☐	☐	☐	☐	☐	☐	☐	☐	☐	☐	☐

Betrachten Sie bitte die Antwortskala als "Ärgerthermometer".

Wer an der Universität Trier eine Online-Datenerhebung mit EFS Survey durchführen möchte, findet Informationen zum Erwerb der Zugangsberechtigung auf der folgenden Webseite:

<https://www.uni-trier.de/index.php?id=53873>

¹ https://www.destatis.de/DE/ZahlenFakten/GesellschaftStaat/EinkommenKonsumLebensbedingungen/ITNutzung/Aktuell_ITNutzung.html

3.1.2 Manuelle Verfahren

3.1.2.1 Datenerfassung nach einer Papier-gestützten Datenerhebung

Kommt bei einer papiergestützten Datenerhebung der Einsatz einer Scanner-Lösung nicht in Frage, müssen die Daten per Tastatur unter Beachtung eines Kodierplans in eine Computer-Datei befördert werden. Beim Entwurf des Kodierplans ist darauf zu achten, dass dem Erfasser keine unnötigen und fehleranfälligen Arbeiten zugemutet werden (siehe Abschnitt 1.4).

Von den möglichen manuellen Erfassungsmethoden werden in diesem Manuskript vorgestellt:

- **Erfassung mit dem SPSS-Dateneditor**

Der SPSS-Dateneditor ist ein integraler Bestandteil des SPSS-Systems, so dass wir uns mit seiner Bedienung auf jeden Fall vertraut machen müssen. Er ist nicht perfekt geeignet für die Erfassung *größerer* Datenmengen, kann aber in kleinen bis mittleren Projekten verwendet werden. Relativ ähnliche Arbeitsbedingungen für die Datenerfassung bieten Tabellenkalkulationsprogramme wie z.B. Microsoft Excel.

- **Einsatz eines speziellen Datenerfassungsprogramms**

Ein spezielles Datenerfassungsprogramm bietet Vorteile gegenüber dem SPSS-Dateneditor, erfordert aber auch zusätzlichen Einarbeitungsaufwand.

Aufgrund des relativ geringen Datenaufkommens in unserem KFA-Projekt ist der SPSS-Dateneditor das optimale Erfassungswerkzeug. Weil in Abschnitt 3.2 die Erfassung der KFA-Daten mit dem SPSS-Dateneditor ausführlich beschrieben wird, können wir uns im aktuellen Abschnitt auf Erläuterungen zu den spezialisierten Datenerfassungsprogrammen beschränken.

Wenn bei *größeren* Projekten eine manuelle Datenerfassung unumgänglich ist, dann sollte in der Regel ein spezielles Datenerfassungsprogramm verwendet werden:

- Angehörige der Universität Trier im Besitz einer SPSS-Einzelplatzlizenz (vgl. Abschnitt 2.1) können zu diesem Zweck das Programm **SPSS Data Collection Data Entry** nutzen.¹
- Ein Datenbankprogramm mit der Möglichkeit zur Formulardefinition (z.B. MS-Access) bietet ähnliche Möglichkeiten.
- Sofern ein Arbeitsplatz mit permanenter Internet-Verbindung zur Verfügung steht, kann auch ein Online-Umfragesystem für die manuelle Dateneingabe eingesetzt werden (vgl. Abschnitt 3.1.1). Diese Lösung hat sogar den Vorteil, dass an den Erfassungsplätzen als Software nur ein Betriebssystem und ein Web-Browser benötigt werden. Weil die Datenerfasser wie normale Probanden behandelt werden, können sie allerdings einen abschließend quitierten Fall später innerhalb des Online-Umfragesystems nicht mehr korrigieren.

Bei Verwendung eines Datenerfassungsprogramms arbeitet man mit einer *Erfassungsmaske*, die einen *einzelnen* Fall in übersichtlicher Form auf dem Bildschirm präsentiert. Außerdem machen folgende Techniken die Datenerfassung rationeller und sicherer:

¹ <http://public.dhe.ibm.com/common/ssi/ecm/en/ytd03064usen/YTD03064USEN.PDF>

- **Filterführung** (*Skip & Fill*)

In Abhängigkeit vom erfassten Wert einer Filtervariablen verzweigen die Datenerfassungsspezialisten zu unterschiedlichen Folgevariablen und versorgen dabei übersprungene Variablen mit einem MD-Indikator.

- **Plausibilitätsprüfungen**

Man kann z.B. dafür sorgen, dass bei der Variablen GESCHL nur die Werte 1 und 2 akzeptiert werden.

Allerdings entstehen beim Einsatz eines speziellen Datenerfassungsprogramms auch Kosten:

- Es muss ein zusätzliches Programm erlernt werden.
- Für jedes Projekt sind einige Konfigurationsarbeiten erforderlich (z.B. Gestaltung der Erfassungsmaske, Definition der Regeln zur Plausibilitätskontrolle).

3.1.2.2 Interviews mit sofortiger Datenerfassung

Bei bestimmten Befragungsthemen oder -kontexten kommen Interviews mit den Probanden in Frage, die von Mitarbeitern des Forschungsprojekts geführt werden. In der Regel ist dann eine sofortige digitale Datenerfassung anzustreben, um den Umweg über Papier zu vermeiden. Nach der Befragungssituation sind zu unterscheiden:

- Vor-Ort-Interview (*CAPI, Computer Assisted Personal Interviewing*)
- Befragung per Telefon (*CATI, Computer Assisted Telephone Interviewing*)

Neben spezialisierten Computerprogrammen, die z.B. bei Telefon-Interviews auch das Wählen übernehmen können, eignen sich zur Interview-begleitenden Datenerfassung auch die in Abschnitt 3.1.2.1 beschriebenen Datenbankspezialisten (z.B. SPSS Data Collection Data Entry). Sie stellen durch eine automatische Filterführung den korrekten Ablauf der Interviews sicher und reduzieren irreguläre Daten durch Plausibilitätskontrollen.

3.2 Erfassung mit dem SPSS-Dateneditor

Für die nächsten Schritte im KFA-Projekt benötigen Sie eine SPSS-Sitzung mit einem leeren Datenfenster. Diese Situation liegt z.B. vor, nachdem Sie SPSS gestartet und den Startassistenten mit dem Ziel **Daten eingeben** verlassen haben. Nötigenfalls können Sie ein leeres Datenfenster mit dem folgenden Menübefehl anfordern:

Datei > Neu > Daten

Im realen SPSS-Kurs steht nun die Variablendeklaration und die Datenerfassung mit dem SPSS-Dateneditor an. Wenn Sie dieses Manuskript im Selbststudium lesen, können und sollten Sie trotzdem die folgenden Arbeitsschritte zur Variablendeklaration konkret nachvollziehen und die Daten des im Manuskript abgedruckten ersten Falles eintragen (siehe Seite 42). Alle Projektphasen nach der Datenerfassung können Sie durch Verwendung der SPSS-Datendatei **kfar.sav** mitmachen, deren Inhalt im weiteren Verlauf erklärt wird. Wie Sie diese Datei via Internet beziehen können, ist im Vorwort zu erfahren.

3.2.1 Dateneditor, Datenblatt und Arbeitsdatei

SPSS speichert die zu analysierenden Daten während der Sitzung in einer temporären Datei, die als **Datenblatt** oder **Daten-Set** bezeichnet wird. Zur Bearbeitung dient ein **Dateneditorfenster**, das wir der Kürze halber oft als **Datenfenster** bezeichnen. Ein Datenblatt enthält:


- Die **rechteckige (Fälle × Variablen)-Datenmatrix**
Diese wird auf dem **Datenansicht**-Registerblatt des Datenfensters bearbeitet.
- Einen **Deklarationsteil**, auch **Datenlexikon** genannt
Eine Variable besitzt mehrere verarbeitungsrelevante Attribute, z.B. einen eindeutigen Namen. Zur Verwaltung der Attribute dient das **Variablenansicht**-Registerblatt des Datenfensters.

Mit Hilfe des Dateneditors oder durch Transformationskommandos (siehe unten) können u.a. folgende Modifikationen an einem Datenblatt vorgenommen werden:

- Definition von neuen Variablen, Änderung von Variablenattributen (z.B. Namen)
- Manuelle Erfassung von neuen Fällen
Wir werden in unserem Demoprojekt die Daten manuell erfassen.
- Löschen von Variablen oder Fällen
- Berechnung neuer Variablen aus bereits vorhandenen über Datentransformationsbefehle
- Einlesen von Daten aus einer vorhandenen Datei mit einem unterstützten Format (z.B. SPSS, Text, Microsoft Excel, SAS, Stata) in ein neues Datenblatt.

Wenn ein Datenblatt über das Ende der Sitzung hinaus erhalten bleiben soll, muss es explizit gesichert werden (in der Regel in eine SPSS-Datendatei, siehe Abschnitt 3.2.3).

SPSS unterstützt die simultane Verwendung *mehrerer* Dateneditorfenster, z.B.:




Das Daten-Set zum *aktiven* Dateneditorfenster wird als **Arbeitsdatei** bezeichnet und z.B. bei Analyseanforderungen per Menüsystem angesprochen. Um ein Datenblatt zur Arbeitsdatei zu befördern, muss man das zugehörige Dateneditorfenster per Mausklick oder **Fenster**-Menü in den Vordergrund holen. Das Datenfenster mit der Arbeitsdatei ist an einem Pluszeichen im Symbol zum Systemmenü  zu erkennen (siehe linken Rand der Titelzeile).

Jedes Datenblatt hat einen Namen, welcher in der Titelzeile seines Dateneditorfensters durch eckige Klammern begrenzt hinter dem Namen der verbundenen Datendatei erscheint (siehe oben) und z.B. über den folgenden Menübefehl zu ändern ist:

Datei > Datenblatt umbenennen

Mit dem Schließen des *letzten* Dateneditorfensters beendet man SPSS:



3.2.2 Variablen definieren


Wie eben erwähnt, verwaltet SPSS für jede Variable eines Datenblatts zahlreiche verarbeitungsrelevante Attribute (z.B. Indikatoren für fehlende Werte). Diese werden im Deklarationsteil des Datenblatts gespeichert und können vom Anwender festgelegt werden. Da SPSS für alle Attribute geeignete Voreinstellungen benutzt, setzt die Datenerfassung nicht unbedingt eine Variablendefinition voraus,¹ doch wird das Erfassen und die spätere Auswertungsarbeit z.B. durch benutzerdefinierte Variablennamen anstelle der automatisch generierten und wenig aussagekräftigen Namen VAR00001, VAR00002 usw. erleichtert. Daher liegt es nahe, dem SPSS-System die in unserem Kodierplan beschriebenen Variablen vor dem Eintragen der Daten bekannt zu machen.

3.2.2.1 Das Datenfenster-Registerblatt Variablenansicht

Ein Datenfenster besitzt zwei Registerblätter zur Anzeige bzw. Bearbeitung eines Datenblatts:

- das Registerblatt **Datenansicht** zur Anzeige und Modifikation der (Fälle × Variablen)-Datenmatrix
- das Registerblatt **Variablenansicht** zur Anzeige und Modifikation der Variablenattribute

In einer Zeile der **Variablenansicht** wird eine Variable beschrieben, wozu in den Spalten insgesamt elf Attribute zur Verfügung stehen. Für unsere erste Variable (FNR) eignen sich z.B. folgende Angaben:



¹ Da in SPSS der Variablentyp *numerisch* voreingestellt ist, müssten wir vor dem Erfassen von Daten anderen Typs auf jeden Fall eine Variablendefinition vornehmen. Allerdings sind solche Variablen in unserem Kodierplan nicht vorgesehen.

Um eine neue Variable anzulegen, trägt man ihren Namen in die nächste freie Zeile der Tabelle ein. Nach dem Verlassen der Namenszelle werden die restlichen Attribute der neuen Variablen automatisch mit Voreinstellungswerten versorgt, die man nach Bedarf ersetzt. Darüber hinaus kann man Variablen einfügen, löschen oder verschieben (siehe unten).

3.2.2.2 Die SPSS-Variablenattribute

Bevor wir die Variablen unserer KFA-Studie deklarieren, sollen die SPSS-Variablenattribute erläutert werden:

- **Name**

Die wesentlichen Regeln für SPSS-Variablenamen wurden schon im Zusammenhang mit dem Kodierplan genannt (siehe Seite 39).

- **Typ**

Die wichtigsten SPSS-Variablentypen sind schon benannt: Numerisch, Zeichenfolge und Datum (siehe Seite 33). In der Regel empfiehlt sich auch bei nominalskalierten Merkmalen eine numerische Kodierung (siehe Abschnitt 1.4.3), so dass der voreingestellte numerische Variablentyp meist beibehalten werden kann.

- **Spaltenformat**

Bei einer regulären (nicht eingeschränkten) numerischen Variablen beeinflusst dieses Attribut lediglich ihre voreingestellte Breite (inkl. Vorzeichen und Dezimaltrennzeichen) bei der Ausgabe in eine Textdatendatei (z.B. über das Kommando WRITE) und ist daher für die Arbeit mit dem Daten- und dem Ausgabefenster wenig relevant. Allerdings muss der Spaltenformatwert stets größer sein als die Anzahl der Dezimalstellen (siehe unten).

Bei einer *eingeschränkten* numerischen Variablen, die nichtnegative ganze Zahlen als Werte annehmen kann, legt das **Spaltenformat** die maximale Anzahl der Ziffern fest. Schöpft ein Wert die maximale Breite nicht aus, wird er links mit Nullen aufgefüllt.

Bei einer *alphanumerischen* Variablen legt das **Spaltenformat** die maximale Anzahl der Zeichen fest. Bei einer nachträglichen Reduktion des **Spaltenformats** werden entsprechend viele Zeichen am rechten Rand gelöscht.

- **Dezimalstellen**

Bei einer *numerischen* Variablen können Sie festlegen, welche Anzahl von Dezimalstellen bei der Anzeige ihrer Werte im Datenfenster und in der Ergebnisausgabe verwendet werden soll. Diese Angabe betrifft *nicht* die Speichergenauigkeit, sondern nur die Anzeige. Bei einer *alphanumerischen* Variablen ist das Attribut irrelevant und auf den Wert Null fixiert.

- **Beschriftung**

Es kann optional eine Beschriftung (frühere Bezeichnung: *Variablenlabel*) vereinbart werden, die in Ergebnistabellen und Diagrammen an Stelle des aus praktischen Erwägungen möglichst kurz gewählten und mit Syntaxrestriktionen belasteten Variablennamens (z.B. Verbot von Leerzeichen) angezeigt werden soll, z.B.:

Variablenname	Variablenlabel
FB	Fachbereich an der Universität Trier
GEWICHT	Körpergewicht (in kg)

Während wir die Variablennamen in SPSS der Einfachheit halber meist klein schreiben, ist bei den Variablenbeschriftungen eine publikationsreife Groß/Kleinschreibung angemessen.

- **Werte**

Hier kann man Wertbeschriftungen (frühere Bezeichnung: *Wertelabels*) mit maximal 120 Zeichen definieren, die in Ergebnistabellen und Diagrammen an Stelle der Werte einer Variablen erscheinen. SPSS empfiehlt Wertbeschriftungen bei nominalen und bei ordinalen Variablen. Bei numerisch kodierten nominalskalierten Merkmalen sind sie fast unverzichtbar, z.B.:

Variablenname	Werte	Wertelabels
GESCHL	1	Frau
	2	Mann

Im Abschnitt 3.2.2.6 wird die Definition von GESCHL-Wertelabels konkret vorgeführt.

Man erhält nicht nur ansehnliche Beschriftungen (z.B. in einem Balkendiagramm), sondern beeinflusst unter bestimmten Umständen auch die Berücksichtigung von Kategorien: Soll eine unbesetzte Kategorie (mit der Häufigkeit Null) in einem Diagramm erscheinen (z.B. als Balken mit der Höhe Null), muss der zugehörige (in den Daten nicht vorhandene) Wert eine Wertbeschriftung erhalten.


Bei metrischen Variablen sind Wertelabels nur für benutzerdefinierte MD-Indikatoren von Interesse.

In der Datenansicht bietet der Dateneditor über den Menübefehl

Ansicht > Wertbeschriftungen

bzw. den Symbolschalter  einige Unterstützung für die Etiketten:

- Sie werden an Stelle der Werte angezeigt.
- Alternativ zur Werteingabe per Tastatur kann man per Drop-Down-Menü ein Label wählen, z.B.:




Es ist aber *nicht* möglich, durch Vergabe von Wertelabels die Menge der gültigen Werte einer Variablen zu definieren und eine Plausibilitätskontrolle für die Erfassung per Dateneditor einzurichten. Trotz obiger Wertelabels-Vereinbarung wird der SPSS-Dateneditor bei der Variablen GESCHL beliebige Zahlen akzeptieren.


- **Fehlend**

Wenn Sie bei einer Variablen *benutzerdefinierte* MD-Indikatoren verwenden wollen, müssen Sie diese unbedingt deklarieren, weil sie sonst wie gültige Werte behandelt werden, z.B. bei einer Mittelwertsbildung:

- Markieren Sie bei der betroffenen Variablen die Zelle zum Attribut **Fehlend**.
- Nach einem Mausklick auf den nun vorhandenen Erweiterungsschalter [...] erscheint eine Dialogbox, in der man entweder bis zu drei Einzelwerte oder aber ein Intervall samt zusätzlichem Einzelwert als MD-Indikatoren vereinbaren kann, z.B.:



- Soll bei einer *Zeichenfolgenvariable* die leere Zeichenfolge als MD-Indikator deklariert werden, ist ein einzelnes Leerzeichen einzutragen, z.B.:



• Spalten und Ausrichtung

Wie breit soll die Spalte einer Variablen im Dateneditorfenster sein? Wie sollen die Werte ausgerichtet werden (linksbündig, zentriert, rechtsbündig)? Die Attribute **Spalten** und **Ausrichtung** wirken sich nur auf die Darstellung einer Variablen im Datenfenster aus. Genügt die **Spalten**-Zahl nicht, versucht SPSS bei numerischen Variablen, das Platzproblem durch die Exponentialschreibweise zu lösen, z.B.:

	11111111
a	var
1,11E+007	

Noch größere Platznot signalisiert SPSS durch Pünktchen:

	1111111111
a	var
1,11E...	

Bei der **Ausrichtung** hält sich SPSS an die Konvention, Texte links- und Zahlen rechtsbündig zu schreiben, so dass es kaum einen Grund gibt, dieses Attribut zu ändern.

• Messniveau

Über die technischen Variablenattribute hinaus sollte das Messniveau der Variablen deklariert werden, wobei die Ausprägungen **Metrisch** (Intervall- bzw. Rationalskalenni-

veau), **Ordinal** und **Nominal** möglich sind. Bislang spielt das deklarierte Messniveau der Variablen bei den meisten SPSS-Prozeduren noch keine Rolle. Bei der Diagrammerstellung (siehe Abschnitt 11.1.1) hängt die Behandlung einer Variablen jedoch vom deklarierten Messniveau ab, und SPSS empfiehlt ausdrücklich, für alle bei einem Diagramm beteiligten Variablen das Messniveau korrekt anzugeben.

- **Rolle**

Man kann man den Variablen eine Rolle zuweisen, die in einigen Dialogfeldern zur Variablenvorauswahl genutzt wird:

- **Eingabe**
Die Variable kommt als Regressor (unabhängige Variable) in Frage.
- **Ziel**
Die Variable kommt als Kriterium (abhängige Variable) in Frage.
- **Beide**
Die Variable kommt als Regressor (unabhängige Variable) und als Kriterium (abhängige Variable) in Frage.
- **Keine**
Die Variable erhält keine Rolle.
- **Partitionieren**
Die Variable dient zur Zerlegung der Stichprobe, z.B. in Modellierungs- und Kreuzvalidierungsfälle.
- **Splitten**
Diese Rolle ist im Hinblick auf das Produkt SPSS Modeler vorhanden und in SPSS Statistics irrelevant.

3.2.2.3 Variablendefinition durchführen

Aktivieren Sie nun die **Variablenansicht** des Datenfensters, und tragen Sie für die erste Variable (zur Fallidentifikation) den Namen FNR ein. Nach dem Markieren der zugehörigen Zelle können Sie sofort mit dem Eintippen des Namens beginnen. Die Groß/Kleinschreibung ist bzgl. der Identifikation von Variablen irrelevant. Die folgenden Namen bezeichnen allesamt dieselbe Variable:

fnr Fnr FNR

Im Manuskript werden Variablennamen aus darstellungstechnischen Gründen groß geschrieben.


Sobald Sie die Zelle mit dem Variablennamen verlassen (z.B. per Mausklick auf eine andere Zelle oder per Tabulatortaste) wird eine neue Variable mit dem gewünschten Namen in die Arbeitsdatei aufgenommen, sofern gegen den Variablennamen keine Einwände bestehen, und die restlichen Attribute der neuen Variablen werden mit Standardwerten versorgt.

Als **Typ** übernehmen wir (wie bei allen anderen Variablen) die Voreinstellung **numerisch**.

Nach dem Markieren der Zelle **Dezimalstellen** kann man die gewünschte Anzahl von Dezimalstellen durch Eingabe einer Zahl oder per Up-Down - Regler wählen:

Analog wird auch das Attribut **Spaltenformat** festgelegt, das allerdings bei der von uns geplanten Arbeitsweise keine große Rolle spielt (siehe oben).

Eine alternative Möglichkeit zum Einstellen der Attribute **Typ**, **Dezimalstellen** und **Spaltenformat** findet sich in der Dialogbox **Variablentyp definieren**, die nach einen Mausklick auf den Erweiterungsschalter  in der markierten **Typ**-Zelle erscheint:




Tipp: Wenn in einem Projekt das voreingestellte Anzeigeformat für numerische Variablen (Breite = 8, Dezimalstellen = 2) häufig durch eine bestimmte Alternative ersetzt werden muss, kann zur Vereinfachung der Deklaration die Voreinstellung entsprechend geändert werden. Dazu öffnet man mit **Bearbeiten > Optionen** die Dialogbox **Optionen**, wechselt hier zum Registerblatt **Daten** und nimmt im Rahmen **Anzeigeformat für neue numerische Variablen** die gewünschten Einstellungen vor, z.B.:



Wenngleich die Variable FNR im Ausgabefenster nicht allzu oft auftauchen wird, tragen wir in die Zelle zum Attribut **Variablenbeschriftung** den Text *Fallnummer* ein.

Statt die Breite der FNR-Spalte im Datenfenster über eine gut geschätzte **Spalten**-Angabe festzulegen, können Sie bei aktiviertem Registerblatt **Datenansicht** auch folgendermaßen vorgehen:


- Setzen Sie den Mauszeiger auf den rechten Rand der Zelle mit dem Variablennamen, woraufhin der Zeiger eine neue Form und dementsprechend eine neue Funktion erhält:




- Nun lässt sich der rechte Rand der aktuellen Spalte verschieben: Linke Maustaste drücken, ziehen und an der gewünschten Position wieder loslassen.

Eine so festgelegte Spaltenbreite wird von SPSS als **Spalten**-Wert übernommen.


Öffnen Sie in der markierten **Messniveau**-Zelle das Drop-Down-Menü, um für die Fallnummer ein nominales Skalenniveau zu deklarieren:



Öffnen Sie in der markierten Zelle zur Entscheidung über eine **Rolle** das Drop-Down-Menü, um der Variablen Fallnummer eine Rolle zu verweigern:




MD-Indikatoren und Wertelabels sind bei der augenblicklich bearbeiteten Fallnummernvariablen irrelevant, und das Attribut **Ausrichtung** übernehmen wir stets unverändert. Daher können wir die Deklaration der Variablen FNR beenden:



Bei Bedarf sind Anpassungen jederzeit möglich.

Vereinbaren Sie nun in der zweiten Zeile der Variablenansicht für den Ärger ohne KFA-Wirkung den Variablennamen AERGO, eine Anzeige ohne Dezimalstellen und das Variablenlabel *Ärger ohne KFA* ein. Wir gehen von Intervallniveau aus und vergeben im SPSS-Dateneditor die zugehörige Attributausprägung **Metrisch**. Wie ein kurzer Besuch auf dem Registerblatt **Datenansicht** zeigt, genügt die **Spalten**-Breite 4. Als mutmaßlich dominante **Rolle** der Variablen AERGO legen wir **Ziel** fest, sodass sich im Dateneditor nun folgendes Bild zeigt:




3.2.2.4 Variablen einfügen, löschen oder verschieben

Bei der Variablendefinition kann sich leicht die Notwendigkeit ergeben, Variablen einzufügen oder zu löschen.


3.2.2.4.1 Variablen einfügen

Wenn wir z.B. nach FNR die Variable AERGM definiert, also die Variable AERGO vergessen hätten, könnten wir das Missgeschick in der Variablenansicht folgendermaßen korrigieren:

- Rechter Mausklick auf die Nummer der AERGM-Zeile (am linken Rand der Tabelle).
- Kontextmenü-Option **Variable einfügen** wählen



Daraufhin stellt SPSS vor AERGM eine neue Variable mit voreingestellten Attributen zur Verfügung, die nun beliebig angepasst werden können:



Auf analoge Weise lässt sich eine neue Variable auch in der Datenansicht einfügen:

- Setzen Sie einen rechten Mausklick auf die Beschriftung der AERGM-Spalte im Kopfbereich der Tabelle.
- Wählen Sie die Option **Variable einfügen** aus dem Kontextmenü.

3.2.2.4.2 Variablen löschen

Gehen Sie in der Variablenansicht folgendermaßen vor, um eine Variable zu löschen:

- Setzen Sie einen rechten Mausklick auf die Zeilennummer der betroffenen Variablen in der Nummerierungsspalte am linken Fensterrand.
- Wählen Sie die aus dem Kontextmenü Option **Löschen**.

Auf analoge Weise lässt sich eine Variable auch in der Datenansicht löschen.

3.2.2.4.3 Variablen verschieben

a) Verschieben über eine kurze Distanz

Gehen Sie in der Variablenansicht folgendermaßen vor, um Variablen per Drag & Drop (Ziehen und Ablegen) über eine kurze Distanz (z.B. innerhalb des sichtbaren Datenblattsegments) zu verschieben:

- Markieren Sie die zu verschiebenden Variablen auf Windows-übliche Weise über Mauseaktionen in der Nummerierungsspalte am linken Fensterrand, ggf. ergänzt durch die  - und/oder  - Taste. Lassen Sie anschließend die Maustaste wieder los.
- Klicken Sie in der Nummerierungsspalte erneut auf die zu verschiebende Variablenauswahl, und halten Sie dabei die linke Maustaste gedrückt.
- Bewegen Sie bei gedrückter Maustaste den Mauszeiger zum Ziel der Verschiebungsaktion. Der aktuell anvisierte Zielort wird von SPSS durch eine rote Linie gekennzeichnet.
- Wenn Sie die Maustaste loslassen, erscheinen die Variablen am neuen Ort.

Auf analoge Weise lässt sich eine Variablenauswahl auch in der Datenansicht verschieben.

b) Verschieben über eine lange Distanz

Das eben beschriebene Verfahren ist unpraktisch beim Verschieben über eine größere Distanz, z.B. wenn eine Variable von der Position 800 auf die Position 3 zu verschieben ist. Muss zum Ansteuern der neuen Position der Datenfensterinhalt gerollt werden, verläuft die Bewegung unangenehm langsam. In dieser Lage ist das folgende Verfahren zu empfehlen, das aber wegen potentieller Datenverluste sorgfältig ausgeführt werden muss:


- Wechseln Sie zur **Datenansicht**.
- Markieren Sie die zu verschiebenden Variablen auf Windows-übliche Weise.
- Wählen Sie aus dem Kontextmenü der markierten Variablen das Item **Ausschneiden**, um die Variablen in die Windows-Zwischenablage zu befördern und am alten Ort zu löschen.
- Fügen Sie an der Zielposition so viele neue, leere Variablen ein, dass alle Umzügler Platz finden. Das geht am einfachsten über das Item **Variable einfügen** aus dem Kontextmenü zu derjenigen Variablen, die zum neuen rechten Nachbarn der Umzügler werden soll.
- Markieren Sie die neuen, noch leeren Spalten, und wählen Sie aus deren Kontextmenü das Item **Einfügen**.

3.2.2.5 Attribute auf andere Variablen übertragen

3.2.2.5.1 Variablendeklaration vervielfältigen


Für unsere zwölf LOT-Fragen sollen natürlich alle Variablenattribute mit Ausnahme des Namens identisch sein. Erfreulicherweise müssen wir die identische Variablendefinition nicht 12-mal wiederholen, sondern können nach einer ersten Definition die Attribute auf alle anderen Variablen übertragen. Mit der folgenden Vorgehensweise lässt sich sogar das Schreiben der restlichen Variablennamen automatisieren:

- Deklarieren Sie die Variable LOT1 mit geeigneten Attributen, z.B.:




Das voreingestellte metrische Messniveau (**Skala**) kann beibehalten werden, obwohl die fünfstufigen Variablen LOT1 bis LOT12 wohl eher grobschlächtige Indikatoren für das angenommene latente Merkmal Optimismus sind. In den geplanten Auswertungen werden wir nicht die zwölf Rohvariablen selbst, sondern eine daraus abgeleitete Mittelwertvariable verwenden, für die ein approximativ metrisches Messniveau angenommen werden darf.

- Öffnen Sie das Kontextmenü zur Variablen LOT1 per Mausrechtsklick auf ihre Zeilennummer in der Nummerierungsspalte am linken Fensterrand, und wählen Sie das Item **Kopieren**, um alle Attribute der Variablen in die Windows-Zwischenablage zu befördern.
- Setzen Sie einen rechten Mausklick auf die Nummer der nächsten freie Zeile der Variablenansicht und wählen Sie aus dem Kontextmenü die Option **Variablen einfügen** mit den drei Punkten am Ende der Beschriftung:



Diese Option ist nur verfügbar, wenn sich eine komplette Variablenbeschreibung in der Zwischenablage befindet.


- In der folgenden Dialogbox



können Sie nun festlegen, ...

- wie viele neue Variablen benötigt werden,
- welche gemeinsame Wurzel die neuen Variablennamen haben sollen,
- mit welchem Indexwert der erste Variablenname komplettiert werden soll.

Nach dem Quittieren der obigen Dialogbox entstehen elf neue Variablen mit den gewünschten Namen und Attributen:



3.2.2.5.2 Alle Attribute einer Variablen auf andere Variablen übertragen

Gehen Sie z.B. folgendermaßen vor, um alle Attribute einer Variablen (mit Ausnahme des Namens) auf andere, bereits vorhandene Variablen zu übertragen:

- Öffnen Sie das Kontextmenü zur Quellvariablen per Mausrechtsklick auf ihre Zeilennummer in der Nummerierungsspalte am linken Fensterrand, und wählen Sie das Item **Kopieren**, um alle Attribute der Variablen in die Zwischenablage zu befördern.
- Markieren Sie *eine* Zielvariable per Mausklick auf ihre Zeilennummer oder *mehrere* Zielvariablen durch Mausklicks in Kombination mit der  - und/oder **Strg** - Taste.
- Übertragen Sie die in der Zwischenablage gespeicherten Attribute über das Kontextmenü-Item **Einfügen**, mit der Tastenkombination **Strg+V** oder mit dem Menübefehl


Bearbeiten > Einfügen

auf alle markierten Variablen.


3.2.2.5.3 Einzelne Attribute einer Variablen auf andere Variablen übertragen

Es ist auch möglich, ein *einzelnes* Attribut von einer Variablen auf andere zu übertragen:

- Kontextmenü zur Quell-Attributzelle durch einen rechten Mausklick öffnen und das Item **Kopieren** wählen, z.B.:



- Zu verändernde Attributzellen mit der rechten Maustaste markieren



und den Attributwert über das Kontextmenü-Item **Einfügen** aus der Zwischenablage übernehmen.


3.2.2.5.4 Übung

Definieren Sie die laut Kodierplan aus dem Teil 3 unseres Fragebogens resultierenden Variablen.

3.2.2.6 Numerische Kodierung auch bei nominalskalierten Merkmalen

Vereinbaren Sie für das Merkmal Geschlecht den Variablennamen GESCHL, eine numerische Kodierung, eine Anzeige ohne Dezimalstellen und die Variablenbeschriftung *Geschlecht*. Dabei wird die Empfehlung aus Abschnitt 3.2.2.2 umgesetzt, auch bei nominalskalierten Merkmalen eine numerische Kodierung zu verwenden.

Nach der numerischen Kodierung des nominalskalierten Merkmals Geschlecht ist es sehr empfehlenswert, die willkürliche Zuweisung von Zahlen zu den beiden Kategorien durch Wertelabels zu dokumentieren, damit bei der Lektüre von Ergebnisausgaben niemand rätseln muss, welches Geschlecht die Nummer Eins ist. Öffnen Sie daher mit einem Mausklick auf den Erweiterungsschalter  in der markierten **Werte**-Zelle die folgende Dialogbox:




Legen Sie z.B. das weibliche Label folgendermaßen fest:

- Tragen Sie den **Wert** 1 und die **Beschriftung** *Frau* ein.
- Drücken Sie auf den Schalter **Hinzufügen**.


In der Schaltflächen-Beschriftung Hinzufügen signalisiert das unterstrichene H, dass der Mausklick auf die Schaltfläche durch die Tastenkombination **Alt+H** ersetzt werden kann.

3.2.2.7 Benutzerdefinierte MD-Indikatoren

Bei der Variablen GESCHL muss der zur Residualkategorie *Keine Angabe* gehörige Wert 8 als MD-Indikator vereinbart werden. Öffnen Sie daher mit einem Mausklick auf den Erweiterungsschalter  in der markierten **Fehlend**-Zelle die folgende Dialogbox und tragen Sie hier die 8 als **einzelnen fehlenden Wert** ein:



Abschließend sind für GESCHL noch eine **Spalten**-Breite, das nominale Messniveau und die **Eingabe**-Rolle zu deklarieren, so dass sich im Dateneditor folgendes Bild ergibt:



3.2.2.8 Übung

Definieren Sie die restlichen Variablen aus dem Fragebogenteil 4.


3.2.3 Sichern eines Datenblatts als SPSS-Datendatei

Wenn ein neu erstelltes Datenblatt über das Ende der Sitzung hinaus erhalten bleiben soll, muss es explizit auf einen permanenten Datenträger gesichert werden, wobei eine **SPSS-Datendatei** entsteht. In späteren Sitzungen kann durch Öffnen dieser Datendatei der gesicherte Zustand des Datenblatts wiederhergestellt werden.

Zwar enthält Ihre aktuelle Arbeitsdatei (das aktive und vermutlich einzige Datenblatt) noch keine Daten, aber im Datenlexikon (Deklarationsteil) befinden sich bereits wertvolle Informationen, deren Verlust recht schmerzlich wäre. Daher sollten Sie schon jetzt die temporäre Arbeitsdatei in eine permanente SPSS-Datendatei sichern, indem Sie den folgenden Menübefehl wählen:

Datei > Speichern unter...


In der erscheinenden Dialogbox ist für die zu erzeugende SPSS-Datendatei ein Laufwerk, ein Verzeichnis und ein Name anzugeben:




Wenn Sie die für SPSS-Datendateien vorgegebene Namensendung **.sav** beibehalten, geht das spätere Öffnen besonders bequem.

Als Name für unsere Beispieldatei wird **kfar.sav** vorgeschlagen, verbunden mit der Versicherung, die Begründung für das **r** im nächsten Abschnitt nachzuliefern.


Nach dem **Speichern** zeigt die Titelzeile des Datenfensters neben dem Datenblattnamen auch den Namen der nunmehr zugeordneten Datendatei, in unserem Fall also **kfar.sav**:



Sobald ein Datenblatt gegenüber dem zuletzt gespeicherten Zustand geändert worden ist, erscheint ein Sternchen vor dem Dateinamen, und die Symbolleiste-Schaltfläche zum Speichern (mit dem Diskettensymbol) wird aktiv, z.B.:



Beim Speichern führt der SPSS-Prozessor das Kommando **SAVE** aus, was später noch zu erläutern ist (siehe Abschnitt 6.7.1). Weil SPSS per Voreinstellung ausgeführte Kommandos protokolliert, erscheint überraschend früh ein Ausgabefenster:




Nähere Informationen zu den Ausgabefenstern folgen in den Abschnitt 4.4 und 9.4.

Nach dem Menübefehl

Bearbeiten > Optionen

kann man im **Optionen**-Dialog auf der Registerkarte **Viewer** das Protokollieren der Kommandos abschalten:



Beim Speichern eines Datenblatts können auch alternative Dateiformate gewählt werden (z.B. EXCEL, SAS, Stata, Text).

Zum späteren Sichern in eine bereits zugeordnete Datei dient der Befehl:

Datei > Speichern

Alternativ können Sie mit der Maus auf das Symbol  klicken oder die Tastenkombination **Strg+S** benutzen.

3.2.4 Rohdatendatei, Transformationsprogramm und Fertigdatendatei

Möglicherweise haben Sie sich beim Lesen des letzten Abschnitts gefragt, was das **r** im vorgeschlagenen Dateinamen **kfar.sav** bedeuten soll. Bei der Beantwortung dieser Frage sind leider einige Vorgriffe auf spätere Abschnitte nötig. Versuchen wir es trotzdem. Das **r** soll signalisieren, dass in dieser Datei die nach den Vorschriften des Kodierplans erfassten **Rohdaten** stehen. In **kfar.sav** sollen also ausschließlich folgende Arbeitsschritte einfließen:

- Variablendeklaration gemäß Kodierplan
- Datenerfassung gemäß Kodierplan
- Nötigenfalls spätere Korrekturen von Erfassungsfehlern

Damit ist diese Datei für viele im Demoprojekt geplante Auswertungsschritte noch nicht geeignet. Es fehlt z.B. der Optimismustestwert, welcher aus den zwölf LOT-Fragen zu berechnen ist.


Aus der Rohdatendatei werden wir bald eine **Fertigdatendatei** herstellen, in die alle projektweit relevanten Variablenmodifikationen und -neuberechnungen einfließen sollen, so dass sie eine bequeme Datenbasis für alle statistischen und grafischen Analysen darstellt. In fast jedem Forschungsprojekt sind Variablenmodifikationen und -neuberechnungen in erheblichem Umfang erforderlich.

Profis basteln dabei nicht „per Hand“ so lange an der Rohdatendatei herum, bis die Fertigdatendatei entstanden ist, sondern sie erstellen (z.B. durch Konservieren von bearbeiteten Dialogboxen) ein **SPSS-Programm** (siehe unten), das alle Transformationen erledigt und das bei Bedarf wiederholt ausgeführt werden kann.

Die zweistufige Projektdatenverwaltung mit Roh- und Fertigdatendatei verhindert in Kombination mit dem vermittelnden SPSS-Transformationsprogramm, dass bei jeder Änderung der Rohdaten die erwähnten Transformationen zur Fertigdatei wiederholt werden müssen. Solche Änderungen der Rohdaten (z.B. durch Fehlerkorrekturen oder Stichprobenerweiterungen) sind eher die Regel als die Ausnahme.

Weil die Kommandos des Transformationsprogramms auch mit Hilfe von korrespondierenden Dialogboxen erstellt werden können, erfordert die professionelle Vorgehensweise kaum Programmierkenntnisse.

Es wird also folgende Struktur für die Verwaltung der Projektdaten vorgeschlagen:




Die Erläuterungen in diesem Abschnitt werden vermutlich erst dann voll verständlich, wenn Sie sich mit Variablentransformationen und SPSS-Programmen auskennen.

Nach diesem Vorausblick wenden wir uns wieder der aktuellen Aufgabe zu: Wir tragen die erhobenen Daten in die Rohdatendatei **kfar.sav** ein.

3.2.5 Dateneingabe

Wechseln Sie bei Bedarf zur **Datenansicht** des (vermutlich noch einzigen) Dateneditorfensters, und geben Sie die Daten des ersten Falles ein:


- Aktivieren Sie nötigenfalls die Zelle zur ersten Variablen, und tippen Sie den zugehörigen Wert ein.
- Drücken Sie die Tabulatortaste  oder die Taste mit dem Rechtspfeil , um den eingetippten Wert zu quittieren und die Zellenmarkierung um eine Spalte nach *rechts* zu verschieben (zur nächsten Variablen):



Auch die **Enter**-Taste quittiert den eingetippten Wert, bewegt jedoch anschließend die Zellenmarkierung um eine Zeile nach *unten* (zum nächsten Fall), was in unserer jetzigen Lage weniger praktisch ist.

Wenn Sie auf Abwege geraten sind, können Sie die Zellenmarkierung jederzeit per Mausklick neu positionieren.


- Sobald für einen neuen Fall die erste Variablenausprägung eingetragen und quittiert wurde, erhält er für die restlichen Variablen den Initialisierungswert SYSMIS (dargestellt durch einen Punkt).
- Wenn über den Menübefehl **Ansicht > Wertbeschriftungen** oder den Symbolschalter  die Anzeige von Wertbeschriftungen aktiviert worden ist, lässt sich z.B. in der MOTIV1-Zelle ein Drop-Down - Menü zur Unterstützung der Werteingabe öffnen:



So ist eine Datenerfassung ohne Kenntnis der Kodierungsvorschriften möglich, wobei allerdings der Zeitaufwand steigt. Es lohnt sich also, die Kodierungsvorschriften im Kopf

zu haben. Selbstverständlich ist auch bei aktivierter Beschriftungsanzeige die rationelle Werteingabe möglich.

- Tragen Sie die restlichen Werte des ersten Falles ein, jeweils quittiert mit der Tabulator-taste. So sieht der vollständig erfasste erste Fall der Manuskriptstichprobe (vgl. Seite 42) im Datenfenster aus (bei abgeschalteter Beschriftungsanzeige):




- Wenn Sie den Wert der letzten Variablen mit der Tabulatortaste quittieren, setzt SPSS freundlicherweise die Zellenmarkierung gleich in die erste Datenzelle des nächsten Falles, so dass Sie die Dateneingabe unmittelbar fortsetzen können.

3.2.6 Daten korrigieren

3.2.6.1 Wert einer Zelle ändern

Natürlich können die Eintragungen in einer Zelle jederzeit korrigiert werden:

- Wert ersetzen:
 - Zelle markieren
 - neuen Wert eintippen, wobei der alte überschrieben wird
- Wert in der Eingabezone editieren:
 - Zelle markieren
 - Wert in der Eingabezone oberhalb der Datenmatrix editieren



- Wert in der Zelle editieren:
 - Doppelklick auf die Zelle
 - Nun kann der Wert in der Zelle geändert werden.

3.2.6.2 Einen Fall einfügen

Gehen Sie folgendermaßen vor, um einen Fall einzufügen:

- Setzen Sie einen rechten Mausklick auf die (von SPSS gesetzte) Zeilennummer desjenigen Falles, vor dem ein neuer Fall eingefügt werden soll. Daraufhin wird die gesamte angeklickte Zeile markiert, und es erscheint ein Kontextmenü.
- Wählen Sie aus dem Kontextmenü die Option **Fälle einfügen**

Der neue Fall erhält bei allen Variablen den Initialisierungswert SYSMIS.

3.2.6.3 Einen Fall löschen

Gehen Sie folgendermaßen vor, um einen Fall, d.h. eine Zeile der Datenmatrix, komplett zu löschen:

- Setzen Sie einen rechten Mausklick die Zeilennummer des überflüssigen Falles in der Nummerierungsspalte am linken Fensterrand. Daraufhin wird die gesamte angeklickte Zeile markiert, und es erscheint ein Kontextmenü.
- Wählen Sie aus dem Kontextmenü das Item **Löschen**

3.2.6.4 Fälle verschieben

Gehen Sie folgendermaßen vor, um Fälle per Drag & Drop (Ziehen und Ablegen) zu verschieben:

- Markieren Sie die zu verschiebenden Fälle auf Windows-übliche Weise über Mausaktionen in der Nummerierungsspalte am linken Fensterrand, ggf. ergänzt durch die **Strg** - und/oder  - Taste. Lassen Sie anschließend die Maustaste wieder los.
- Klicken Sie in der Nummerierungsspalte erneut auf die zu verschiebende Fallauswahl, und halten Sie dabei die linke Maustaste gedrückt.
- Bewegen Sie bei gedrückter Maustaste den Mauszeiger zum Ziel der Verschiebungsaktion. Der augenblicklich eingestellte Zielort wird von SPSS durch eine rote Linie markiert.
- Wenn Sie die Maustaste loslassen, erscheinen die Fälle am neuen Ort.

3.2.7 Weitere Möglichkeiten des Dateneditors

Über die beschriebenen Methoden hinaus bietet der Dateneditor u.a. die Möglichkeit, beliebige rechteckige Segmente einer Datenmatrix auszuschneiden, zu kopieren und einzufügen (auch zwischen verschiedenen Datenblättern).

Wer derartige, relativ fehleranfällige Umbaumaßnahmen vornimmt, wird gelegentlich von der Möglichkeit profitieren, mit der Tastenkombination **Strg+Z**, über den Symbolschalter  oder mit dem Menübefehl:

Bearbeiten > Rückgängig

die letzte Änderung rückgängig machen zu können.

In Abschnitt 4.7 wird beschrieben, wie man im Datenfenster nach Variablenausprägungen suchen kann.

3.2.8 Übung

Für die Teilnehmer(innen) des realen statistischen Praktikums mit SPSS steht nun die Erfassung der erhobenen Daten an. Geben Sie alle Fälle ein, und sichern Sie (auch zwischendurch) in die zugeordnete Datendatei, z.B. **U:\Eigene Dateien\SPSS\kfar.sav**.

Wer dem Vorschlag aus Abschnitt 1.4.2.4 folgend zur Erfassung der Antworten auf die offene Frage im Fragebogenteil 3b eine dynamische Kategorienliste in Kombination mit einem sparsamen Set aus kategorialen Variablen vorgesehen hat (z.B. METH1 bis METH3), der muss nicht nur mechanisch Daten eintippen, sondern auch gelegentlich mit Kreativität und Ordnungssinn neue Methodenkategorien definieren und dokumentieren. Beim Erfassen der Daten, die in diesem Manuskript analysiert werden, entstand folgende Liste:

Kategorie	Code
Faktorenanalyse	1
Regressionsanalyse	2
Korrelationsanalyse	3
Varianzanalyse	4
Strukturgleichungsanalyse	5
Clusteranalyse	6
Diskriminanzanalyse	7
Logistische Regression	8
Conjoint-Analyse	9

Diese Tabelle vervollständigt unseren Kodierplan (vgl. Abschnitt 1.4.3.5). Es ist empfehlenswert, die Definition der Variablen METH1 bis METH3 durch entsprechende Wertbeschriftungen zu komplettieren (vgl. Abschnitt 3.2.2.3).

4 Univariate Verteilungs- und Fehleranalysen

In diesem Abschnitt werden Sie erfahren, wie schnell und bequem mit SPSS numerische und grafische Verteilungsanalysen durchgeführt werden können. Dabei sind zwei Aufgaben zu erledigen:

- Kontrolle auf irreguläre Werte (z.B. aufgrund von Erfassungsfehlern)
- Inspektion der univariaten Verteilungen
Die univariaten Verteilungen enthalten wichtige Informationen über die Zusammensetzung und das Verhalten der Stichprobe. Im Demonstrationsprojekt sind wir bei einigen Variablen besonders neugierig auf die Verteilungen (z.B. bei AERGO und AERGM).

Eine *Beschränkung* auf univariate Analysen ist allerdings der Regel *nicht* sinnvoll, weil dabei keine Ursachen aufgeklärt oder Prognosemodelle entwickelt werden können. Dazu sind multivariate Zusammenhangsanalysen erforderlich.

Auch bei univariaten Analysen greift die pure Deskription zu kurz, weil man in der Regel Informationen über die *Population* gewinnen möchte, aus der die Stichprobe stammt. So muss etwa die Wahlforschung zu den geschätzten Stimmanteilen der Parteien in der Regel auch Vertrauensintervalle liefern, also Inferenzstatistik betreiben.

4.1 Fehlerhafte Werte aufspüren

Speziell bei der manuellen Datenerfassung sind Fehler praktisch unvermeidbar. Aber auch bei automatisierten Verfahren sind fehlerhafte Werte möglich. So liefert z.B. das in Abschnitt 3.1.1 vorgestellte Online-Umfrage-System, EFS Survey bei einer Einfachwahlfrage mit regulären Werten von 1 bis 5 den Exportwert 0, wenn eine Person zur Umfrageseite mit der Frage gelangt ist, aber die Frage nicht beantwortet hat. Anders als der Wert -77, den eine Person erhält, welche die betroffene Umfrageseite nie gesehen hat (z.B. wegen Abbruch oder Filterführung), wird der Wert 0 in der von EFS Survey gelieferten SPSS-Datendatei *nicht* als Indikator für fehlende Werte deklariert.

Manche Fehler sind als Verstöße gegen Gültigkeitsregeln relativ leicht aufzuspüren:

Beispiel: Wenn bei der Variablen GESCHL nur die Werte 1 (für Frauen), 2 (für Männer) und 8 (Keine Angabe) erlaubt sind, dann ist z.B. der Wert 3 sofort als Fehler zu erkennen.

Von den *logisch* unmöglichen Werten (z.B. Geschlecht = 3) kann man noch die *empirisch* unmöglichen unterscheiden (z.B. Alter über 120 Jahre). Wie die von einem irregulären Wert betroffenen Fälle zu identifizieren sind, ist in Abschnitt 4.7 zu erfahren.

Weit schwieriger zu entdecken sind Fehler, die keine allgemeine Gültigkeitsregel verletzen:

Beispiel: Wenn unter der oben angegebenen GESCHL-Kodierungsvorschrift für den Untersuchungsteilnehmer Kurt Müller versehentlich der Wert 1 eingegeben wurde, dann kann dieser Fehler nur gefunden werden, wenn ...

- schriftliche oder sonstige Untersuchungsdokumente vorhanden sind
- und aufwändige Handarbeit investiert wird.

Welcher Aufwand bei der Datenprüfung erforderlich bzw. sinnvoll ist, hängt von der verwendeten Erhebungs- bzw. Erfassungsmethode (und damit von der Fehlerwahrscheinlichkeit) sowie von der Stichprobengröße ab.

Entdeckte Fehler sind nach Möglichkeit (z.B. aufgrund von schriftlichen Untersuchungsdokumenten) zu korrigieren. Ist dies nicht möglich, bestehen folgende Optionen:

- Den fehlerhaften Wert als MD-Indikator deklarieren (siehe Abschnitt 3.2.2.2).
- Den fehlerhaften Wert durch einen MD-Indikator ersetzen, z.B. durch Löschen auf SYSMIS setzen.

Bei einem Fall mit zahlreichen fehlerhaften und/oder fehlenden Werten kommt auch das komplette Löschen des Falles in Betracht.

Weitere Details zu Ursachen und Behandlungsmethoden für fehlerhafte Daten finden sich bei Lück (2011, S. 66ff).

Im Zusammenhang mit der Fehlerbereinigung soll noch das SPSS-Modul *Data Preparation* erwähnt werden, das die routinemäßige Untersuchung von strukturgleichen Datendateien durch passend definierbare Regeln unterstützt (siehe Handbuch IBM Corp. 2013a und Menübefehl **Daten > Validierung**). Im Vergleich zum anschließend vorgestellten Verfahren, die Suche nach unzulässigen Werten parallel zur univariaten Verteilungsanalyse zu betreiben, erlauben die Prozeduren im Modul *Data Preparation* eine schnellere Identifikation von Fällen mit unzulässigen Werten. Die Definition eines entsprechenden Regelpakets lohnt sich z.B. dann, wenn in einer Forschungseinrichtung oder Firma regelmäßig Datendateien mit identischen Variablen eintreffen, die einer Qualitätskontrolle unterzogen werden müssen.

4.1.1 Suche nach unzulässigen Werten

Über ein Online-Werkzeug erfasste Daten sind bei einer sorgfältig konfigurierten Eingangskontrolle frei von unzulässigen Werten.¹ Auch bei der manuellen Dateneingabe mit einem spezialisierten Erfassungsprogramm (vgl. Abschnitt 3.1.2) lassen sich durch sorgfältige Konfiguration unzulässige Werte von der Datendatei fern halten.

Bei der manuellen Erfassung mit dem SPSS-Dateneditor findet eine derartige Eingangskontrolle *nicht* statt. Das Definieren von Wertbeschriftungen hat zwar nützliche Effekte auf Tabellen und auf das Verhalten von einigen Dialogboxen bzw. Assistenten in SPSS (z.B. bei der Diagrammerstellung), man kann auf diese Weise aber *nicht* die Menge der zulässigen Werte definieren. Eine per Dateneditor erfasste Datendatei muss daher systematisch nach Werten außerhalb der zulässigen Bereiche durchsucht werden. Dies kann allerdings ohne großen Zusatzaufwand im Rahmen der aus wissenschaftlichen Gründen ohnehin erforderlichen univariaten Verteilungsanalyse geschehen.

Gelegentlich ist eine *bivariate* Verteilungsanalyse erforderlich, um unzulässige, d.h. aus logischen oder empirischen Gründen unmögliche, Werte zu identifizieren. So sind z.B. Studierende im 17. Semester oder mit einem Alter von 19 Jahren nicht ungewöhnlich, doch wäre eine Kombination der beiden Merkmalsausprägungen eindeutig als irregulär zu erkennen. Wir werden im Kurs nicht systematisch mit bivariaten oder noch komplexeren Techniken auf Fehlersuche gehen. Wenn jedoch z.B. ein bivariates Streudiagramm zur grafischen Analyse bzw. Präsentation von Daten zum Einsatz kommt (vgl. Kapitel 11), sollten irreguläre Wertekombinationen einem wachsamem Auge nicht entgehen.

¹ Allerdings fehlen in einer so entstandenen Datendatei eventuell auch einige Basketballspieler, die empört die Studienteilnahme angebrochen haben, nachdem ihre Körpergröße von z.B. 235 cm als unzulässig abgelehnt wurde. Bei Plausibilitätskontrollen in Online-Erfassungswerkzeugen darf man also nicht zu kleinlich sein.

4.1.2 Einzelprüfung aller Werte

Fehler, die gegen keine Gültigkeitsregel verstoßen, lassen sich nur mit Fleißarbeit entdecken, wobei z.B. die erfassten Daten Wert für Wert mit schriftlichen Unterlagen zu vergleichen sind.

Eine aufwendige Prüfmethode ist *bei kleinen Stichproben* durchaus empfehlenswert, denn:

- Erfassungsfehler wirken sich hier besonders stark aus.
- Der Zeitaufwand ist erträglich.

Wir wollen exemplarisch den Effekt von Erfassungsfehlern auf die Varianz (Unsicherheit) eines Stichprobenmittelwerts als Schätzer für den zugehörigen Populationserwartungswert untersuchen. Für n erfasste Werte X_i ($i = 1, \dots, n$) nehmen wir an, dass sie jeweils mit einem Erfassungsfehler F_i belastet sind, wobei die Erfassungsfehler den Erwartungswert Null haben sowie untereinander und von den korrekten Beobachtungswerten T_i unabhängig sein sollen:

$$X_i = T_i + F_i, \quad E(F_i) = 0, \quad E(X_i) = E(T_i) = \mu$$

$$\text{Var}(T_i) = \sigma^2, \quad \text{Var}(F_i) = \sigma_F^2$$

Der Stichprobenmittelwert $\bar{X}$ aus den fehlerhaft erfassten Werten hat denselben Erwartungswert μ wie der Stichprobenmittelwert $\bar{T}$ aus den fehlerfrei erfassten Werten.

Für die Varianz von $\bar{T}$ gilt:

$$\text{Var}(\bar{T}) = \text{Var}\left(\frac{1}{n} \sum_{i=1}^n T_i\right) = \frac{1}{n^2} \sum_{i=1}^n \text{Var}(T_i) = \frac{1}{n^2} n \sigma^2 = \frac{\sigma^2}{n}$$

Für die Varianz von $\bar{X}$ erhalten wir:

$$\text{Var}(\bar{X}) = \text{Var}\left(\frac{1}{n} \sum_{i=1}^n (T_i + F_i)\right) = \frac{1}{n^2} \sum_{i=1}^n (\text{Var}(T_i) + \text{Var}(F_i)) = \frac{1}{n^2} n (\sigma^2 + \sigma_F^2) = \frac{\sigma^2}{n} + \frac{\sigma_F^2}{n}$$

Offenbar hängt der Präzisionsverlust im Stichprobenmittelwert, der als Schätzwert für den Erwartungswert der Population dient, von der Erfassungsfehlervarianz σ_F^2 und der Stichprobengröße n ab. Während sich in einer großen Stichprobe der niedrige Ausgangswert $\frac{\sigma^2}{n}$ der Unsicherheit nur unwesentlich erhöht, kommt es in einer kleinen Stichprobe mit ihrem bereits ungünstigen Ausgangsniveau zu einem erheblichen Präzisionsverlust. Als unerwünschte Folgen stellen sich ein:

- Ungenaue Schätzung des Erwartungswerts
- Reduzierte Power bei Hypothesentests über den Erwartungswert

Wir werden im Demonstrationsprojekt die Differenzvariable (AERGM – AERGO) betrachten, um den Effekt von kontrafaktischen Alternativen auf den erlebten Ärger zu untersuchen. Erfassungsfehler können den Stichprobenmittelwert dieser Variablen und damit den KFA-Effekt verfälschten. Außerdem leidet die Power des Tests zur KFA-Hypothese.

Obwohl bei unserer kleinen Stichprobe eine Einzelprüfung aller Werte angemessen wäre, verzichten wir aus Zeitgründen darauf. Es gehört übrigens zu den lehrreichen Erfahrungen im statistischen Praktikum mit SPSS, dass die selbständig als Untersuchungsleiter agierenden Kursteilnehmer aus Kopien desselben Fragebogenstapels aufgrund individueller Erfassungsfehler recht unterschiedliche Ergebnisse ermitteln (auch bei den zentralen Hypothesentests).

4.2 Öffnen von Datendateien

Vermutlich haben Sie nach der anstrengenden Datenerfassung eine Pause eingelegt und SPSS verlassen, so dass wir jetzt offiziell das Öffnen einer Datendatei üben können.

4.2.1 SPSS-Datendateien

Starten Sie SPSS, und öffnen Sie Ihre vorhandene Rohdatendatei **kfar.sav** entweder mit Hilfe des Begrüßungsdialogs oder über den Menübefehl

Datei > Zuletzt verwendete Daten

Während die bisher beschriebenen Verfahren auf dem Erinnerungsvermögen von SPSS basieren, klappt der folgende Menübefehl generell:

Datei > Öffnen > Daten

Ist eine SPSS-Datendatei in einem geöffneten Fenster des Windows-Explorers für Mausektionen zugänglich, dann stehen weitere Techniken zum Öffnen zur Verfügung:

- Doppelklick
- Drag & Drop: Ziehen und auf einem beliebigen SPSS-Fenster fallen lassen

Beim Öffnen einer Datendatei legt SPSS ein neues Datenblatt an und kopiert die eingelesenen Daten samt Variablendeklarationen dorthin. Alle Veränderungen, die Sie in der Datenmatrix oder im Deklarationsteil vornehmen, wirken sich zunächst nur auf das temporäre Datenblatt aus. Gegebenenfalls müssen Sie also diese Änderungen über den Menübefehl

Datei > Speichern

in die permanente SPSS-Datendatei übernehmen.

4.2.2 Andere Formate

Auch bei Datendateien in Fremdformaten, stellt das Einlesen durch SPSS selten ein Problem dar:

- SPSS unterstützt beim Datenimport zahlreiche Formate (z.B. Textdateien, Microsoft Excel, SAS, Stata). Das Einlesen von Textdateien wird in Kapitel 16 beschrieben.
- Auf den Pool-PCs der Universität Trier steht mit dem Programm **StatTransfer** ein Konvertierungsspezialist zur Verfügung, der Dateien gängiger Datenbanken oder Statistikprogramme in das SPSS-Format übersetzen kann. Im Startmenü ist das Programm so zu finden:

Start > Alle Programme > Wissenschaftliche Programme > StatTransfer

SPSS übernimmt die eingelesenen Daten in ein neues Datenblatt. Bei Bedarf können Sie anschließend Variablendeklarationen vornehmen (vgl. Abschnitt 3.2.2) und das Ergebnis mit dem Menübefehl

Datei > Speichern

in eine neue SPSS-Datendatei sichern.


4.3 Verteilungsanalysen für kategoriale Variablen

Da wir unsere Daten mit dem SPSS-Dateneditor erfasst haben, der keine Plausibilitätskontrolle bei der Eingabe vornimmt, müssen wir nach den Überlegungen aus Abschnitt 4.1 systematisch nach unzulässigen Werten suchen. Dies kann ohne nennenswerten Zusatzaufwand im Rahmen der univariaten Verteilungsanalysen geschehen, die wir aus Gründen der wissenschaftlichen Sorgfalt und Neugier routinemäßig durchführen.

Wir untersuchen zunächst die Verteilungen der nominalskalierten Variablen GESCHL und FB mit Hilfe von Häufigkeitstabellen und Balkendiagrammen. Mit dem Menübefehl


Analysieren > Deskriptive Statistiken > Häufigkeiten...

erhalten wir die folgende Dialogbox zur Anforderung von Häufigkeitsanalysen:




Zur bequemen Spezifikation der im aktuellen Prozeduraufruf zu analysierenden Variablen dienen die beiden Variablen-Auswahlbereiche. Links stehen alle Variablen der Arbeitsdatei, die derzeit *nicht* für die Analyse ausgewählt sind (*Anwärterliste*). Rechts daneben, unter dem Etikett **Variable(n)**, stehen die Ausgewählten (*Teilnehmerliste*). Dazwischen befindet sich ein Transportschalter , mit dem sich links markierte Variablen nach rechts und rechts markierte Variablen nach links verschieben lassen. Selbstverständlich ist es möglich, in eine Häufigkeitsanalyse zwei oder mehr Variablen einzubeziehen, wobei alle Variablen (unabhängig vom deklarierten Messniveau) identisch behandelt werden.


Alle SPSS-Dialogboxen lassen sich in der Größe verändern, wobei der verfügbare Platz auf die Bedienelemente dynamisch aufgeteilt wird. Daher kann man im konkreten Beispiel für die komplette Anzeige der Variablenbeschriftungen und der dahinter (zwischen eckigen Klammern) folgenden Variablenamen sorgen:



Markieren Sie in der Anwrterliste (links) die Variablen GESCHL und FB, und befrdern Sie diese per Mausklick auf den Transportschalter  in die Teilnehmerliste (rechts):




Statt den Schalter  zu benutzen, knnen Sie in SPSS solche Transportaufgaben auch per Drag & Drop (Ziehen und Ablegen) erledigen:



Bei einer lngeren Liste ist es sehr hilfreich, dass SPSS beim Eintippen einer Variablenbezeichnung das nchste kompatible Listenelement markiert, wobei der Name oder die Variablenbeschriftung (falls vorhanden) einzugeben ist.

Begeben Sie sich anschlieend in den Subdialog **Diagramme**, indem Sie einen Mausklick auf den gleichnamigen Schalter setzen. Whlen Sie im Rahmen **Diagrammtyp** die fr nominalskalierte Merkmale angemessene Option **Balkendiagramme**:



Wer Erläuterungen zu den verfügbaren Diagrammtypen wünscht, kann diese per Mausklick auf den Schalter **Hilfe** anfordern.

Quittieren Sie die Subdialogbox **Diagramme** mit **Weiter** und die Hauptdialogbox mit **OK**. Daraufhin präsentiert SPSS die Ergebnisse im Ausgabefenster (**IBM SPSS Statistics Viewer** betitelt), das sich in den Vordergrund drängt.

Wir erfahren in der ersten Tabelle, dass bei den untersuchten Variablen alle Werte vorhanden waren:

Statistiken			
		Geschlecht	Fachbereich
N	Gültig	31	31
	Fehlend	0	0


Bei Anforderung einer Häufigkeitsanalyse produziert SPSS per Voreinstellung eine Tabelle, die für jeden aufgetretenen Wert eine Zeile mit folgenden Angaben enthält:

- Absolute Häufigkeit
- Prozentualer Anteil vom Stichprobenumfang
- Prozentualer Anteil an den validen Werten (ohne MD-deklarierte Werte)
- kumulativer valider Prozentanteil (Anteil valider Werte, die nicht größer sind)

Für GESCHL erhalten wir diese Häufigkeitstabelle:

Geschlecht					
		Häufigkeit	Prozent	Gültige Prozente	Kumulierte Prozente
Gültig	Frau	25	80,6	80,6	80,6
	Mann	6	19,4	19,4	100,0
	Gesamt	31	100,0	100,0	

und das folgende Balkendiagramm:




Zunächst beobachten wir, dass bei der Variablen GESCHL kein unzulässiger Wert vorliegt.

Bei der Geschlechtsverteilung stellen wir einen sehr hohen Frauenanteil fest ($\hat{p} = 0,81$), der als wesentliches Merkmal unserer Stichprobe berichtet werden muss. Bei potentiell geschlechtsabhängigen Ergebnissen müssen wir besonders vorsichtig interpretieren bzw. generalisieren.

Das Vertrauensintervall zu einer Proportion kann die SPSS-Prozedur zur Häufigkeitsanalyse leider *nicht* liefern. Wie es trotzdem mit SPSS zu ermitteln ist, erfahren Sie in Abschnitt 4.8.

Erste Hinweise zur möglichen Ursache der hohen Frauenquote in der Manuskriptstichprobe liefert die empirische Verteilung der Fachbereichs-Variablen:


Fachbereich				
		Häufigkeit	Prozent	Gültige Prozente
Gültig	I	19	61,3	61,3
	III	2	6,5	6,5
	IV	6	19,4	19,4
	VI	4	12,9	12,9
	Gesamt	31	100,0	100,0



Wir sehen, dass im SPSS-Kurs, der die Manuskriptdaten geliefert hat, der Fachbereich I sehr stark vertreten war, was mit dem Kurstermin zusammenhängen mag. Im Fachbereich I der Universität Trier (Fächer: Philosophie, Pädagogik, Psychologie) ist der Frauenanteil relativ hoch (vgl. Abschnitt 13.2).

Ein Balkendiagramm zeigt für jeden aufgetretenen Wert seine absolute oder relative Häufigkeit durch einen Balken entsprechender Höhe. Man kann die Balkenhöhen, also die (relativen) Häufigkeiten der Werte, gut miteinander vergleichen, während der Vergleich mit dem Ganzen (alle Balken übereinander gestapelt) weniger gut gelingt.

Der Kreis ist wohl das ideale Sinnbild für das Ganze, und dementsprechend lässt sich die Zerlegung (Verteilung) des Ganzen auf die Werte einer Variablen sehr gut durch Kreissegmente mit passendem Winkel veranschaulichen, z.B. bei der Variablen FB:




Für den Wert i mit der absoluten Häufigkeit h_i wird der Winkel w_i so ermittelt, dass gilt:

$$\frac{h_i}{n} = \frac{w_i}{360}$$

Man kann für jeden Wert seinen Anteil gut beurteilen, während der Vergleich mit anderen, nicht direkt benachbarten Werten gelegentlich schwer fällt.

Um die Balkendiagramme durch Kreisdiagramme zu ersetzen, müssen Sie lediglich Ihre Wahl im Subdialog **Diagramme** ändern:




Der aktuelle Abschnitt sollte nur einen ersten Eindruck von den Grafikmöglichkeiten des SPSS-Systems vermitteln. Wir haben eine integrierte Option der Dialogbox zur Häufigkeitsanalyse benutzt und auf eine Nachbearbeitung per Diagramm-Editor verzichtet (siehe Abschnitt 11.2). Die meisten grafischen Darstellungsmöglichkeiten bietet SPSS über das Hauptmenü **Grafik** an, mit dem wir uns später befassen werden (siehe Kapitel 11).

Die obigen SPSS-Ausgaben wurden übrigens über die Windows-Zwischenablage in das Textverarbeitungsprogramm Microsoft Word übertragen. Mit dieser Form des Datenaustauschs und mit anderen Optionen beim Arbeiten mit dem Ausgabefenster beschäftigen wir uns im nächsten Abschnitt.

4.4 Arbeiten mit dem Ausgabefenster (Teil I)

In seiner voreingestellten Variante ist das SPSS-Ausgabefenster, das auch als **Viewer** bezeichnet wird, zweigeteilt in den Navigationsbereich (die Gliederungsansicht) am linken Rand und den Inhaltsbereich:



So wird ein schnelles Navigieren zwischen den verschiedenen Ausgabebestandteilen ermöglicht.

Um die Platzverteilung auf die beiden Viewer-Segmente zu ändern, klickt man auf die Trennlinie und verschiebt sie bei gedrückter Maustaste.

Wesentliche Bestandteile des Inhaltsbereichs sind Tabellen und Diagramme. Zu ihrer Nachbearbeitung steht jeweils ein spezieller Editor zur Verfügung, der per Doppelklick auf ein Objekt gestartet wird. Außerdem können in einem Viewer-Dokument noch SPSS-Kommandos, Textausgaben, Warnungen, Anmerkungen und Titelzeilen auftreten.

4.4.1 Arbeiten im Navigationsbereich

Die meisten der anschließend beschriebenen Aktionen im Navigationsbereich wirken sich synchron auch auf den Inhaltsbereich aus.

4.4.1.1 Fokus positionieren


Ein kleiner roter Pfeil zeigt im Gliederungsbereich auf die Bezeichnung derjenigen Ausgabe, die gerade im Inhaltsbereich privilegiert dargestellt wird. Per Mausklick auf eine andere Ausgabenbeschriftung kann dieser Fokus verschoben werden.

4.4.1.2 Ausgabeblöcke bzw. Teilausgaben aus- oder einblenden

Ein *Block* mit zusammengehörigen Ausgaben (in der Regel entstanden aus einer Analyseanforderung) wird ...


- ausgeblendet: per Mausklick auf das Minus-Zeichen neben dem Symbol  für einen expandierten Block oder per Doppelklick auf das Block-Symbol.

Beispiel:



- eingeblendet: per Mausklick auf das Plus-Zeichen neben Symbol  für einen reduzierten Block oder per Doppelklick auf das Block-Symbol.

Beispiel:



Eine *Teilausgabe* innerhalb eines Blocks wird per Doppelklick auf das zugehörige Buchsymbol aus- bzw. eingeblendet. Das Buchsymbol erscheint dementsprechend zugeklappt (im Beispiel: **Hinweise**) oder aufgeklappt (im Beispiel: **Statistiken**).

4.4.1.3 Ausgabeblöcke oder Teilausgaben markieren

Im Navigationsbereich kann man Ausgabeblöcke und/oder Teilausgaben (z.B. zum anschließenden Löschen) so markieren:

- Einen Ausgabeblock: Per Mausklick auf das Blocksymbol
- Eine Teilausgabe: Per Mausklick auf das Buchsymbol
- Mehrere Blöcke bzw. Teile: Durch Mausklicks in Kombination mit der  - bzw. **Strg** - Taste

4.4.1.4 Ausgabeblöcke oder Teilausgaben löschen oder verschieben

Markierte Blöcke bzw. Teilausgaben kann man ...


- löschen: mit der **Entf**-Taste oder mit dem Menübefehl **Bearbeiten > Löschen**
- per Maus verschieben: Ziehen und Ablegen

4.4.2 Viewer-Dokumente drucken

Über den Menübefehl

Datei > Drucken

können Sie alle angezeigten oder alle markierten Ausgabebestandteile drucken, z.B.:



4.4.3 Ausgaben sichern und öffnen

Zum Speichern eines Viewer-Dokuments dienen die Menübefehle

Datei > Speichern unter bzw. **Datei > Speichern**

Dabei entstehen Viewer-Dateien, die üblicherweise die Namensendung **.spv** erhalten. SPSS-Ausgaben sollten z.B. dann in elektronischer Form gespeichert werden, wenn sie (auszugsweise) in Dokumente anderer Programme eingegangen sind. Mit SPSS ist eine nachträgliche Modifikation der Ausgaben leicht möglich, mit den Fremdprogrammen aber kaum.

Das Öffnen eines Viewer-Dokuments gelingt per Menübefehl

Datei > Öffnen > Ausgabe bzw. **Datei > Zuletzt geöffnete Dateien**

oder durch eine Mausektion (Doppelklick bzw. Drag & Drop)

4.4.4 Objekte via Zwischenablage in andere Anwendungen übertragen

Mit der Tastenkombination **Strg+C**, mit dem Kontextmenü-Item **Kopieren** oder mit dem Menübefehl

Bearbeiten > Kopieren

fordert man SPSS auf, die markierten Ausgabeobjekte (z.B. Tabellen und/oder Diagramme) in die Windows-Zwischenablage zu befördern. Per Voreinstellung wird dabei allerdings die Fähigkeit von SPSS, Tabellen und Diagramme in verschiedenen Formaten in die Zwischenablage zu kopieren, nicht vollständig ausgenutzt:

- Diagramme werden nur als Bitmap (PNG, JPG) abgelegt, so dass im Zielprogramm nur eine Bitmap (Pixelgrafik) ankommt. Spätestens nach einer Größenänderung im Zielprogramm ist die Qualität suboptimal.
- Bei Tabellen bleiben die Optionen Vektorgrafik (WMF, EMF) und Bitmap (PNG, JPG) ungenutzt.

Wählen Sie daher einmalig beim Zwischenablagentransfer aus dem Kontextmenü zum Quellobjekt oder aus dem **Bearbeiten**-Menü das Item **Kopieren Spezial**. In der nun auftauchenden Dialogbox



sollten Sie *alle* Optionen in der Liste der zu **kopierenden Formate** markieren und diesen Wunschzettel **als Standard speichern**. Durch Quittieren mit **OK** werden alle Formate in die Zwischenablage kopiert. Ab der nächsten SPSS-Sitzung (also noch nicht in der aktuellen Sitzung) kann der Komplet-Transfer auch über die Tastenkombination **Strg+C** oder den Menübefehl **Bearbeiten > Kopieren** veranlasst werden.

Sind Sie beim Einfügen eines SPSS-Objekts mit dem vom Zielprogramm bevorzugten Format zufrieden, taugt bei traditioneller Menübedienung der Befehl

Bearbeiten > Einfügen


Bei Microsoft Word® ab Version 2007 ist aus dem **Start**-Menüband das **Einfügen**-Symbol zu verwenden (siehe Abbildung unten). Mit der Tastenkombination **Strg+V** sollte es bei allen Programmen klappen.

Word bevorzugt in der Rolle als Zielprogramm von einer SPSS-Tabelle in der Windows-Zwischenablage das RTF-Format, so dass man schließlich eine Word-Tabelle erhält, die sich uneingeschränkt mit Word-Techniken editieren lässt.


Befindet sich eine SPSS-Tabelle oder -Grafik in verschiedenen Formaten in der Windows-Zwischenablage, kann es sinnvoll sein, auf das vom Zielprogramm entnommene Format Einfluss zu nehmen, was traditionell über den Menübefehl

Bearbeiten > Inhalte Einfügen

möglich ist und auch bei modernen Programmen mit Menüband-Bedienung gelingt:



Wenn Sie beim Einfügen eines *Diagramms* das Format **Bild (Erweiterte Metadatei)** wählen, erhalten Sie in der Ziellanwendung eine Vektorgrafik, die im Vergleich zur voreingestellten Bitmap-Grafik eine bessere Qualität (Schärfe) besitzt:



Zudem hat eine Vektorgrafik den Vorteil, dass ihre Qualität bei einer Größenänderung unverändert bleibt, während eine Bitmap-Grafik speziell bei einer Vergrößerung deutlich an Qualität verliert.


Wenn Sie beim Einfügen einer Tabelle das Format **Bild (Erweiterte Metadatei)** wählen, erhalten Sie in der Zielanwendung ein Grafikimplantat mit dem Original-Design aus dem SPSS-Viewer.

4.4.5 Ausgaben exportieren


Über den Menübefehl

Datei > Exportieren...

lassen sich Ausgabebestandteile (alle, die sichtbaren oder die ausgewählten) in diversen Formaten exportieren (z.B. HTML, PDF, Microsoft Word®, Microsoft PowerPoint®, Text). Mit folgender Dialogbox wird z.B. das gesamte Viewer-Dokument im PDF-Format exportiert:



Aus den Elementen der Viewer-Gliederungsansicht entstehen PDF-Lesezeichen:




4.4.6 Mehrere Ausgabefenster verwenden

Bislang war immer von *dem* Ausgabefenster die Rede. Im Verlauf einer längeren Auswertungsarbeit kann es aber der Übersichtlichkeit dienen, zusätzliche Ausgabefenster anzufordern. Dazu taugt der Menübefehl:

Datei > Neu > Ausgabe

Sind mehrere Ausgabefenster vorhanden, muss geregelt sein, in welchem Fenster zukünftige Ausgaben landen sollen. Daher ist stets ein *Hauptausgabefenster* festgelegt. Es ist an einem Pluszeichen im Symbol zum Systemmenü  (siehe linken Rand der Titelzeile) sowie an einem *passiven* Hauptfenster-Schalter  in seiner Symbolleiste zu erkennen, z.B.:



Dieser Schalter dient nämlich im aktiven Zustand  dazu, ein Ausgabefenster zum *Hauptausgabefenster* zu ernennen.

Um ein bestimmtes Ausgabefenster in den Vordergrund zu holen, können Sie es anklicken oder über das **Fenster**-Menü eines beliebigen SPSS-Fensters auswählen. Jedes Ausgabefenster kann auf Windows-übliche Weise geschlossen werden, z.B. über den Menübefehl:

Datei > Schließen

4.4.7 Übung

- 1) Markieren Sie im Viewer-Fenster den zuerst angeforderten Ausgabeblock (Häufigkeitsanalysen für GESCHL und FB mit Balkendiagrammen), und löschen Sie ihn per **Entf**-Taste.
- 2) Öffnen Sie erneut die Dialogbox zur Häufigkeitsanalyse. Statt den zugehörigen Menübefehl zu wiederholen, können Sie mit dem Symbol  eine Liste der zuletzt benutzten Dialogboxen aufrufen und daraus per Mausklick den Eintrag **Häufigkeiten** wählen. Die Dialogbox ist noch im selben Zustand, den Sie eben verlassen haben. Dies gilt generell in SPSS, so dass Sie bei der sukzessiven Modifikation einer Anforderung innerhalb einer Sitzung jeweils auf dem letzten Stand weitermachen können. SPSS verwaltet ggf. sogar für mehrere Datenblätter jeweils eine eigene Liste mit Dialogfeldkonfigurationen.
- 3) Wählen Sie in der Subdialogbox **Diagramme** durch **Prozentwerte** beschriftete Balkendiagramme.

4.5 Verteilungsanalysen für metrische Merkmale

Bei metrischen Merkmalen mit hoher Messgenauigkeit und annähernd stetiger Verteilung treten in der Stichprobe zahlreiche verschiedene Werte auf, und eine Häufigkeitstabelle ist zur Beschreibung der Verteilung wenig geeignet. Im Extremfall haben alle aufgetretenen Werte die Häufigkeit 1, sodass eine sehr unhandliche Tabelle entsteht. Allerdings kann ein metrisches Merkmal auch eine *diskrete* Verteilung mit relativ wenigen Werten besitzen, so dass eine Häufigkeitstabelle angemessen ist. Das passiert insbesondere bei *Zählvariablen* (z.B. Anzahl der im letzten Jahr gelesenen Bücher, Anzahl der Punkte in der Flensburger Verkehrssünderkartei).¹


Durch statistische Kennwerte für die zentrale Tendenz, die Dispersion und die Gestalt können bei metrischen Merkmalen die wichtigsten Aspekte der Verteilung kompakt beschrieben werden.

Zur grafischen Darstellung verwendet man bei approximativ stetiger Verteilung ein Histogramm, das für Intervalle geeigneter Breite die Häufigkeit durch einen Balken darstellt, wobei die Balken lückenlos aneinander grenzen. Ist ein metrisches Merkmal diskret verteilt, kommt eher ein Balkendiagramm in Frage, das für jeden aufgetretenen Wert seine Häufigkeit durch einen Balken darstellt.


Um die oben beschriebene Prozedur für univariate Verteilungsanalysen davon abzuhalten, (über- große) Häufigkeitstabellen zu erstellen, haben Sie zwei Möglichkeiten:

- Entfernen Sie die per Voreinstellung vorhandene Markierung des für Häufigkeitstabellen zuständigen Kontrollkästchens in der Dialogbox **Häufigkeiten**:

¹ Für kontinuierliche Variablen konstruierte Analyseverfahren arbeiten auch mit diskret verteilten Variablen akzeptabel, wenn die Anzahl der verschiedenen Werte nicht zu klein (< 5) und die Verteilung nicht zu schief ist. Man sollte Modelle, die normalverteilte Residuen benötigen, aber nicht überstrapazieren, sondern ggf. auf generalisierte lineare Modelle ausweichen (siehe Baltes-Götz 2015).



- Im Subdialog **Format** lassen sich Häufigkeitstabellen unterdrücken, die eine vorgegebene Anzahl unterschiedlicher Werte überschreiten:



4.5.1 Lagemaße

Ein Maß für die Lage (die zentrale Tendenz) einer Verteilung soll die *typische Ausprägung* angeben. Die SPSS-Prozedur zur Häufigkeitsanalyse kann folgende Lagemaße berechnen:

- **Modus**
Den Wert mit der größten Häufigkeit zu bestimmen, ist bei jedem Messniveau möglich und besonders informativ bei Variablen mit relativ wenigen verschiedenen Werten. Tritt die maximale Häufigkeit bei *mehreren* Werten auf, nennt SPSS den kleinsten Wert aus dieser Menge.
- **Median**
Wenn ein Merkmal mindestens ordinales Messniveau besitzt, kann der als *Median* bezeichnete Wert bestimmt werden, der 50% der Fälle links von sich lässt, den also 50% der Beobachtungswerte *nicht* übertreffen. Alternative Bezeichnungen sind:
 - 50. Perzentil (P_{50})
 - 2. Quartil (Q_2)

Wenn mit

$$X_{(1)}, X_{(2)}, X_{(3)}, \dots, X_{(n)}$$

die geordneten X -Beobachtungswerte in einer Stichprobe mit dem Umfang n bezeichnet werden, dann kann die Stichprobenschätzung des Medians so definiert werden:

$$md := \begin{cases} X_{((n+1)/2)} & \text{für ungerades } n \\ \frac{X_{(n/2)} + X_{(n/2+1)}}{2} & \text{für gerades } n \end{cases}$$

Während der Median (das zweite Quartil) 50% aller Fälle links von sich lässt, sind es beim ersten bzw. beim dritten Quartil 25% bzw. 75%. Zur Schätzung der beiden anderen Quartile wird eine analoge Formel benutzt. Wenn die Beobachtungswerte als Intervallmitten zu interpretieren sind (gruppierte Daten), dann ist eine aufwändigere Berechnung des Medians anzuwenden (siehe Abschnitt 4.5.5).

- **Mittelwert**

Das arithmetische Mittel mit der Definition

$$\bar{x} := \frac{1}{n} \sum_{i=1}^n x_i$$

ist der beste Schätzer für den Erwartungswert der Verteilung, sofern keine irregulären Daten (Ausreißer) vorliegen.

Bei einer schiefen (asymmetrischen) oder durch Ausreißer belasteten Verteilung eines metrischen Merkmals ist der Median als Maß der zentralen Tendenz besser geeignet als der Mittelwert. Bei einer symmetrischen Verteilung sind Median und Mittelwert identisch.

Einsatzempfehlungen für die Lagemaße:

- Bei nominalskalierten Merkmalen kommt nur der Modus in Frage.
- Bei ordinalskalierten Merkmalen sind Median und Modus möglich, wobei der Median zu bevorzugen ist.
- Bei metrischen Merkmalen mit annähernd symmetrischer Verteilung ist der Mittelwert als Maß der zentralen Tendenz zu bevorzugen.
- Bei metrischen Merkmalen mit asymmetrischer Verteilung sollte man Mittelwert *und* Median bestimmen.

Beim Mittelwert und beim Median sind auch die *Vertrauensintervalle* von Interesse, die leider von der SPSS-Prozedur zur Häufigkeitsanalyse *nicht* geliefert werden. In Kapitel 8 lernen Sie eine SPSS-Prozedur kennen, die auf eine Verteilungsanalyse bei *metrischen* Variablen spezialisiert ist und auch das Vertrauensintervall für den Mittelwert anbietet (siehe Abschnitt 8.6.1). Per Bootstrapping kann auch für den Median ein Vertrauensintervall bestimmt werden (siehe Abschnitt 8.6.2).

4.5.2 Streuungsmaße

Um das Streuungsverhalten eines *metrischen* Merkmals zu quantifizieren, kommen folgende Statistiken in Frage:

- **Spannweite**

Dies ist schlicht die Differenz zwischen dem größten und kleinsten Wert in der Stichprobe. Weil nur wenig Information eingeht, ist die Spannweite selten ein gutes Streuungsmaß.

- **Varianz**

Auf der Populationsebene ist die Varianz einer Variablen X definiert durch die erwartete quadrierte Abweichung vom Erwartungswert $E(X)$:

$$\text{Var}(X) := E[(X - E(X))^2]$$

Eine erwartungstreue Schätzung aufgrund von Stichprobendaten gelingt durch die folgende Statistik:

$$\frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x})^2$$

Eine Normalverteilung wird durch ihren Erwartungswert und ihre Varianz vollständig beschrieben, was die Bedeutung der Varianz als Verteilungsparameter unterstreicht.

- **Standardabweichung**

Die Standardabweichung ist definiert durch die Wurzel aus der Varianz. Man erhält Werte in der Maßeinheit des betrachteten Merkmals, was die Interpretation im Vergleich zur Varianz erleichtert. Bei einer Normalverteilung mit dem Erwartungswert μ und der Standardabweichung σ befinden sich ...

- im Intervall $[\mu - \sigma, \mu + \sigma]$ ca. 68% der Verteilungsmasse
- im Intervall $[\mu - 2\sigma, \mu + 2\sigma]$ ca. 95% der Verteilungsmasse

- **Interquartilsbereich**

Der Interquartilsbereich (Interquartilsabstand) ist definiert durch die Differenz zwischen dem 3. und dem 1. Quartil bzw. zwischen dem 75. und dem 25. Perzentil:

$$Q_3 - Q_1 = P_{75} - P_{25}$$

Bei einer schiefen Verteilung und bei Anwesenheit von Ausreißern (extremen, ungewöhnlichen Werten) ist der Interquartilsbereich gegenüber der Varianz und der Standardabweichung zu bevorzugen.


Bei einem *ordinalen* Merkmal kommen die Spannweite und der Interquartilsbereich als Streuungsmaße in Frage, wobei der Interquartilsbereich zu bevorzugen ist.

4.5.3 Schiefe und Wölbung

In diesem Abschnitt werden Statistiken vorgestellt, welche die Form der Verteilung eines metrischen Merkmals beschreiben.

4.5.3.1 Schiefe

Bei einem symmetrisch verteilten Merkmal hat die Schiefestatistik den Wert 0. Sie wird positiv bei einem linkssteil (bzw. rechtsschief) verteilten Merkmal, wenn also die Verteilungsmasse am linken Rand konzentriert ist, und negativ bei einem rechtssteil (bzw. linksschief) verteilten Merkmal, z.B.:



Zur Stichprobenschiefe liefert SPSS auch den zugehörigen Standardfehler, mit dessen Hilfe man Tests zur Populationsschiefe veranstalten kann. Diese sind allerdings nur approximativ gültig (bei unendlich großen Stichproben) und folglich bei kleinen Stichproben mit Vorsicht zu genießen. Ihr Vorzug gegenüber den später vorzustellenden Normalverteilungs-Anpassungstests (siehe Abschnitt 8) besteht darin, dass sie gezielt auf Verletzungen der Verteilungssymmetrie ansprechen.

Bei einem α -Fehlerrisiko von 5% ist die *ungerichtete* Nullhypothese, dass die Schiefe in der Population gleich null sei, zu verwerfen, wenn gilt:

$$\frac{|\text{Schiefe}|}{\text{SF}(\text{Schiefe})} > 1,96$$

Beim Wert 1,96 handelt es sich um das 97,5 - Perzentil der Standardnormalverteilung.

Der Test zum *gerichteten* Hypothesenpaar:

$$H_0: \text{Schiefe} \geq 0 \quad \text{versus} \quad H_1: \text{Schiefe} < 0$$

entscheidet sich beim selben α -Niveau gegen seine Nullhypothese, wenn der Quotient aus der Schiefe und ihrem Standardfehler das 5. Perzentil der Standardnormalverteilung unterbietet:

$$\frac{\text{Schiefe}}{\text{SF}(\text{Schiefe})} < -1,65$$

Analog lässt sich auch die gerichtete Hypothese mit umgekehrtem Vorzeichen prüfen.¹

¹ Wer in seinem Gedächtnis nicht mehr genügend Kenntnisse zur Inferenzstatistik reaktivieren konnte, der sei auf den Abschnitt 7.1 vertröstet.

4.5.3.2 Wölbung (Kurtosis)

Die Wölbung (synonym: *Kurtosis*) ist bei einer Normalverteilung gleich Null.¹ Sie wird ...

- *positiv*, wenn sich im Vergleich zur Normalverteilung mit demselben Erwartungswert und derselben Varianz *mehr* Verteilungsmasse an den Rändern befindet. Damit dieselbe Varianz resultiert, müssen gleichzeitig in der Verteilungsmasse viele *kleine* Varianzbeiträge auftreten. Das „Gedränge um den Mittelwert“ sorgt für einen schmalgipfligen Eindruck.
- *negativ*, wenn sich im Vergleich zur Normalverteilung mit demselben Erwartungswert und derselben Varianz *weniger* Verteilungsmasse an den Rändern befindet. Damit dieselbe Varianz resultiert, dürfen gleichzeitig nur wenige kleine Varianzbeiträge auftreten, so dass ein breitgipfliger Eindruck entsteht.


Mit Hilfe des zugehörigen Standardfehlers können analog zum Vorgehen bei der Schiefe-Statistik (siehe Abschnitt 4.5.3.1) approximativ (bei unendlich großen Stichproben) gültige Tests zur Wölbung in der Population durchgeführt werden.

4.5.3.3 Übung

Die beiden Ärgermaße sowie die Merkmale Geburtsjahr, Größe und Gewicht können näherungsweise als metrisch angesehen werden. Öffnen Sie erneut die Dialogbox zur Häufigkeitsanalyse. Statt den zugehörigen Menübefehl zu wiederholen, können Sie mit dem Symbol  eine Liste der zuletzt benutzten Dialogboxen aufrufen und daraus per Mausklick den Eintrag **Häufigkeiten** wählen. Lassen Sie sich für die genannten Variablen ausgeben:

- Histogramme mit eingezeichneter Normalverteilungsdichte
Um diesen Wunsch zu artikulieren, müssen Sie den Subdialog **Diagramme** öffnen.
- Keine Häufigkeitstabellen
Das für Häufigkeitstabellen zuständige Kontrollkästchen in der Dialogbox **Häufigkeiten** ist per Voreinstellung markiert. Sie müssen also die Markierung entfernen.
- Folgende Statistiken: Mittelwert, Median, Modus, Standardabweichung, Varianz, Minimum, Maximum, Schiefe, Kurtosis
Zur Auswahl der gewünschten **Statistiken** müssen Sie die zuständige Subdialogbox per Knopfdruck aktivieren:

¹ Andere Statistikprogramme und auch Lehrbücher verwenden eine alternative Definition der Wölbung, die zum Wert 3 für die Normalverteilung führt. Bei Aussagen zur Wölbung (in der Statistikliteratur oder in einer Programmausgabe) muss also die zugrunde liegende Definition berücksichtigt werden.



- Die Quartile (also das 25., das 50. und das 75. Perzentil)

Die Vergleiche mit der Normalverteilung über das Histogramm sowie die Statistiken Schiefe und Kurtosis erfolgen hier aus purem Interesse an den Verteilungen der betrachteten Variablen, ohne dabei an die *Verteilungsvoraussetzungen* irgendwelcher Testverfahren zu denken. Diese Voraussetzungen beziehen sich ohnehin in der Regel nicht auf die momentan von uns analysierten (unbedingten) Verteilungen von Beobachtungsvariablen, sondern auf die Verteilungen der *Residuen* eines bestimmten statistischen Modells. Genauere Aussagen sind nur im Zusammenhang mit konkreten Testverfahren möglich.


4.5.4 Diskussion ausgewählter Ergebnisse

Wie die Statistiken Minimum und Maximum zeigen, liegen keine irregulären Werte vor:

		Statistiken				
		Ärger ohne kontrafaktische Alternative	Ärger mit kontrafaktischer Alternative	Geburtsjahr	Körpergröße (in cm)	Körpergewicht (in kg)
N	Gültig	31	31	31	31	31
	Fehlend	0	0	0	0	0
Mittelwert		5,68	7,68	1968,94	172,81	63,484
Median		6,00	8,00	1969,00	174,00	60,000
Modus		5 ^a	8	1967 ^a	176	60,0
Standardabweichung		2,006	2,271	3,214	8,288	10,4940
Varianz		4,026	5,159	10,329	68,695	110,125
Schiefe		-,080	-1,451	,017	,448	1,265
Standardfehler der Schiefe		,421	,421	,421	,421	,421
Kurtosis		-,277	2,013	,241	-,166	1,889
Standardfehler der Kurtosis		,821	,821	,821	,821	,821
Minimum		2	1	1961	158	50,0
Maximum		10	10	1975	192	96,0
Perzentile	25	4,00	6,00	1967,00	165,00	55,000
	50	6,00	8,00	1969,00	174,00	60,000
	75	7,00	9,00	1970,00	178,00	70,000


a. Mehrere Modi vorhanden. Der kleinste Wert wird angezeigt.

Die Verteilung der Ärgermessung in der Situation *ohne* kontrafaktische Alternative (AERGO) macht einen recht „normalen“ Eindruck:



Die Verteilungskennwerte Schiefe ($= -0,08$) und Kurtosis ($= -0,277$) sind nach den oben angegebenen Tests nicht signifikant von Null verschieden.

Wir sind nun sehr gespannt auf die Verteilung der Ärgermessung in der Situation *mit* kontrafaktischer Alternative (AERGM), weil sich ein KFA-Effekt hier deutlich abzeichnen sollte. Es ist generell zu empfehlen, sich mit Diagrammen und deskriptiven Statistiken ein präzises Bild von der Effektlage zu verschaffen, statt einem Signifikanztest blind zu vertrauen, der eventuell durch technische Fehler belastet ist. Im Vergleich zur relativ symmetrischen Verteilung von AERGO um den Mittelwert 5,68 ist die AERGM-Verteilung deutlich nach rechts verschoben (Mittelwert 7,68) und „deformiert“:



Wir sehen einen mittleren Ärgeranstieg um 20° (bei Rückübersetzung in die Celsius-Skala des Fragebogens). Außerdem ist die AERGM-Verteilung am rechten Rand konzentriert und deutlich verschieden von einer Normalverteilung, was sich auch in signifikanten Ergebnissen der Tests zu Schiefe und Kurtosis widerspiegelt:


$$\frac{|\text{Schiefe}|}{\text{SF}(\text{Schiefe})} = \frac{1,45}{0,42} = 3,45 > 1,96$$

$$\frac{|\text{Kurtosis}|}{\text{SF}(\text{Kurtosis})} = \frac{2,01}{0,82} = 2,45 > 1,96$$

Hier sind *zweiseitige* Tests durchzuführen, weil keine gerichteten Hypothesen vorlagen. Wir haben zwar eine explizite Hypothese über die Richtung des KFA-Effekts (vgl. Abschnitt 1.3.2), doch muss die Verschiebung einer Verteilung nach rechts nicht zwangsläufig zu einer negativen Schiefe führen (siehe Abbildung in Abschnitt 1.3.2). Offenbar ist aber der KFA-Effekt so stark, dass er die Ärgerverteilung an die „Decke“ geschoben und damit rechtssteil (negativ schief) gemacht hat.

4.5.5 Median und andere Perzentile aus gruppierten Daten

Wird SPSS angewiesen, von *gruppierten* Daten auszugehen, also die für eine Variable vorhandenen Werte als Mittelwerte von Intervallen aufzufassen,



dann wird ein relativ aufwändiges Verfahren angewendet, um den Median und andere Perzentile zu den ungruppierten Daten zu schätzen. Den etwas anstrengenden Rest des Abschnitts sollte nur lesen, wer die Berechnungsvorschrift für gruppierte Daten in nächster Zeit anwenden und verstehen möchte.

Für die k geordneten Beobachtungs- bzw. Mittelwerte $x_1 < x_2 < \dots < x_k$ in der Stichprobe mit den zugehörigen Häufigkeiten $n_1, n_2, \dots, n_k$ werden die kumulativen Häufigkeiten c_j folgendermaßen definiert:

$$c_j := \sum_{v=1}^{j-1} n_v + \frac{n_j}{2}$$

Hinter dieser Formel steckt die Annahme, dass von den n_j Fällen mit dem gemeinsamen Mittelwert x_j gerade 50% einen wahren Wert kleiner oder gleich x_j und 50% einen wahren Wert größer als x_j haben. Das folgende Zahlenbeispiel illustriert die Definition:

x_j	n_j	c_j
1	4	$2 = 0 + 4/2$
2	6	$7 = 4 + 6/2$
3	2	$11 = 10 + 2/2$

Auf dem Weg zum Median ist die Beobachtung x_m zu bestimmen mit:

$$c_{m-1} \leq \frac{n}{2} < c_m$$

Aus dem Intervall $(c_{m-1}, c_m]$ werden noch

$$\frac{n}{2} - c_{m-1}$$

Fälle benötigt, um 50% der Fälle gemäß Mediandefinition zu erreichen. In diesem Intervall befinden sich

$$c_m - c_{m-1}$$

Fälle. Man geht davon aus, dass die unbekannten Originalwerte gleichmäßig im Intervall verteilt sind und bestimmt nach folgender Formel den erforderlichen Anteil der im Intervall befindlichen Fälle:

$$A = \frac{\frac{n}{2} - c_{m-1}}{c_m - c_{m-1}}$$

Das Produkt dieses Anteils mit der Intervallbreite addiert man zur linken Intervallgrenze, um den geschätzten Median zu den ursprünglichen Daten zu erhalten:

$$A(x_m - x_{m-1}) + x_{m-1} = (1 - A)x_{m-1} + Ax_m$$

Im Zahlenbeispiel resultiert:

$$A = \frac{12 \cdot 0,5 - 2}{7 - 2} = \frac{4}{5}$$

$$(1 - \frac{4}{5})1 + \frac{4}{5}2 = 1,8$$

Genau diesen Wert liefert SPSS für gruppierte Daten,

Statistiken

x		
N	Gültig	12
	Fehlend	0
Median		1,8000 ^a

a. Aus gruppierten Daten berechnet

während die in Abschnitt 4.5.1 mitgeteilte Definition bzw. Berechnungsvorschrift zum Wert 2 führt.

4.6 Übung

Führen Sie die restlichen Verteilungs- bzw. Fehleranalysen zu unserem Projekt durch. Die mehrfach benötigte **Häufigkeiten**-Dialogbox sollte jeweils über den Schalter **Zurücksetzen** von alten Einstellungen (auch in den Subdialogboxen) befreit werden.

1) Lassen Sie sich für die LOT-Variablen ausgeben:

- Häufigkeitstabellen
- keine Diagramme
- folgende Statistiken: Mittelwert, Median, Modalwert, Standardabweichung, Varianz, Minimum, Maximum

2) Lassen Sie sich für die Variablen MOTIV1 bis MOTIV5, ANDERE, SMG und METH1 bis METH3 ausgeben:

- Häufigkeitstabellen
- keine Diagramme
- keine Statistiken

Bei den Variablen MOTIV1 bis MOTIV5, ANDERE, SMG und METH1 bis METH3 ist zu beachten, dass die Behandlung fehlender Werte durch Techniken der Datentransformation noch aussteht (vgl. Abschnitt 6.5).

3) Kontrollieren Sie bei allen Variablen, ob unzulässige Werte vorliegen.

4.7 Suche nach Daten

Die Fehleranalyse liefert nur einen „Treffer“. In der Häufigkeitstabelle zur Variablen LOT10 entdecken wir den verbotenen Wert Null:

lot10				
	Häufigkeit	Prozent	Gültige Prozente	Kumulierte Prozente
Gültig 0	1	3,2	3,2	3,2
1	4	12,9	12,9	16,1
2	10	32,3	32,3	48,4
3	9	29,0	29,0	77,4
4	7	22,6	22,6	100,0
Gesamt	31	100,0	100,0	

Diese Fehlerquote kann als erfreulich niedrig eingestuft werden.


Nun möchten wir natürlich wissen, bei welchem Fall dieser Wert auftritt, um eine Korrektur vornehmen zu können. Der betroffene Fall ist leicht zu ermitteln:

- Holen Sie nötigenfalls das Datenfenster mit der Arbeitsdatei in den Vordergrund.
- Markieren Sie in der **Datenansicht** die Variable LOT10 durch einen Klick auf ihren Namen in der Spaltenbeschriftungszone.

In unserem kleinen Datensatz ist eine einzelne Variable leicht zu lokalisieren. SPSS eignet sich aber auch für Projekte mit Tausenden von Variablen und stellt nach dem Menübefehl

Bearbeiten > Gehe zu Variable...

oder einem Klick auf den Symbolleistenschalter  mit der Dialogbox **Gehe zu** eine nützliche Navigationshilfe zur Verfügung, z.B.:




Passend zum bereits eingetippten Namensanfang wird eine Liste mit allen Variablennamen geöffnet und die erste kompatible Zeile markiert. Nach dem Quittieren einer Auswahl mit dem Schalter **Gehe** ist im Datenfenster die zugehörige Variable markiert.

Im Datenfenster mit der markierten Variablen LOT10 findet man leicht zu den Fällen mit einem interessierenden Wert:

- Klicken Sie auf das Symbol , oder wählen Sie den Menübefehl:

Bearbeiten > Suchen...

Dann erscheint die folgende Dialogbox:



- Tragen Sie den zu suchenden Wert ein, und klicken Sie auf den Schalter **Weitersuchen**. Für die Suche nach SYSMIS ist ein Punkt einzutragen.
- Daraufhin markiert SPSS die erste Trefferzelle, und Sie kennen den Fall mit fehlerhaftem LOT10-Wert: Es ist zufällig der erste Fall (FNR = 1), dessen ausgefüllter Fragebogen im Manuskript wiedergegeben ist (siehe Seite 42), so dass Sie den korrekten Wert ablesen und im Datenfenster eintragen können. Nach dieser Datenkorrektur sollten Sie die Arbeitsdatei sichern und damit die SPSS-Datendatei **kfar.sav** auf den neuen Stand bringen.

4.8 Populationsanteil einer Kategorie und Vertrauensintervall

Liegt eine Zufallsstichprobe aus einer Population vor, beschränkt man sich nicht darauf, die Stichprobenverteilungen der untersuchten Merkmale zu beschreiben, sondern strebt nach Aussagen über die Verteilungen in der Population. Bei einem nominalskalierten Merkmal interessieren als Populationsparameter die Anteile der einzelnen Kategorien. Aus einer Stichprobe mit Führungskräften möchte man z.B. bei einer Analyse des Merkmals Geschlecht möglichst präzise Informationen über den Frauenanteil in der Population gewinnen.

Wir verwenden bei den anschließenden Übungen und Aufgaben die Variable GESCHL aus unserer Kursprojekt, deren Häufigkeitstabelle wir schon in Abschnitt 4.3 angefordert und diskutiert haben.

Geschlecht					
		Häufigkeit	Prozent	Gültige Prozente	Kumulierte Prozente
Gültig	Frau	25	80,6	80,6	80,6
	Mann	6	19,4	19,4	100,0
	Gesamt	31	100,0	100,0	

Wir gehen davon aus, dass eine Zufallsstichprobe aus der Population der Interessenten für die ZIMK-Lehrveranstaltung *Statistisches Praktikum mit SPSS* vorliegt. Für die **Wahrscheinlichkeit**, beim zufälligen Ziehen aus dieser Population eine Frau anzutreffen, liefert die Stichprobe mit der relativen Häufigkeit die folgende **Punktschätzung**:

$$\frac{25}{31} = 0,806 = \hat{p}$$

Als Symbol für die Wahrscheinlichkeit verwenden wir den Kleinbuchstaben p (Abkürzung für *probability*), und für die geschätzte Wahrscheinlichkeit setzen wir ein Dach darüber ($\hat{p}$).

Vermutlich rechnen Sie nicht damit, in einer anderen Stichprobe aus derselben Population denselben Schätzwert zu erhalten. Jede Stichprobe liefert einen anderen Frauenanteil, also eine andere Schätzung für die interessierende Wahrscheinlichkeit. Immerhin haben alle Schätzungen die interessierende Wahrscheinlichkeit als gemeinsamen Erwartungswert, d.h. sie pendeln um diesen Wert herum.

Der Auftraggeber Ihrer statistischen Analyse ist an der **Präzision** der gelieferten Schätzung interessiert. Konkret will er wissen, in welchem Intervall um die Anteilsschätzung aus der einzig vorhandenen Stichprobe die Populationswahrscheinlichkeit mit einer gewünschten Sicherheit von z.B. 95% anzunehmen ist. Bei einer Wählerbefragung möchte das beauftragende Presseorgan (und auch der Medienkonsument) wissen, in welchem Intervall um den Schätzwert der wahre Stimmenanteil für eine Partei mit einer gewünschten Sicherheit von z.B. 95% liegt. Folglich müssen Sie auch eine **Intervallschätzung** abliefern. Deren Ergebnis bezeichnet man als **Konfidenz-** oder **Vertrauensintervall**.

Bei der statistischen Sicherheit zu einem Vertrauensintervall (mit typischen Werten von 95% oder 99%) spricht man vom **Konfidenzniveau**, und das Gegenstück nennt man **Irrtumswahrscheinlichkeit** (mit typischen Werten von 5% oder 1%).

Der Begriff *Vertrauensintervall* ist im Kurs schon mehrfach ohne Erläuterung benutzt worden in der Annahme, dass Grundbegriffe in einem statistischen Praktikum als bekannt vorausgesetzt werden dürfen. Allerdings liegt erfahrungsgemäß bei manchen Kursteilnehmern die statistische Grundausbildung schon länger zurück, so dass bei besonders wichtigen Begriffen neben der


praktischen Anwendung auch eine wiederholende Erläuterung angemessen ist. Der aktuelle Abschnitt 4.8 soll daher Ihr Wissen über die Intervallschätzung auffrischen, wobei wir als Beispiel die Intervallschätzung zu einer Proportion betrachten.

4.8.1 Vertrauensintervall verstehen und näherungsweise berechnen

Wir werden später das Vertrauensintervall für eine Anteilsschätzung von SPSS berechnen lassen, wobei ein komplexer Algorithmus zum Einsatz kommt. Vorab lernen Sie einen Weg kennen, ein approximatives, aber in vielen Fällen ausreichend genaues Vertrauensintervall auf sehr einfache Weise manuell zu ermitteln. Für die Beschäftigung mit dem manuellen Verfahren gibt es mindestens zwei gute Gründe:

- Sie gewinnen ein gutes Verständnis für die statistischen Grundlagen von Vertrauensintervallen.
- Sie gewinnen ein einfaches Verfahren, um schon bei der Planung einer Studie für eine vorgegebene Vertrauensintervallbreite und ein gefordertes Konfidenzniveau den benötigten Stichprobenumfang berechnen zu können (siehe Abschnitt 4.8.3). Weil SPSS und auch G*Power vergleichbare Kalkulationen *nicht* anbieten, hat das Do-It-Yourself – Verfahren einen hohen praktischen Nutzen.

Wir stellen uns vor, unendlich viele Zufallsstichproben derselben Größe aus einer Population zu ziehen und jeweils die Anteilsschätzung zu berechnen. Zunächst geht es um die Frage, von welcher Gestalt die Verteilung der Anteilsschätzungen für ein Ereignis ist. Sie können es glauben, nach wenigen Jahren Mathematikstudium beweisen (Stichwort: zentraler Grenzwertsatz) oder mit Hilfe einer Computer-Simulation (z.B. mit SPSS) ausprobieren: Es resultiert die als **Gauss-** oder **Normalverteilung** bezeichnet Glockengestalt! In einem Zufallsexperiment mit SPSS-Hilfe habe ich aus einer Population mit der wahren Wahrscheinlichkeit 0,806 für ein Ereignis 1000 Stichproben der Größe 31 gezogen und jeweils die relative Häufigkeit für das Ereignis ermittelt. Wie das folgende Histogramm zeigt, kommt das Ergebnis trotz des relativ kleinen Stichprobenumfangs der Glockenform schon ziemlich nahe, wenngleich noch eine (aus dem hohen Populationsanteil von 0,806 resultierende) Tendenz zur negativen Schiefe erkennbar ist (vgl. Abschnitt 4.5.3.1):



Was Sie hier sehen, ist eine simulierte Stichprobenverteilung für den Anteilsschätzer aus Stichproben der Größe $n = 31$ bei einer Populationswahrscheinlichkeit von $p = 0,806$.

Nach Rumsey (2008, S. 181) müssen folgende Anforderungen an die Stichprobengröße erfüllt sein, um eine akzeptable Normalverteilungsanpassung für die Verteilung der Anteilsschätzungen zu erreichen:¹

$$n \cdot p \geq 5$$

$$n \cdot (1 - p) \geq 5$$

Ist die Wahrscheinlichkeit p unbekannt, darf man zur Prüfung der beiden Voraussetzungen auch den Anteilsschätzer $\hat{p}$ aus der Stichprobe verwenden. Im Beispiel sind die Bedingungen erfüllt:

$$31 \cdot 0,806 = 24,986$$

$$31 \cdot (1 - 0,806) = 6,014$$

Zwar hat die Stichprobenverteilung als Mittel- bzw. Erwartungswert gerade die gesuchte Populationswahrscheinlichkeit p , doch zeigt sich keinesfalls in *jeder* Stichprobe genau dieser Wert. Bei der Konstruktion eines Konfidenzintervalls für die Schätzung aus der einen vorhandenen Stichprobe spielt die Standardabweichung der Stichprobenverteilung eine entscheidende Rolle. Weil man diese Standardabweichung als den typischen Fehler bei der Schätzung des Populationsanteils durch eine Stichprobe interpretieren kann, spricht man vom **Standardfehler** des Anteilsschätzers $\hat{p}$. Als Symbol für den Standardfehler verwenden wir anschließend $\sigma(\hat{p})$.

Für konkrete Werte von n und p lässt sich der Standardfehler zum Anteilsschätzer $\hat{p}$ mit der folgenden Formel berechnen:

$$\sigma(\hat{p}) = \sqrt{\frac{p \cdot (1 - p)}{n}}$$

In der Praxis steht statt der Populationswahrscheinlichkeit p nur eine Schätzung $\hat{p}$ aus der Stichprobe zur Verfügung, so dass man sich beim Standardfehler mit der Schätzung $\hat{\sigma}(\hat{p})$ zufrieden geben muss:

$$\hat{\sigma}(\hat{p}) = \sqrt{\frac{\hat{p} \cdot (1 - \hat{p})}{n}}$$

Für eine Normalverteilung mit dem Mittelwert μ und der Standardabweichung σ weiß man generell z.B., dass sich 95% der gesamten Verteilungsmasse im folgenden Intervall befinden:

$$[\mu - 1,96 \cdot \sigma; \mu + 1,96 \cdot \sigma]$$

Bei einer ausreichenden Stichprobengröße ist die Stichprobenverteilung des Anteilsschätzers $\hat{p}$ approximativ normal und die Stichprobenschätzung des Standardfehlers hinreichend präzise, sodass 95% aller Stichproben eine Schätzung $\hat{p}$ liefern mit:

$$\hat{p} \in \left[p - 1,96 \cdot \sqrt{\frac{\hat{p} \cdot (1 - \hat{p})}{n}}; p + 1,96 \cdot \sqrt{\frac{\hat{p} \cdot (1 - \hat{p})}{n}} \right]$$

Eine einfache Termumformung ergibt, dass in all diesen Fällen für den Populationsanteil p erfüllt ist:

¹ Andere Autoren sind skeptisch bzgl. der Normalverteilungsapproximation bei kleinen Stichproben (siehe z.B. Agresti 2007, S. 9; Brown et al. 2001 und 2002). Diese Debatte ist wenig relevant für unser Ziel, das Vertrauensintervall am Beispiel der Anteilsschätzung zu erläutern. Für die Forschungspraxis wird in Abschnitt 4.8.2 die Verwendung eines aufwendiger (von SPSS) berechneten Vertrauensintervalls empfohlen.

$$p \in \left[\hat{p} - 1,96 \cdot \sqrt{\frac{\hat{p} \cdot (1 - \hat{p})}{n}}; \hat{p} + 1,96 \cdot \sqrt{\frac{\hat{p} \cdot (1 - \hat{p})}{n}} \right]$$

Folglich liefern die Stichproben ein 95% - Vertrauensintervall für den Populationsparameter p .

Für den Frauenanteil im *statistischen Praktikum mit SPSS* ergibt sich so aus der Manuskriptstichprobe das folgende 95% - Vertrauensintervall:

$$\left[0,806 - 1,96 \cdot \sqrt{\frac{0,806 \cdot (1 - 0,806)}{31}}; 0,806 + 1,96 \cdot \sqrt{\frac{0,806 \cdot (1 - 0,806)}{31}} \right] = [0,667; 0,945]$$

Wenn Sie ein 95% - Vertrauensintervall regelkonform ermitteln (also eine echte Zufallsstichprobe ziehen und die Rechnung korrekt ausführen), dann wird es mit einer Wahrscheinlichkeit von 0,95 den korrekten Populationsparameter enthalten. Immerhin mit einer Wahrscheinlichkeit von 0,05 werden Sie hingegen ein Konfidenzintervall erhalten, das den fraglichen Parameter *nicht* enthält. Für das einzige tatsächlich berechnete Vertrauensintervall kann man *nicht* sagen, dass es den Parameter mit 95% - iger Wahrscheinlichkeit enthält. Die statistische Sicherheit betrifft nicht ein konkretes Konfidenzintervall, sondern das *Verfahren* zur Ermittlung von Konfidenzintervallen. In der Praxis sind die streng genommen fehlerhaften Wahrscheinlichkeitsaussagen über konkrete Vertrauensintervalle häufig anzutreffen. Allerdings weicht die übliche Redeweise nur in harmloser Weise von der Logik der Vertrauensintervalle ab.

Nicht ganz so harmlos sind beim beschriebenen approximativen Berechnungsverfahren die Abweichungen zwischen der nominellen und der tatsächlichen Überdeckungswahrscheinlichkeit des Vertrauensintervalls. Bei einer Stichprobengröße von $n = 31$ hat die Stichprobenverteilung der Anteilsschätzungen zur Populationswahrscheinlichkeit von $p = 0,806$ noch keine perfekte Normalität erreicht. Daher wird gleich in Abschnitt 4.8.2 beschrieben, wie man von SPSS ein Vertrauensintervall mit höherer Präzision berechnen lässt.

4.8.2 Jeffreys-Vertrauensintervall von SPSS berechnen lassen

Das in Abschnitt 4.8.1 vorgestellte approximative Verfahren war aufgrund seiner Einfachheit gut geeignet, das Konzept des Vertrauensintervalls am Beispiel der Anteilsschätzung zu erläutern. Allerdings ist die verwendete Normalverteilungsapproximation bei kleinen Stichproben (auch bei Beachtung der Abschnitt 4.8.1 angegebenen Regeln) zu ungenau (siehe z.B. Agresti 2007, S. 9). Im Resultat kann die Überdeckungswahrscheinlichkeit für ein approximativ berechnetes Vertrauensintervall deutlich unter 0,95 liegen. Für die Forschungspraxis wird daher die Verwendung des Jeffreys-Vertrauensintervalls empfohlen.


4.8.2.1 Anforderung

Gehen Sie folgendermaßen vor, um das Jeffreys-Vertrauensintervall zum Frauenanteil im SPSS-Kurs von SPSS berechnen zu lassen:


- Öffnen Sie mit dem Menübefehl

Analysieren > Nichtparametrische Tests > Eine Stichprobe


den folgenden Dialog **Nichtparametrische Tests bei einer Stichprobe**:



- Wechseln Sie zur Registerkarte **Felder**, und entfernen Sie alle **Testfelder** mit Ausnahme der Variablen GESCHL:




- Wechseln Sie zur Registerkarte **Einstellungen**, wo per Voreinstellung das Element **Tests auswählen** markiert ist. Stellen Sie nötigenfalls diese Markierung her, wählen Sie die Option **Tests anpassen**, und markieren Sie das Kontrollkästchen **Beobachtete und hypothetische Binärwahrscheinlichkeit vergleichen**:




- Öffnen Sie über den Schalter **Optionen** den folgenden Dialog **Binomialoptionen**, der im Rahmen **Konfidenzintervall** drei Methoden zur Berechnung des Vertrauensintervalls anbietet:
 - **Clopper-Pearson (exakt)**
Von diesem Verfahren gelieferte Vertrauensintervalle besitzen stets die versprochene, meist sogar eine höhere Überdeckungswahrscheinlichkeit. Was positiv klingt, ist negativ zu beurteilen, weil die Vertrauensintervalle meist sehr konservativ, also zu breit ausfallen. Brown et al. (2002, S. 169) bezeichnen das Clopper-Pearson - Intervall daher als „excessively conservative and inefficient“.
 - **Jeffreys**
Eine für Statistikeinsteiger geheimnisvoll klingende Beschreibung, mit der einige Vorbelastete vielleicht etwas anfangen können: Das Jeffreys-Intervall wird nach den Prinzipien der Bayes-Statistik mit einer nichtinformativen a-priori - Verteilung berechnet.
 - **Likelihood Quotient**
Auch zu diesem Vertrauensintervall gibt es eine Beschreibung mit Begriffen, die leider im Kurs nicht erläutert werden können: Das Likelihood-Quotienten - Vertrauensintervall wird durch Inversion des Likelihood-Quotienten - Tests zur Nullhypothese $H_0: p = p_0$ konstruiert.

Nach Brown et al. (2002, S. 186) halten das Jeffreys- und das Likelihood-Quotienten - Intervall die versprochene Überdeckungswahrscheinlichkeit mit akzeptabler Genauigkeit ein, wobei das Jeffreys-Intervall tendenziell kleiner ausfällt. Daher entscheiden wir uns für das Jeffreys-Intervall:




Wird in SPSS per Diagrammerstellung (siehe Kapitel 11) für eine kategoriale (nominale oder ordinale) Variable ein Balkendiagramm mit Fehlerbalken angefordert, verwendet SPSS übrigens per Voreinstellung auch das 95% - ige Jeffreys- Vertrauensintervall, z.B.:



Wer ein numerisches Vertrauensintervall zusammen mit einem solchen Diagramm präsentiert, sollte natürlich aus Konsistenzgründen für das numerische Intervall ebenfalls die Jeffreys-Definition verwenden.

- Legen Sie im Rahmen **Erfolg für kategoriale Felder definieren** den **Erfolgswert 1** fest. Das ist bei der Variablen GESCHL der Wert für Frauen.
- Quittieren Sie den Dialog **Binomialoptionen** mit **OK**.
- Zurück im Dialog **Nichtparametrische Tests bei einer Stichprobe** wollen Sie vielleicht das Element **Testoptionen** markieren und für das **Konfidenzintervall** die voreingestellte Sicherheit von 95% ändern:



- Fordern Sie schließlich im Dialog **Nichtparametrische Tests bei einer Stichprobe** per Mausklick auf den Schalter **Ausführen** die Ergebnisse an.

4.8.2.2 Handhabung der Modellviewer-Ergebnisanzeige


Der Dialog für **Nichtparametrische Tests bei einer Stichprobe** erzeugt per Voreinstellung keine Pivot-Tabellen und Diagramme, sondern die folgende Ausgabe:

Hypothesentestübersicht				
	Nullhypothese	Test	Sig.	Entscheidung
1	Die durch Geschlecht = (Frau) and (Mann) definierten Kategorien treten mit den Wahrscheinlichkeiten 0,5 und 0,5 auf.	Test auf Binomialverteilung bei einer Stichprobe	,001	Nullhypothese ablehnen


Asymptotische Signifikanz werden angezeigt. Das Signifikanzniveau ist ,05.

Gehen Sie folgendermaßen vor, um das zunächst nicht sichtbare Jeffreys-Konfidenzintervall anzeigen zu lassen:

- Setzen Sie einen Doppelklick auf die Ausgabe, so dass der **Modellviewer** erscheint. Mit diesem Dialog lassen sich weitere Ergebnisse (darunter das Konfidenzintervall) hervorzaubern:



- Wählen Sie im Bedienelement **Ansicht** (unten links) die **Konfidenzintervallübersicht**, um endlich das gewünschte Ergebnis zu erhalten:



- Nach dem Schließen des **Modellviewers** erscheint das Konfidenzintervall auch im Ausgabefenster:

Konfidenzintervallübersicht

Konfidenzintervalltyp	Parameter	Schätzung	95% Konfidenzintervall	
			Unterer	Oberer
Erfolgsrate der Binomialverteilung einer Stichprobe (Jeffreys)	Wahrscheinlichkeit (Geschlecht= Frau)	,806	,644	,915


Das Jeffreys-Vertrauensintervall [0,644; 0,915] weicht deutlich vom approximativen Vertrauensintervall [0,667; 0,945] ab. Es ist etwas kleiner und vor allem *nicht* symmetrisch um die Punktschätzung. Bei einer Stichprobe der Größe $n = 31$ und $\hat{p} = 0,806$ ist das im zentralen Grenzwertsatz beschriebene Streben der Stichprobenverteilung in Richtung Normalität (speziell zur Symmetrie) offenbar noch nicht abgeschlossen (siehe Histogramm in Abschnitt 4.8.1).

4.8.2.3 Modelviewer abschalten

Über die Bedienungsvorteile der eben erlebten Modellanzeige im Vergleich zur konventionellen Ergebnispräsentation durch Pivot-Tabellen und Diagramme bestehen unterschiedliche Meinungen. Nach dem Menübefehl

Bearbeiten > Optionen

kann man im **Optionen**-Dialog auf der Registerkarte **Ausgabe** dafür sorgen, dass auch die Prozedur für nichtparametrische Verfahren die konventionelle, aus Pivot-Tabellen und Diagrammen bestehende Ausgabe produziert:



Mit den oben beschriebenen Einstellungen im Dialog **Nichtparametrische Tests bei einer Stichprobe** erhält man dann ohne weitere Umstände u.a. die folgende Tabelle mit dem Vertrauensintervall:

Konfidenzintervallübersicht

Konfidenzintervalltyp	Parameter	Schätzer	95,0%-Konfidenzintervall	
			Unterer Wert	Oberer Wert
Binomialerfolgsrate für eine Stichprobe (Jeffreys)	Wahrscheinlichkeit(Geschlecht=Frau).	,806	,644	,915


4.8.3 Stichprobenumfang für eine gewünschte Präzision berechnen

Bei der *Präzision* einer Intervallschätzung sind zwei Forderungen im Spiel:

- Das Konfidenzniveau soll möglichst groß sein.
- Das Konfidenzintervall soll möglichst klein sein.

Dummerweise verhalten sich die beiden Forderungen konträr: Je höher das Konfidenzniveau (je kleiner die tolerierte Irrtumswahrscheinlichkeit), desto breiter wird das Konfidenzintervall. In der Planungsphase können Sie aber doch beide Forderungen unter einen Hut bringen, indem Sie die Stichprobe so groß wählen, dass bei einer festgelegten Irrtumswahrscheinlichkeit ein Konfidenzintervall der gewünschten Breite resultiert.

Um einzusehen, warum die Steigerung des geforderten Konfidenzniveaus zu einem breiteren Konfidenzintervall führt, betrachten wir die Stichprobenverteilung des Anteils, von der wir mittlerweile wissen, dass sie zumindest bei großen Stichproben annähernd normal ist. Wird etwa eine Sicherheit von 99% an Stelle des Standardwerts von 95% verlangt, dann muss ein breiteres Segment der Stichprobenverteilung einbezogen werden, um entsprechend viel Verteilungsmasse einzusammeln:



In der Formel zur näherungsweisen Berechnung des Vertrauensintervalls ist im Vergleich zur 95% - Version

$$\left[\hat{p} - 1,96 \cdot \sqrt{\frac{\hat{p} \cdot (1 - \hat{p})}{n}}; \hat{p} + 1,96 \cdot \sqrt{\frac{\hat{p} \cdot (1 - \hat{p})}{n}} \right]$$

der Faktor zu ändern, mit dem der geschätzte Standardfehler $\hat{\sigma}(\hat{p})$ der Stichprobenverteilung zu multiplizieren ist. Dieser Faktor stammt aus der speziellen Normalverteilung mit dem Mittelwert 0 und der Streuung 1, die man als *Standardnormalverteilung* bezeichnet. Zum Konfidenzniveau 95% (also zur Irrtumswahrscheinlichkeit 5%) gehört der Wert 1,96, weil dieser bei einer Standardnormalverteilung genau 2,5% der Verteilungsmasse am rechten Rand abschneidet. Mit anderen Worten: Bei der Ziehung einer Zufallsgröße mit Standardnormalverteilung wird der Wert 1,96 mit einer Wahrscheinlichkeit von 0,025 überschritten. Der zu einer beliebigen Irrtumswahrscheinlichkeit α gehörige Wert, der am rechten Rand der Standardnormalverteilung die Verteilungsmasse $\alpha/2$ abschneidet, soll anschließend als $z_{1-\alpha/2}$ bezeichnet werden.

Mit dem Konfidenzniveau wächst der Faktor $z_{1-\alpha/2}$ und damit auch die Breite des Vertrauensintervalls. In der folgenden Tabelle sind die am häufigsten verwendeten Werte angegeben:

Konfidenzniveau	$z_{1-\alpha/2}$
80%	1,282
90%	1,645
95%	1,960
99%	2,576

Mit dem zu einem Konfidenzniveau gehörigen Wert $z_{1-\alpha/2}$ ermittelt man folgendermaßen das Konfidenzintervall zur Anteilsschätzung $\hat{p}$ aus einer Stichprobe mit n Fällen:

$$\left[\hat{p} - z_{1-\alpha/2} \cdot \sqrt{\frac{\hat{p} \cdot (1-\hat{p})}{n}}; \hat{p} + z_{1-\alpha/2} \cdot \sqrt{\frac{\hat{p} \cdot (1-\hat{p})}{n}} \right]$$

Im Beispiel mit dem Frauenanteil im statistischen Praktikum erhalten wir das approximative 99% - Vertrauensintervall $[0,623; 0,989]$. Es ist erwartungsgemäß um den Faktor $\frac{2,58}{1,96} = 1,32$ breiter als das 95% - Gegenstück.

Wer ein schmales Vertrauensintervall angeben möchte, muss bei konstanter Stichprobengröße den Faktor $z_{1-\alpha/2}$ reduzieren, was nach obiger Tabelle zu Lasten der statistischen Sicherheit geht.

Wenn Sie rechtzeitig (vor der Datenerhebung) planen und beim Stichprobenumfang nicht an Grenzen stoßen, können Sie beide Aspekte der Präzision kontrollieren:

- Legen Sie das Konfidenzniveau fest.
- Wählen Sie die gewünschte Intervallbreite.
Üblicherweise interessiert man sich für die *einseitige* Fehlerbreite b und berichtet das Vertrauensintervall in der Notation $\hat{p} \pm b$.
- Berechnen Sie die erforderliche Stichprobengröße.

Nur für den Fall, dass Ihnen die Formel zum dritten Punkt nicht spontan einfällt, gebe ich sie samt der recht simplen Herleitung an. Die folgende Formel für die Fehlerbreite b

$$b = z_{1-\alpha/2} \cdot \sqrt{\frac{p \cdot (1-p)}{n}}$$

muss nach der Stichprobengröße n aufgelöst werden. Zur Berechnung des Standardfehlers wird hier kein Anteilsschätzer verwendet, sondern die angenommene Populationswahrscheinlichkeit, weil wir uns geistig in die Planungsphase einer Studie versetzt haben, also noch keinen Schätzwert zur Verfügung haben. Wir dividieren beide Seiten der Gleichung durch $z_{1-\alpha/2}$ und quadrieren:

$$\frac{b^2}{z_{1-\alpha/2}^2} = \frac{p \cdot (1-p)}{n}$$

Der Rest ist simpel:

$$n = z_{1-\alpha/2}^2 \frac{p \cdot (1-p)}{b^2}$$

Ist bei einer angenommenen Populationswahrscheinlichkeit von 0,3 ein Konfidenzniveau von 95% (nach obiger Tabelle $z_{1-\alpha/2} = 1,96$) sowie eine Fehlerbreite (gleich halbe Konfidenzintervallbreite) von 0,02 gewünscht, dann resultiert als minimal erforderlicher Stichprobenumfang:

$$n = 1,96^2 \frac{0,3 \cdot (1-0,3)}{0,02^2} \approx 3,84 \frac{0,21}{0,0004} = 2016$$


Um also z.B. einen Stimmenanteil von 30% mit einer Genauigkeit von $\pm 2\%$ schätzen zu können, muss man mindestens 2016 zufällig ermittelte Wahlberechtigte befragen.

Dummerweise muss der unbekannte, in der Stichprobe zu schätzende Populationsparameter für die Berechnung des benötigten Stichprobenumfangs bereits zur Verfügung stehen. Wenn noch nicht einmal eine grobe Vorstellung über den Populationsparameter existiert, geht man vom un-

günstigsten Fall $p = 0,5$ aus, der den größten Standardfehler und damit den größten Stichprobenbedarf zur Folge hat. Wenn Sie dieser Behauptung über das Maximum der Funktion

$$p \cdot (1 - p) = p - p^2$$

nicht trauen, werfen Sie doch einfach einen Blick auf den Graphen der Funktion:



Mit $p = 0,5$ statt $p = 0,3$ erhöht sich der zuletzt berechnete Stichprobenbedarf auf 2400:

$$n = 1,96^2 \frac{0,5 \cdot (1 - 0,5)}{0,02^2} \approx 3,84 \frac{0,25}{0,0004} = 2400$$

Meinungsforschungsinstitute verwenden zur Erfassung der politischen Stimmungslage in der Regel eine Stichprobengröße von ca. 2500 Fällen.¹


¹ Auf der folgenden Webseite (abgerufen am 15.03.2016) finden Sie die Stichprobenumfänge von zahlreichen Forsa-Umfragen: <http://www.wahlrecht.de/umfragen/forsa.htm>

5 Speichern der SPSS-Kommandos zu wichtigen Anweisungsfolgen

5.1 Zur Motivation

Eventuell erhalten Sie nach Abschluss der Fehlerkontrolle noch weitere ausgefüllte Fragebögen. Sie freuen sich natürlich über die Stichprobenerweiterung und erfassen sofort die neuen Fälle. Dann allerdings fällt Ihnen ein, dass nun alle Kontrollanalysen wiederholt werden müssen.

Um solchen Frust zu vermeiden, brauchen wir eine Möglichkeit, aufwändige und potentiell mehrfach benötigte Anweisungssequenzen zur späteren Wiederverwendung abzuspeichern. In SPSS eignen sich dazu die **Kommandos**, die den einzelnen Dialogboxen zugrunde liegen, und die von SPSS stets im Hintergrund erzeugt und ausgeführt werden, wenn wir eine ausgefüllte Dialogbox mit **OK** abschicken. Wie Sie inzwischen wissen, werden diese Kommandos per Voreinstellung im Ausgabefenster protokolliert, z.B. bei der Häufigkeitsanalyse für die Variablen GESCHL und FB:



In diesem Zusammenhang lohnt ein kurzer Blick auf die Architektur des SPSS-Systems, das aus den beiden folgenden Komponenten besteht:

- **Bedienoberfläche**
Wir interagieren mit der Bedienoberfläche, die unsere Anweisungen entgegennimmt und die Ergebnisse präsentiert. Wir können der Bedienoberfläche unsere Anweisungen in Form von ausgefüllten Dialogboxen oder als Folge von SPSS-Kommandos übergeben.
- **SPSS-Prozessor**
Die Bedienoberfläche gibt unsere Anweisungen in jedem Fall in Form von SPSS-Kommandos an den Prozessor weiter, der im Hintergrund arbeitet. Wir erfahren übrigens in der Statuszeile der SPSS-Fenster, was der Prozessor gerade treibt. Da wir den Prozessor bislang nur minimal belastet haben, war in der Statuszeile meist zu lesen:


IBM SPSS Statistics Prozessor ist bereit

Während der Prozessor arbeitet, wird in der Statuszeile angezeigt, mit welchem SPSS-Kommando er gerade beschäftigt ist. Nach dem Abschicken einer Häufigkeitsdialogbox erscheint z.B. (bei unserem kleinen Datensatz allerdings nur sehr kurz):

Ausführen: FREQUENCIES

Wenn wir eine ausgefüllte Häufigkeitsdialogbox mit **OK** quittieren, führt der SPSS-Prozessor also im Hintergrund das korrespondierende FREQUENCIES-Kommando aus.

In fast allen SPSS-Dialogboxen kann man über die Schaltfläche **Einfügen** die zugrunde liegenden SPSS-Kommandos produzieren lassen. Diese werden dann *nicht* ausgeführt, sondern in ein so genanntes **Syntaxfenster** übertragen, das die Bearbeitung von Kommandos u.a. durch eine Navigationszone am linken Rand, die farbliche Unterscheidung verschiedener Syntaxbestandteile und eine intelligente Syntaxvervollständigung unterstützt:



Hier kann man zusammengehörige Kommandos zu einer Sequenz ansammeln, nach Bedarf einzeln oder gemeinsam ausführen lassen und schließlich in einer Datei abspeichern. Später kann man die Kommandos aus dieser Datei wieder laden und, eventuell nach manueller Überarbeitung, erneut ausführen lassen. Das genaue Vorgehen wird in Abschnitt 5.2 an einem konkreten Beispiel geübt.

Eine Folge von SPSS-Kommandos kann man (leicht hochstaplerisch) als **SPSS-Programm** bezeichnen. In fast jedem Projekt sollte es mindestens *ein* SPSS-Programm geben, nämlich das bereits in Abschnitt 3.2.4 vorgeschlagene **Transformationsprogramm**, das aus der Rohdatendatei durch diverse Transformationen die Fertigdatendatei des Projekts erstellt. Wir werden für unser KFA-Projekt ein solches Programm in Kapitel 6 erstellen.

Ob sich bei einer konkreten Anweisungssequenz das Abspeichern als SPSS-Programm lohnt, muss von Fall zu Fall entschieden werden. Bei kurzen, simplen Sequenzen mit geringer Wiederholungswahrscheinlichkeit ist ein Konservieren unrentabel.

Es soll nicht verschwiegen werden, dass die Ausführung einer Anweisungssequenz mit dem Umweg über ein Syntaxfenster geringfügig mehr SPSS-Kenntnisse erfordert als die direkte Ausführung durch Quittieren von Dialogboxen mit **OK**. Wer sich beim Umgang mit SPSS-Kommandos unsicher fühlt, bei seinem relativ kleinen Projekt eventuell erforderliche Wiederholungen von Dialogbox-Sequenzen nicht scheut und das Risiko inkonsistenter Datenzustände durch Sorgfalt kontrolliert, der kann auf das Erzeugen und Abspeichern von SPSS-Kommandos verzichten.

Für ambitionierte SPSS-Anwender(innen) muss noch klargestellt werden, dass die Erstellung, Überarbeitung und Ausführung von Programmen in einem Syntaxfenster eine eigenständige Methode der SPSS-Benutzung darstellt, über die fast alle Leistungen des Programms erreichbar sind. Viele SPSS-Optionen stehen sogar *ausschließlich* über die Syntax zur Verfügung, z.B.:

- die Conjoint-Analyse
- Kontrollstrukturen, mit denen man Datentransformationen auf effiziente Weise durchführen kann (wie z.B. die DO REPEAT - Schleife)
- die MATRIX-Programmiersprache, mit der man eigene Statistikprozeduren erstellen kann

Im aktuellen Kapitel 5 werden nur sehr elementare Hinweise zur Kommandosprache gegeben. Diese sollten genügen für Anwender, die nicht frei programmieren, sondern nur gelegentlich ein von SPSS erzeugtes Kommando modifizieren wollen. Der Anhang zu diesem Manuskript enthält eine ausführlichere Beschreibung der Kommandosprache. Eine vollständige Dokumentation auf ca. 2200 Seiten finden Sie als PDF-Dokument im Hilfesystem von SPSS über

Hilfe > Befehlssyntax-Referenz

Dieses Dokument ist nicht nur ein gutes Nachschlagewerk mit Details zu allen Kommandos, sondern bietet im Kapitel *Universals* auch eine Einführung in generelle Themen im Zusammenhang mit Kommandos, Dateien, Variablen und Transformationen. Wertvolle Informationen bietet auch die syntaxorientierte Einführung von Levesque & IBM Corp. (2011) in die Datenverwaltung mit SPSS.

Wie schon erwähnt, sind die Dialogboxen beim Erstellen eines SPSS-Programms sehr nützlich. Mit Hilfe der bislang ignorierten Schaltfläche **Einfügen** kann man die zu einer Dialogbox-Bearbeitung äquivalente Kommandofolge in ein Syntaxfenster übertragen. Sie müssen sich also nicht zwischen zwei unabhängigen SPSS-Bediensystemen entscheiden, sondern können eine rationelle Kombination der beiden Techniken verwenden.

5.2 Dialogunterstützte Erstellung von SPSS-Programmen

Das folgende SPSS-Programm führt für unser KFA-Projekt die Verteilungs- und Fehleranalysen für die Variablen GESCHL, FB, AERGO, AERGM, GEBJ, GROESSE und GEWICHT durch (vgl. Kapitel 4):

```
GET
  FILE='U:\Eigene Dateien\SPSS\kfar.sav'.
DATASET NAME DatenSet1 WINDOW=FRONT.

DATASET ACTIVATE DatenSet1.
FREQUENCIES VARIABLES=geschl fb
  /BARCHART FREQ
  /ORDER=ANALYSIS.


FREQUENCIES VARIABLES=aergo aergm gebj groesse gewicht
  /FORMAT=NOTABLE
  /NTILES=4
  /STATISTICS=STDDEV VARIANCE MINIMUM MAXIMUM MEAN MEDIAN
  SKEWNESS SESKEW KURTOSIS SEKURT
  /HISTOGRAM NORMAL
  /ORDER=ANALYSIS.
```

Wir werden dieses Programm gleich mit drei Mausklicks auf **Einfügen**-Schalter produzieren und dabei auch seine Bestandteile kurz beschreiben. Als Ausgangssituation für die anschließenden Erläuterungen wird eine neue SPSS-Sitzung mit einem leeren Datenfenster angenommen. Verzichten Sie also beim SPSS-Start auf das Öffnen einer Datendatei per Begrüßungsdialog (z.B. durch einen Mausklick auf den Schalter **Abbrechen**). Dabei erhalten Sie ein leeres Daten-


fenster mit dem Namen **DatenSet0**. Rufen Sie die Dialogbox zum Öffnen einer Datendatei mit dem folgenden Menübefehl auf:

Datei > Öffnen > Daten

Navigieren Sie zum Ordner mit Ihrer Rohdatendatei, schreiben oder klicken Sie deren Namen in das Feld **Dateiname**, und betätigen Sie dann den Schalter **Einfügen**.



Daraufhin beginnt SPSS *nicht* damit, aus der angegebenen Datendatei ein neues Datenset zu erstellen, sondern schreibt das für diese Aktionen zuständige GET-Kommando in ein Syntaxfenster:



Das GET-Kommando ist sehr einfach aufgebaut:


- Es beginnt mit dem Kommandonamen GET.
- Im FILE-Subkommando wird die zu öffnende Datendatei angegeben.
- Am Ende muss wie bei jedem SPSS-Kommando ein **Punkt** stehen.

Das zusätzlich angelegte Kommando DATASET NAME gibt dem per GET erzeugten neuen Datenblatt den Namen **DatenSet1** und holt es in den Vordergrund, macht es also zur Arbeitsdatei. Auch das Kommando DATASET NAME endet mit einem Punkt.

Noch sind die beiden Kommandos nicht ausgeführt worden, und das leere Datenblatt mit dem Namen **DatenSet0** ist immer noch die Arbeitsdatei. Der Versuch, zur Produktion des ersten FREQUENCIES-Kommandos über dem Menübefehl

Analysieren > Deskriptive Statistiken > Häufigkeiten...

eine Häufigkeits-Dialogbox zu öffnen, führt daher zur Meldung:



Brechen Sie diesen Dialog ab, und lassen Sie die im Syntaxfenster befindlichen Kommandos GET und DATASET NAME ausführen, um die Daten einzulesen. Wählen Sie dazu im Syntaxfenster den Menübefehl

Ausführen > Alle

Daraufhin werden folgende Aktionen ausgeführt:

- Es wird ein neues, noch unbenanntes Datenblatt angelegt.
- Dorthin werden die Daten aus der angegebenen Datei kopiert.
- Das neue Datenblatt ist mit der Rohdatendatei **kfar.sav** verbunden.
- Das beim Programmstart vorhandene, leere Datenblatt mit dem Namen **DatenSet0** wird geschlossen.
- Das neue Datenblatt erhält den Namen **DatenSet1** und gelangt in den Vordergrund, wird also zur Arbeitsdatei

Spezifizieren Sie jetzt mit Hilfe der zuständigen Dialogbox dieselbe Häufigkeitsanalyse zu den Variablen GESCHL und FB wie in Abschnitt 4.3. Verlassen Sie die Dialogbox jedoch nicht mit **OK**, sondern mit **Einfügen**. Daraufhin erscheint am Ende des Syntaxfensters ein FREQUENCIES-Kommando (siehe oben):

- Es beginnt mit dem Kommandonamen FREQUENCIES.
- Im VARIABLES-Subkommando ist angegeben, welche Variablen analysiert werden sollen.
- Das BARCHART-Subkommando sorgt dafür, dass Balkendiagramme mit einer Häufigkeitsbeschriftung erscheinen.
- Das ORDER-Subkommando entscheidet bei der Analyse mehrerer Variablen darüber, ob die Statistiken für jede Variable in einer eigenen Tabelle oder für alle Variablen in einer gemeinsamen Tabelle erscheinen sollen. Um diese Entscheidung in der **Häufigkeiten**-Dialogbox zu treffen, müssen Sie übrigens die **Format**-Subdialogbox öffnen und im Rahmen **Mehrere Variablen** die passende Option wählen.
- Das FREQUENCIES-Kommando wird wie jedes SPSS-Kommando durch einen **Punkt** abgeschlossen.

Das zusammen mit der Häufigkeitsanalyse automatisch erstellte Kommando

```
DATASET ACTIVATE DatenSet1.
```


aktiviert vorsichtshalber das mit der Rohdatendatei **kfar.sav** verbundene **DatenSet1**. Es ist momentan überflüssig, weil gar kein anderes Datenblatt existiert.

Produzieren Sie als Nächstes die Syntax zu der in Abschnitt 4.5 durchgeführten Häufigkeitsanalyse für die Variablen AERGO, AERGM, GEBJ, GROESSE und GEWICHT.

Nun sollte Ihr Syntaxfenster den zu Beginn des Abschnitts wiedergegebenen Inhalt haben. Die Kommandos GET und DATASET NAME sind schon gelaufen. Das Kommando DATASET ACTIVATE ist momentan überflüssig, doch würde seine Ausführung keinen Schaden anrichten.

Um die Häufigkeitsanalysen zu erhalten, müssen Sie die beiden FREQUENCIES-Kommandos ausführen lassen. Weil es sich um eine Teilmenge der im Syntaxfenster vorhandenen Kommandos handelt, müssen Sie folgendermaßen vorgehen:

- Markieren Sie zunächst per Maus *die beiden* auszuführenden Kommandos, wobei von jedem Kommando wenigstens ein Zeichen in die Markierung einbezogen werden muss, z.B.:



- Klicken Sie dann auf den Symbolleisten-Schalter , oder drücken Sie die Tastenkombination **Strg+R**. Daraufhin werden alle Kommandos im Syntaxfenster ausgeführt, die (zumindest teilweise) markiert sind.

Im Ausgabefenster protokolliert SPSS per Voreinstellung die verarbeiteten Kommandos in **Protokoll**-Teilausgaben, falls Sie dieses Verhalten nicht per **Optionen**-Dialog auf der Registerkarte **Viewer** abschalten (siehe Abschnitt 3.2.3). Außerdem protokolliert SPSS zu jeder Analyseanforderung in der zunächst zugeklappten Teilausgabe **Hinweise** u.a. die zugrunde liegende Syntax, z.B.:

Hinweise

Ausgabe erstellt		26-FEB-2014 02:51:21
Kommentare		
Eingabe	Daten	U:\Eigene Dateien\SPSS\kfar.sav
	Aktives Dataset	DataSet1
	Filter	<ohne>
	Stärke	<ohne>
	Aufgeteilte Datei	<ohne>
	Anzahl Zeilen in Arbeitsdatendatei	31
Handhabung fehlender Werte	Definition von 'Fehlend'	Benutzerdefiniert fehlende Werte werden als fehlend behandelt
	Verwendete Fälle	Die Statistik basiert auf allen Fällen mit gültigen Daten.
Syntax		FREQUENCIES VARIABLES=geschl fb /BARCHART FREQ /ORDER=ANALYSIS.
Ressourcen	Prozessorzeit	00:00:01,42
	Verstrichene Zeit	00:00:00,84

Damit sich durch spätere Wiederverwendung der SPSS-Kommandos der gewünschte Rationalisierungseffekt einstellen kann, müssen Sie Ihr SPSS-Programm sichern. Wechseln Sie dazu nötigenfalls zum Syntaxfenster, und wählen Sie den Menübefehl:

Datei > Speichen unter...

Verwenden Sie im Dateinamen die vorgeschlagene Erweiterung **.sps**, indem Sie *keine* Erweiterung angeben.

Wenn Sie später dieselbe Auswertung nochmals benötigen, müssen Sie lediglich das vorhandene Programm mit dem Menübefehl:

Datei > Öffnen > Syntax

laden und ausführen lassen.

Um die Ausführung *sämtlicher* Kommandos in einem Syntaxfenster anzuordnen, haben Sie folgende Möglichkeiten:

- Menübefehl **Ausführen > Alle**
- Alle Kommandos markieren (z.B. mit **Strg+A**) und die Ausführung anfordern (z.B. per Mausklick auf das Symbol  oder mit der Tastenkombination **Strg+R**)

Lässt man obiges Programm innerhalb einer SPSS-Sitzung erneut komplett ausführen, erscheinen folgende Warnungen im Ausgabefenster:

```
GET
FILE='U:\Eigene Dateien\SPSS\kfar.sav'.
```

```
Warnung Nr. 67. Befehlsname: GET FILE
Das Dokument wird bereits von einem anderen Benutzer oder Prozess verwendet.
Wenn Sie das Dokument ändern, können so Änderungen anderer Benutzer
überschrieben oder Ihre Änderungen durch andere überschrieben werden.
Geöffnete Datei U:\Eigene Dateien\SPSS\kfar.sav
DATASET NAME DatenSet1 WINDOW=FRONT.
```


Warnungen

Das aktive Daten-Set ersetzt das vorhandene Daten-Set mit dem Namen DatenSet1.


Leider sorgt die generell begrüßenswerte Möglichkeit, in einer SPSS-Sitzung *mehrere* Datenblätter zu verwenden, aktuell für eine Komplikation. Damit daraus keine Konfusion wird, müssen wir das Geschehen im Detail verfolgen:

- Vor dem erneuten Ausführen des Programms existiert ein Datenblatt mit dem Namen **DatenSet1**, das mit der Rohdatendatei **kfar.sav** verbunden ist.
- Das erneut ausgeführte GET-Kommando erzeugt ein neues Datenblatt und kopiert den Inhalt der Rohdatendatei dorthin.
- Die erste Warnung vor dem Parallelzugriff auf die Datei **kfar.sav** ist unkritisch, wie der weitere Verlauf zeigt.
- Die Rohdatendatei **kfar.sav** bleibt mit dem älteren Datenblatt verbunden, das noch den Namen **DatenSet1** trägt.
- Das erneut ausgeführte Kommando DATASET NAME gibt dem neuen Datenblatt den bereits in Verwendung befindlichen Namen **DatenSet1**, woraufhin das alte Datenblatt mit diesem Namen geschlossen wird (siehe zweite Warnung).

Insgesamt führt die erneute Ausführung des Programms dazu, dass ein Datenblatt namens **DatenSet1** mit dem Inhalt der Rohdatendatei existiert, das aber *nicht* mit der Rohdatendatei verbunden ist:



Wenn dieses Verhalten stört, kann man z.B. die Kommandos DATASET NAME und DATASET ACTIVATE streichen. Dann bleibt das per GET befüllte und mit der Rohdatendatei verbundene Datenblatt unbenannt und wird bei jeder Ausführung des Programms überschrieben(!):



5.3 Arbeiten mit dem Syntax-Fenster

In einem Syntaxfenster lassen sich automatisch erstellte SPSS-Kommandos leicht modifizieren, um z.B. die in einer Statistikprozedur zu analysierenden Variablen auszutauschen.

Man kann ein neues Syntaxfenster auch unabhängig vom **Einfügen**-Schalter einer Dialogbox direkt anfordern mit:

Datei > Neu > Syntax


Wenn *mehrere* Syntaxfenster vorhanden sind, muss geregelt werden, in welches Fenster SPSS die per **Einfügen**-Schalter automatisch erzeugten Kommandos übertragen soll. Dies geschieht genauso wie bei den Ausgabefenstern: Ein Mausklick auf den aktiven Schalter  in seiner Symbolleiste macht ein Syntaxfenster zum **Hauptfenster** in seiner Kategorie. Es ist an einem Pluszeichen im Symbol zum Systemmenü  zu erkennen (siehe linken Rand der Titelzeile).

Um ein bestimmtes Syntaxfenster in den Vordergrund zu holen, können Sie es anklicken oder über das **Fenster**-Menü eines beliebigen SPSS-Fensters wählen. Jedes Syntaxfenster kann auf Windows-übliche Weise geschlossen werden, z.B. über den Menübefehl:

Datei > Schließen

Wenn SPSS bei der Ausführung eines Programms unerwartet und ohne Fehlermeldung stoppt, haben Sie vermutlich per Mausklick im Bereich der Zeilennummerierung einen **Haltepunkt** ge-

setzt. Im folgenden Syntaxfenster ist ein Haltepunkt neben der Startzeile des zweiten FREQUENCIES-Kommandos zu sehen:



Nach dem Starten über den Menübefehl

Ausführen > Alle

wird das Programm durch den Haltepunkt gestoppt und kann über den Symbolschalter  fortgesetzt werden. Um einen Haltepunkt zu beseitigen, setzt man einen Mausklick darauf. Über den Menübefehl

Tools > Alle Haltepunkte löschen

wird man alle Haltepunkte wieder los.

Wenn Sie längere Zeit mit SPSS arbeiten, wird sich vermutlich Ihr Umgang mit SPSS-Syntax in folgenden Stufen weiterentwickeln:

- Kommandos automatisch erzeugen lassen und später unverändert wiederverwenden
Bei dieser Arbeitsweise müssen Sie nur wissen, wie man SPSS-Kommandos per Dialog-box in ein Syntaxfenster befördert, und wie man überflüssige Kommandos löscht.
- Automatisch erzeugte Kommandos modifizieren
Es zeigt sich, dass SPSS-Kommandos meist leicht zu durchschauen und zu modifizieren sind.
- Freies Programmieren

5.4 Elementare Regeln zur SPSS-Syntax

Für den im Kurs vorgeschlagenen Einsatz von SPSS-Kommandos sollte die Kenntnis der folgenden Regeln genügen:

- Ein Kommando besteht aus seinem Namen und den Spezifikationen, die sich aus Schlüsselwörtern (z.B. VARIABLES, STATISTICS), Variablennamen usw. zusammensetzen, z.B.:

Kommandoname	→	FREQUENCIES
Spezifikationen	{	VARIABLES=gesch1 fb /BARCHART FREQ /ORDER=ANALYSIS.


- Bei den Schlüsselwörtern der SPSS-Kommandosprache ist die Groß-/Kleinschreibung irrelevant. Bei der automatisch (per **Einfügen**-Schalter) erzeugten Syntax schreibt SPSS die Schlüsselwörter in Großbuchstaben.
- Zwei Elemente der Kommandosprache sind durch mindestens ein Leerzeichen oder durch einen Zeilenwechsel voneinander zu trennen. Manche Zeichen mit festgelegter Bedeutung wie z.B. "=", "/", "(", "+", ">" sind allerdings selbstbegrenzend, d.h. davor und danach sind keine Leerzeichen nötig (aber erlaubt).
- Ein Kommando kann sich über beliebig viele Fortsetzungszeilen erstrecken, dabei dürfen aber *innerhalb* des Kommandos keine Leerzeilen auftreten. Diese signalisieren nämlich per Voreinstellung (wie der Punkt) das Ende des Kommandos.
- *Zwischen* zwei Kommandos dürfen beliebig viele Leerzeilen stehen, was eine übersichtliche Gestaltung von SPSS-Programmen erlaubt.
- Jedes Kommando muss in einer neuen Zeile beginnen.
- **Es ist dringend zu empfehlen, jedes Kommando explizit mit einem Punkt zu beenden.**

Gut kommentierte Programme sind später leichter zu verstehen. Die SPSS-Syntax bietet zum Kommentieren das Kommando COMMENT, dessen Name durch ein Sternchen ersetzt werden darf, z.B.:

```
* Mit diesem Programm wird die Rohdatendatei KFAR.SAV
  auf Erfassungsfehler untersucht.
GET
  FILE='U:\Eigene Dateien\SPSS\KFAR.SAV'.
. . .
```

Beachten Sie beim Kommentar-Kommando:

- Es darf sich über beliebig viele Fortsetzungszeilen erstrecken, wobei innerhalb des Kommandos keine Leerzeilen erlaubt sind.
- **Jedes Kommentar-Kommando sollte unbedingt mit einem Punkt abgeschlossen werden.** Wenn Sie den Punkt am Ende vergessen, dann betrachtet SPSS den folgenden Programmtext bis zum nächsten Punkt (oder zur nächsten Leerzeile) als Teil des Kommentars! Dank der farblichen Unterscheidung von Syntaxbestandteilen (mit grauer Schrift für die Kommentare) fällt dieser Fehler allerdings sofort auf, z.B.:



- Endet eine Kommentarzeile mit einem Punkt, so betrachtet SPSS das Kommentar-Kommando als abgeschlossen. Wenn Sie einen Punkt als *Satzzeichen* ans Ende einer Kommentarzeile gesetzt haben, müssen Sie die nächste Kommentarzeile also wieder mit COMMENT oder * einleiten.
- Punkte innerhalb einer Kommentarzeile sind kein Problem.

6 Datentransformation

Die zur Untersuchung unserer differentialpsychologischen Hypothese benötigte Optimismus-Variable existiert noch nicht, sondern muss erst aus den 12 LOT-Variablen berechnet werden. Vor dieser Berechnung müssen allerdings die aus messtechnischen Gründen umgepolten (negativ formulierten) LOT-Fragen geeignet rekodiert werden (z.B. Frage 3).¹ Es ist typisch für empirische Studien, dass vor dem eigentlichen Start der Datenanalyse aus den Rohvariablen mit zahlreichen Datentransformationen neue oder modifizierte Fertigvariablen erstellt werden müssen. Dabei geht es sowohl um sorgfältig zu absolvierende Pflichtübungen (z.B. LOT-Berechnung nach den Vorschriften der Testautoren) als auch um kreative Begriffsbildungen mit dem Ziel, durch geschickte Kombination vorhandener Informationen begrifflichen Mehrwert zu schaffen. Wir werden z.B. aus den „einfachen“ Begriffen *Gewicht* und *Größe* den für unsere ernährungswissenschaftlichen Begleitstudien relevanten *Body Mass Index* nach folgender Formel berechnen:

$$\frac{\text{Gewicht (in kg)}}{\text{Größe}^2 \text{ (in m)}}$$

Im aktuellen Kapitel werden Sie häufig benötigte SPSS-Befehle zur Datentransformation kennen lernen. Diese wirken sich auf die Arbeitsdatei (das aktive Datenblatt) aus, wo entweder neue Variablen aufgenommen oder vorhandene Variablen verändert werden.

Per Voreinstellung werden dabei *alle Fälle gleichermaßen* behandelt. Man kann die Ausführung einer Datentransformation aber auch von einer Bedingung abhängig machen, so dass nicht mehr alle Fälle davon betroffen sind. Diese Möglichkeit werden wir dazu verwenden, die MD-Behandlung bei den Motiv-Variablen in Ordnung zu bringen, indem wir genau für die Fälle mit

$$\text{MOTIV1} = \text{MOTIV2} = \dots = \text{ANDERE} = 0$$

bei allen genannten Variablen die Null durch SYSMIS ersetzen.

SPSS unterstützt Transformationen für Variablen beliebigen Typs. Wir beschränken uns jedoch auf die besonders wichtigen numerischer Variablen.

6.1 Vorbemerkungen

6.1.1 Transformationsprogramm

In Abschnitt 3.2.4 wurde vorgeschlagen, zu jedem Projekt ein SPSS-Transformationsprogramm zu erstellen, dessen Aufgabe darin besteht, ausgehend von der Rohdatendatei alle Fertigvariablen zu entwickeln, die im weiteren Verlauf routinemäßig benötigt werden. *Alle* potentiell relevanten Variablen (roh oder fertig) sollen in eine erweiterte Datendatei gesichert werden, die sich für alle Auswertungsarbeiten eignet.² Mit Rücksicht auf diese Idee haben wir die bislang existierende

¹ Das Rekodieren ist keine zwingende Voraussetzung für die Berechnung des Optimismus-Schätzwerts, hat aber gravierende Vorteile (z.B. einfachere Berechnung, Möglichkeit zur Skalenanalyse).

² Unter gewissen, am ehesten in großen Projekten anzutreffenden Umständen kann es sinnvoll bzw. notwendig sein, die auszuwertenden Daten in *mehreren* Dateien bereitzuhalten. Werden die Variablen oder Fälle einer Tabelle auf mehrere Dateien verteilt, kann es leicht zu dem Problem kommen, dass sich die in einer Analyse zu vergleichenden Fälle oder Variablen in verschiedenen Dateien befinden. Treten in einem Projekt mehrere Entitäten auf (z.B. Kunden und Mitarbeiter), werden natürlich entsprechend viele Datendateien benötigt.

Datendatei mit **kfar.sav** (*r* für *roh*) bezeichnet. Im Namen der Fertigdatendatei werden wir das **r** dann weglassen.

Wir werden im Verlauf des aktuellen Kapitels das SPSS-Transformationsprogramm zu unserem KFA-Projekt erstellen, indem wir passend konfigurierte Dialogboxen mit dem Schalter **Einfügen** quittieren, um die äquivalenten SPSS-Kommandos in einem Syntaxfenster zu sammeln (vgl. Kapitel 5). Dabei ist eine hohe Sorgfalt erforderlich, weil fehlerhafte Anweisungen im Transformationsprogramm schwerwiegende Konsequenzen für die weitere Arbeit haben können.

Das fertige Transformationsprogramm wird anschließend ausgeführt, wobei die Fertigdatendatei entsteht. Außerdem wird das Transformationsprogramm in einer Datei gespeichert, damit es z.B. nach einer Stichprobenerweiterung ohne großen Aufwand erneut ausgeführt werden kann. Als Dateinamen werden wir **kfat.sps** verwenden.

Man kann alle erforderlichen Transformationen auch durch direkte Ausführung der zuständigen Dialogboxen erledigen (Schalter **OK**). Diese Arbeitsweise ist zweifellos für Anfänger leichter zu handhaben als die programmorientierte Methode, hat aber folgende Nachteile:

- Beim sukzessiven manuellen Modifizieren der Datendatei geht bei größeren Projekten leicht der Überblick verloren. Z.B. weiß irgendwann von einer abgeleiteten Variablen niemand mehr, in welchen Zwischenschritten sie aus welchen Rohvariablen berechnet worden ist. Spätestens nach dem Auftreten unplausibler Ergebnisse muss die *tatsächlich* angewendete Berechnungsvorschrift als mögliche Fehlerquelle überprüft werden. Bei der Verwendung eines Transformationsprogramms ist die Herkunft der abgeleiteten Variablen stets dokumentiert.
- Sind Wiederholungen von Datentransformationen erforderlich, müssen diese komplett neu spezifiziert werden. Solche Wiederholungen sind z.B. nach einer Datenkorrektur fällig, weil SPSS abgeleitete Variablen **nicht** automatisch anpasst, wenn sich Werte der Ursprungsvariablen ändern. Nach einer Korrektur bei einer Rohvariablen müssen Sie also alle Datentransformationen wiederholen, bei denen diese Rohvariable direkt oder indirekt beteiligt ist. Ein weiterer potentieller Anlass für die Wiederholungen von Datentransformationen ist die Erweiterung der Stichprobe.

Die für ein Projekt erforderlichen Datentransformationen in Form von SPSS-Kommandos zu konservieren, lohnt sich meistens, denn:

- Die einzelnen Anweisungen sind relativ komplex und damit ebenso fehleranfällig wie zeitaufwändig.
- Es ist relativ wahrscheinlich, dass die gesamte Anweisungsfolge wiederholt durchgeführt werden muss (z.B. bei entdeckten Fehlern in den Rohvariablen oder bei einer Stichprobenerweiterung).
- Die Anweisungen zur Datentransformation sind dokumentationspflichtig.


6.1.2 Datensicherheit

Ihre Rohdaten können nach der sorgfältigen Datenerfassung und -prüfung als korrekt gelten. Sichern Sie den erreichten Stand, indem Sie die Rohdaten in mindestens **zwei** Dateien speichern (möglichst auf verschiedenen Datenträgern).

Es ist sinnvoll, für beide Dateien das Schreibschutzattribut zu setzen, was für eine in SPSS geöffnete Datendatei über den folgenden Menübefehl des Dateneditorfensters geschehen kann:

Datei > Datei als schreibgeschützt markieren

Alternativ lässt sich der Schreibschutz per Windows-Explorer im Eigenschaftsdialog einer betroffenen Datei aktivieren, z.B.:




Vor der geplanten Änderung einer Datei muss der Schreibschutz wieder aufgehoben werden.

Mit dem SPSS-Kommando PERMISSIONS lässt sich der Schreibschutz auch per Syntax (de)aktivieren. Man muss das Kommando manuell verfassen, was aber aufgrund seines einfachen Aufbaus keine Schwierigkeiten macht, z.B.:

```
PERMISSIONS FILE = 'U:\Eigene Dateien\SPSS\kfar.sav' /PERMISSIONS READONLY.  
PERMISSIONS FILE = 'U:\Eigene Dateien\SPSS\kfar.sav' /PERMISSIONS WRITEABLE.
```

Nach seiner Fertigstellung verdient auch das Transformationsprogramm eine sorgfältige Aufbewahrung.

Wenn Sie beim Verlassen von SPSS gefragt werden, ob Sie ein Daten- oder Syntaxfenster sichern wollen, sollten Sie sehr sorgfältig prüfen, ob beim betroffenen Dokument während der Sitzung tatsächlich nur geplante Veränderungen stattgefunden haben.



Antworten Sie im Zweifelsfall mit **Nein**. Möglicherweise haben Sie durch unbeabsichtigte Tastendrucke Daten gelöscht oder verändert. Diese Fehler sollten dann auf keinen Fall auf einen permanenten Datenträger (z B. Festplatte) geschrieben werden.

6.1.3 Initialisierung neuer numerischer Variablen

Wenn Sie in einer Datentransformationsanweisung die Erstellung einer *neuen* numerischen Variablen anfordern, dann wird die (Fälle $\times$ Variablen) - Datenmatrix in der Arbeitsdatei (im aktiven Datenblatt) um eine Spalte erweitert (am rechten Rand). SPSS initialisiert zunächst die neue Variable, indem alle Fälle den MD-Indikator SYSMIS als vorläufigen Wert erhalten. Gelingt anschließend für einen Fall die Ermittlung der neuen Variablenausprägung, dann wird der Initialwert entsprechend ersetzt. Anderenfalls bleibt SYSMIS stehen, so dass der betroffene Fall bei allen Berechnungen mit der neuen Variablen ausgeschlossen wird.

6.2 Alte Werte einer Variablen auf neue abbilden (Umkodieren)

Mit den Befehlen zum **Umkodieren** aus dem Menü **Transformieren** bzw. mit dem äquivalenten RECODE-Kommando können die Werte einer bestehenden Variablen in neue Werte überführt werden. Man kann die Ausgangsvariable verändern oder eine neue Variable mit dem rekodierten Wertevektor erstellen.

6.2.1 Das praktische Vorgehen am Beispiel einer Gruppenbildung

Da wir im Kapitel 6 das KFA-Transformationsprogramm sukzessive aufbauen wollen, benötigen wir eine Arbeitsdatei mit unseren Rohdaten. Öffnen Sie daher nötigenfalls über den Menübefehl

Datei > Öffnen > Daten

die Rohdatendatei **kfar.sav**, wobei ein benanntes, der Rohdatendatei zugeordnetes Datenblatt entsteht.

Um das Umkodieren zu üben, wählen wir ein mäßig sinnvolles Beispiel aus unserer Studie: Wir konstruieren unter dem Namen DEKADE eine vergrößerte Variante der Jahrgangsvariablen, bei der alle in den 60'er Jahren geborenen Personen den Wert 1 und alle in den 70'er Jahren geborenen Personen den Wert 2 erhalten sollen. Wie man sich anhand der Häufigkeitstabelle zur Variablen GEBJ

		Geburtsjahr			
		Häufigkeit	Prozent	Gültige Prozente	Kumulierte Prozente
Gültig	1961	1	3,2	3,2	3,2
	1964	1	3,2	3,2	6,5
	1965	1	3,2	3,2	9,7
	1966	2	6,5	6,5	16,1
	1967	7	22,6	22,6	38,7
	1968	3	9,7	9,7	48,4
	1969	2	6,5	6,5	54,8
	1970	7	22,6	22,6	77,4
	1972	3	9,7	9,7	87,1
	1974	2	6,5	6,5	93,5
	1975	2	6,5	6,5	100,0
	Gesamt	31	100,0	100,0	

überzeugen kann, ist damit für alle Fälle in unserer Stichprobe ein DEKADE-Wert definiert. Mit Hilfe der neuen Variablen kann man z.B. den Einfluss des Geburtsjahrzehnts auf diverse abhängige Variablen untersuchen, wobei man sich von der Informationsreduktion (im Vergleich zu GEBJ) keinen allzu großen Nutzen versprechen sollte.

Es hat sich mittlerweile herumgesprochen, dass die Informations-reduzierende und willkürliche Gruppenbildung selten Nutzen stiftet, aber oft zu Problemen führt:

- Reduzierte Power in Folge von erhöhter Fehlervarianz
- Verfälschte Ergebnisse bei datenabhängiger Wahl von Trennpunkten

Von diesen Problemen ist insbesondere die beliebte Median-Dichotomisierung betroffen (siehe z.B. MacCallum et al. 2002).

Bei der geplanten Rekodierung wird die (Fälle $\times$ Variablen)-Datenmatrix der Arbeitsdatei um eine neue Variable erweitert, die folgendermaßen aus der vorhandenen Variablen GEBJ entsteht:


GEBJ		DEKADE
1969	→	1
1970	→	2
1969	→	1
1967	→	1
.		.
.		.
.		.
1972		2
1968	→	1
1967	→	1
1967	→	1

Wählen Sie den Menübefehl

Transformieren > Umkodieren in andere Variablen

und machen Sie folgendermaßen weiter:


- Befördern Sie in der Dialogbox **Umkodieren in andere Variablen** die Variable GEBJ in das Feld **Eingabevariable -> Ausgabevariable**. Statt den Schalter  zu benutzen, können Sie in SPSS solche Transportaufgaben auch per Drag & Drop (Ziehen und Ablegen) erledigen:



- Tragen Sie im Bereich **Ausgabevariable** den gewünschten **Namen** der neu zu erzeugenden Variablen ein.

- Optional kann eine **Beschriftung** ergänzt werden. Wir verzichten darauf, so dass der Variablenname *Dekade* auch zur Beschriftung der Ausgabe verwendet werden wird. In dieser Situation sollte man beim Variablennamen auf die korrekte Schreibweise achten.
- Klicken Sie auf **Ändern**.

Danach müsste Ihre Dialogbox ungefähr so aussehen:



Legen Sie nun die Abbildungsregeln fest:

- Aktivieren Sie mit dem Schalter **Alte und neue Werte** die Subdialogbox **Umkodieren in andere Variablen: Alte und neue Werte**.
- Geben Sie im Rahmen **Alter Wert** den **Bereich** von 1960 bis 1969 an, und wählen Sie als zugehörigen **Neuen Wert** die Eins.
- Kompletieren Sie die Definition der ersten Abbildungsvorschrift mit **Hinzufügen**.
- Vereinbaren Sie analog die Zuordnungsvorschrift: „1970 bis 1979 → 2“.

Jetzt müssten Sie dieses Bild sehen:



Damit ist die Rekodierung vollständig spezifiziert. Quittieren Sie die Subdialogbox mit **Weiter**. Da wir das KFA-Transformationsprogramm sukzessive aufbauen wollen, müssen Sie nun in der

Dialogbox **Umkodieren in andere Variablen** auf den Schalter **Einfügen** klicken, um die implizit definierten Kommandos zu produzieren. Wir erhalten ein Syntaxfenster mit folgendem Inhalt:


```

DATASET ACTIVATE DatenSet1.
RECODE gebj (1960 thru 1969=1) (1970 thru 1979=2) INTO Dekade.
EXECUTE.

```

Das erste Kommando macht das **DatenSet1** zur Arbeitsdatei und soll verhindern, dass die nachfolgenden Kommandos auf ein ungeeignetes Datenblatt treffen. Sein Nutzen ist aber fragwürdig, weil bei einer späteren Wiederverwendung des Programms nicht unbedingt ein Datenblatt mit dem Namen **DatenSet1** und einem passenden Inhalt vorhanden ist. Hinter das RECODE-Kommando, das die Umkodierung bewirkt, hat SPSS noch ein EXECUTE gesetzt, dessen Rolle in Abschnitt 6.3 erläutert wird.

Unabhängig von den guten Argumenten für das Transformationsprogramm gibt es in Ihrer aktuellen Lernphase einen Grund, die obige **Umkodieren**-Dialogbox per **OK**-Schalter zu quittieren oder die zugehörigen Kommandos jetzt schon ausführen zu lassen: Sie können den Effekt auf die Arbeitsdatei sofort beobachten, statt bis zum Ausführen des kompletten Transformationsprogramms warten zu müssen. Weil keine Konflikte mit unserer langfristigen Strategie zu befürchten sind, kehren wir (z.B. über den Symbolschalter ) zur **Umkodieren**-Dialogbox zurück und quittieren sie mit **OK**. Anschließend befindet sich am rechten Rand der Arbeitsdatei die neue Variable DEKADE:



	andere	smg	meth1	meth2	meth3	geschl	gebj	fb	groesse	gewicht	Dekade
1	0	1	1	2	3	1	1969	1	163	51,0	1,00
2	0	1	1	2	.	1	1970	1	158	56,0	2,00
3	1	1	4	.	.	1	1969	1	174	58,0	1,00
4	0	1	1	2	5	2	1967	1	182	77,0	1,00
5	0	1	3	2	4	1	1967	1	180	69,0	1,00

6.2.2 Technische Details

Obwohl das Umkodieren eine simple Datentransformation ist, sind bei der praktischen Anwendung doch einige technische Details zu beachten:

- Über den Dialog **Umkodieren in andere Variablen** erhält man neue Variablen als reko-dierte Varianten der Ausgangsvariablen. Über den Dialog **Umkodieren in dieselben Variablen** werden vorhandene Variablen verändert.
- Bei einem Einsatz eines Umkodieren-Dialogs kann man beliebig viele Variablen gleichzeitig rekodieren.

- Bei der Spezifikation der alten Werte, die auf einen neuen Wert abgebildet werden sollen, kann man angeben:
 - Einen einzelnen **Wert**
 - **Systemdefiniert fehlend** (SYSMIS)
So ist es also möglich, den systemseitigen MD-Indikator durch einen anderen Wert zu ersetzen.
 - **System- oder benutzerdefinierte fehlende Werte**
Alle MD-Indikatoren werden umgesetzt.
 - Den **Bereich** von einem ersten Wert bis zu einem zweiten Wert (inklusive Grenzwerte)
Bei allen Bereichen (auch den anschließend behandelten halboffenen Bereichen) ist zu beachten, dass im Bereich liegende *benutzerdefinierte* MD-Indikatoren einbezogen werden. Dies lässt sich z.B. mit einer *einleitenden* Ersetzungsvorschrift (MISSING = COPY) verhindern. Um diese Vorschrift per Dialogbox zu erzeugen, wählt man als alten Wert **System- oder benutzerdefinierte fehlende Werte** und als neuen Wert **Alte Werte kopieren** (siehe unten).
 - Den **Bereich** vom kleinsten Wert in der Stichprobe bis zu einem bestimmten Wert (inklusive Grenzwert)
 - Den **Bereich** von einem bestimmten Wert bis zum größten Wert in der Stichprobe (inklusive Grenzwert)
 - **Alle anderen Werte**
Damit sind alle in keiner anderen Ersetzungsvorschrift genannten Werte angesprochen (inklusive MD-Indikatoren, auch SYMIS). Um zu verhindern, dass auch MD-Indikatoren einbezogen werden, muss man diese Werte zuvor in einer speziellen Ersetzungsvorschrift behandeln, z.B. (MISSING = COPY). **Alle anderen Werte** kann nur in *einer* Ersetzungsvorschrift angegeben werden. Diese wird von SPSS in der Liste aller Ersetzungsvorschriften automatisch an die letzte Stelle gesetzt und damit bei der Ausführung zuletzt abgearbeitet.
- Als neuen Wert, auf den die alten Werte einer Ersetzungsvorschrift abgebildet werden sollen, können Sie angeben:
 - Einen **Wert**
 - **Systemdefiniert fehlend** (SYSMIS)
Dann werden alle zugehörigen alten Werte durch SYSMIS ersetzt.
 - **Alte Werte kopieren**
Diese Möglichkeit steht nur beim Umkodieren in *andere* Variablen zur Verfügung und bewirkt für die zugehörigen alten Werte eine unveränderte Übernahme. Dies ist besonders nützlich, wenn die alten Werte mit **Alle anderen Werte** spezifiziert worden sind.
- Sie können beliebig viele Ersetzungsvorschriften festlegen. SPSS bringt diese automatisch in eine sinnvolle Ordnung.
- Bei jedem Fall wird die *erste zutreffende* Ersetzungsregel angewendet. Alle weiteren (eventuell ebenfalls zutreffenden) Ersetzungsregeln werden ignoriert.
- Um lückenlos aufeinander folgende Intervalle zu erhalten, verwendet man dieselbe Zahl zweimal als Intervallgrenze, z.B.
(1 thru 5 = 1) (5 thru 10 = 2)
Im Beispiel resultiert die Abbildung:

$[1, 5] \rightarrow 1, (5, 10] \rightarrow 2$

Bei umgekehrter Anordnung derselben Ersetzungsregeln

$(5 \text{ thru } 10 = 2) (1 \text{ thru } 5 = 1)$

erhält man hingegen die Abbildung:

$[1, 5] \rightarrow 1, [5, 10] \rightarrow 2$


- Wenn beim Umkodieren in andere Variablen eine *neue* Variable entsteht, so wird diese zunächst mit dem Wert SYSMIS initialisiert (vgl. Abschnitt 6.1.3). Wird der alte Wert eines Falles in keiner Übersetzungsregel angesprochen, dann bleibt bei der neuen Variablen der Initialisierungswert SYSMIS stehen. Dies würde in obigem Beispiel etwa einem 1980 geborenen Untersuchungsteilnehmer passieren.
- Benutzerdefinierte MD-Indikatoren werden wie gültige Werte behandelt! Ist z.B. beim **Umkodieren in dieselben Variablen** für eine Variable der Wert 99 ein benutzerdefinierter MD-Indikator, und wird die 99 rekodiert zur 98, dann **bleibt** die 99 ein MD-Indikator der Variablen, und die 98 wird **nicht** zum MD-Indikator. Eventuell muss also nach der Rekodierung die Variablendeklaration angepasst werden. Oben wurde schon erläutert, wie man bei Bereichen alter Werte die unerwünschte Mitbehandlung von benutzerdefinierte MD-Indikatoren verhindern kann.


Gelegentlich kommt es vor, dass numerische Merkmalsausprägungen in einer Variablen mit dem Typ *Zeichenfolge* landen und infolgedessen eine zusätzliche Variable mit den numerischen Werten erstellt werden muss. Dies kann per RECODE-Kommando über das Schlüsselwort CONVERT erfolgen, das nur in Verbindung mit dem Schlüsselwort INTO zulässig ist, z.B.:

```
recode astr (convert) into anum.
```

6.2.3 Übungen

1) In den beiden folgenden Dialogboxen, die wir allerdings in unserem Projekt *nicht* ausführen wollen, wird jeweils eine Umkodierung der Fachbereichsvariablen (FB) in eine andere (neue) Variable spezifiziert. Hätten die beiden Dialogboxen denselben Effekt?





2) Bei unserem LOT-Fragebogen wurden die Fragen 3, 4, 5, und 12 aus messtechnischen Gründen umgepolt (negativ formuliert). Indem eine optimistische Antwort abwechselnd durch Zustimmung oder Ablehnung zum Ausdruck kommt, wird vermieden, dass systematische Ja- oder Neinsager einen extremen Optimismuswert erhalten. Bevor wir aus den LOT-Items durch Mittelwertbildung einen Optimismus-Schätzwert berechnen können, müssen die negativ gepolten Variablen folgendermaßen umkodiert werden:

5	→	1
4	→	2
2	→	4
1	→	5

Wählen Sie den Menübefehl:

Transformieren > Umkodieren in dieselben Variablen


Quittieren Sie die bearbeitete Dialogbox **Umkodieren in dieselben Variablen** nicht mit **OK**, sondern mit **Einfügen**, damit das zugehörige RECODE-Kommando in das Syntaxfenster eingetragen wird, in dem wir gerade unser Transformationsprogramm aufbauen. Machen Sie sich klar, warum die Abbildungsvorschrift „3 → 3“ beim Umkodieren **In dieselben Variablen** überflüssig ist, beim Umkodieren in andere (neue) Variablen aber unbedingt erforderlich wäre.

6.2.4 Visuelles Klassieren


Über den Menübefehl

Transformieren > Visuelle Klassierung

ist ein Assistent zur Unterstützung der Klassenbildung zugänglich. Im ersten Schritt wählt man die Ausgangsvariable, z.B.:



Im nächsten Dialog gibt man den **Namen** und (optional) eine **Beschriftung** für die Zielvariable an:



Ein Histogramm gibt eventuell Anregungen zur Aufteilung, und mit dem Kontrollkästchen **Skala umkehren** könnte man im Beispiel dafür sorgen, dass die Klasse mit den niedrigsten Geburtsjahren den höchsten Wert bei der Zielvariablen erhält.

Nach einem Klick auf den Schalter **Trennwerte erstellen** kann man im folgenden Dialog z.B. die Bildung von zwei annähernd gleich stark besetzten Klassen veranlassen:

Im Hauptdialog wird nun der Trennwert angezeigt, z.B.:

Über den Schalter **Einfügen** erhält man u.a. das vom Assistenten erstellte RECODE-Kommando, z.B.:

```
RECODE gebj (MISSING=COPY) (LO THRU 1969=1) (LO THRU HI=2) (ELSE=SYSMIS) INTO Dekade.
```

Es führt im Beispiel zum selben Ergebnis wie unsere eigene Syntax (siehe Abschnitt 6.2.1) und demonstriert, wie man durch die geschickte Anordnung von Abbildungsvorschriften mit überlappenden Intervallen alter Werte dafür sorgt, dass *alle* alten Werte angesprochen werden.

6.3 Zur Rolle des EXECUTE-Kommandos

Wenn Sie eine **Umkodieren**-Dialogbox mit **OK** quittieren, dann führt SPSS per Voreinstellung die angeforderte Rekodierung sofort in der Arbeitsdatei aus. Obwohl dieses Verhalten sehr nahe liegend erscheint, gibt es doch eine erwägenswerte Alternative. Zum Rekodieren muss SPSS nämlich die Arbeitsdatei vollständig durchlaufen, was bei einer großen Stichprobe durchaus einige Zeit in Anspruch nehmen kann. Bei einer nächsten und übernächsten Transformationsanweisung (z.B. Rekodierung oder Neuberechnung) ist jeweils ein weiterer Durchlauf fällig. Dabei könnte SPSS zeitsparend *alle* Transformationen in einer *einzig* Datenpassage erledigen. Diese könnte so lange aufgeschoben werden, bis durch die Anforderung einer Statistikprozedur das Durchhackern der Daten unvermeidlich wäre. Genau in dem zuletzt beschriebenen, zeitökonomischen Sinn funktionieren seit jeher in SPSS die Transformationskommandos, die Änderungen an der Datenmatrix bewirken: Sie werden vorgemerkt und erst bei der nächsten Prozedur gemeinsam ausgeführt. Allerdings kann dieses zeitoptimierte Verhalten SPSS-Neulinge verwirren. Daher setzt die SPSS-Bedienoberfläche hinter jedes per Dialogbox produzierte Transformationskommando per Voreinstellung automatisch ein EXECUTE-Kommando, welches die *sofortige Ausführung* aller offenen Transformationen erzwingt. Wenn wir z.B. eine **Umkodieren**-Dialogbox mit **OK** quittieren, verarbeitet der SPSS-Prozessor im Hintergrund ein RECODE- und ein EXECUTE-Kommando. Das erste bewirkt nur eine Arbeitsvorbereitung, das zweite erzwingt die Ausführung der vorbereiteten Arbeit. Quittieren wir dieselbe Dialogbox mit **Einfügen**, erscheinen die beiden Kommandos im Syntaxfenster (siehe oben).¹


Bei der in diesem Manuskript vorgestellten Arbeitsweise sind die von SPSS produzierten EXECUTE-Kommandos in der Regel überflüssig. Aufgrund der heutzutage verfügbaren Rechenleistung lohnt es sich allerdings nur bei einer sehr großen Arbeitsdatei, die überflüssigen EXECUTE-Kommandos aus einem automatisch produzierten Programm zu entfernen. Bei einer Testdatei mit ca. 200.000 Fällen und 10 Transformationen ergab sich *mit* 9 überflüssigen EXECUTE-Anweisungen auf einem PC mit der Intel-CPU Core i7 860 eine Laufzeit von ca. 10 Sekunden, die sich durch Entfernen der überflüssigen EXECUTE-Kommandos auf ca. 1 Sekunde reduzieren ließ.

Beim Arbeiten mit dem Syntaxfenster kann es zu dem folgenden, recht frustrierenden Erlebnis kommen: Sie lassen wohlgeformte Transformationskommandos ausführen, doch im Datenfenster stellt sich nur ein partieller Erfolg ein. Zwar erscheinen die neu anzulegenden Variablen, doch haben alle Fälle den Wert SYSMIS, z.B.:

¹ Man kann nach

Bearbeiten > Optionen > Daten

im Rahmen **Optionen für Transformieren und Zusammenfügen** mit der Option **Werte vor Verwendung berechnen** die voreingestellte EXECUTE-Inflation abstellen. Dann zeigt SPSS das oben beschriebene zeitoptimierte Verhalten, führt also z.B. nach dem Quittieren einer **Umkodieren**-Dialogbox mit **OK** das zugrunde liegende RECODE-Kommando zunächst noch *nicht* aus, sondern reiht es in die Warteschlange der offenen Transformationen ein. Diese werden vom SPSS-Prozessor erst dann ausgeführt, wenn er ein Prozedur- oder ein EXECUTE-Kommando erhält.



Die Ursache ist dann meist: Sie haben nach den Transformationskommandos noch kein Prozedur- oder EXECUTE-Kommando ausführen lassen, so dass SPSS zwar die neuen Variablen initialisiert, aber noch keine Werte ermittelt hat. In dieser Situation wird in der Statuszeile angezeigt, dass **Anstehende Transformationen** vorhanden sind. Sie können deren Ausführung erzwingen, indem Sie im Syntaxfenster ein EXECUTE-Kommando abschicken oder den folgenden Menübefehl wählen:

Transformieren > Anstehende Transformationen ausführen

Es soll nicht verschwiegen werden, dass hier für SPSS-Neulinge Schwierigkeiten auftauchen, die bei rein interaktiver Dialogbox-Nutzung und voreingestelltem EXECUTE-Einsatz nicht entstehen können.

Für angehende SPSS-Profis soll noch erwähnt werden, dass EXECUTE-Kommandos *innerhalb eines Blocks von Transformationsanweisungen* durchaus bedeutsam sein können. In dem folgenden (manuell erstellten) Beispiel wird mit Hilfe des Transformationskommandos SELECT IF jeder zweite Fall aus der Arbeitsdatei entfernt:

```
compute nr = $casenum.
execute.
select if (mod(nr,2) = 1).
execute.
```

Lässt man jedoch das erste EXECUTE-Kommando weg, entfernt das Programm *alle* Fälle mit Ausnahme des ersten.

6.4 Berechnung von Variablen nach mathematischen Formeln

In der Dialogbox **Variable berechnen** bzw. im äquivalenten COMPUTE-Kommando wird ein numerischer Ausdruck (z.B. GROESSE - 100) definiert und einer Ergebnisvariablen zugewiesen. Dabei kann man eine *neue* Variable erzeugen oder eine vorhandene verändern.

6.4.1 Beispiel

Sie sollen später anhand unserer Stichprobe untersuchen, ob die Trierer Studierenden im Mittel wenigstens das folgende Idealgewicht auf die Waage bringen (Nullhypothese)

$$\overset{!}{\text{Gewicht (in kg)}} = \text{Größe (in cm)} - 100$$

oder ob sie relativ zu dieser Formel zu leicht sind (Alternativhypothese). Mit den Symbolen μ_R für den Realgewichtsmittelwert und μ_I für den Idealgewichtsmittelwert kann man die beiden konkurrierenden Hypothesen so notieren:

$$H_0 : \mu_R \geq \mu_I \quad \text{versus} \quad H_1 : \mu_R < \mu_I$$

Zur Prüfung dieser Frage mit einem t-Test für verbundene Stichproben muss die Arbeitsdatei um eine neue Variable, z.B. IDGEW genannt, erweitert werden, deren Werte nach der Formel

$$\text{GROESSE} - 100$$

aus der Körpergröße zu berechnen sind. Anschließend enthält die (Fälle $\times$ Variablen)-Datenmatrix in der Arbeitsdatei u.a. die beiden folgenden Variablen:

GROESSE	IDGEW
163	63
158	58
174	74
182	82
.	.
.	.
.	.
176	76
176	76
170	70
169	69


Starten Sie zum Definieren der neuen Variablen die Dialogbox **Variable berechnen** mit:

Transformieren > Variable berechnen

Tragen Sie zunächst im Feld **Zielvariable** den Namen für die zu erstellende Variable ein (IDGEW), und schreiben Sie dann in das Feld **Numerischer Ausdruck** die Definitionsvorschrift (GROESSE - 100), wobei einige Schreibhilfen zur Verfügung stehen:


- Der Variablenname GROESSE kann aus einer Liste per Transportschalter , Drag & Drop oder Doppelklick übernommen werden.
- Mit Hilfe einer virtuellen Tastatur können Sie das Minuszeichen und die Zahl 100 auch per Maus eingeben.

Anschließend sollte Ihre Dialogbox ungefähr so aussehen:



Die Dialogbox bietet über unsere momentanen Bedürfnisse hinausgehend auch die in SPSS verfügbaren Funktionen (vgl. Abschnitt 6.4.2.1) und spezielle Systemvariablen (z.B. **\$Casenum** mit einer bei 1 startenden Nummerierung der Arbeitsdateifälle) in **Funktionsgruppen** geordnet zum Transport in das Feld **Numerischer Ausdruck** an, so dass man bei der Verwendung von Funktionen Tippfehler vermeiden und Zeit sparen kann.

Rufen Sie nun die Subdialogbox **Typ und Beschriftung** mit dem gleichnamigen Schalter auf, und tragen Sie dort zur Variablen IDGEW die **Beschriftung** *Idealgewicht nach der Formel Größe - 100* ein:



Quittieren Sie die Subdialogbox mit **Weiter** und die Hauptdialogbox mit **Einfügen**. Daraufhin erhalten Sie im Syntaxfenster ein COMPUTE - und ein VARIABLE LABELS - Kommando:

```
COMPUTE idgew = groesse - 100.
VARIABLE LABELS idgew 'Idealgewicht nach der Formel Größe - 100'.
EXECUTE.
```

Außerdem erscheint natürlich wieder ein EXECUTE-Kommando, dessen (meist überflüssige) Rolle in Abschnitt 6.3 erläutert wurde.

6.4.2 Technische Details

Im mehrzeiligen Texteingabefeld **Numerischer Ausdruck** der Dialogbox **Variable berechnen** sind wir trotz der SPSS-Schreibhilfen mit der Aufgabe konfrontiert, „auf einem leeren Blatt“ einen formalsprachlichen Ausdruck nach gewissen Regeln zu erstellen. Zum Glück sind uns numerische Ausdrücke aus der Schule wohlbekannt.¹

Ein numerischer Ausdruck im Sinne von SPSS darf folgende Bestandteile enthalten:

- bereits definierte Variablen
- Zahlen
- arithmetische Operatoren:
 - Addition (+)
 - Subtraktion (-)
 - Multiplikation (*)
 - Division (/)
 - Potenzieren (**)
- Klammern
- Funktionen

6.4.2.1 Numerische Funktionen

In numerischen Ausdrücken können Sie zahlreiche Funktionen verwenden, die numerische Variablen oder Zahlen als Argumente (in den folgenden Syntaxdarstellungen vertreten durch den Platzhalter *arg*) verarbeiten.² Diese Funktionen lassen sich in mehrere Gruppen einteilen, aus denen anschließend jeweils einige wichtige Vertreter genannt werden sollen:

- **Arithmetische Funktionen, z.B.:**

- | | |
|------------------------------------|---|
| - ABS(<i>arg</i>) | Absoluter Wert |
| - EXP(<i>arg</i>) | Exponentialfunktion |
| - LN(<i>arg</i>) | Natürlicher Logarithmus |
| - MOD(<i>arg1</i> , <i>arg2</i>) | Rest aus der Division von <i>arg1</i> durch <i>arg2</i> |
| - RND(<i>arg</i>) | Auf die nächst gelegene ganze Zahl gerundeter Wert |
| - SQRT(<i>arg</i>) | Quadratwurzel |

Beispiel: `compute absresid = abs(res_1).`

Für jeden Fall wird von der vorhandenen Variablen RES_1 der Betrag gebildet und in der neuen Variablen ABSRESID gespeichert.

¹ Zwar gibt es gewisse Unterschiede zwischen mathematischen *Gleichungen* (z.B. $y = a + b \cdot x$) und EDV-sprachlichen *Zuweisungen* (z.B. `compute x = x + 2.`), doch sind die Regeln für die numerischen Ausdrücke auf den *rechten* Seiten weitgehend identisch.

² SPSS kennt auch zahlreiche Funktionen für String- und Datumsvariablen, die aber aus Zeitgründen in diesem Kurs nicht behandelt werden. Informieren Sie sich bei Bedarf im Hilfesystem, z.B. über eine Indexsuche nach dem Stichwort *Funktionen*.

- **Statistische Funktionen**, z.B.:

- MEAN[.m](arg1, arg2[, ...]) Arithmetisches Mittel
- MEDIAN[.m](arg1, arg2[, ...]) Median
- MAX[.m](arg1, arg2[, ...]) Maximum
- MIN[.m](arg1, arg2[, ...]) Minimum
- SD[.m](arg1, arg2[, ...]) Standardabweichung
- SUM[.m](arg1, arg2[, ...]) Summe

Regeln:

- Die eckigen Klammern schließen optionale Angaben ein.
- Der optionale Funktionsparameter *m* hat folgende Bedeutung: Wenn bei einem Fall mindestens *m* valide Argumente vorliegen, wird der Funktionswert berechnet. Ansonsten wird dem Fall der Wert SYSMIS zugewiesen. Wird *m* nicht angegeben, gelten die sehr liberalen Voreinstellungen 1 (z.B. bei MEAN) oder 2 (z.B. bei SD).

Zwei häufige Fehler beim Einsatz des Minimalanforderungsparameters *m*:

- Punkt zwischen dem Funktionsnamen und *m* vergessen

Dieser Funktionsaufruf

```
mean2(hund, katze, maus)
```

hat denselben Effekt wie der Aufruf

```
mean(hund, katze, maus)
```

- Leerzeichen zwischen dem Funktionsnamen und dem Punkt gesetzt

Dieser Funktionsaufruf

```
mean .2(hund, katze, maus)
```

führt zu einer Fehlermeldung.

- Mit „[, ...]“ wird zum Ausdruck gebracht, dass die Liste der Argumente optional beliebig verlängert werden darf.
- Man kann eine Serie von Variablen, *die in der Arbeitsdatei hintereinander stehen*, über das Schlüsselwort TO bequem in einer Argumentenliste angeben:

```
erste TO letzte
```

Beispiel:

```
compute mfrei = mean.45(sport to angeln).
```

Wenn für einen Fall bei den Variablen SPORT bis ANGELN, die in der Arbeitsdatei hintereinander stehen, mindestens 45 valide Argumente vorliegen, wird deren Mittelwert der Variablen MFREI zugewiesen, ansonsten wird der MD-Indikator SYSMIS zugewiesen.

Beachten Sie den Unterschied zwischen den gerade beschriebenen statistischen *Funktionen* und den Statistik*prozeduren*, mit denen wir z.B. die Verteilungsanalysen durchgeführt haben:

- Wenn wir in der Dialogbox **Häufigkeiten** (erreichbar über **Analysieren > Deskriptive Statistiken > Häufigkeiten**) z.B. den Mittelwert der Variablen GEWICHT anfordern, werden die (validen) Gewichtsangaben aller Fälle in der Stichprobe gemittelt. Es werden also die Ausprägungen *einer Variablen* über *alle Fälle* gemittelt. SPSS arbeitet sich *senkrecht* durch eine komplette Variable bzw. Spalte der Arbeitsdatei. Es resultiert ein einziger Stichprobenkennwert, der im Ausgabefenster erscheint.
- Mit der statistischen Funktion MEAN können wir für *jede einzelne Person* z.B. den Mittelwert über *mehrere LOT-Variablen* berechnen lassen. SPSS geht *waagerecht* vor, wobei dasselbe Verfahren *auf jeden Fall, d.h. auf jede Zeile* der Datenmatrix angewendet wird. Die statistische Funktion MEAN erzeugt

(oder modifiziert) eine Variable, d.h. eine Spalte in der Arbeitsdatei, in die für jeden Fall sein eigenes Berechnungsergebnis eingetragen wird.

- **Funktionen für fehlende Werte, z.B.:**

- `NMISS(arg1[, ...])` Anzahl fehlender Werte bei den aufgelisteten Variablen
- `NVALID(arg1[, ...])` Anzahl gültiger Werte bei den aufgelisteten Variablen
- `VALUE(arg)` Es wird der Wert der Variablen *arg* geliefert, wobei *benutzerdefinierte* MD-Deklarationen ignoriert werden.

Regeln:

- Mit „[, ...]“ wird zum Ausdruck gebracht, dass die Liste der zu untersuchenden Variablen optional beliebig verlängert werden darf.
- Mit dem Schlüsselwort `TO` kann eine Serie von Variablen angegeben werden (siehe obige Erläuterungen bei den statistischen Funktionen).

Beispiel: `compute nmfrei = nmiss(sport to angeln).`
 Der numerische Ausdruck liefert die Anzahl der fehlenden Werte (SYMIS oder benutzerdefiniert) bei den Variablen `SPORT` bis `ANGELN`, die in der Arbeitsdatei hintereinander stehen.

- **Pseudozufallszahlgeneratoren, z.B.:**

- `NORMAL(arg)` Die Funktion liefert normalverteilte Pseudozufallszahlen mit Mittelwert Null und Standardabweichung *arg*.
- `UNIFORM(arg)` Die Funktion liefert gleichverteilte Pseudozufallszahlen im Intervall von Null bis *arg*.

Beispiel: `COMPUTE av = NORMAL(1).`
`EXECUTE.`
`T-TEST`
`GROUPS=geschl(1 2)`
`/MISSING=ANALYSIS`
`/VARIABLES=av`
`/CRITERIA=CIN(.95).`

Die Kommandos in diesem Beispiel wurden mit Hilfe von Dialogboxen erzeugt (Schalter **Einfügen**). Im `COMPUTE`-Kommando wird die standardnormalverteilte Zufallsvariable `AV` erstellt. Es ist klar, dass Frauen und Männer bei `AV` denselben Erwartungswert (Populationsmittelwert) Null haben. Damit können wir ausprobieren, wie sich der t-Test für unabhängige Stichproben bei Gültigkeit der Nullhypothese verhält. Die Dialogbox zu diesem t-Test erhält man mit **Analysieren > Mittelwerte vergleichen > T-Test bei unabhängigen Stichproben**.

Wenn Ihnen die Erläuterungen zu diesem Beispiel „spanisch“ vorkommen, hilft Ihnen vielleicht der Abschnitt 7.1 weiter, wo einige Grundprinzipien der Inferenzstatistik erläutert werden. Mit dem t-Test für unabhängige Stichproben beschäftigen wir uns „offiziell“ in Kapitel 10.

Hinweis: Bei `NORMAL` und `UNIFORM` wird ein Pseudozufallszahlengenerator verwendet, der per Voreinstellung mit dem festen Wert 2.000.000 startet und damit stets dieselben Zahlen liefert. Zur Wahl eines alternativen Startwerts, der andere Pseudozufallszahlen bewirkt, haben Sie folgende Möglichkeiten:

- Menübefehl:
 Transformieren > Zufallszahlengeneratoren
- SPSS-Kommando:
 - a) Traditioneller Zufallszahlengenerator:
 SET RNG=MC SEED=*start*.
 - b) Mersenne-Twister (verbesserter Zufallszahlengenerator):
 SET RNG=MT MTINDEX=*start*.

6.4.2.2 Regeln für die Bildung numerischer Ausdrücke

Auch bei Verwendung der Dialogbox **Variable berechnen** müssen wir den numerischen Ausdruck im Wesentlichen selbst formulieren. Dabei sind folgende Regeln zu beachten:

- Sind mehrere Operatoren vorhanden, ist die **Auswertungsreihenfolge** relevant. Diese hängt von den Prioritäten der Operatoren ab. Es gilt folgende Rangordnung:

Priorität 1: Funktionen

Priorität 2: Potenzieren (**)

Priorität 3: Multiplikation (*), Division (/)

Priorität 4: Addition (+), Subtraktion (-)

Bei gleicher Priorität erfolgt die Auswertung von links nach rechts. Eine alternative Auswertungsreihenfolge kann durch Klammern erzwungen werden: Klammerausdrücke werden zuerst ausgewertet. Bei geschachtelten Klammern erfolgt die Auswertung von innen nach außen.

- Bei Funktionen mit mehreren Argumenten müssen die einzelnen Argumente **durch jeweils genau ein Komma** (optional ergänzt durch Leerzeichen) getrennt werden.

Beispiel: `compute mabc = mean.2(a,b, c).`

- Obwohl SPSS *im Daten- und im Ausgabefenster* das ländertypische Dezimaltrennzeichen benutzt, bei uns also das Komma, müssen in numerischen Ausdrücken gebrochene Zahlen generell mit **Dezimalpunkt** geschrieben werden:

Richtig: 2.75

Falsch: 2,75

Dies gilt sowohl für das Feld **Numerischer Ausdruck** der Dialogbox **Variable berechnen** als auch für das COMPUTE-Kommando in einem Syntaxfenster. Es kann also durchaus passieren, dass Sie ein und dieselbe Zahl im Datenfenster (als Wert eines Falles für eine bestimmte Variable) mit *Dezimalkomma* und in der Dialogbox **Variable berechnen** (als Konstante in einem numerischen Ausdruck) mit *Dezimalpunkt* schreiben müssen.

- Bei den meisten Funktionen sind auch numerische Ausdrücke als Argumente zugelassen. Beispiel: `compute albmax = max(a, ln(b)).`

6.4.2.3 Sonstige Hinweise

a) SYSMIS als Ergebnis eines numerischen Ausdrucks

Durch eine Berechnungsanweisung wird der Wert des numerischen Ausdrucks auch dann der Zielvariablen zugewiesen, wenn dieser Wert gleich SYSMIS ist (z.B. bei fehlenden Argumenten). Ist die Zielvariable bereits *vorhanden*, bleibt bei missglückter Berechnung des numerischen Ausdrucks keinesfalls der alte Wert bestehen, sondern wird sinnvollerweise durch SYSMIS ersetzt.

b) Rechnen mit fehlenden Werten

Fehlt bei einem Fall zur Berechnung eines numerischen Ausdrucks eine Argumentvariable, dann erhält die Ergebnisvariable den Wert SYSMIS. Ausnahmen sind die folgenden Regeln für das „Rechnen“ mit fehlenden Werten:

- $0 * \text{unbekannt} = 0$
Diese Regel ist schlau, denn für beliebige reelle Zahlen x gilt:

$$0 \cdot x = 0$$

- $0 / \text{unbekannt} = 0$
Diese Regel ist kritisierbar, denn:

$$\frac{0}{x} = \begin{cases} 0 & \text{für } x \neq 0 \\ \text{undefiniert} & \text{für } x = 0 \end{cases}$$

Im folgenden Datenfenster erhält der dritte Fall (mit dem Wert Null bei der Variablen A und einem fehlenden B-Wert) für das Produkt $A * B$ und den Quotienten A / B von SPSS den Ergebniswert Null:

	a	b	produkt	quotient	var	var	var
1	1,00	2,00	2,00	,50			
2	2,00	2,00	4,00	1,00			
3	,00	.	,00	,00			

6.4.3 Übungen

1) Welche Werte haben die folgenden numerischen Ausdrücke?

$$(3 + 4) / 2$$

$$3 + 4 / 2$$

$$(3 ** 2 / 2) + 4$$

$$3 ** 2 / 2 + 4$$

2) Erstellen Sie im KFA-Projekt die Variablen, auf die sich unsere zentralen Hypothesen beziehen (vgl. Abschnitt 1.3):

- Berechnen Sie die Variable LOT als arithmetisches Mittel der (notigenfalls rekodierten!) LOT-Items 1, 3, 4, 5, 8, 9, 11 und 12. Die restlichen Items dienen nicht zur Messung von Optimismus, sondern sollen verhindern, dass der Zweck des Fragebogens deutlich wird.

Dies könnte das Antwortverhalten verzerren.¹ Tolerieren Sie bei der Berechnung des Mittelwerts bis zu zwei fehlende Werte. Bei der Schätzung einer latenten Variablen durch den Mittelwert aus manifesten Indikatoren einige fehlende Items zu tolerieren und den Mittelwert aus den vorhandenen Items zu berechnen, ist übrigens eine spezielle Technik zur Behandlung des Problems fehlender Werte, die gelegentlich als *ipsative Mittelwerts-Imputation* bezeichnet wird (siehe Baltes-Götz 2013b, S. 21).

- Berechnen Sie die Variable AERGAM als arithmetisches Mittel der beiden Ärgervariablen und die Variable AERGZ als Ärgerzuwachs auf Grund der kontrafaktischen Alternative. AERGAM benötigen wir zum Testen der differentialpsychologischen Hypothese. Beim geplanten t-Test für abhängige Stichproben zum Vergleich der Mittelwerte von AERGO und AERGM wird letztlich mit einem Einstichproben-t-Test geprüft, ob der Erwartungswert der Differenzvariablen (AERGM - AERGO) signifikant größer Null ist. Dabei wird vorausgesetzt, dass die Differenzvariable in der Population normalverteilt ist (vgl. Abschnitt 7.1). Selbstverständlich ist es für den t-Test *nicht* erforderlich, die Differenzvariable per Datentransformation zu erstellen. Allerdings bietet die t-Test-Prozedur keine Möglichkeit, die Normalverteilungsvoraussetzung zu prüfen. Daher berechnen wir die Variable AERGZ explizit und prüfen ihre Verteilung mit der Prozedur zur explorativen Datenanalyse auf Normalität (siehe Kapitel 8).

Rufen Sie jeweils mit dem Menübefehl:

Transformieren > Variable berechnen

die zuständige Dialogbox auf. Quittieren Sie Ihre Eintragungen nicht mit **OK**, sondern mit **Einfügen**, damit die zugehörigen COMPUTE-Kommandos in das Syntaxfenster eingetragen werden, in dem gerade das Transformationsprogramm zum KFA-Projekt entsteht.

Weil SPSS eine Folge von mehreren Kommandos stets in der natürlichen Reihenfolge abarbeitet, wird beim späteren Ablauf unseres Transformationsprogramms z.B. die für einige Items angeordnete Rekodierung (vgl. Abschnitt 6.2.3) bereits erledigt sein, wenn das COMPUTE-Kommando zur LOT-Berechnung ausgeführt wird.

- 3) Erstellen Sie eine Variable namens BMI mit dem aus Körpergröße und Körpergewicht nach folgender Formel

$$\frac{\text{Gewicht (in kg)}}{\text{Größe}^2 \text{ (in m)}}$$

berechneten **Body Mass Index**. Wir werden später im Rahmen unserer ernährungsphysiologischen Begleitstudien der Frage nachgehen, ob beim BMI Geschlechtsunterschiede bestehen (siehe Kapitel 10).

- 4) Berechnen Sie aus dem Geburtsjahr der Untersuchungsteilnehmer das Alter.² Wir haben bei der Datenerhebung nach dem Geburtsjahr gefragt, weil manche Auskunftspersonen diese Information leichter und genauer liefern können als das Alter. Bei der Forschungsarbeit und in Ergebnisberichten ist das Alter jedoch anschaulicher. Außerdem ist zu befürchten, dass mit dem Wissen um den Erhebungszeitpunkt einer Studie irgendwann das Wissen um das Alter der Befragten verloren geht.

¹ Die von Scheier & Carver (1985) verwendete Verschleierungstechnik kann sicher in speziellen Fällen zur Verbesserung der Datenqualität beitragen, soll aber hier keinesfalls als Routinetechnik empfohlen werden.

² Bei Verwendung der Manuskriptstichprobe muss berücksichtigt werden, dass diese aus dem Jahr 1999 stammt.

6.5 Bedingte Datentransformation

Gelegentlich ist es erforderlich, eine Datenmodifikation auf diejenigen Fälle zu beschränken, die eine Bedingung erfüllen. Wir benötigen z.B. im KFA-Projekt eine solche Möglichkeit, um bei den Motivations- und Methodenvariablen die Behandlung fehlender Werte komplettieren zu können (siehe Abschnitt 1.4.3.2.5).

Bei manchen Transformationen ist eine **Fallunterscheidung** erforderlich. Z.B. könnte im Rahmen einer ernährungsphysiologischen Studie ein Idealgewichtsbegriff zum Einsatz kommen, der bei Frauen und Männern unterschiedliche Formeln vorschreibt.

In den Transformations-Dialogboxen von SPSS erreichen Sie über den Schalter **Falls** eine Sub-dialogbox zur Definition einer Bedingung, unter der die Transformation ausgeführt werden soll. Sie können z.B. eine bedingte Umkodierung (vgl. Abschnitt 6.2), Berechnung (vgl. Abschnitt 6.4) oder Wertauszählung (vgl. Abschnitt 6.6) vornehmen.

Wenn unter ein und derselben Bedingung gleich *mehrere* Transformationen vorgenommen werden sollen, muss diese Bedingung in allen benötigten Transformations-Dialogboxen, wiederholt werden. Ähnlich umständlich ist die Realisation von Fallunterscheidungen mit Hilfe der Transformations-Dialogboxen. Bei solchen Aufgaben ist es oft einfacher, in einem Syntaxfenster eine DO IF - ELSE - END IF – Konstruktion zu erstellen, z.B.:

```
do if (geschl = 1).  
  compute idgew = (groesse - 100) * 0.85.  
  compute rle = 82.5 - alter.  
else.  
  compute idgew = (groesse - 100) * 0.9.  
  compute rle = 77.5 - alter.  
end if.
```

6.5.1 Beispiel

In diesem Abschnitt soll endlich die Behandlung fehlender Werte bei den Motivationsvariablen abgeschlossen werden. Wir haben bei den Variablen MOTIV1 bis MOTIV5 und ANDERE die markierten Kästchen mit Eins und die leeren Kästchen mit Null kodiert. Ein Fall mit Nullen bei MOTIV1 bis MOTIV5 und ANDERE hat aber offenbar den Fragebogenteil 3a komplett ausgelassen, denn:


- In der Stichprobe befinden sich ausschließlich Kursteilnehmer.
- Aufgrund der Restkategorie (Variable ANDERE) sind alle möglichen Motive zur Kursteilnahme berücksichtigt.

Daher sollten für genau diese Fälle die Nullen bei den Variablen MOTIV1 bis MOTIV5 und ANDERE in SYSMIS umkodiert werden. Gehen Sie folgendermaßen vor:


- Wählen Sie den Menübefehl:

Transformieren > Umkodieren in dieselben Variablen


- Transportieren Sie die Variablennamen MOTIV1 bis MOTIV5 und ANDERE in die Teilnehmerliste der **Umkodieren**-Dialogbox.



- Legen Sie in der Subdialogbox **Alte und neue Werte** die benötigte Abbildungsvorschrift fest:



- Öffnen Sie die **Falls**-Subdialogbox, markieren Sie die Option **Fall einschließen, wenn Bedingung erfüllt ist**, und tragen Sie in das darunter liegende Textfeld eine geeignete Bedingung ein, z.B.:



Aufgrund unserer Datenüberprüfung (siehe Kapitel 4) können wir uns darauf verlassen, dass bei den Variablen MOTIV1 bis MOTIV5 und ANDERE ausschließlich die Werte Null und Eins vorliegen. Daher ist die Summe dieser Variablen genau dann gleich Null, wenn jede einzelne Variable gleich Null ist. Somit lässt sich die erforderliche Bedingung mit Hilfe der statistischen Funktion SUM (vgl. Abschnitt 6.4.2.1) besonders einfach formulieren.

Die obige Eintragung im Bedingungsfeld (siehe Bildschirmfoto) kann „semiautomatisch“ z.B. so erzeugt werden:

- Wählen Sie die Funktionsgruppe **Statistisch**, markieren Sie die Funktion **Sum**, und klicken Sie auf den Transportschalter , so dass im Bedingungsfeld eine Vorlage für einen SUM() - Funktionsaufruf erscheint:

SUM(??)

- Transportieren Sie aus der Variablenliste am linken Rand der Dialogbox per Transportschalter , Drag & Drop oder Doppelklick die Variable MOTIV1 in das Bedingungsfeld, wobei in der Vorlage das markierte Fragezeichen automatisch durch den Variablennamen ersetzt wird.
- Ersetzen Sie das Komma in der Vorlage durch das Schlüsselwort TO, und komplettieren Sie die Liste durch den Variablennamen ANDERE, den Sie wiederum aus der Variablenliste in das Bedingungsfeld transportieren können.
- Erstellen Sie aus dem bis jetzt vorhandenen Funktionsaufruf eine Bedingung, indem Sie ein Gleichheitszeichen und den Wert Null anhängen.
- Machen Sie **weiter**, und quittieren Sie die **Umkodieren**-Dialogbox mit **Einfügen**.

Daraufhin wird Ihr Transformationsprogramm um die folgende Kommandosequenz mit einer DO IF - End IF - Kontrollstruktur erweitert:

```
DO IF (SUM(motiv1 to andere) = 0).
RECODE motiv1 motiv2 motiv3 motiv4 motiv5 andere (0=SYSMIS).
END IF.
EXECUTE.
```

Wenn Sie diese Kommandos ausführen lassen, gleichgültig ob direkt per **OK** in der **Umkodieren**-Dialogbox oder indirekt via Syntaxfenster, passiert bei jedem einzelnen Fall in der Stichprobe folgendes:

- SPSS prüft die Bedingung, die wir auch als **logischen Ausdruck** bezeichnen wollen.
- Ist bei einem Fall die Bedingung erfüllt, dann wird umkodiert, anderenfalls passiert nichts.

Weil die Variablen MOTIV1 bis MOTIV5 und ANDERE vor der Rekodierung garantiert nur Nullen oder Einsen als Werte aufweisen, hat unser logischer Ausdruck die Eigenschaft, in jedem Fall entweder wahr oder falsch zu sein. Das ist in der empirischen Forschung z.B. wegen des nahezu allgegenwärtigen Problems fehlender Werte keineswegs der Normalfall. Generell kann z.B. der logische Ausdruck „GESCHL = 1“ folgende Wahrheitswerte annehmen:

- wahr ⇔ Der GESCHL-Wert ist gleich Eins.
- falsch ⇔ Der GESCHL-Wert ist eine von Eins verschiedene Zahl.
- unbestimmt ⇔ GESCHL hat einen MD-Indikator als Wert.

Komplettiert um Regeln für unbestimmte logische Ausdrücke ist das Verhalten von SPSS bei bedingten Transformationen so zu beschreiben:

- Ist der logische Ausdruck **wahr**, dann wird die Transformation ausgeführt.
Im Fall einer bedingten Berechnung (COMPUTE-Kommando) wird der Ergebnisvariablen also der Wert des numerischen Ausdrucks zugewiesen. Die Zuweisung erfolgt auch dann, wenn der numerische Ausdruck den Wert SYSMIS hat.

- Ist der logische Ausdruck **falsch oder unbestimmt**, dann passiert **nichts**, d.h.:
 - Bei einer bereits vorhandenen Ergebnisvariablen behält der betroffene Fall seinen bisherigen Wert.
 - Bei einer neu definierten Variablen behält der betroffene Fall den Initialisierungswert SYSMIS.

6.5.2 Bedingungen formulieren

Der im obigen Beispiel aufgetretene logische Ausdruck war recht einfach aufgebaut, weil er aus einem einzigen Vergleich bestand. Obwohl Ihnen auch komplexere Exemplare (z.B. aus der Schule) wohlvertraut sein dürften, soll der Begriff *logischer Ausdruck* zur Klärung einiger Spezialprobleme genau beschrieben werden. Zunächst wird der einfachere Begriff *Vergleich* eingeführt.

6.5.2.1 Vergleich

Ein Vergleich besteht aus zwei numerischen Ausdrücken und einem Vergleichsoperator:

numerischer_ausdruck *vergleichsoperator* *numerischer_ausdruck*

Die bekannten **Vergleichsoperatoren** können in SPSS alternativ durch EDV-Varianten der mathematischen Symbole oder durch Schlüsselwörter dargestellt werden:

Bedeutung	Symbol	Schlüsselwort
gleich	=	EQ
ungleich	<> oder ~=	NE
kleiner als	<	LT
kleiner oder gleich	<=	LE
größer als	>	GT
größer oder gleich	>=	GE

Beispiele: `beruf >= 4`
 `beruf ge 4`

6.5.2.2 Logischer Ausdruck

Ausgehend vom einfachen Begriff *Vergleich* wird nun durch eine rekursive Definition der komplexere Begriff *logischer Ausdruck* konstruiert:

- i) Jeder Vergleich ist ein logischer Ausdruck.
- ii) Durch Anwendung des logischen Operators **NOT** auf einen logischen Ausdruck oder durch Anwendung der logischen Operatoren **AND** bzw. **OR** auf zwei logische Ausdrücke entsteht ein neuer logischer Ausdruck:

`NOT   logischer_ausdruck`

`logischer_ausdruck_1   AND   logischer_ausdruck_2`

`logischer_ausdruck_1   OR   logischer_ausdruck_2`

Den Wahrheitswert eines zusammengesetzten logischen Ausdrucks erhält man aus den Wahrheitswerten der Argumente nach den Regeln für logische Operatoren, die in den so genannten Wahrheitstafeln festgelegt sind (siehe unten).

Es lassen sich sukzessiv beliebig komplexe logische Ausdrücke aufbauen, die für jeden konkreten Fall die Wahrheitswerte *wahr*, *falsch* oder *unbestimmt* haben können.

Beispiel: (beruf >= 4) and (schule <> 7)

Mit unbestimmten Wahrheitswerten in logischen Ausdrücken verfährt SPSS analog zum Rechnen mit fehlenden Werten in numerischen Ausdrücken (siehe Abschnitt 6.4.2.3). Die folgenden Wahrheitstafeln sind gegenüber der klassischen Aussagenlogik um den Wahrheitswert *unbestimmt* erweitert (*la1* und *la2* seien logische Ausdrücke):

<i>la1</i>	NOT <i>la1</i>
wahr	falsch
falsch	wahr
unbestimmt	unbestimmt

<i>la1</i>	<i>la2</i>	<i>la1</i> AND <i>la2</i>	<i>la1</i> OR <i>la2</i>
wahr	wahr	wahr	wahr
wahr	falsch	falsch	wahr
wahr	unbestimmt	unbestimmt	wahr
falsch	wahr	falsch	wahr
falsch	falsch	falsch	falsch
falsch	unbestimmt	falsch	unbestimmt
unbestimmt	wahr	unbestimmt	wahr
unbestimmt	falsch	falsch	unbestimmt
unbestimmt	unbestimmt	unbestimmt	unbestimmt

Konjunktion und Adjunktion können per Schlüsselwort oder Symbol ausgedrückt werden:

Schlüsselwort	Symbol
AND	&
OR	

6.5.2.3 Regeln für die Auswertung logischer Ausdrücke

Bei der Auswertung von logischen Ausdrücken gelten in SPSS folgende Regeln:

- Die Auswertungsreihenfolge hängt von den Prioritäten der Operatoren ab. Es gilt folgende Rangordnung:

Priorität 1:	Funktionen
Priorität 2:	Potenzieren (**)
Priorität 3:	Multiplikation (*), Division (/)
Priorität 4:	Addition (+), Subtraktion (-)
Priorität 5:	Vergleichsoperatoren
Priorität 6:	NOT
Priorität 7:	AND
Priorität 8:	OR

- Bei gleicher Priorität: Auswertung von links nach rechts.
- Eine alternative Auswertungsreihenfolge kann durch Klammern erzwungen werden.

Das Beispiel für einen zusammengesetzten logischen Ausdruck aus Abschnitt 6.5.2.2 kann wegen der voreingestellten Abarbeitungsreihenfolge auch kürzer geschrieben werden:

```
beruf >= 4 and schule <> 7
```

Die aus Computer-Sicht überflüssigen Klammern verbessern allerdings die Lesbarkeit des Ausdrucks für Menschen und reduzieren so das Fehlerrisiko.

6.5.3 Übung

Bei den Variablen METH1 bis METH3 haben wir zur Vereinfachung der Erfassung im Kodierplan festgelegt, dass „unbenutzte“ Variablen einfach leer bleiben sollen. Nun wollen wir aber bei Fällen mit regulärem Antwortmuster die SYSMIS - Werte durch Nullen ersetzen. Die Null soll z.B. bei der Variablen METH2 bedeuten: Die Option, einen zweiten Methodenwunsch zu äußern, wurde nicht genutzt.

Die folgende Tabelle, die wir in Abschnitt 1.4.3.2.5 vereinbart haben, legt im Einzelnen fest, was unter den möglichen Bedingungskonstellationen geschehen soll:

		Mindestens eine speziell interessierende Methode angeben?	
		Ja	Nein
SMG	1	METH1 ... METH3: SYSMIS → 0 Bem.: Korrektes Antwortverhalten. Variablen zu nicht benutzten Optionen (gem. Kodierplan bisher auf SYSMIS) werden auf 0 gesetzt.	SMG: 1 → SYSMIS Bem.: Irreguläres Antwortverhalten. METH1 bis METH3 behalten SYMIS. SMG wird ebenfalls auf SYMIS gesetzt.
	0	SMG: 0 → 1 METH1 ... METH3: SYSMIS → 0 Bem.: Leicht irreguläres Antwortverhalten. Wir sind großzügig und setzen SMG auf 1 sowie die Variablen zu nicht benutzten Optionen auf 0.	METH1 ... METH3: SYSMIS → 0 Bem.: Korrektes Antwortverhalten. Die Variablen zu allen Optionen (gem. Kodierplan bisher auf SYSMIS) werden auf 0 gesetzt.
	SYSMIS	SMG: SYSMIS → 1 METH1 ... METH3: SYSMIS → 0 Bem.: Leicht irreguläres Antwortverhalten. Wir sind großzügig und setzen SMG auf 1 sowie die Variablen zu nicht benutzten Optionen auf 0.	Bem.: Irreguläres Antwortverhalten. Alle Variablen behalten den Wert SYSMIS.

In den beiden obersten Zeilen jeder Zelle sind die erforderlichen Korrekturen bei SMG bzw. METH1 bis METH3 angegeben. Erweitern Sie Ihr Programm **kfat.sps** um passende Transformationsanweisungen.

6.6 Häufigkeit bestimmter Werte bei einem Fall ermitteln

Mit dem Befehl **Werte in Fällen zählen** aus dem Menü **Transformieren** bzw. mit dem zugrunde liegenden COUNT-Kommando kann man für ...


- eine Liste von k Ausgangsvariablen
- sowie eine Liste mit kritischen (relevanten) Werten

eine Zählvariable erstellen lassen, die für jeden Fall festhält, wie viele Ausgangsvariablen einen kritischen Wert haben. Das minimale Zählergebnis ist Null (keine Ausgangsvariable hat einen kritischen Wert), und das maximale Ergebnis ist k (jede Ausgangsvariable hat einen kritischen Wert).


Wir wollen eine neue Variable namens POLYMOT berechnen lassen, die für jede Person festhält, wie viele Motive zur Kursteilnahme sie im Fragebogenteil 3a angegeben hat. Aktivieren Sie die Dialogbox **Häufigkeiten von Werten in Fällen zählen** mit

Transformieren > Werte in Fällen zählen

Vereinbaren Sie für die **Zielvariable** den Namen POLYMOT sowie die **Beschriftung** *Anzahl der Motive für die Kursteilnahme*, und transportieren Sie die Variablen MOTIV1 bis ANDERE in die Teilnehmerliste. Danach müsste Ihre Dialogbox ungefähr so aussehen:



Wechseln Sie jetzt mit dem Schalter **Werte definieren** in die Subdialogbox **Werte in Fällen zählen: Welche Werte**, tragen Sie dort den kritischen **Wert 1** ein, und klicken Sie auf **Hinzufügen**:



Die in dieser Subdialogbox angebotenen sonstigen Möglichkeiten zur Festlegung der Trefferwerte kennen Sie schon aus der Subdialogbox **Umkodieren: Alte und neue Werte** (siehe Abschnitt 6.2).

Da SPSS eine Folge von mehreren Kommandos stets in der natürlichen Reihenfolge abarbeitet, wird beim späteren Ablauf unseres Transformationsprogramms die MD-Behandlung bei den Variablen MOTIV1 bis ANDERE bereits erledigt sein, wenn die **Zählen**-Anweisung an die Reihe kommt. Bei Personen, die den Fragebogenteil 3a *nicht* korrekt bearbeitet haben, wird also gelten:

$$\text{MOTIV1} = \text{MOTIV2} = \dots = \text{ANDERE} = \text{SYSMIS}$$

Wir müssen die folgende Eigenschaft des COUNT-Kommandos beachten: Die Ergebnisvariable hat *stets* einen validen Wert größer oder gleich Null. Wenn ein Fall z.B. bei allen Ausgangsvariablen den Wert SYSMIS hat, resultiert das valide Ergebnis Null! In dieser Situation wissen wir aber *nichts* von den Motiven der Person und dürfen ihr keine Motivationslosigkeit (POLYMOT = 0) unterstellen.

Weil im konkreten Beispiel das Zählergebnis 0 generell als irregulär einzustufen ist, könnten wir durch ein gewöhnliches (unbedingtes) Umkodieren

$$0 \rightarrow \text{SYSMIS}$$

dafür sorgen, dass ein Fall bei POLYMOT den Wert SYSMIS erhält, wenn er den Fragebogen teil 3a nicht korrekt bearbeitet hat. Im Allgemeinen kann das Zählergebnis 0 jedoch auch auf reguläre Weise zustande kommen, und auch ein von 0 verschiedenes Zählergebnis kann MD-belastet sein. Daher ist es meist erforderlich, durch eine *bedingte* Datentransformation MD-belastete Zählergebnisse zu verhindern.

Wir wollen das generelle Verfahren der Übung halber auch im aktuellen Beispiel einsetzen und formulieren mit Hilfe der in Abschnitt 6.4.2.1 beschriebenen Funktion NMISS die folgende Bedingung

$$\text{NMISS}(\text{MOTIV1 TO ANDERE}) = 0$$

Sie ist genau dann wahr, wenn ein Fall bei den Variablen MOTIV1, ..., MOTIV5, ANDERE sechs gültige (nicht MD-deklarierte) Werte hat. Klicken Sie in der Dialogbox **Häufigkeiten von Werten in Fällen zählen** auf den **Falls**-Schalter, und tragen Sie die vorgeschlagene Bedingung ein. Wenn Sie dann **weiter** machen und die Hauptdialogbox mit **Einfügen** quittieren, erhalten Sie im Syntaxfenster die folgenden Kommandos:

```
DO IF (NMISS(MOTIV1 TO ANDERE) = 0).  
COUNT polymot=motiv1 motiv2 motiv3 motiv4 motiv5 andere(1).  
VARIABLE LABELS polymot 'Anzahl der Motive für die Kursteilnahme'.  
END IF.  
EXECUTE.
```

Was hier zählt, ist offenbar das COUNT-Kommando. Es enthält im Wesentlichen eine Liste der zu untersuchenden Variablen, gefolgt von einer eingeklammerten Liste der kritischen Werte. Das VARIABLE LABELS - Kommando hat SPSS aufgrund unserer Eintragung im **Beschriftungs-**Textfeld erstellt. Das Zählergebnis wird nur dann ermittelt und der neuen Variablen POLYMOT als Wert zugewiesen, wenn die Bedingung im DO IF - Kommando erfüllt ist. Anderenfalls behält POLYMOT den Initialisierungswert SYSMIS.

Weil bei den Variablen MOTIV1, MOTIV2, MOTIV3, MOTIV4, MOTIV5 und ANDERE nur die Werte 0, 1 und SYSMIS auftreten, kann man die Variable POLYMOT auch per COMPUTE-Kommando berechnen:

```
COMPUTE polymot=motiv1+motiv2+motiv3+motiv4+motiv5+andere.
```

Fälle mit einem MD-Indikator bei mindestens einer Variablen erhalten automatisch den Ergebniswert SYMIS, so dass im Vergleich zur obigen COUNT-Lösung Aufwand gespart wird. Bei anderen Zählaufträgen ist COUNT aber unverzichtbar, z.B.: Wie viele Variablen aus einer Liste haben den Wert 1, 2, 3 oder 7?

6.7 Erstellung der Fertigdatendatei mit dem Transformationsprogramm

Aufgrund von nachvollzogenen Demonstrationsbeispielen oder Übungsaufgaben in den Abschnitten 6.2 (Erstellung von DEKADE durch Rekodierung von GEBJ, Umkodieren der negativ formulierten LOT-Fragen), 6.4 (Berechnung von IDGEW, LOT, AERGAM, AERGZ, BMI und ALTER), 6.5 (MD-Behandlung für die Motiv- und für die Methoden-Variablen) und 6.6 (Aus zählen der Kursmotive) sollten jetzt alle vorläufig im KFA-Projekt benötigten Transformationskommandos in einem Syntaxfenster stehen.

6.7.1 Transformationsprogramm vervollständigen

Um daraus ein komfortables SPSS-Programm zu machen, das die Rohdatendatei **kfar.sav** selbständig in ein neues Datenblatt einließt, alle Transformationen ausführt und schließlich das Ergebnis in die Fertigdatendatei **kfa.sav** sichert, müssen wir an den Anfang des Syntaxfensters noch ein GET-Kommando zum Öffnen von **kfar.sav** und ans Ende noch ein SAVE-Kommando zum Sichern in **kfa.sav** setzen. Wie Sie das GET-Kommando produzieren können, haben Sie schon in Abschnitt 5.2 erfahren. Wenn Sie das Kommando jetzt erzeugen lassen, erscheint es am Ende des Syntaxfensters, und Sie müssen es an den Anfang verschieben.

Wir verzichten auf das automatisch erzeugte, in der Regel hinter dem GET-Kommando positionierte DATASET NAME - Kommando, streichen es also aus dem Programm. Ein fester Datenblattname im Programm führt beim Ausführen des Programms zu einer störenden Warnung, wenn in einer SPSS-Sitzung bereits ein Datenblatt mit diesem Namen existiert, was z.B. bei der wiederholten Ausführung des Programms innerhalb einer Sitzung passiert. Weil wir uns entschieden haben, mit dem *unbenannten* Datenblatt zu arbeiten, entfernen wir auch die automatisch erzeugten DATASET ACTIVATE - Kommandos aus dem Transformationsprogramm, weil diese ein Datenblatt mit einem bestimmten Namen ansprechen.

Um das SAVE-Kommando zu generieren, wechseln wir ins Datenfenster und aktivieren mit **Datei > Speichern unter** die zugehörige Dialogbox. Dann tragen wir den gewünschten Dateinamen **kfa.sav** ein und erzeugen mit **Einfügen** das benötigte SAVE-Kommando.

Um Komplikationen aus dem Weg zu gehen, sollte das Transformationsprogramm stets *komplett* ausgeführt werden (siehe Abschnitt 6.7.2). Damit ist sichergestellt, dass sich alle Kommandos auf dasselbe Datenblatt beziehen, das erstellt, mit den Rohdaten befüllt, transformiert und schließlich in die Fertigdatendatei gespeichert wird.

Hinweise zur Ausgabedatei eines Transformationsprogramms:

- Verwenden Sie niemals dieselbe Datei als Quelle und Ziel des Transformationsprogramms. Schreiben Sie also keinesfalls mit Ihrem Transformationsprogramm in die Rohdatendatei. Wenn Sie der Empfehlung in Abschnitt 6.1.2 folgend für die Rohdatendatei das Schreibschutzattribut gesetzt haben, kann dieses Desaster auch nicht versehentlich passieren.
- Bei der Ausführung des Transformationsprogramms darf für seine Ausgabedatei, also für die Fertigdatendatei, das Schreibschutzattribut natürlich nicht gesetzt sein.

Abgesehen von einigen Ergänzungen, die gleich erläutert werden, sollte das von Ihnen erstellte Transformationsprogramm so aussehen:

```
GET
  FILE='U:\Eigene Dateien\SPSS\kfar.sav'.

* DEKADE.
RECODE gebj (1960 thru 1969=1) (1970 thru 1979=2) INTO Dekade.
value labels  dekade  1 '60er'  2 '70er'.
EXECUTE.

* LOT-Fragen umkodieren.
RECODE lot3 lot4 lot5 lot12 (5=1) (4=2) (2=4) (1=5).
EXECUTE.

* IDGEW berechnen.
COMPUTE idgew = groesse - 100.
VARIABLE LABELS idgew 'Idealgewicht nach der Formel Größe - 100'.
EXECUTE.

* LOT berechnen.
COMPUTE lot = MEAN.6(lot1,lot3,lot4,lot5,lot8,lot9,lot11,lot12).
VARIABLE LABELS lot 'LOT-Optimismus'.
EXECUTE.

* AERGAM berechnen.
COMPUTE aergam = (aergo + aergm)/2.
VARIABLE LABELS aergam 'Mittel der Ärgervariablen'.
EXECUTE.

* AERGFZ berechnen.
COMPUTE aergz = aergm - aergo.
VARIABLE LABELS aergz 'Ärgerzuwachs durch die KFA'.
EXECUTE.
```

```
* BMI berechnen.
COMPUTE bmi = gewicht / (groesse/100)**2.
VARIABLE LABELS bmi 'Body Mass Index'.
EXECUTE.

* Alter berechnen.
COMPUTE Alter = 1999 - gebj.
EXECUTE.

* MD-Behandlung für die Motiv-Variablen.
DO IF (SUM(motiv1 to andere) = 0).
RECODE motiv1 motiv2 motiv3 motiv4 motiv5 andere (0=SYSMIS).
END IF.
EXECUTE.

* MD-Behandlung für die Methoden-Variablen, Zelle (1,1) der Tabelle.
DO IF (smg=1 and nmiss(meth1 to meth3) < 3).
RECODE meth1 meth2 meth3 (SYSMIS=0).
END IF.
EXECUTE.

* MD-Behandlung für die Methoden-Variablen, Zelle (1,2) der Tabelle.
DO IF (smg=1 and nmiss(meth1 to meth3) = 3).
RECODE smg (1=SYSMIS).
END IF.
EXECUTE.

* MD-Behandlung für die Methoden-Variablen, Zelle (2,1) der Tabelle.
DO IF ((smg = 0) and (nmiss(meth1 to meth3) < 3)).
RECODE smg (0=1).
END IF.
EXECUTE .
DO IF ((smg = 0) and (nmiss(meth1 to meth3) < 3)).
RECODE meth1 meth2 meth3 (SYSMIS=0).
END IF.
EXECUTE.

* MD-Behandlung für die Methoden-Variablen, Zelle (2,2) der Tabelle.
DO IF (smg=0 and nmiss(meth1 to meth3) = 3).
RECODE meth1 meth2 meth3 (SYSMIS=0).
END IF.
EXECUTE.

* MD-Behandlung für die Methoden-Variablen, Zelle (3,1) der Tabelle.
DO IF ((nmiss(smg) = 1) and (nmiss(meth1 to meth3) < 3)).
RECODE smg (SYSMIS=1).
END IF.
EXECUTE.
DO IF ((nmiss(smg) = 1) and (nmiss(meth1 to meth3) < 3)).
RECODE meth1 meth2 meth3 (SYSMIS=0).
END IF.
EXECUTE.
```

```

* POLYMOT berechnen.
DO IF (NMISS(motiv1 to andere) = 0).
COUNT polymot=motiv1 motiv2 motiv3 motiv4 motiv5 andere(1).
VARIABLE LABELS polymot 'Anzahl der Motive für die Kursteilnahme'.
END IF.
EXECUTE.

* Variablenattribute setzen.
formats dekade idgew aergz alter polymot (f8.0) aergam (f8.1) lot bmi (f8.2).
variable width dekade to polymot (7).
variable level dekade (ordinal) / idgew to polymot (scale).
variable role
  /input dekade idgew lot alter
  /target aergam aergz bmi
  /both polymot.

SAVE OUTFILE='U:\Eigene Dateien\SPSS\kfa.sav'
  /COMPRESSED.

```

In diesen Lösungsvorschlag ist etwas Handarbeit eingeflossen:

- Zwischen manchen Kommandos sind der Übersichtlichkeit halber Leerzeilen eingefügt worden. Man darf aber auf keinen Fall *innerhalb* eines Kommandos (d.h. zwischen dem Kommandonamen und dem abschließenden Punkt) eine Leerzeile einfügen (vgl. Abschnitt 5.4).
- Die mit einem Sternchen (*) eingeleiteten Zeilen beinhalten *Kommentare*, die nachträglich eingefügt wurden, um die spätere Orientierung im Programm zu erleichtern (vgl. Abschnitt 5.4).

Wichtig: Ein Kommentar hat ebenfalls Kommandostatus und muss daher unbedingt mit einem Punkt abgeschlossen werden. Sonst erstreckt sich der Kommentar bis zur nächsten Zeile, die entweder komplett leer ist oder mit einem Punkt endet.

- Für die ordinale Variable DEKADE sollten Wertelabels definiert werden, was über das folgende VALUE LABELS – Kommando geschehen kann:

```
value labels dekade 1 '60er' 2 '70er'.
```

Fügen Sie das Kommando hinter dem RECODE-Kommando ein, das die Variable DEKADE erstellt. Wie in Abschnitt 5.4 erläutert, ist bei den Schlüsselwörtern der SPSS-Kommandosprache (hier: Kommandoname VALUE LABELS) die Groß-/Kleinschreibung syntaktisch irrelevant. Bei selbst verfassten Kommandos muss man sich also nicht an die von SPSS bei automatisch erstellten Kommandos meist verwendete Großschreibung halten. Zur Groß-/Kleinschreibung beim Variablennamen DEKADE soll der Klarheit halber noch einmal an folgende Regeln erinnert werden:

- Bzgl. der Identifikation von Variablen ist die Groß-/Kleinschreibung irrelevant.
- Wird bei einer Variablen auf die optionale Variablenbeschriftung verzichtet, dann erscheint in Ergebnistabellen und Diagrammen der Name. In dieser Situation sollte an folgenden Stellen auf eine „publikationsreife“ Schreibweise des Namens geachtet werden:

- Bei der Variablendeklaration in Dateneditor (Registerkarte **Variablenansicht**).
- Bei Transformationskommandos, die eine neue Variable erzeugen, z.B.:

```
RECODE gebj (1960 thru 1969=1) (1970 thru 1979=2) INTO Dekade.
```

Wird in einem Transformations- oder Datenverwaltungskommando eine bereits *vorhandene* Variable angesprochen, ist die Groß-/Kleinschreibung irrelevant.

- Eventuell legen Sie Wert darauf, dass auch die neu berechneten Variablen mit einer optimalen Anzahl von Dezimalstellen angezeigt werden. Eine manuelle Einstellung per Dateneditor (vgl. Abschnitt 3.2.2) ist wenig attraktiv, weil unser Transformationsprogramm ja mit einiger Wahrscheinlichkeit mehrfach ausgeführt werden muss. Die bessere Alternative besteht darin, das Programm um ein FORMATS-Kommando zu erweitern, das die Anzahl der Dezimalstellen setzt:

```
formats dekade idgew aergz alter polymot (f8.0) aergam (f8.1) lot bmi (f8.2).
```

Im Ausdruck „(fb.d)“ legt man mit *b* die Gesamtbreite der Wertausgabe (entspricht dem Dateneditorattribut **Spaltenformat**) und mit *d* die Anzahl der Dezimalstellen fest. Weil bei numerischen Variablen die Gesamtbreite für uns irrelevant ist, haben wir bei den Rohvariablen auf eine Anpassung der Voreinstellung 8 verzichtet. So verfahren wir der Einheitlichkeit halber auch bei den abgeleiteten Variablen.

Fügen Sie das FORMATS-Kommando am Ende des Transformationsprogramms ein (unmittelbar vor dem SAVE-Kommando).

- Mit den folgenden Kommandos

```
variable width dekade to polymot (7).
variable level dekade (ordinal) / idgew to polymot (scale).
variable role
  /input dekade idgew lot alter
  /target aergam aergz bmi
  /both polymot.
```

werden für die neuen Variablen eingestellt:

- Breite der Datenfensterspalte (entspricht dem Dateneditorattribut **Spalten**)
- Messniveau
- Rolle

Fügen Sie die Kommandos am Ende des Transformationsprogramms ein (hinter dem FORMATS-Kommando).

- Hinter den Kommandos FORMATS, VARIABLE WIDTH, VARIABLE LEVEL und VARIABLE ROLE muss *kein* EXECUTE-Kommando stehen (vgl. Abschnitt 6.3). Weil sich diese Kommandos nicht auf die Datenmatrix beziehen, sondern auf die Metadaten (das Datenlexikon), werden sie auf jeden Fall sofort ausgeführt.

Beachten Sie im Zusammenhang mit dem Thema Datensicherheit:

- Wenn zum Zeitpunkt der Programmausführung ein unbenanntes Datenblatt existiert, wird dieses vom GET-Kommando ohne Nachfrage überschrieben!
- Das SAVE-Kommando überschreibt eine eventuell vorhandene Datei **kfa.sav** ohne Nachfrage, was jedoch bei der im Manuskript vorgeschlagenen Arbeitsweise (vgl. Abschnitt 6.1.1) unproblematisch ist.

Damit ist das Transformationsprogramm zum KFA-Projekt fertig. Falls noch nicht geschehen, müssen Sie es unbedingt sichern, z.B. in das Verzeichnis **U:\Eigene Dateien\SPSS** unter dem oben vorgeschlagenen Dateinamen **kfat.sps**.

6.7.2 Transformationsprogramm ausführen

Um die spätere Erfolgskontrolle zu vereinfachen, sollte vor dem Start des Transformationsprogramms das aktive Ausgabefenster leer sein, oder es sollte gar kein Ausgabefenster vorhanden

sein. Auf jeden Fall sollten ältere Warnungen bzw. Fehlermeldungen aus dem aktiven Ausgabefenster gelöscht werden, um Unklarheiten zu vermeiden.

Lassen Sie das Transformationsprogramm ausführen, z.B. mit

Ausführen > Alle

Wenn alles glatt läuft, finden Sie anschließend im (aktiven) Ausgabefenster nur die protokollierten Kommandos.

Bei der in Kapitel 6 beschriebenen Vorgehensweise ist beim Start des Transformationsprogramms die Rohdatendatei bereits geöffnet, und es erscheint die folgende Warnung, die ignoriert werden darf:

Warnungsnummer 67. Befehlsname: GET FILE
Das Dokument wird bereits von einem anderen Benutzer oder Prozess verwendet. Wenn Sie Änderungen an dem Dokument vornehmen, können diese gegebenenfalls Änderungen anderer Benutzer überschreiben bzw. Ihre Änderungen werden von anderen Benutzern überschrieben.
Geöffnete Datei: U:\Eigene Dateien\SPSS\kfar.sav

Durch einen gelungenen Lauf unseres Transformationsprogramms entsteht ein unbenanntes Datenblatt, das mit der Fertigdatendatei **kfa.sav** verbunden ist. Am rechten Rand der Datenmatrix sind die neuen Variablen zu finden, z.B.:

	gebj	fb	groesse	gewicht	Dekade	idgew	lot	aergam	aergz	bmi	Alter	polymot
1	1969	1	163	51,0	1	63	4,13	6,5	3	19,20	31	1
2	1970	1	158	56,0	2	58	3,88	6,5	3	22,43	30	1
3	1969	1	174	58,0	1	74	3,63	6,0	4	19,16	31	1
4	1967	1	182	77,0	1	82	3,75	4,0	-4	23,25	33	1
5	1967	1	180	69,0	1	80	3,88	8,0	0	21,30	33	1

Außerdem sind die Attribute der neuen Variablen korrekt gesetzt:

	Name	Typ	Spaltenformat	Dezimalstellen	Beschriftung	Werte	Fehlend	Spalten	Ausrichtung	Messniveau	Rolle
31	Dekade	Numerisch	8	0		{1, 60er}...	Keine	7	Rechts	Ordinal	Eingabe
32	idgew	Numerisch	8	0	Idealgewicht nach der Formel Größe -...	Keine	Keine	7	Rechts	Metrisch	Eingabe
33	lot	Numerisch	8	2	LOT-Optimismus	Keine	Keine	7	Rechts	Metrisch	Eingabe
34	aergam	Numerisch	8	1	Mittel der Ärgervariablen	Keine	Keine	7	Rechts	Metrisch	Ziel
35	aergz	Numerisch	8	0	Ärgerzuwachs durch die KFA	Keine	Keine	7	Rechts	Metrisch	Ziel
36	bmi	Numerisch	8	2	Body Mass Index	Keine	Keine	7	Rechts	Metrisch	Ziel
37	Alter	Numerisch	8	0		Keine	Keine	7	Rechts	Metrisch	Eingabe
38	polymot	Numerisch	8	0	Anzahl der Motive für die Kursteilnahme	Keine	Keine	7	Rechts	Metrisch	Beides

Das seit Beginn unserer Arbeit am Transformationsprogramm vorhandene, mit der Rohdatendatei verbundene Datenblatt ändert sich durch den Programmlauf *nicht*, weil es einen Namen erhalten hatte (z.B. **DatenSet1**) und daher vom GET-Kommando des Transformationsprogramms

nicht tangiert wird. Sie müssen also vor der Erfolgskontrolle das tatsächlich relevante Dateneditorfenster ansteuern (z.B. per **Fenster**-Menü).

Sie dürfen Ihre Erfolgskontrolle keinesfalls auf das Datenfenster beschränken, sondern müssen unbedingt das Ausgabefenster auf Fehlermeldungen und Warnungen überprüfen. SPSS stoppt nämlich die Programmausführung **nicht** beim Auftreten des ersten fehlerhaften Kommandos, sondern ignoriert das fehlerhafte Kommando und macht unverdrossen mit den nächsten Kommandos weiter. Diese arbeiten aber in der Regel aufgrund des vorangegangenen Fehlers mit falschen Zwischenergebnissen und produzieren Unsinn. Es kann also passieren, dass nach einem fehlerhaften Lauf des Transformationsprogramms alle erwarteten neuen Variablen vorhanden sind, jedoch teilweise falsche Werte enthalten.

Zwar kann es durchaus sinnvoll sein, *einzelne* Transformationskommandos ausführen zu lassen, doch sollten SPSS-Einsteiger vorläufig darauf verzichten. Damit eine korrekte Fertigdatendatei entsteht, müssen alle Kommandos

- genau **einmal**
- und in der **korrekten Reihenfolge**

ausgeführt werden. Bei der separaten Ausführung einzelner Kommandos kann man diese Regeln leicht verletzen. Wiederholt man z.B. das Umkodieren der LOT-Variablen, so entsteht wieder der Ausgangszustand! Von solchen Tücken bleibt verschont, wer das Transformationsprogramm stets komplett ausführen lässt.

7 Hypothesentests

Damit die bald anstehende Prüfung der zentralen Hypothesen unserer Kursstudie (emotionaler Effekt kontrafaktischer Alternativen, Ärgerdämpfung durch Optimismus) fehlerfrei über die Bühne geht, beschäftigen wir uns in diesem Kapitel mit den Grundprinzipien und den Voraussetzungen von statistischen Hypothesentests. Obwohl die im Rahmen der Kursstudie konkret geplanten Verfahren (t-Test für abhängige Stichproben, bivariate lineare Regression) als Beispiele im Vordergrund stehen, generalisieren die behandelten Themen gut auf andere Testverfahren. Wer sich bei den im bisherigen Kursverlauf (z.B. in Abschnitt 4.5) gelegentlich angewandten statistische Hypothesenprüfungen unsicher gefühlt hat, wird hoffentlich nun ein solides Verständnis (wieder-)erlangen.

7.1 Grundprinzipien am Beispiel des Einstichproben - t-Tests

In diesem Abschnitt werden einige Grundprinzipien der Inferenzstatistik nach dem binären Entscheidungskonzept von Neyman und Pearson am Beispiel unserer KFA-Hypothese demonstriert. Dabei handelt es sich *nicht* um eine systematische Behandlung des Themas, die erheblich mehr Platz beanspruchen würde (siehe z.B. Eid et al. 2013, Kap. 8). Im Wesentlichen sollen die statistischen Entscheidungsregeln so präsentiert werden, dass sie mit Hilfe der SPSS-Ausgaben unmittelbar umgesetzt werden können. Zumindest in älteren Statistikbüchern findet man nämlich Formulierungen mit wenig Bezug zu den heute üblichen Ausgaben von Statistikprogrammen.

7.1.1 Gerichtete Hypothese über den KFA-Effekt

Wenn mit μ_O der Erwartungswert (Populationsmittelwert) des Merkmals AERGO und mit μ_M der Erwartungswert des Merkmals AERGM bezeichnet wird, dann lautet unser KFA-Testproblem:

$$H_0 : \mu_M \leq \mu_O \quad \text{vs.} \quad H_1 : \mu_M > \mu_O$$

Mit Hilfe der Differenz- bzw. Zuwachsvariablen $\text{AER}GZ := \text{AER}GM - \text{AER}GO$, deren Erwartungswert mit μ_Z bezeichnet werden soll, lässt sich das Testproblem äquivalent noch kompakter formulieren:

$$H_0 : \mu_Z \leq 0 \quad \text{vs.} \quad H_1 : \mu_Z > 0$$

Bei der Reformulierung wird die folgende Identität ausgenutzt (Linearität des Erwartungswerts):

$$\mu_Z = \mu_M - \mu_O$$

Durch Betrachtung der Differenzvariablen AERGZ lässt sich der t-Test für abhängige Stichproben auf den besonders einfachen **Einstichproben - t-Test** zurückführen, der nun beschrieben werden soll.

7.1.2 Voraussetzungen für den Einstichproben - t-Tests

Wir setzen voraus, dass die Differenzvariable AERGZ in der Population normalverteilt ist mit dem Erwartungswert μ_Z und der Varianz σ_Z^2 :

$$\text{AER}GZ \sim N(\mu_Z, \sigma_Z^2)$$

Für die n AERGZ-Beobachtungen in der Stichprobe nehmen wir an, dass sie durch **unabhängiges** Ziehen aus der eben beschriebenen Population entstanden sind.

Wir haben also ...

- eine Voraussetzung über die Verteilung von AERGZ in der Population
- und eine Voraussetzung über die Stichprobenziehung.

7.1.3 Teststatistik

7.1.3.1 Anforderungen

Ein inferenzstatistisches Entscheidungsverfahren verwendet eine so genannte **Teststatistik T** (synonym: **Prüfgröße**), die aus den Stichprobendaten berechnet werden kann und folgende Eigenschaften besitzt:

- Sie ist **indikativ für Abweichungen der wahren Populationsverteilung von der Nullhypothesebehauptung** und wächst tendenziell mit der Effektstärke. Die Teststatistik quantifiziert also, wie gut bzw. schlecht die Nullhypothese mit den Stichprobendaten vereinbar ist. In unserem Fall ist die Effektstärke folgendermaßen definiert (vgl. Abschnitt 1.3.2):

$$d_z := \frac{\mu_z}{\sigma_z}$$

- Es ist bekannt, welcher **Verteilung die Teststatistik T bei gültiger Nullhypothese** folgt, in unserem Beispiel also bei $\mu_z \leq 0$. Damit lässt sich für den konkreten Wert T_{emp} der Teststatistik in einer bestimmten Stichprobe berechnen, mit welcher Wahrscheinlichkeit eine Nullhypothese population Zufallsstichproben mit einer Teststatistikausprägung größer oder gleich T_{emp} liefert. Ist diese so genannte **Überschreitungswahrscheinlichkeit** sehr klein, liegt der Schluss nahe, dass die konkret vorliegende Stichprobe *nicht* aus einer Nullhypothese population stammt. Von *der* Überschreitungswahrscheinlichkeit zu sprechen ist allerdings ungenau, weil die Nullhypothese i.A. (jedenfalls bei einer *gerichteten* Fragestellung) eine *Menge* von unendlich vielen Verteilungen ist, die jeweils eine andere Überschreitungswahrscheinlichkeit liefern. Wir müssen eine „Worst Case“-Analyse anstellen und für das über alle Elemente der Nullhypothese-Verteilungsfamilie ermittelte *Maximum* der Überschreitungswahrscheinlichkeiten beurteilen, ob es klein genug ist.

7.1.3.2 Die Prüfgröße zum Einstichproben - t-Test

Zur Prüfung von Hypothesen über den Erwartungswert der Variablen AERGZ eignet sich die folgende Teststatistik T_Z :

$$T_Z := \frac{\bar{Z}}{S_Z} \sqrt{n} \quad \text{mit} \quad \bar{Z} := \frac{1}{n} \sum_{i=1}^n Z_i \quad \text{und} \quad S_Z := \sqrt{\frac{1}{n-1} \sum_{i=1}^n (Z_i - \bar{Z})^2}$$

Dabei ist $\bar{Z}$ das Stichprobenmittel und S_Z die Wurzel aus dem erwartungstreuen Schätzer der Populationsvarianz σ_Z^2 .

T_Z erfüllt die oben formulierten Anforderungen an eine Teststatistik:

- Die wesentliche, ergebnisabhängige T_Z – Komponente $\frac{\bar{Z}}{S_Z}$ ist offenbar ein Schätzer für die Effektstärke $\frac{\mu_Z}{\sigma_Z}$ in der Population. Folglich wächst T_Z stochastisch mit zunehmender Effektstärke.
- Für $\mu_Z = 0$ besitzt T_Z (bei beliebigem Nebenparameter σ_Z^2) unter den in Abschnitt 7.1.2 genannten Voraussetzungen eine t-Verteilung mit $n - 1$ Freiheitsgraden. Damit kennen wir das Verhalten der Teststatistik *am Rand* der Nullhypothese. Man kann leicht zeigen, dass die Wahrscheinlichkeit, einen T_Z - Wert größer oder gleich T_{emp} zu erhalten, bei $\mu_Z = 0$ maximal wird. Um beurteilen zu können, ob *alle* Nullhypothesenüberschreitungswahrscheinlichkeiten $P_{H_0}(T_Z \geq T_{\text{emp}})$ klein genug sind, muss man also nur den Fall $\mu_Z = 0$ betrachten.

Bevor wir uns dem Testentscheid unter Verwendung der T_Z - Prüfgröße zuwenden, beobachten wir noch, dass diese Statistik einem typischen Konstruktionsprinzip für Hypothesentests über Populationsparameter genügt. Für das Stichprobenmittel $\bar{Z}$ (als Zufallsvariable aufgefasst) ergibt sich die Varianz

$$\text{Var}(\bar{Z}) = \text{Var}\left(\frac{1}{n} \sum_{i=1}^n Z_i\right) = \frac{1}{n^2} \text{Var}\left(\sum_{i=1}^n Z_i\right) = \frac{1}{n^2} \sum_{i=1}^n \text{Var}(Z_i) = \frac{1}{n^2} \sum_{i=1}^n \sigma_Z^2 = \frac{n \sigma_Z^2}{n^2} = \frac{\sigma_Z^2}{n}$$

und damit die Streuung (der so genannte *Standardfehler*)

$$\sqrt{\text{Var}(\bar{Z})} = \frac{\sigma_Z}{\sqrt{n}}$$

Folglich schätzt $\frac{S_Z}{\sqrt{n}}$ den Standardfehler des Stichprobenmittelwerts, und T_Z ist gerade der **Quotient aus dem Stichprobenmittelwert und seinem geschätzten Standardfehler**:

$$T_Z = \frac{\bar{Z}}{S_Z} \sqrt{n} = \frac{\bar{Z}}{\frac{S_Z}{\sqrt{n}}}$$

Teststatistiken von analoger Bauart sind uns schon bei den approximativen Tests zur Schiefe bzw. Wölbung einer univariaten Verteilung in Abschnitt 4.5 begegnet.

7.1.4 Entscheidungsregel

Die maximale Überschreitungswahrscheinlichkeit, die ab jetzt mit $P_{H_0}(T_Z \geq T_{\text{emp}})$ bezeichnet werden soll, tritt nach obigen Überlegungen bei $\mu_Z = 0$ (mit beliebiger Varianz σ_Z^2) auf und kann (von einem Statistiker oder von einer Statistik-Software) leicht berechnet werden. In der SPSS-Ausgabe zum t-Test für verbundene Stichproben wird sie als **Sig.** bezeichnet.¹

¹ Allerdings berichtet SPSS beim t-Test für verbundene Stichproben ausschließlich die *zweiseitige* Überschreitungswahrscheinlichkeit $P_{H_0}(|T_Z| \geq |T_{\text{emp}}|)$ (siehe unten), während wir unsere KFA-Hypothese mit gutem Grund *einseitig* formuliert haben und daher auch die einseitige Überschreitungswahrscheinlichkeit benötigen. Es

Bei einem akzeptierten **Fehlerrisiko erster Art** von $\alpha = 0,05$ verwendet man die folgende **Entscheidungsregel**:

$$P_{H_0}(T_Z \geq T_{\text{emp}}) \begin{cases} \geq 0,05 & \Rightarrow H_0 \text{ beibehalten} \\ < 0,05 & \Rightarrow H_0 \text{ verwerfen (Entscheidung für } H_1) \end{cases} \quad (7-1)$$

Die Nullhypothese wird also abgelehnt, wenn die Teststatistik in der beobachteten Stichprobe einen Wert annimmt, der bei Zufallsstichproben aus einer Nullhypothese population (genauer: bei $\mu_Z = 0$), nur relativ selten (mit einer Wahrscheinlichkeit kleiner 0,05) erreicht oder übertroffen wird.

7.1.5 Kritischer Wert und Ablehnungsbereich

In Statistiklehrbüchern wird oft für den Signifikanztest zum Niveau $\alpha = 0,05$ ein **kritischer Wert** T_{krit} so bestimmt, dass gilt:

$$P_{H_0}(T_Z \geq T_{\text{krit}}) = 0,05$$

Damit kann obige Entscheidungsregel äquivalent folgendermaßen formuliert werden:


$$T_{\text{emp}} \begin{cases} \leq T_{\text{krit}} & \Rightarrow H_0 \text{ beibehalten} \\ > T_{\text{krit}} & \Rightarrow H_0 \text{ verwerfen (Entscheidung für } H_1) \end{cases} \quad (7-2)$$

In unserer Situation ist T_{krit} gerade das 95. Perzentil der t-Verteilung mit $n - 1$ Freiheitsgraden. Bei der Stichprobengröße $n = 31$ erhalten wir $T_{\text{krit}} = 1,70$.

Wir haben bei den approximativen Tests zur Schiefe und Wölbung einer univariaten Verteilung (siehe Abschnitt 4.5) die Testentscheidung anhand von kritischen Werten vorgenommen. Dort waren wir ausnahmsweise in der Lage, keine Überschreitungswahrscheinlichkeiten zu kennen, aber die kritischen Werte der Teststatistiken (als Perzentile der Standardnormalverteilung) leicht ermitteln zu können. Weil SPSS und vergleichbare Statistikprogramme in der Regel Überschreitungswahrscheinlichkeiten liefern, werden die im Anhang vieler Statistiklehrbücher tabellierten kritischen Werte wichtiger Prüfverteilungen (z.B. t, F, χ^2) nur noch selten benötigt.

Die folgende Abbildung zeigt die Wahrscheinlichkeitsdichte der t-Verteilung mit 30 Freiheitsgraden und den **H_0 -Ablehnungsbereich** (||) bei einseitiger Fragestellung im Sinne unserer KFA-Hypothese:

wird sich aber gleich zeigen, dass man die einseitige Überschreitungswahrscheinlichkeit durch Halbieren aus der zweiseitigen berechnen kann.



Diese Dichte beschreibt das Verteilungsverhalten einer Zufallsgröße, zu der eine einzelne Realisation folgendermaßen zu ermitteln ist: Ziehe aus einer Population mit

$$\text{AERGZ} \sim N(0, \sigma_Z^2)$$

eine Zufallsstichprobe der Größe $n = 31$, ermittle die AERGZ-Werte und berechne T_Z .

Die obige Abbildung beschreibt das Verhalten der T_Z -Werte von Stichproben aus einer für unseren Test besonders ungünstigen Nullhypothesenpopulation (mit $\mu_Z = 0$). Wir kommen zu einer Testentscheidung, indem wir unser Stichprobenergebnis T_{emp} vor dem Hintergrund dieses Erwartungshorizonts beurteilen. Wir lehnen die Nullhypothese (eine Menge von Verteilungen) ab, wenn selbst der „extremste“ Vertreter dieser Menge nur selten (mit einer Wahrscheinlichkeit $< 0,05$) ein Stichprobenergebnis mit einem T_Z -Werte größer oder gleich T_{emp} hervorbringt.

7.1.6 Akzeptiertes Risiko erster Art

Wenn wir aus einer Nullhypothesenpopulation mit $\mu_Z = 0$ eine Zufallsstichprobe der Größe $n = 31$ ziehen und T_{emp} ermitteln, werden wir mit der Wahrscheinlichkeit 0,05 einen Wert größer $T_{\text{krit}} = 1,70$ erhalten und falsch gegen die H_0 entscheiden, also einen **Fehler erster Art** begehen. Für die „extreme“ Nullhypothesenpopulation mit $\mu_Z = 0$ ist das Risiko erster Art also gleich 0,05. Für alle anderen Elemente aus der Nullhypothesen-Verteilungsfamilie ist es kleiner.

Das akzeptierte Risiko erster Art sollte umso niedriger angesetzt werden, je gravierender (schädlicher, teurer) das irrtümliche Ablehnen einer gültigen Nullhypothese ist.

7.1.7 Faktoren mit Einfluss auf das Risiko zweiter Art

Das Risiko, bei Gültigkeit der *Alternativhypothese* falsch zu entscheiden (**Fehler zweiter Art**, β -**Fehler**), hängt von folgenden Faktoren ab:

- **Effektstärke**

Bei unserem KFA-Testproblem ist die Effektstärke definiert durch $\frac{\mu_z}{\sigma_z}$. Weil die Prüfstatistik im Kern ein Stichprobenschätzer für die Effektstärke ist, gilt offenbar: Je größer die Effektstärke, desto wahrscheinlicher ist ein T_{emp} - Wert mit $P_{H_0}(T_Z \geq T_{\text{emp}}) < 0,05$ bzw. $T_{\text{emp}} > T_{\text{krit}}$, also eine korrekte Entscheidung gegen die H_0 .

- **Akzeptiertes Fehlerrisiko erster Art**

Reduziert man den akzeptierten α -Fehler, so steigt der kritische Wert T_{krit} . Folglich steigt auch das Risiko dafür, dass der T_{emp} - Wert einer Stichprobe trotz gültiger Alternativhypothese den kritischen Wert T_{krit} *nicht* übertrifft. In diesem Fall kommt es *nicht* zur korrekten Entscheidung gegen die H_0 , sondern zu einem Fehler zweiter Art.

- **Korrekte Anwendung der ein- oder zweiseitigen Testung**

Wer sich auf die Richtung des Effekts festlegt und einseitig testet, wird im Fall einer korrekten Annahme mit einer höheren Power (Entdeckungswahrscheinlichkeit) im Vergleich zu der in Statistikprogrammen oft voreingestellten zweiseitigen Testung belohnt (siehe unten).

- **Sensibilität des verwendeten Signifikanztests**

Die Wahrscheinlichkeit dafür, dass ein bestimmter Populationseffekt in einer Stichprobe zu einem signifikanten Testergebnis führt, wächst generell mit der **Stichprobengröße**, hängt aber auch von der Güte des Verfahrens ab.

Wir betrachten exemplarisch, was beim Einstichproben - t-Test passiert, wenn bei gültiger Alternativhypothese ($\mu_z > 0$) die Stichprobengröße n steigt:

- Der Quotient $\frac{\bar{Z}}{S_z}$ konvergiert stochastisch gegen $\frac{\mu_z}{\sigma}$, also gegen eine feste Zahl > 0 .
- Die Prüfgröße

$$T_z := \frac{\bar{Z}}{S_z} \sqrt{n}$$

wächst stochastisch gegen Unendlich.

- T_{krit} konvergiert gegen 1,65 (95. Perzentil der Standardnormalverteilung).

Folglich steigt mit der Stichprobengröße die Wahrscheinlichkeit, die T_{krit} - Hürde zu nehmen, also die falsche H_0 zu verwerfen.

Alternative Testverfahren verwenden unterschiedliche Prüfgrößen und unterscheiden sich bei ihren Annahmen über das Messniveau und die Verteilung der beteiligten Variablen. Von zwei mathematisch ausgereiften Verfahren besitzt dasjenige mit den stärkeren Annahmen die bessere Güte, *falls seine Voraussetzungen erfüllt sind*. Wir werden zur Prüfung der allgemeinspsychologischen Hypothese den t-Test für verbundene Stichproben nur dann einsetzen, wenn sich die Variable AERZ in unserer Stichprobe als annähernd normalverteilt erweist. Sind die Voraussetzungen eines Verfahrens erheblich verletzt, darf es wegen potentiell verfälschter Ergebnisse nicht verwendet werden. In der Regel wäre das Verfahren in dieser Situation aber auch eine schlechte Wahl. Ob bereits eine erhebliche Verletzung der Voraussetzungen vorliegt, oder noch auf die Robustheit eines

Verfahrens vertraut werden kann, ist leider nicht immer durch eine Routineprüfung zu entscheiden.

Wie Sie aus der Stichprobenumfangsplanung in Abschnitt 1.3.2 wissen, kann man zum t-Test für abhängige Stichproben für eine konkret vorgegebene Populationseffektstärke d_z , eine Testausrichtung (ein- oder zweiseitig) und ein α -Fehlerniveau ...

- die Teststärke (Power) bzw. das β -Fehler-Risiko zu einer festen Stichprobengröße ausrechnen,
- für eine gewünschte Teststärke (z.B. $1 - \beta = 0,8$) die erforderliche Stichprobengröße ermitteln.

7.1.8 Zweiseitiges Testproblem

Passend zu unserer KFA-Hypothese haben wir bislang das *einseitige* Testproblem behandelt. Wir wollen noch das folgende **zweiseitige Testproblem** betrachten:


$$H_0 : \mu_M = \mu_O \quad \text{vs.} \quad H_1 : \mu_M \neq \mu_O$$

bzw.

$$H_0 : \mu_Z = 0 \quad \text{vs.} \quad H_1 : \mu_Z \neq 0$$

Die H_0 des zweiseitigen Tests ist identisch mit dem *Rand* der H_0 zum einseitigen Test.

Man verwendet beim zweiseitigen Test dieselbe Teststatistik T_Z wie beim einseitigen Test. Nun sind aber *betragsmäßig* große T_{emp} - Werte (mit *positivem oder negativem* Vorzeichen) indikativ für eine Abweichung von der Nullhypothese. Nach einem generellen Prinzip der Testkonstruktion müssen *alle* Elemente der Alternativhypothese (im zweiseitigen Fall also mit $\mu_Z < 0$ oder $\mu_Z > 0$) eine faire Chance haben, sich in einem signifikanten Ergebnis zu artikulieren. Anderenfalls resultiert ein so genannter *verfälschter Test*. Daher sind beim zweiseitigen Test *zwei* symmetrisch angeordnete Ablehnungsbereiche zu verwenden, damit T_{emp} - Werte mit einem großen positiven *oder* negativen Abstand vom Wert 0 (T_Z -Erwartungswert unter der Nullhypothese) zum signifikanten Testergebnis führen können:



Damit ein zweiseitiger Test das α -Niveau einhält, muss für seinen kritischen Wert $T_{\text{krit},2}$ gelten:

$$P_{H_0}(T_Z \leq -T_{\text{krit},2}) + P_{H_0}(T_Z \geq T_{\text{krit},2}) = P_{H_0}(|T_Z| \geq |T_{\text{krit},2}|) = \alpha$$

Für $\alpha = 0,05$ und $n = 31$ erhält man $T_{\text{krit},2} = \pm 2,04$.

EDV-Programme liefern allerdings keine kritischen Werte, sondern die Überschreitungswahrscheinlichkeit

$$P_{H_0}(|T_Z| \geq |T_{\text{emp}}|)$$

Damit führt man analog zum einseitigen Fall den Testentscheid zum gewünschten α -Niveau durch, z.B.:

$$P_{H_0}(|T_Z| \geq |T_{\text{emp}}|) \begin{cases} \geq 0,05 & \Rightarrow H_0 \text{ beibehalten} \\ < 0,05 & \Rightarrow H_0 \text{ verwerfen (Entscheidung für } H_1) \end{cases} \quad (7-3)$$

7.1.9 Einseitige Überschreitungswahrscheinlichkeit aus der zweiseitigen bestimmen

Weil unsere Teststatistik T_Z unter der Nullhypothese (genauer: bei $\mu_Z = 0$) symmetrisch um den Wert 0 verteilt ist, gilt für $T_{\text{emp}} \geq 0$:

$$P_{H_0}(T_Z \geq T_{\text{emp}}) = \frac{1}{2} \cdot P_{H_0}(|T_Z| \geq |T_{\text{emp}}|) \quad (7-4)$$

Die Überschreitungswahrscheinlichkeit des einseitigen t-Tests ergibt sich also durch Halbieren aus der Überschreitungswahrscheinlichkeit des zweiseitigen t-Tests (, sofern die Prüfgröße das von der einseitigen H_1 behauptete Vorzeichen besitzt). Dieser Zusammenhang ist wichtig in der statistischen Praxis mit SPSS, weil dieses Programm bei t-Tests häufig nur die zweiseitige Überschreitungswahrscheinlichkeit mitteilt.

Sie dürfen aber den Zusammenhang in Gleichung (7-4) aber nicht auf beliebige Testverfahren generalisieren. Wir werden z.B. im Zusammenhang mit der Kreuztabellenanalyse den exakten Test von Fisher kennen lernen, bei dem eine analoge Gleichung *nicht* gilt (vgl. Abschnitt 13.4.5.1).

7.2 Teststatistik und Annahmen im Modell der bivariaten linearen Regression

Unsere *differentialpsychologische* Hypothese bezieht sich auf den Steigungskoeffizienten β_1 in der linearen Regression von AERGAM auf LOT:

$$\text{AERGAM} = \beta_0 + \beta_1 \text{LOT} + \varepsilon, \quad \varepsilon \sim N(0, \sigma^2)$$

Die Hypothesen des Testproblems lauten:

$$H_0 : \beta_1 \geq 0 \quad \text{vs.} \quad H_1 : \beta_1 < 0$$

7.2.1 Teststatistik

Es kommt eine Teststatistik zum Einsatz, die sich im vorliegenden Fall der *bivariaten* linearen Regression besonders bequem mit Hilfe der Stichprobenkorrelation r zwischen Kriterium und Regressor ausdrücken lässt:

$$T_r := \frac{r\sqrt{n-2}}{\sqrt{1-r^2}}$$

Als Effektstärkemaß zur bivariaten linearen Regression haben wir in Abschnitt 1.3.3 kennen gelernt:

$$f^2 = \frac{\rho^2}{1-\rho^2}$$

Offenbar ist das Quadrat der Teststatistik

$$T_r^2 = \frac{r^2}{1-r^2} (n-2)$$

abgesehen vom ergebnisunabhängigen Faktor $(n-2)$ ein Schätzer für die Effektstärke. Damit zeigt die Prüfgröße T_r an, wie stark die Daten von der Nullhypothesenbehauptung abweichen.

Außerdem ist T_r bei gültiger Nullhypothese (genauer: bei $\beta_1 = 0$) t-verteilt mit $n-2$ Freiheitsgraden, sofern die Voraussetzungen des Regressionsmodells erfüllt sind (siehe Abschnitt 7.2.2). Damit kann analog zu Abschnitt 7.1.4 die Überschreitungswahrscheinlichkeit für einen Stichprobenwert der Prüfgröße berechnet werden.

Für statistisch besonders Interessierte soll noch eine alternative Darstellung für T_r vorgeführt werden. Weil der Stichprobenschätzer b_1 des Steigungskoeffizienten in folgender Beziehung zur Stichprobenkorrelation r und den Schätzern $\hat{\sigma}_Y$ und $\hat{\sigma}_X$ für die Standardabweichungen des Kriteriums Y und des Regressors X steht,

$$b_1 = r \frac{\hat{\sigma}_Y}{\hat{\sigma}_X}$$

und der geschätzte Standardfehler zu b_1 gleich

$$\hat{\sigma}(b_1) = \frac{\hat{\sigma}_Y}{\hat{\sigma}_X} \frac{\sqrt{1-r^2}}{\sqrt{n-2}}$$

ist (siehe z.B. Cohen et al. 2003, S. 42), kann die Prüfgröße T_r als Quotient aus dem Stichprobenschätzer b_1 und seinem geschätzten Standardfehler geschrieben werden:

$$T_r = b_1 \frac{\hat{\sigma}_X}{\hat{\sigma}_Y} \frac{\sqrt{n-2}}{\sqrt{1-r^2}} = \frac{b_1}{\hat{\sigma}(b_1)}$$

Diese Prüfgrößenkonstruktion ist typisch für Tests über Populationsparameter.

7.2.2 Annahmen

Die Annahmen im Modell der bivariaten linearen Regression werden anschließend der bequemen Schreibweise halber für ein Kriterium Y und einen Regressor X beschrieben.

Um verbreiteten Missverständnissen entgegen zu wirken, soll vorab betont werden:

- Es wird *keine* Annahme über die Verteilung des Regressors benötigt.
- Es wird keine Annahme über die *univariate* Verteilung des Kriteriums (die so genannte *Randverteilung*) benötigt.
- Es sind die **Residuen des Modells**, welche die gleich zu erläuternden Verteilungsvoraussetzungen (Erwartungswert Null für alle Werte des Regressors, Normalität, Varianzhomogenität, Unkorreliertheit) erfüllen müssen.

7.2.2.1 Linearität


Für die (nicht direkt beobachtbare) Fehler- bzw. Residualvariable ε wird angenommen, dass sie für jeden festen X -Wert den Erwartungswert 0 hat ($\varepsilon \sim N(0, \sigma^2)$). Folglich hängt der X -bedingte Erwartungswert $E_X(Y)$ des Kriteriums **linear** von X ab:

$$E_X(Y) = \beta_0 + \beta_1 X$$

Für jeden festen X -Wert liegt der Erwartungswert $E_X(Y)$ der zugehörigen Y -Werte auf der **Regressionsgeraden** durch die Punktepaaire

$$(X, \beta_0 + \beta_1 X)$$

Dabei ist β_0 der Schnittpunkt der Regressionsgeraden mit der Y -Achse (Ordinatenabschnitt) und β_1 die Steigung der Regressionsgeraden (der Tangens des Winkels γ der Regressionsgeraden mit der X -Achse). Unserer differentialpsychologischen Hypothese entspricht eine Regressionsgerade mit negativer Steigung, weil wir eine Ärgerreduktion bei zunehmendem Optimismus erwarten:



Zur Interpretation des Koeffizienten β_1 : Erhöht man X um eine Einheit, so sinkt modellgemäß der Erwartungswert $E_X(Y)$ um β_1 Einheiten.

7.2.2.2 Normalität der Residuen

Für Residualvariable ε wird angenommen, dass sie normalverteilt ist. Sie dürfen sich vorstellen, dass es für jede X -Ausprägung eine Normalverteilung potentieller ε -Werte gibt, aus der zufällige Realisationen gezogen werden, die zusammen mit dem konstanten Anteil $\beta_0 + \beta_1 X$ die Realisationen der abhängigen Variablen Y ergeben.

7.2.2.3 Varianzhomogenität der Residuen

Die Normalverteilungen der ε -Variablen zu den verschiedenen X -Ausprägungen haben alle dieselbe Varianz σ^2 . Statt von *Varianzhomogenität* spricht man auch von *Homoskedastizität*.

7.2.2.4 Unkorreliertheit der Residuen

Die Residuen zu den einzelnen Beobachtungen (Fällen) in der Stichprobe sind unkorreliert.

Bei unserer querschnittlich angelegten Studie mit Einzelpersonen als Untersuchungseinheiten sind korrelierte Residuen nahezu ausgeschlossen. Begründete Zweifel an der Unkorreliertheit bestehen in folgenden Situationen:

- Zeitreihen-Stichprobe (z.B. Arbeitsmarktdaten aus 40 aufeinander folgenden Jahren)
Zu Regressionsmodellen für seriell abhängige Daten siehe z.B. Baltes-Götz (2014).
- Panel-Stichprobe (z.B. 100 Teilnehmer und 5 Untersuchungswellen) oder
Cluster-Stichprobe (z.B. 300 Schüler aus insgesamt 20 Schulklassen)
In solchen Fällen kann man eine so genannte **Mehrebenenanalyse** durchführen (siehe z.B. Baltes-Götz 2013a) oder ein **GEE-Modell** (*Generalized Estimating Equation*) anwenden (siehe z.B. Baltes-Götz 2015b).

8 Gründliche Verteilungsanalyse für metrische Variablen

Für die folgenden Schritte wird eine aktive SPSS-Sitzung mit geöffneter Fertigdatendatei **kfa.sav** vorausgesetzt. Ob Sie die SPSS-Kommandos zu den anstehenden Analysen für eine spätere Wiederverwendung konservieren wollen, bleibt Ihnen überlassen.


Wir untersuchen die univariaten Verteilungen der abgeleiteten Variablen LOT, AERGAM, A-ERGZ und BMI. U.a. kümmern wir uns um die gemäß Abschnitt 7.1 beim t-Test für verbundene Stichproben zur Prüfung unserer allgemeinspsychologischen KFA-Hypothese benötigte **Normalverteilungsannahme** für AERGZ.

Analog zu den Verteilungsanalysen in Kapitel 4, die auch zur Datenprüfung dienten, wollen wir bei den Verteilungen der abgeleiteten Variablen auch auf Anomalien infolge fehlerhafter oder schlecht durchdachter Berechnungsvorschriften achten. Außerdem wollen wir noch eine weitere Gefahrenquelle für unser Forschungsprojekt ins Visier nehmen:

8.1 Diagnose von Ausreißern

Als **Ausreißer** bezeichnet man extreme Werte, die zwar innerhalb des logisch möglichen Wertebereichs liegen, aber doch mit großer Wahrscheinlichkeit *nicht* aus der interessierenden Verteilung bzw. Population stammen. Diese Werte haben insbesondere auf parametrische Auswertungsverfahren einen starken, verzerrenden Einfluss. Daher wollen wir ab jetzt auch auf Ausreißer achten.

Dazu lassen wir uns für jede Variable einen **Boxplot** erstellen. Dieses Instrument der explorativen Datenanalyse zeigt auf prägnante Weise wesentliche Verteilungsinformationen, und ist zur Identifikation von Ausreißern gut geeignet. Die Bestandteile eines Boxplots haben folgende Bedeutung:



Man bezeichnet Q_1 bzw. Q_3 auch als den *unteren* bzw. *oberen Angelpunkt* (engl.: *hinge*) der Verteilung und spricht gelegentlich von den *Tukey-Angelpunkten*, um die Verdienste von John Tukey bei der Entwicklung der explorativen Datenanalyse zu würdigen. Die Länge der Box (Bereich von Q_1 bis Q_3) ist gerade der *Interquartilsbereich* (engl. interquartile range, abgekürzt IQR), den wir schon in Abschnitt 4.5.2 als robustes Streuungsmaß kennen gelernt haben.

Bei der Boxplot-basierten Ausreißerdiagnose differenziert man zwischen zwei Schweregraden: Ist ein Wert von der Box mehr als 1,5 und maximal 3 Boxlängen entfernt, wird er als **Ausreißer** bezeichnet. Ist ein Wert von der Box mehr als 3 Boxlängen entfernt, wird er als **extrem** bezeichnet.

Als Ursachen für Ausreißer und extreme Werte kommen in Frage:

- Erhebungs- bzw. Erfassungsfehler
Messwerte können falsch ermittelt oder fehlerhaft in die EDV übernommen worden sein.
- Besondere Umstände beim Merkmalsträger
Bei einer Agrarstudie zum Ertrag verschiedene Getreidesorten kann z.B. der Boden in einer bestimmten Versuchsparzelle durch einen Ölunfall verseucht worden sein.

Eindeutig irreguläre Daten müssen natürlich entfernt werden. Sie können z.B. mit dem Dateneditor in der Rohdatendatei:

- einen Wert löschen, d.h. durch SYSMIS ersetzen
- einen Wert als MD-Indikator deklarieren
- einen kompletten Fall löschen

Natürlich dürfen Sie keine Daten eliminieren, weil sie Ihren Hypothesen widersprechen.


8.2 Die SPSS-Prozedur zur explorativen Datenanalyse

Für die Verteilungsanalyse bei intervallskalierten Variablen (inklusive Ausreißerdiagnose und Normalverteilungsbeurteilung) eignet sich die SPSS-Prozedur zur explorativen Datenanalyse besser als die in Kapitel 4 der Einfachheit halber bevorzugte Häufigkeitsanalyse. Natürlich sollten Sie in Zukunft auch die Verteilungen von metrischen Rohvariablen mit der leistungsfähigeren explorativen Datenanalyse untersuchen.


Starten Sie deren Dialogbox mit:

Analysieren > Deskriptive Statistiken > Explorative Datenanalyse

Transportieren Sie die zu untersuchenden Variablen in die Liste der **abhängigen Variablen**, und wählen Sie die Variable FNR zur Fallbeschriftung aus, damit mögliche Ausreißer durch ihre Fallnummer identifiziert werden können:




Fordern Sie in der **Diagramme**-Subdialogbox zusätzlich **Histogramme** sowie **Normalverteilungdiagramme mit Tests** an:



Das Kontrollkästchen zum Anfordern von Normalverteilungsanpassungstests (Kolmogorov-Smirnov mit Lilliefors-Korrektur und Shapiro-Wilk) hat SPSS wirklich sehr gut in der **Diagramme**-Subdialogbox der explorativen Datenanalyse versteckt.

Der Klarheit halber soll nochmals betont werden, dass wir nur für die Variable AERGZ eine Normalverteilungsvoraussetzung zu prüfen haben (vgl. Abschnitt 7.1.2). Allerdings sind die teilweise irrelevanten Ausgaben für LOT, AERGAM und BMI kein Grund dafür, zwei verschiedene Analysen anzufordern.

Wie ein Blick in den **Optionen**-Dialog zeigt, arbeitet die explorative Datenanalyse per Voreinstellung mit dem **listenweisen Fallausschluss**, so dass nur Fälle mit gültigen Werten für *alle* abhängigen Variablen in der Analyse verbleiben:



Mit dem alternativen **paarweisen Ausschluss** können Sie z.B. verhindern, dass bei der AERGZ-Verteilungsanalyse Fälle ausgeschlossen werden, weil deren BMI-Wert fehlt. In der

Manuskriptstichprobe sind allerdings bei den vier aktuell betrachteten Variablen alle Werte vorhanden.

Wir erhalten im Ausgabefenster u.a. für jede abhängige Variable einen Boxplot.


8.3 Ausreißer- und Normalverteilungsbeurteilung für AERGZ

Bei der Ausreißeranalyse gibt es nur einen Problemfall und zwar ausgerechnet bei der Variablen AERGZ, über die unsere zentrale KFA-Hypothese geprüft werden soll. Hier tanzt Fall Nr. 4 aus der Reihe:




Diese Person hatte *ohne* KFA eine Ärgerstemperatur von 60° gemeldet, die sich dann durch die KFA-Komponente auf 20° abkühlte. Zwar darf dieses Muster nicht a-priori als verdächtig gelten, weil es unserer Hypothese widerspricht, doch der Boxplot gibt eine klare Empfehlung, den Fall bei dieser Analyse auszuschließen. Allerdings scheut sich ein redlicher Forscher, Daten zu neutralisieren, die der eigenen Hypothese widersprechen.

Vor einer endgültigen Entscheidung wollen wir die Verteilung von AERGZ noch weiter analysieren, da beim geplanten t-Test zur allgemeinspsychologischen KFA-Hypothese vorausgesetzt werden muss, dass AERGZ (in der Population) normalverteilt ist. Damit der extreme AERGZ-Wert von Fall Nr. 4 die weitere Verteilungsanalyse nicht beeinflusst, soll er vorübergehend neutralisiert werden. Weil wir noch keine Methode kennen, komplette Fälle von einer Analyse fern zu halten (siehe Kapitel 12), deklarieren wir den betroffenen Wert (= -4) kurzerhand als MD-Indikator. Markieren Sie in der Variablenansicht des Datenfensters die **Fehlend** - Zelle zur Variablen AERGZ, klicken Sie auf den Erweiterungsschalter , und tragen Sie den Wert -4 als einzelnen MD-Indikator ein:



Das folgende Histogramm zeigt, dass die AERGZ-Verteilung auch *nach* Elimination von Fall Nr. 4 noch deutlich von der Normalität abweicht:



Tatsächlich lehnen auch *nach* der Elimination des Ausreißers die beiden von SPSS angebotenen Normalverteilungstests (Kolmogorov-Smirnov mit Lilliefors-Korrektur und Shapiro-Wilk) die im t-Test benötigte Normalverteilungsannahme ab:

Tests auf Normalverteilung

	Kolmogorov-Smirnov ^a			Shapiro-Wilk		
	Statistik	df	Signifikanz	Statistik	df	Signifikanz
Ärger-Zuwachs durch die KFA	,207	30	,002	,913	30	,018

a. Signifikanzkorrektur nach Lilliefors

Auch diese Testentscheidung folgt der in Abschnitt 7.1 beschriebenen Logik, wobei folgende Hypothesen zur Konkurrenz stehen:

H_0 : AERGZ ist normalverteilt versus H_1 : AERGZ ist *nicht* normalverteilt

Die von SPSS berechnete Überschreitungswahrscheinlichkeit (**Signifikanz**) ist bei beiden Teststatistiken kleiner als 0,05, so dass beide Tests übereinstimmend die Nullhypothese verwerfen.

Dies ist vor allem deshalb ein ernst zu nehmender Befund, weil unsere Stichprobe relativ klein und damit die Power der Tests eher gering ist.

Von den beiden Tests zur Normalitäts-Nullhypothese hat das Verfahren von Shapiro-Wilk den besseren Ruf. Nach Brosius (2013, S. 405) ist es vor allem bei kleineren Stichproben ($N < 50$) zu bevorzugen.

Bei einer *großen* Stichprobe besitzen die Normalitätstests eine hohe Power und decken auch kleine (z.B. für die Validität eines geplanten t-Tests irrelevante) Abweichungen von der Nullhypothese auf. Folglich ist dann ein signifikantes Testergebnis „nicht tragisch“. Wenn bei einer *kleinen* Stichprobe ein Normalitätstest „anschlägt“, ist jedoch von einer relevanten Verletzung der Normalitätsannahme auszugehen.

8.4 Nichtparametrische Testalternativen

Aufgrund der problematischen Verteilungsverhältnisse bei AERGZ entscheiden wir uns, zur Prüfung der KFA-Hypothese statt des geplanten parametrischen t-Tests für verbundene Stichproben einen nichtparametrischen Lagevergleich mit dem **Vorzeichentest** durchzuführen (siehe z.B. Hartung 1989, S. 242f; Siegel 1976, S. 65ff).

Gegen den häufig als Alternative zum t-Test für abhängige Stichproben verwendeten **Wilcoxon-Test** (auch als *Wilcoxon-Vorzeichen-Rangsummentest* bezeichnet) spricht seine Voraussetzung einer *symmetrischen* Verteilung der Differenzen. Wir beobachten für AERGZ auch nach Elimination von Fall Nr. 4 eine negativ-schiefe Verteilung, wobei allerdings das in Abschnitt 4.5.3.1 beschriebene Testverfahren (eventuell aufgrund seiner geringen Teststärke) keine Signifikanz meldet:

Deskriptive Statistik			
		Statistik	Standardfehler
Ärgerzuwachs durch die KFA	Schiefe	-,585	,427
	Kurtosis	-,059	,833

Bei erfüllter Symmetriebedingung wäre der Wilcoxon-Test aufgrund seiner besseren Teststärke gegenüber dem Vorzeichentest zu bevorzugen. Mittlerweile wissen wir allerdings, dass in der ARGZ-Verteilung die positiven Werte so stark dominieren, dass die Power des Vorzeichentests mehr als ausreichend sein dürfte. Wir bevorzugen daher den voraussetzungsarmen Vorzeichentest und vermeiden jeden Zweifel an der Korrektheit der Entscheidung.

Die gerichtete Variante des Vorzeichentests entscheidet sich zwischen den folgenden Hypothesen:

$$H_0: P(\text{AERGZ} > 0) \leq P(\text{AERGZ} < 0).$$

Die Wahrscheinlichkeit für einen Ärgerzuwachs ist nicht höher als die Wahrscheinlichkeit für eine Ärgerreduktion.

versus

$$H_1: P(\text{AERGZ} > 0) > P(\text{AERGZ} < 0)$$

Die Wahrscheinlichkeit für einen Ärgerzuwachs ist höher als die Wahrscheinlichkeit für eine Ärgerreduktion.





Statt der in Abschnitt 7.1 ausführlich vorgestellten Teststatistik T_Z verwendet der Vorzeichentest eine Prüfgröße, die im Wesentlichen auf der Anzahl der positiven AERGZ-Ausprägungen in der

Stichprobe basiert. Sie wird üblicherweise mit Z bezeichnet, weil sie unter der H_0 (genauer: bei einem Median von Null) approximativ z-verteilt (d.h. standardnormalverteilt) ist.¹


Man geht davon aus, dass die Verteilungs-Approximation ab $n \geq 20$ hinreichend genau ist, so dass wir den Test bei unserer Stichprobe ($n = 31$) in der üblichen approximativen Form anwenden dürfen. Bei kleineren Stichproben muss die *exakte* Variante des Tests eingesetzt werden, die von SPSS ebenfalls unterstützt wird.

8.5 Ausreißerbeurteilung für LOT, AERGAM und BMI

Bei den Variablen LOT, AERGAM und BMI finden sich keine Hinweise auf Fehler in den Berechnungsanweisungen oder auf extreme Ausreißer:



¹ Leider kollidiert die Bezeichnung mit der oben eingeführten Abkürzung für unsere Ärgerzuwachsvariable.



Die in den Boxplots auftauchenden Ausreißer sind nicht extrem (Abstand vom 25. bzw. 75. Perzentil kleiner als drei Boxlängen) und sollten aufgrund einer relativ kleinen Stichprobe, welche die Populationsverteilungen nur grob charakterisiert, *nicht* ausgeschlossen werden.

8.6 Vertrauensintervalle für Lageparameter

Bei der bisherigen Diskussion der AERGZ-Verteilung haben wir uns auf Gefahrenquellen für die Interpretierbarkeit des geplanten KFA-Hypothesentests konzentriert (Ausreißer, Abweichung von der Normalverteilung). Wir sollten aber auch jede Möglichkeit nutzen, anhand von Verteilungsdiagrammen und -statistiken einen Eindruck von der empirischen Bewährung der KFA-Hypothese zu gewinnen. Eine genaue Kenntnis des deskriptiven Ergebnisbilds kann verhindern, dass wir von einem durch technische Defekte verfälschten Testergebnis in die Irre geführt werden. Der Boxplot und das Histogramm zu AERGZ (siehe Seite 178 bzw. 179) sprechen klar für einen starken KFA-Effekt in der erwarteten Richtung. Weil fast alle Fälle (aus der nicht allzu kleinen Stichprobe) in der Bedingung *mit* KFA mehr Ärger erleben, bestehen keine ernsthaften Zweifel an der statistischen Bedeutsamkeit des Effekts.

Neben der Existenz und der Richtung des KFA-Effekts interessiert auch seine Stärke, die durch ein Maß der zentralen Tendenz für die Variable AERGZ charakterisiert werden kann. Bezogen auf das „Ärgerthermometer“ aus dem Fragebogen unserer Studie ist von Interesse, um wieviel Grad das Ärgerniveau durch den KFA-Effekt gesteigert wird. Im Unterschied zum Effektstärkenbegriff bei der Stichprobenumfangsplanung (vgl. Abschnitt 1.3.2.4) betrachten wir nun den *unstandardisierten* Ärgerszuwachs.

Auch bei einem Lageparameter ist neben der Punktschätzung ein Vertrauensintervall erwünscht, das den wahren Wert mit einer gewünschten Wahrscheinlichkeit enthält (vgl. Abschnitt 4.8).

8.6.1 Normalverteilungs-Vertrauensintervall für das arithmetische Mittel

Weil die Variable AERGZ auch nach der Elimination von Fall Nr. 4 tendenziell negativ-schief verteilt ist (siehe Abschnitt 8.3), ist das arithmetische Mittel als Maß für die zentrale Tendenz nicht perfekt geeignet (vgl. Abschnitt 4.5.1). In vielen Fällen ist jedoch das Vertrauensintervall für einen *Mittelwert* von Interesse, so dass wir uns jetzt damit beschäftigen wollen, wie ein solches Vertrauensintervall mit SPSS zu ermitteln ist.

Während die SPSS-Prozedur zur Häufigkeitsanalyse, die wir in Kapitel 4 verwendet haben, keine Vertrauensintervalle liefert, erhalten wir von der in Abschnitt 8.2 vorgestellten explorativen

Verteilungsanalyse unaufgefordert das Vertrauensintervall für den Mittelwert, z.B. bei AERGZ (aus der Stichprobe *ohne* den als Ausreißer identifizierten Wert -4):

Deskriptive Statistik			Statistik	Standardfehler
Ärgerzuwachs durch die KFA	Mittelwert		2,20	,242
	95 % Konfidenzintervall für Mittelwert	Untergrenze	1,71	
		Obergrenze	2,69	
	5% getrimmter Mittelwert		2,26	
	Median		2,00	
	Varianz		1,752	
	Standardabweichung		1,324	
	Minimum		-1	
	Maximum		4	
	Bereich		5	
	Interquartilbereich		1	
	Schiefe		-,585	,427
	Kurtosis		-,059	,833

Bei einer akzeptierten Irrtumswahrscheinlichkeit von $\alpha = 0,05$ (Konfidenzniveau 95%) berechnet sich das Konfidenzintervall folgendermaßen aus dem geschätzten arithmetischen Mittel $\bar{Z}$, der geschätzten Standardabweichung S_z und dem $(1-\alpha/2)$ - Quantil der t-Verteilung mit $n - 1$ Freiheitsgraden, das wie in Abschnitt 7.1.5 als T_{krit} bezeichnet werden soll:

$$\left[\bar{Z} - T_{krit} \cdot \frac{S_z}{\sqrt{n}}; \bar{Z} + T_{krit} \cdot \frac{S_z}{\sqrt{n}} \right]$$

Dabei wird die Normalverteilung der betrachteten Variablen vorausgesetzt.

Mit den nach Elimination von Fall 4 noch verbliebenen 30 Fällen resultiert exakt das von der explorativen Datenanalyse berechnete Vertrauensintervall:

$$\left[2,2 - 2,045 \cdot \frac{1,324}{\sqrt{30}}; 2,2 + 2,045 \cdot \frac{1,324}{\sqrt{30}} \right] = [1,71; 2,69]$$

Es ist allerdings nicht vertrauenswürdig, weil seine Berechnung auf der Normalverteilungsannahme für AERGZ beruht, von der wir uns bereits distanziert haben.

Es besteht ein wichtiger Zusammenhang zwischen dem Vertrauensintervall für den Mittelwert und dem *zweiseitigen* Einstichproben - t-Test. Für den t-Test haben wir in Abschnitt 7.1.8 die folgende Entscheidungsregel notiert:

$$\frac{|\bar{Z}|}{S_z} \sqrt{n} > T_{krit,2} \Rightarrow H_0 \text{ verwerfen}$$

Aus der Äquivalenz

$$\frac{|\bar{Z}|}{S_z} \sqrt{n} > T_{krit,2} \Leftrightarrow |\bar{Z}| - T_{krit,2} \cdot \frac{S_z}{\sqrt{n}} > 0$$

folgt unmittelbar, dass der zweiseitige t-Test seine Nullhypothese genau dann verwirft, wenn das Vertrauensintervall zum Mittelwert den Wert Null *nicht* enthält.


Im Beispiel liegt die Null weit vom zweiseitigen Vertrauensintervall entfernt, doch hält uns die verletzte Normalverteilungsannahme noch davon ab, die KFA-Nullhypothese zu verwerfen.

Mit dem *einseitigen* Vertrauensintervall zum Mittelwert existiert übrigens unter den Techniken der Intervallschätzung auch eine Entsprechung zum *einseitigen* Einstichproben - t-Test, der in sehr vielen Fällen gegenüber der zweiseitigen (ungerichteten) Variante zu bevorzugen ist. Allerdings wird das einseitige Vertrauensintervall zum Mittelwert nur selten benutzt, und SPSS kann es nicht berechnen.

Mit der Berechnung eines Vertrauensintervalls zu einer Parameterschätzung sind also bestimmte Hypothesentests zum Vergleich des Parameters mit einem Referenzwert (z.B. Null) bereits entschieden.

8.6.2 Bootstrapping-Vertrauensintervall für das getrimmte Mittel

Die explorative Datenanalyse liefert mit dem **5% getrimmten Mittel** einen gegenüber Ausreißern robusten Schätzwert für den Populationserwartungswert. Bei seiner Berechnung werden vor Anwendung der üblichen Formel für das arithmetische Mittel die 5% der Fälle mit den kleinsten sowie die 5% der Fälle mit den größten Werten ausgeschlossen. Im folgenden Beispiel mit 20 Fällen



The screenshot shows the IBM SPSS Statistics Data Editor window for a file named 'Getrimmtes Mittel.sav'. The window displays a data grid with 20 rows (cases) and 2 columns (variables 'a' and 'b'). The values for variable 'a' are 1 through 19, and for variable 'b' are 2 through 20. The status bar at the bottom indicates 'IBM SPSS Statistics - Prozessor ist bereit' and 'Unicode: ON'.

	a	b	var	var	var	var	var	var	var
1	1	2							
2	2	3							
3	3	4							
4	4	5							
5	5	6							
6	6	7							
7	7	8							
8	8	9							
9	9	10							
10	10	11							
11	11	12							
12	12	13							
13	13	14							
14	14	15							
15	15	16							
16	16	17							
17	17	18							
18	18	19							
19	19	20							
20	120								

ist das getrimmte Mittel der Variablen A identisch mit dem arithmetischen Mittel der Variablen B, weil bei der Berechnung des getrimmten Mittels der Fall mit dem kleinsten Wert und der Fall mit dem größten Wert ausgeschlossen werden:

Deskriptive Statistik			Statistik	Standardfehler
a	Mittelwert		15,5000	5,63471
	95% Konfidenzintervall des Mittelwerts	Untergrenze	3,7064	
		Obergrenze	27,2936	
	5% getrimmtes Mittel		10,5000	
	Median		10,5000	
	Varianz		635,000	
	Standardabweichung		25,19921	
	Minimum		1,00	
	Maximum		120,00	
	Spannweite		119,00	
	Interquartilbereich		10,50	
	Schiefe		4,125	,512
	Kurtosis		17,852	,992
b	Mittelwert		10,5000	1,25831
	95% Konfidenzintervall des Mittelwerts	Untergrenze	7,8452	
		Obergrenze	13,1548	
	5% getrimmtes Mittel		10,5000	
	Median		10,5000	
	Varianz		28,500	
	Standardabweichung		5,33854	
	Minimum		2,00	
	Maximum		19,00	
	Spannweite		17,00	
	Interquartilbereich		9,50	
	Schiefe		,000	,536
	Kurtosis		-1,200	1,038

Das getrimmte Mittel ist gegenüber Ausreißern ähnlich robust wie der Median, verwertet aber mehr Informationen. Es eignet sich insbesondere dann, wenn eine Verteilung relativ symmetrisch, aber durch Ausreißer belastet ist. Bei der Variablen AERGZ wird bei der Berechnung des getrimmten Mittels insbesondere der im Boxplot als Ausreißer identifizierte Fall mit dem Wert -4 neutralisiert:

Deskriptive Statistik			Statistik	Standardfehler
Ärgerzuwachs durch die KFA	Mittelwert		2,00	,308
	95% Konfidenzintervall des Mittelwerts	Untergrenze	1,37	
		Obergrenze	2,63	
	5% getrimmtes Mittel		2,16	
	Median		2,00	
	Varianz		2,933	
	Standardabweichung		1,713	
	Minimum		-4	
	Maximum		4	
	Spannweite		8	
	Interquartilbereich		2	
	Schiefe		-1,575	,421
	Kurtosis		3,850	,821

Auch für das getrimmte Mittel sollte ein Vertrauensintervall angegeben werden, wobei aber die komplexe Definition eine mathematische Herleitung verhindert. In dieser Situation hilft uns eine flexible statistische Technik namens **Bootstrapping** weiter, die zu Recht eine zunehmende Verbreitung erfährt.

In der amerikanischen Variante der Münchhausen-Geschichte schafft es der Held, sich an den eigenen Stiefelriemen aus dem Sumpf zu ziehen, und dieses Verfahren liefert den Namen für eine prominente statistische Schätz- und Testmethodologie, die erstmals von Efron (1982) formuliert worden ist.


Man behandelt die Stichprobe als *Population*, ermittelt durch Ziehen *mit Zurücklegen* zahlreiche Sekundärstichproben (z.B. 1000) mit derselben Größe wie die Original- bzw. Primärstichprobe, wobei in der Regel etliche Fälle *mehrfach* in einer Sekundärstichprobe vertreten sind. Aus jeder Sekundärstichprobe wird mit den üblichen Methoden ein Schätzer für den interessierenden Parameter gewonnen, so dass man eine empirische Stichprobenverteilung erhält. Diese ersetzt die theoretische Stichprobenverteilung, die z.B. auf der Normalverteilungsannahme basiert. Aus der empirischen Stichprobenverteilung lassen sich Vertrauensintervalle und Testentscheidungen konstruieren, die nicht von der Normalverteilungsannahme abhängen.

Lange war die benötigte Rechenleistung ein Hindernis für die Weiterentwicklung und Anwendung der Bootstrap-Technologie, doch mittlerweile suchen die CPU-Hersteller nach relevanten Anwendungen für ihre Gigahertz- und Multicore-Boliden.


In den folgenden Situationen ist die verteilungsvoraussetzungsfreie und sehr generell einsetzbare Ermittlung von Vertrauensintervallen zu Parameterschätzungen durch Bootstrap-Methoden von Interesse:

- Für manche Parameter (z.B. getrimmtes Mittel) ist die mathematische Herleitung des Vertrauensintervalls sehr aufwändig oder unmöglich. Per Bootstrap-Technik ersetzt man die theoretische Stichprobenverteilung durch die oben beschriebene empirische Stichprobenverteilung.
- Bei einer grob verletzten Verteilungsannahme resultieren fehlerhafte (zu kleine oder zu große) Vertrauensintervalle. Mit Hilfe der Bootstrap-Technik erhält man in vielen Fällen realistischere Ergebnisse.

SPSS kann bei vielen Prozeduren das Erstellen von Bootstrap-Sekundärstichproben und die Zusammenfassung der Ergebnisse automatisieren. Wenn eine Prozedur das Bootstrapping unterstützt, ist ein entsprechender Schalter in ihrer Dialogbox vorhanden, z.B. bei der explorativen Datenanalyse:



Im **Bootstrap**-Dialog



aktiviert man das Bootstrapping und wählt eine Anzahl von Sekundärstichproben (z.B. 1000). Ein Startwert für den Pseudozufallszahlengenerator (**Mersenne Twister**) macht das Bootstrap-Ergebnis reproduzierbar.

Für die **Vertrauensintervalle** legt man das Konfidenzniveau fest und wählt in der Regel die **Bias corrected and accelerated** - Methode.

Diagramme produziert SPSS im Bootstrap-Betrieb *nicht*.

Für die Variable AERGS

Deskriptive Statistik								
			Statistik	Standardfehler	Bootstrap a			
					Verzerrung	Standardfehler	95% Konfidenzintervall	
Ärgerzuwachs durch die KFA	Mittelwert		2,00	,308	-,01	,30	1,39	2,52
	95% Konfidenzintervall des Mittelwerts	Untergrenze	1,37					
		Obergrenze	2,63					
	5% getrimmtes Mittel		2,16		-,05	,28	1,54	2,65
	Median		2,00		,18	,39	2,00	3,00
	Varianz		2,933		-,066	1,163	1,181	5,479
	Standardabweichung		1,713		-,054	,341	1,087	2,341
	Minimum		-4					
	Maximum		4					
	Spannweite		8					
	Interquartilbereich		2		0	1	1	3
	Schiefe		-1,575	,421	,341	,596	-2,312	-,170
	Kurtosis		3,850	,821	-1,535	2,427	-,930	7,769

a. Sofern nicht anders angegeben, beruhen die Bootstrap-Ergebnisse auf 1000 Bootstrap-Stichproben

erhalten wir (mit der kompletten Stichprobe) zum getrimmten Mittel das 95% - Konfidenzintervall [1,54; 2,65].

Auch mit einem Bootstrap-basierten Vertrauensintervall lässt sich Signifikanztest zum Vergleich eines Parameters mit einem Referenzwert durchführen (vgl. Abschnitt 8.6.1). Im Beispiel liegt der Referenzwert Null eindeutig links vom Bootstrap-Vertrauensintervall für das getrimmte Mittel. Wir schließen daraus, dass in der Population der Erwartungswert von AERGS größer als Null ist. Damit ist die KFA-Nullhypothese im Grunde verworfen. Der in Abschnitt 8.4 geplante Vorzeichentest ist allerdings nicht ganz überflüssig, weil sein Ergebnis weder von der Normal-

verteilungsannahme, noch von der Bootstrap-Technik abhängig und damit für manche Forschungsinteressenten besonders überzeugend ist.

Nachdem in SPSS im Rahmen einer Analyseanforderung die Bootstrap-Technik eingeschaltet worden ist, wird sie anschließend von allen unterstützenden Prozeduren verwendet. Ist dies bei einer Prozedur unerwünscht, sucht man den **Bootstrap**-Dialog auf und schaltet das Bootstrapping wieder aus.

9 Prüfung der zentralen Projekt-Hypothesen

In diesem Kapitel machen wir uns daran, die zentralen Hypothesen der Kursstudie zu prüfen (emotionaler Effekt kontrafaktischer Alternativen, Ärgerdämpfung durch Optimismus).


9.1 Prüfung der differentialpsychologischen Hypothese

9.1.1 Regression von AERGAM auf LOT


Um die lineare Regression von AERGAM auf LOT zu untersuchen, öffnen wir mit dem Menübefehl

Analysieren > Regression > Linear


die folgende Dialogbox:



In der **Statistiken** - Subdialogbox verlangen wir über die Voreinstellung hinausgehend die Berechnung von **Konfidenzintervallen** zu den Regressionskoeffizienten:



Zur Prüfung der in Abschnitt 7.2 beschriebenen Voraussetzungen ordern wir in der **Diagramme**-Subdialogbox



folgende Ausgaben:

- Das **Streudiagramm** der ausgeschlossen-studentisierten Residuen (interne Variable SDRESID) gegen die standardisierte Modellprognose (interne Variable ZPRED)
Weil die Modellprognose eine lineare Funktion des Regressors ist ($\hat{Y} = b_0 + b_1 X$), erhalten wir letztlich einen Plot der ausgeschlossen-studentisierten Residuen gegen den Regressor. Damit lassen sich die Linearität und die Varianzhomogenität beurteilen.
- Das **Histogramm** der standardisierten Residuen
Damit lässt sich die Normalität der Residuen beurteilen. Zwar wäre ein Histogramm der ausgeschlossen-studentisierten Residuen wünschenswert, doch sind keine relevante Unterschiede zwischen den beiden Residualdiagrammen zu erwarten.

Mit den beiden Diagrammen lassen sich drei Voraussetzungen (Linearität, Varianzhomogenität und Normalität der Residuen) optisch prüfen, die unser Modell


$$\text{AERGAM} = \beta_0 + \beta_1 \text{LOT} + \varepsilon, \quad \varepsilon \sim N(0, \sigma^2)$$

sehr kompakt formuliert in der Formel

$$\varepsilon \sim N(0, \sigma^2)$$


enthält.

Das Streudiagramm bietet wenig Anlass zur Sorge um die Linearität und die Varianzhomogenität:




Wir sehen ein „signifikantes“ Residuum (standardisierter Wert betragsmäßig größer 2), was aber bei 31 Fällen mit der Annahme eines gültigen Modells vereinbar ist. Bei Gültigkeit aller Modellvoraussetzungen sind ca. 5 % standardisierte Residuen mit einem Betrag größer 2 zu erwarten.

Das Histogramm der standardisierten Residuen zeigt eine zufriedenstellende Normalverteilungsapproximation:



Mit den per **Speichern**-Subdialog



in eine neue Variable geschriebenen Residuen lässt sich auch ein formaler Normalverteilungsanpassungstest durchführen (vgl. Abschnitt 8.3). Dabei verwenden wir die zur Normalverteilungsbeurteilung besonders gut geeigneten ausgeschlossen-studentisierten Residuen.

Generell führen derartige Voraussetzungsprüfungen per Signifikanztest nicht unbedingt auf einfache Weise zu einer guten Entscheidung, denn:

- Bei einer kleinen Stichprobe sind Verletzungen der Normalität ernst zu nehmen, können aber mangels Teststärke schwer nachgewiesen werden.
- Bei einer großen Stichprobe verliert die Normalitätsannahme an Bedeutung (zentraler Grenzwertsatz), doch werden hier auch kleine (und für die geplante Inferenzstatistik irrelevante) Abweichungen von der idealen Glockenform signifikant. Nach Bühner & Ziegler (2009, S. 674) ist bei der multiplen linearen Regression ab ca. 100 Fällen eine Verletzung der Normalverteilung der Residuen „weniger problematisch“, wenn keine Ausreißer vorhanden sind. Backhaus et al. (2008, S. 90) rechnen bei unabhängigen Residuen schon ab einem Stichprobenumfang von $N = 40$ mit einer Robustheit der Regressionsanalyse gegenüber Verletzungen der Fehlernormalverteilung.

In unserem Beispiel übersteht die Annahme normalverteilter Residuen auch die Signifikanztests nach Kolmogorov-Smirnov bzw. Shapiro-Wilk:

Tests auf Normalverteilung						
	Kolmogorov-Smirnov ^a			Shapiro-Wilk		
	Statistik	df	Signifikanz	Statistik	df	Signifikanz
Studentized Deleted Residual	,118	31	,200 [*]	,948	31	,133

a. Signifikanzkorrektur nach Lilliefors

*. Dies ist eine untere Grenze der echten Signifikanz.

Nachdem wir die Voraussetzungen als gültig akzeptiert haben, steht einer Inspektion der Regressionsergebnisse nichts mehr im Wege. Wir erhalten zwar, wie erwartet, einen negativen Regressionskoeffizienten, doch ist dieser bei weitem nicht signifikant:

Koeffizienten ^a							
Modell	Nicht standardisierte Koeffizienten		Standardisierte Koeffizienten	T	Sig.	95,0% Konfidenzintervalle für B	
	Regressionskoeffizient B	Standardfehler	Beta			Untergrenze	Obergrenze
1 (Konstante)	7,669	2,947		2,602	,014	1,641	13,697
LOT-Optimismus	-,264	,778	-,063	-,339	,737	-1,854	1,327

a. Abhängige Variable: Mittel der Ärger-Variablen

SPSS ermittelt eine zweiseitige Überschreitungswahrscheinlichkeit von 0,737, die auch nach der zulässigen Halbierung aufgrund unserer einseitigen Fragestellung von der Signifikanzgrenze 0,05 sehr weit entfernt ist. Der LOT-Optimismus zeigt entgegen unserer Annahme fast keinen linearen Zusammenhang mit dem mittleren Ärger in der fiktiven Situation.

Wer sich ausführlicher über die lineare Regressionsanalyse mit SPSS informieren möchte, kann ein ZIMK-Manuskript zu diesem Thema (Baltes-Götz 2014) auf dem Webserver der Universität Trier von der Startseite (<http://www.uni-trier.de/>) ausgehend folgendermaßen finden:

IT-Services (ZIMK) > Downloads & Broschüren > Statistik >
Lineare Regressionsanalyse mit SPSS

9.1.2 Methodologische Anmerkungen

9.1.2.1 Explorative Analysen im Anschluss an einen „gescheiterten“ Hypothesentest

Auf das „Scheitern“ einer konfirmatorischen Forschungsbemühung werden in der Regel explorative Analysen folgen, wobei revidierte bzw. neue Hypothesen entstehen können. Wir werden uns in Abschnitt 11.4 z.B. dafür interessieren, ob eventuell das Geschlecht den Zusammenhang zwischen Optimismus und Ärger moderiert. Allerdings ist es *nicht* möglich, revidierte oder neue Hypothesen anhand *derselben* Stichprobe zu testen. Sie dürfen und sollen aus Ihren Daten etwas lernen, aber ein Test der dabei generierten Hypothesen erfordert eine neue, unabhängige Stichprobe.

Außerdem sollten Sie es nicht unterlassen, das „Scheitern“ einer Hypothese zu veröffentlichen. Ansonsten tragen Sie dazu bei, in der Fachliteratur ein systematisch verzerrtes Bild der Wirklichkeit aufzubauen.

9.1.2.2 Post hoc - Poweranalyse

Bei der Interpretation des Testausgangs zur differentialpsychologischen Hypothese ist außerdem zu beachten, dass die Power des t-Tests zum Regressionskoeffizienten in unserer relativ kleinen Stichprobe recht bescheiden ist, so dass kleine Effekte leicht übersehen werden können (siehe Power-Analyse in Abschnitt 1.3.3). Unser Testergebnis kann nicht als *Beleg* für die Gültigkeit der Nullhypothese interpretiert werden, doch spricht es gegen die Existenz eines *starken* Effekts. Um zu genaueren Aussagen zu kommen, betrachten wir die Power unseres t-Tests bei unterschiedlichen Effektstärken.


Dabei verwenden wir erneut das Programm **G*Power 3.1**, das schon bei der Stichprobenumfangsplanung in Abschnitt 1.3 zum Einsatz kam. Auf den Pool-PCs der Universität Trier unter dem Betriebssystem Windows ist G*Power 3.1 folgendermaßen zu starten

Start > Programme > Statistik > GPower

Wir wählen:

- | | |
|---------------------------------------|---|
| • Test family: | t-Tests |
| • Statistical test: | Linear Multiple Regression: Fixed model, single regression coefficient |
| • Type of power analysis | Post hoc |
| • Tail(s) | One |
| • Effect size f^2 | 0.0989011 |
| • α err prob | 0.05 |
| • Total sample size | 31 |
| • Number of predictors | 1 |


Die Effektstärke von ca. 0,1 resultiert aus der Annahme, dass 9 % der Kriteriumsvarianz durch den Regressor aufgeklärt werden können. Nach einem Klick auf den Schalter **Calculate** wird für den Test zur differentialpsychologischen Hypothese eine Teststärke (Power) von lediglich 0,53 berechnet:



Um zu einer Darstellung der Power als Funktion der Effektstärke zu gelangen, klicken wir auf den Schalter **X-Y plot for a range of values** und wählen

- | | |
|---------------------------|--|
| • Plot (on y axis) | Power (1 - β err prob) |
| • as a function of | Effect size f^2 |
| • from | 0.1 |
| • in steps of | 0.05 |
| • through to | 0.5 |
| • Plot | 1 |

Nach einem Klick auf den Schalter **Draw Plot** zeigt die folgende Abbildung, wie bei fester Stichprobengröße ($n = 31$) die Power des einseitigen Tests von der Effektstärke abhängt:



Erst ab einer Effektstärke von ca. $f^2 = 0,35$ (bzw. $\rho^2 = 0,26$) ist die Power so groß (ca. 0,95), dass man die ausgebliebene Signifikanz als Beleg gegen einen Effekt dieser Stärke werten kann. Unserer Studie hat also keinesfalls die differentialpsychologische Nullhypothese bewiesen, aber doch ein Argument gegen die Existenz eines starken Effekts ($f^2 \geq 0,35$) geliefert.

9.1.2.3 Fehlende Werte

Fehlende Werte haben Einbußen bei der Teststärke und oft auch verzerrte Schätzwerte zur Folge, so dass einige Anstrengungen zur Vermeidung oder Reduktion des Problems angemessen sind. Wir haben bei der Berechnung des LOT-Werts geeignete Maßnahmen ergriffen, um die Anzahl fehlender Werte gering zu halten (vgl. Abschnitt 6.4).

Wer sich über die in SPSS und im Strukturgleichungsanalyseprogramm Amos enthaltenen Möglichkeiten zur Analyse und Behandlung fehlender Werte informieren möchte, kann ein ZIMK-Manuskript zu diesem Thema (Baltes-Götz 2013b) auf dem Webserver der Universität Trier von der Startseite (<http://www.uni-trier.de/>) ausgehend folgendermaßen finden:

IT-Services (ZIMK) > Downloads & Broschüren > Statistik >
Behandlung fehlender Werte in SPSS und Amos

9.2 Übung

Für die Differenzvariable (GEWICHT - IDEGEW) akzeptieren beide Normalverteilungstests die Nullhypothese (vgl. Abschnitt 8):

Tests auf Normalverteilung

	Kolmogorov-Smirnov ^a			Shapiro-Wilk		
	Statistik	df	Signifikanz	Statistik	df	Signifikanz
Gewicht - Idealgewicht	,092	31	,200*	,984	31	,905

a. Signifikanzkorrektur nach Lilliefors

*. Dies ist eine untere Grenze der echten Signifikanz.

Folglich darf mit den Variablen GEWICHT und IDEGEW ein t-Test für verbundene Stichproben zu folgendem Testproblem durchgeführt werden (vgl. Abschnitt 7.2):

H_0 : Das Realgewicht der Trierer Studierenden liegt im Mittel nicht unter dem Idealgewicht nach der Formel „Größe - 100“.

versus

H_1 : Die Trierer Studierenden sind in Relation zur Idealgewichtsformel „Größe - 100“ im Mittel zu leicht.


Mit den Symbolen μ_R für den Realgewichtsmittelwert und μ_I für den Idealgewichtsmittelwert kann man die beiden konkurrierenden Hypothesen kompakter notieren:

$$H_0 : \mu_R \geq \mu_I \text{ versus } H_1 : \mu_R < \mu_I$$

Öffnen Sie mit dem Menübefehl

Analysieren > Mittelwerte vergleichen > T-Test bei gepaarten Stichproben

die zuständige Dialogbox, und bilden Sie über Markieren und Transportieren ein **Paar** aus den beiden Gewichtsvariablen:




Die resultierende T_Z - Prüfstatistik übertrifft betragsmäßig den in Abschnitt 7.1.5 vorgestellten kritischen Wert 1,7 deutlich, und dementsprechend fällt die Überschreitungswahrscheinlichkeit sehr klein aus, so dass die Nullhypothese verworfen werden kann:

Test für Stichproben mit paarigen Werten

	Paarige Differenzen					t	df	Sig. (2-seitig)
	Mittelwert	Standard- abweichung	Standardfehler Mittelwert	95% Konfidenzintervall der Differenz				
				Unterer	Oberer			
Paar 1 Körpergewicht (in kg) - Idealgewicht nach der Formel Größe - 100	-9,3226	6,1881	1,1114	-11,5924	-7,0528	-8,388	30	,000


Zur grafischen Veranschaulichung der Ergebnisse eignet sich eine gemeinsame Darstellung der Boxplots zu den beiden Verteilungen:




Diese Abbildung ist mit geringem Aufwand über die SPSS-Prozedur zur explorativen Datenanalyse zu erstellen. Öffnen Sie deren Dialogbox mit

Analysieren > Deskriptive Statistiken > Explorative Datenanalyse

und verwenden Sie GEWICHT sowie IDGEW als abhängige Variablen:



Veranlassen Sie im Subdialog **Diagramme**, dass die **abhängigen Variablen** zusammen dargestellt werden:



9.3 Vorzeichentest zur KFA-Hypothese

Nun wollen wir die allgemeinspsychologische Kernhypothese unserer Studie prüfen, dass der Ärger über ein ungünstiges Ereignis durch die mentale Verfügbarkeit kontrafaktischer (also positiver) Alternativen gesteigert wird. Aufgrund der Ausreißer- und Verteilungsanalyse in Abschnitt 8.3 haben wir uns dafür entschieden, statt des ursprünglich geplanten parametrischen t-Tests für abhängige Stichproben den nichtparametrischen **Vorzeichentest** zu verwenden.


Weil der Vorzeichentest weit weniger empfindlich auf Ausreißer reagiert als der parametrische t-Test, können wir den in Abschnitt 8.3 identifizierten kritischen Fall Nr. 4 in der Auswertung belassen. Damit vermeiden wir den Verdacht, die Daten zu unseren Gunsten bereinigt zu haben. Heben Sie also bitte die MD-Deklaration für den Wert -4 bei der Variablen AERGZ wieder auf.

Wir starten mit dem Menübefehl:

Analysieren > Nichtparametrische Tests >

Alte Dialogfelder > Zwei verbundene Stichproben

In der folgenden Dialogbox definieren wir ein Paar mit den zu vergleichenden Variablen und wählen den gewünschten Test:



Wir erhalten folgendes Ergebnis:

Häufigkeiten

		H
Ärger mit kontrafaktischer Alternative -	Negative Differenzen ^a	2
Ärger ohne kontrafaktische Alternative	Positive Differenzen ^b	26
	Bindungen ^c	3
	Gesamtsumme	31

a. Ärger mit kontrafaktischer Alternative < Ärger ohne kontrafaktische Alternative

b. Ärger mit kontrafaktischer Alternative > Ärger ohne kontrafaktische Alternative


c. Ärger mit kontrafaktischer Alternative = Ärger ohne kontrafaktische Alternative

Teststatistiken^a

	Ärger mit kontrafaktischer Alternative - Ärger ohne kontrafaktische Alternative
U	-4,347
Asymp. Sig. (2-seitig)	,000

a. Vorzeichentest

In unserer kleinen Stichprobe kann anstelle der per Voreinstellung gelieferten *asymptotischen* Überschreitungswahrscheinlichkeit auch die *exakte* ohne großen Zeitaufwand berechnet werden. Das ist zwar nicht unbedingt erforderlich, weil die Verteilungs-Approximation schon ab $n \geq 20$ hinreichend genau ist, kann aber auch nicht schaden, wenn der Zeitaufwand im Rahmen bleibt. Nach einem Mausklick auf den Schalter **Exakt** in obiger Dialogbox kann der exakte Test folgendermaßen angefordert werden:



Die unserer gerichteten Fragestellung entsprechende einseitige Überschreitungswahrscheinlichkeit ist deutlich kleiner als die übliche Grenze von 0,05. Damit kann die KFA-Nullhypothese (*Kein Ärgerzuwachs durch eine kontrafaktische Alternative*) zurückgewiesen werden:

Teststatistiken^a

	Ärger mit kontrafaktischer Alternative - Ärger ohne kontrafaktische Alternative
U	-4,347
Asymp. Sig. (2-seitig)	,000
Exakte Sig. (2-seitig)	,000
Exakte Sig. (1-seitig)	,000
Punktwahrscheinlichkeit	,000

a. Vorzeichentest

Als gut mit dem Vorzeichentest harmonisierendes Effektstärkemaß bietet sich der Anteil der Personen mit positivem AERGZ-Wert an: $P(\text{AERGZ} > 0)$. Wir erhalten die Schätzung:

$$\frac{26}{31} \approx 0,839$$

Für eine Variable mit den Werten

1, falls AERGZ > 0

0, falls AERGZ ≤ 0

ergibt sich die eben vorgeschlagene Effektstärke als Anteil der Einser-Fälle, und über das in Abschnitt 4.8 beschriebene Verfahren erhalten wir sogar ein Vertrauensintervall für das Effektstärkemaß:

Konfidenzintervallübersicht				
Konfidenzintervalltyp	Parameter	Schätzung	95% Konfidenzintervall	
			Unterer	Oberer
Erfolgsrate der Binomialverteilung einer Stichprobe (Jeffreys)	Wahrscheinlichkeit (KFA=1,00).	,839	,682	,936

Cohen (1988, S. 147) schlägt vor, zur Beschreibung der Effektstärke beim Vorzeichentest von der Wahrscheinlichkeit für positive Differenzen den Wert 0,5 zu subtrahieren:

$$g := P^+ - 0,5$$

Er nennt zur Interpretation seines Effektstärkebegriffs die folgenden Orientierungswerte:

- kleiner Effekt: $g = 0,05$
- mittlerer Effekt: $g = 0,15$
- großer Effekt: $g = 0,25$

Für unsere KFA-Daten resultiert ein sehr großer Effekt:¹

$$\frac{27,5}{31} - 0,5 \approx 0,387$$

Bei einer Power-Analyse zum Vorzeichentest unter Verwendung von Cohens Effektstärkemaß mit dem Programm G*Power 3.1 (vgl. Abschnitt 1.3.2) wählt man:

- **Test family:** **Exact**
- **Statistical test:** **Proportion: Sign test (binomial test)**

Zur Beurteilung der empirischen Effektstärke im Sinne der in Abschnitt 1.3.2.4 verwendeten Definition ziehen wir trotz schiefer Verteilung den Mittelwert und die Standardabweichung von AERGZ heran, schließen aber den in Abschnitt 8.3 diagnostizierten extremen Wert aus. Die folgende Tabelle stammt von der in Abschnitt 8.2 beschriebenen Prozedur zur explorativen Datenanalyse:

¹ Bei der Schätzung von P^+ sollten Fälle mit identischen Werten für beide Merkmale zu gleichen Teilen als positive bzw. negative Differenzen gewertet werden, damit die Subtraktion von 0,5 zu einem sinnvollen Index führt. Daher wurden die 3 Fälle mit einem unveränderten AERGZ-Wert zur Hälfte als positiv betrachtet.

Deskriptive Statistik			Statistik	Standardfehler
Ärgerzuwachs durch die KFA	Mittelwert		2,20	,242
	95% Konfidenzintervall des Mittelwerts	Untergrenze	1,71	
		Obergrenze	2,69	
	5% getrimmtes Mittel		2,26	
	Median		2,00	
	Varianz		1,752	
	Standardabweichung		1,324	
	Minimum		-1	
	Maximum		4	
	Spannweite		5	
	Interquartilbereich		1	
	Schiefe		-,585	,427
	Kurtosis		-,059	,833

Bei Anwendung der Effektstärkendefinition

$$d_z := \frac{\mu_z}{\sigma_z}$$

auf die empirischen Parameterschätzer ergibt sich ein sehr starker Effekt:

$$\frac{2,20}{1,324} = 1,66$$

Nach Klärung der zentralen Hypothesen ist unser Projekt eigentlich abgeschlossen, aber es gibt noch viele SPSS-Optionen kennen zu lernen, und unsere Daten enthalten sicher auch noch einige interessante Details.

9.4 Arbeiten mit dem Ausgabefenster (Teil II)

Unter dem *Pivotieren* einer Tabelle versteht SPSS u.a. die folgenden Operationen:

- Dargestellte Dimensionen neu auf die Zeilen, Spalten und Schichten der Tabelle verteilen
- Schachtelungsordnung bei den Zeilen-, Spalten- oder Schichtdimensionen ändern
- Kategorien einer Dimension gruppieren bzw. eine Gruppierung aufheben
- Kategorien einer Dimension ausblenden, verschieben oder vertauschen


Im SPSS-Ausgabefenster sind die meisten Tabellen pivotierbar, und das zuständige Werkzeug ist der Pivot-Editor. Er unterstützt neben den Pivot-Operationen noch weitere Maßnahmen zur Gestaltung von Tabellen (z.B. Schriftarten wählen, Anzahl der Nachkommastellen bei Datenzellen ändern).

Leider ist zu bemängeln, dass bei der Arbeit mit dem Pivot-Editor einige Pannen auftreten. Wer ein halbwegs stabiles Nervensystem besitzt, kann das Werkzeug aber trotzdem mit Gewinn einsetzen.

9.4.1 Pivot-Editor starten


Um mit dem Editieren einer Tabelle zu beginnen, können Sie einen Doppelklick darauf setzen oder die Option **Inhalt bearbeiten** aus ihrem Kontextmenü wählen.

Bei der letztgenannten Methode bietet ein Untermenü



die Auswahl zwischen dem Bearbeiten **im Viewer** und dem Öffnen in einem **separaten Fenster**.

Ob ein Doppelklick zur Vor-Ort-Bearbeitung oder zum Öffnen eines separaten Fensters führt, hängt von der Größe der Tabelle und vom **Optionen**-Dialog ab (erreichbar über **Bearbeiten > Optionen**). Hier ist auf der Registerkarte **Pivot-Tabellen** der **Standardbearbeitungsmodus** einstellbar:



Auf derselben Registerkarte kann man über eine Markierung beim Kontrollkästchen **Als Legacy-Tabellen (veraltet) rendern** dafür sorgen, dass Tabellen mit altbewährter Technik aufgebaut werden. Ohne diese Markierung sind die anschließend beschriebenen Arbeiten eventuell nicht vollständig nachvollziehbar. Allerdings klappt im Legacy-Modus die mit SPSS 22 eingeführte Tabellennachbearbeitung (z.B. zur ergebnisabhängigen Hervorhebung) nicht, die über den Dialog **Tabellenstil** oder das Kommando OUTPUT MODIFY angefordert werden kann.

Auf bereits vorhandene Tabellen wirkt sich die Rückkehr zur älteren Technik *nicht* aus.

Wenn der Tabelleneditor in einem separaten Fenster

		Gepaarte Differenzen					T
		Mittelwert	Standardabweichung	Standardfehler des Mittelwertes	95% Konfidenzintervall der Differenz		
					Untere	Obere	
Paaren 1	Körpergewicht (in kg) - Idealgewicht nach der Formel Größe - 100	-9,3226	6,1881	1,1114	-11,5924	-7,0528	-8

läuft, dann ...

- ist bei den im Folgenden angegebenen Menübefehlen das Hauptmenü des separaten Fensters gemeint,
- wird das Editieren über das Schließkreuz des separaten Fensters oder sein **Datei**-Menü beendet.


Ist die Vor-Ort-Bearbeitung

		Gepaarte Differenzen					T	df	Sig. (2-seitig)
		Mittelwert	Standardabweichung	Standardfehler des Mittelwertes	95% Konfidenzintervall der Differenz				
					Untere	Obere			
Paaren 1	Körpergewicht (in kg) - Idealgewicht nach der Formel Größe - 100	-9,3226	6,1881	1,1114	-11,5924	-7,0528	-8,388	30	,000

aktiv, dann ...

- erhält das Ausgabefenster ein angepasstes Hauptmenü,
- wird das Editieren (oft unbeabsichtigt) durch einen Mausklick auf den Viewer-Fensterhintergrund *neben* der bearbeiten Tabelle beendet.

Für allgemeine Pivot-Operationen wird das das folgende Dialogfeld benötigt:



Es enthält je eine Ablagezone für die Zeilen, Spalten und Schichten der Tabelle und je einen Eintrag mit Pivotsymbol  für die dargestellten Tabellendimensionen. Sollten Sie das Dialogfeld vermissen, können Sie es mit dem folgenden Menübefehl aktivieren:

Pivot > Pivot-Leisten

Wir wollen als Beispiel die in einer Übung (siehe Abschnitt 9.2) von Ihnen erstellte Tabelle mit dem t-Test zum Vergleich von Real- und Idealgewicht betrachten:


Test bei gepaarten Stichproben									
		Gepaarte Differenzen				T	df	Sig. (2-seitig)	
		Mittelwert	Standardabweichung	Standardfehler des Mittelwertes	95% Konfidenzintervall der Differenz				
					Untere				Obere
Paaren 1	Körpergewicht (in kg) - Idealgewicht nach der Formel Größe - 100	-9,3226	6,1881	1,1114	-11,5924	-7,0528	-8,388	30	,000

Diese Tabelle enthält leider nur *eine* Schicht, so dass wir den Umgang mit Mehrschichttabellen nicht üben können. In den Zeilen der Tabelle wird die Dimension **Paare** dargestellt. Da wir nur ein einziges Variablenpaar untersucht haben, hat diese Dimension nur *eine* Kategorie. Die Spaltendimension **Statistik** sorgt mit ihren zahlreichen Kategorien für eine überbreite Tabelle, die schlecht auf ein DIN-A4-Blatt im Hochformat passt.


9.4.2 Dimensionen verschieben

Durch das Verschieben ihres Pivotsymbols kann man für eine Dimension neu festlegen, ob ihre Kategorien durch Spalten, Zeilen oder Schichten dargestellt werden sollen. Wenn in unserem Beispiel die beiden Pivot symbole bzw. Dimensionen ihre Plätze tauschen,

Verschiebung der Pivot symbole



Ergebnis



benötigt die Tabelle in horizontaler Richtung deutlich weniger Platz:

Test bei gepaarten Stichproben			Paaren 1
			Körpergewicht (in kg) - Idealgewicht nach der Formel Größe - 100
Gepaarte Differenzen	Mittelwert		-9,3226
	Standardabweichung		6,1881
	Standardfehler des Mittelwertes		1,1114
	95% Konfidenzintervall der Differenz	Untere	-11,5924
		Obere	-7,0528
T			-8,388
df			30
Sig. (2-seitig)			,000


Wenn es lediglich um das Vertauschen von Zeilen und Spalten einer Tabelle geht, kann man an Stelle des flexiblen Pivot-Werkzeugs auch den Menübefehl

Pivot > Zeilen und Spalten transponieren

verwenden.

9.4.3 Gruppierungen

Kategorien einer Dimension können zu einer Gruppe zusammengefasst und durch eine etikettierende Zelle hervorgehoben sein. In unserem Beispiel zeigt sich bei der Statistikdimension eine Gruppe mit dem Etikett **Gepaarte Differenzen** und bei der **Paare**-Dimension eine Gruppe mit dem Etikett **Paaren 1**:




The screenshot shows a Pivot Table titled "Test bei gepaarten Stichproben". The table has two main columns: "Gepaarte Differenzen" and "Paaren 1". The "Gepaarte Differenzen" column is further divided into "Mittelwert", "Standardabweichung", "Standardfehler des Mittelwertes", and "95% Konfidenzintervall der Differenz". The "Paaren 1" column contains the corresponding values for each row. The "95% Konfidenzintervall der Differenz" is further divided into "Untere" and "Obere" bounds.

Gepaarte Differenzen		Paaren 1
Mittelwert		-9,3226
Standardabweichung		6,1881
Standardfehler des Mittelwertes		1,1114
95% Konfidenzintervall der Differenz	Untere	-11,5924
	Obere	-7,0528
T		-8,388
df		30
Sig. (2-seitig)		,000

Eigentlich sollte es möglich sein, unerwünschte Gruppierung folgendermaßen zu beseitigen:

- Rechtsklick auf das Kategorienetikett
- Aus dem Kontextmenü wählen: **Gruppierung aufheben**

In SPSS 22 gelingt es zwar, die Gruppenzelle **Paaren 1** der Beispieltabelle mit der beschriebenen Kontextmenü-Option zu entfernen,



The screenshot shows the same Pivot Table as before, but the "Paaren 1" column has been removed. The table now only contains the "Gepaarte Differenzen" column and its sub-rows.

Gepaarte Differenzen	
Mittelwert	
Standardabweichung	
Standardfehler des Mittelwertes	
95% Konfidenzintervall der Differenz	Untere
	Obere
T	
df	
Sig. (2-seitig)	

bei der Gruppenzelle **Gepaarte Differenzen** ist die Kontextmenüoption jedoch nicht verfügbar. Weil es sich um eine Gruppenzelle zu *Zeilenkategorien* handelt, gelingt das Entfernen aber doch, indem man die Breite der Zelle durch Verschieben ihres rechten Rands auf Null bringt:

		Körpergewicht t (in kg) - Idealgewicht nach der Formel Größe - 100
Gepaarte Differenzen	Mittelwert	-9,3226
	Standardabweichung	6,1881
	Standardfehler des Mittelwertes	1,1114
	95% Konfidenzintervall der Differenz	-11,5924
		-7,0528
T		-8,388
df		30
Sig. (2-seitig)		,000

Dass bei der Arbeit mit dem Pivot-Editor Zellbegrenzungen spontan auftauchen oder verschwinden, gehört seit einigen Generationen zu den Eigenarten des Programms, z.B.:

		Körpergewicht t (in kg) - Idealgewicht nach der Formel Größe - 100
Mittelwert		-9,3226
Standardabweichung		6,1881
Standardfehler Mittelwert		1,1114
95% Konfidenzintervall der Differenz	Unterer Oberer	-11,5924 -7,0528
t		-8,388
df		30
Sig. (2-seitig)		,000

Weil die Endredaktion der Tabellen in der Regel in einem Textverarbeitungsprogramm erfolgt und dort ungehindert möglich ist, kann man mit diesem Fehler leben. Für die aktuell bearbeitete Legacy-Tabelle (siehe obige Empfehlung) lässt sich bei den vorggeführten Pivot-Aktionen das Verschwinden von Zellbegrenzungen z.B. durch die folgende Schrittsequenz vermeiden:

- Ausgangstabelle im Pivot-Editor öffnen
- Gruppenzelle **Paaren 1** beseitigen, z.B. über das Kontextmenü-Item **Gruppierung aufheben**
- Zeilen und Spalten vertauschen, z.B. über den Menübefehl **Pivot > Zeilen und Spalten transponieren**
- Gruppenzelle **Gepaarte Differenzen** durch Verschieben ihres rechten Randes verschwinden lassen

Das unfallfreie Ergebnis:

		Körpergewicht t (in kg) - Idealgewicht nach der Formel Größe - 100
Mittelwert		-9,3226
Standardabweichung		6,1881
Standardfehler Mittelwert		1,1114
95% Konfidenzintervall der Differenz	Unterer Oberer	-11,5924 -7,0528
t		-8,388
df		30
Sig. (2-seitig)		,000

Wenn Sie mehrere Kategorien einer Dimension zu einer Gruppe zusammenfassen wollen, können Sie folgendermaßen vorgehen:

- Alle Kategorien markieren
- Aus dem Kontextmenü zum markierten Bereich die Option **Gruppe** wählen

In der folgenden Version unserer Tabelle wurde eine Gruppe mit den drei Kategorien zum t-Test gebildet:

Test bei gepaarten Stichproben		Körpergewicht t (in kg) - Idealgewicht nach der Formel Größe - 100
Mittelwert		-9,3226
Standardabweichung		6,1881
Standardfehler Mittelwert		1,1114
95% Konfidenzintervall der Differenz	Unterer	-11,5924
	Oberer	-7,0528
Gruppenbeschriftung	t	-8,388
	df	30
	Sig. (2-seitig)	,000

Um einen sinnvollen Text für das Etikett und ein vertikales Zentrieren innerhalb der Zelle kümmern wir uns später.

Selbst definierte Gruppierungen lassen sich über das Kontextmenü-Item **Gruppierung aufheben** wieder entfernen.

9.4.4 Kategorien aus- bzw. einblenden

Wenn eine SPSS-Tabelle zu ausführlich erscheint, können Kategorien einer Dimension ausgeblendet werden. In unserem Beispiel wollen wir bei der Statistikdimension auf den Standardfehler des Mittelwerts verzichten:


Test bei gepaarten Stichproben		Körpergewicht t (in kg) - Idealgewicht nach der Formel Größe - 100
Mittelwert		-9,3226
Standardabweichung		6,1881
95% Konfidenzintervall der Differenz	Unterer	-11,5924
	Oberer	-7,0528
Gruppenbeschriftung	t	-8,388
	df	30
	Sig. (2-seitig)	,000

Weil wir uns für den veralteten, mit relativ wenigen Programmfehlern belasteten Pivot-Modus entschieden haben, müssen wir beim Ausblenden einer Kategorie folgendermaßen vorgehen:

- Rechter Mausklick auf das Kategorienetikett
- Aus dem Kontextmenü wählen: **Auswählen > Datenzellen und Beschriftung**
- Erneuter rechter Mausklick auf das Kategorienetikett
- Aus dem Kontextmenü wählen: **Kategorie ausblenden**

In *Spalten* untergebrachte Kategorien kann man auch auf intuitive Weise eliminieren (wie bei unerwünschten Gruppenzellen):

- linker Mausklick auf den rechten Spaltenrand, Maustaste gedrückt halten
- Spaltenbreite durch Verschieben der Maus reduzieren, bis die Quick-Info **Ausblenden** erscheint:



	Mittelwert	Standardabweichung	Standardfehler des Mittelwertes	95% Konfidenzintervall der Differenz		T	df	Sig. (2-seitig)
				Ausblenden	Obere			
Körpergewicht (in kg) - Idealgewicht nach der Formel Größe - 100	-9,3226	6,1881	1,1114	-11,5924	-7,0528	-8,388	30	,000

- Maustaste loslassen

Zum *Einblenden* von vorher abgeschalteten Kategorien kenne ich (neben **Bearbeiten > Rückgängig**) nur die global wirksame Methode:

Ansicht > Alle Kategorien einblenden

9.4.5 Zellen modifizieren

9.4.5.1 Text editieren

Bei aktivem Pivot-Editor können Sie nach einem Doppelklick auf eine Zelle den enthaltenen Text beliebig ändern. In unserem Beispiel sind folgende Änderungen sinnvoll:

- Der Titel sollte etwas informativer und die Beschriftung der rechten Spalte etwas sparsamer werden.
- Die Gruppe mit den Signifikanztestergebnissen benötigt eine passende Beschriftung.
- Außerdem sollten wir konsistent mit der Hypothesenformulierung (siehe Abschnitt 9.2) die *einseitige* Überschreitungswahrscheinlichkeit angeben. Im aktuellen Beispiel wirkt sich allerdings das Halbieren der betragsmäßig sehr kleinen Zahl auf den ersten drei Dezimalstellen nicht aus.

Das Ergebnis:

t-Test zum Vergleich von Real- und Idealgewicht

		Realgewicht - Idealgewicht
Mittelwert		-9,3226
Standardabweichung		6,1881
95% Konfidenzintervall der Differenz	Unterer	-11,5924
	Oberer	-7,0528
Signifikanztest	t	-8,388
	df	30
	Sig. (1-seitig)	,000

9.4.5.2 Zellen zur weiteren Bearbeitung markieren

Mit dem Menübefehl **Bearbeiten > Auswählen** lassen sich Tabellenbestandteile (z.B. Tabellenkorpus, Datenzellen) zur weiteren Bearbeitung markieren. Außerdem stehen die Windows-üblichen Markierungsmethoden per Maus und Tastatur zur Verfügung.

9.4.5.3 Zelleneigenschaften

Über die per Kontextmenü erreichbare Dialogbox mit den **Zelleneigenschaften** können zahlreiche Attribute der markierten Zellen beeinflusst werden:

- Schriftart, Text- und Hintergrundfarbe
- Zahlenformate, Anzahl der Dezimalstellen
- Ausrichtung der Zellinhalte
- Randabstände der Zellinhalte

Bei der folgenden Variante unserer Beispieltabelle wurden die Gruppenbeschriftungen über das Registerblatt **Ausrichtung und Ränder** vertikal zentriert:

t-Test zum Vergleich von Real- und Idealgewicht

		Realgewicht - Idealgewicht
Mittelwert		-9,323
Standardabweichung		6,188
95% Konfidenzintervall der Differenz	Unterer	-11,592
	Oberer	-7,053
Signifikanztest	t	-8,388
	df	30
	Sig. (1-seitig)	,000

Außerdem wurde die Anzahl der Dezimalstellen folgendermaßen auf drei Stellen vereinheitlicht:

- Alle betroffenen Zellen markieren
- Dialogbox **Zelleneigenschaften** per Kontextmenü öffnen
- Auf der **Formatwert**-Registerkarte die gewünschte Anzahl der **Dezimalstellen** eintragen

9.4.5.4 Spaltenbreite


Wenn sich der Mauszeiger über dem rechten Rand einer Spalte befindet, ändert er seine Form zu einem doppelseitigen Pfeil $\Leftrightarrow$. Jetzt können Sie durch Klicken und Ziehen bei gedrückter linker Maustaste die Spaltengrenze verschieben und somit die Spaltenbreite ändern. Diese Technik

haben wir oben schon dazu benutzt, Zellen oder Spalten auf die Breite Null zu bringen und damit komplett auszublenden.

Über den Menübefehl

Format > Breite der Datenzellen

lässt sich die Breite sämtlicher Datenzellen einer Tabelle numerisch spezifizieren, z.B.:



Nach missratenen Gestaltungsbemühungen bringt eventuell der Menübefehl

Format > Automatisch anpassen

wieder ein akzeptables Ergebnis zu Stande.

9.4.6 Tabellenvorlagen

Für eine Pivot-Tabelle kann nach dem Menübefehl

Format > Tabellenvorlagen

das Design einer Tabellenvorlage übernommen werden. So sieht unser Beispiel nach Anwendung der Vorlage **Academic** aus:

t-Test zum Vergleich von Real- und Idealgewicht		
		Realgewicht - Idealgewicht
Mittelwert		-9,323
Standardabweichung		6,188
95% Konfidenzintervall der Differenz	Unterer	-11,592
	Oberer	-7,053
	t	-8,388
Signifikanztest	df	30
	Sig. (1-seitig)	,000

Im **Optionen**-Dialog von SPSS (erreichbar über **Bearbeiten > Optionen**) kann man auf der Registerkarte **Pivot-Tabellen** eine Tabellenvorlage durch Markieren zum Standard machen.

10 T-Test für unabhängige Stichproben

In diesem Abschnitt interessieren wir uns für Geschlechtsunterschiede beim Body Mass Index und führen mit unseren Variablen GESCHL und BMI einen t-Test für unabhängige Stichproben zum folgenden Hypothesenpaar durch:

H_0 : Bei Frauen ist der BMI-Mittelwert mindestens genauso groß wie bei Männern.

versus


H_1 : Bei Frauen ist der BMI-Mittelwert niedriger als bei Männern.

10.1 T-Test anfordern


Fordern Sie mit folgendem Menübefehl die zugehörige Dialogbox an:

Analysieren > Mittelwerte vergleichen > T-Test bei unabhängigen Stichproben

Transportieren Sie den BMI in die Liste der **Testvariable(n)**, und verwenden Sie Geschlecht als **Gruppenvariable**:



Über den Schalter **Gruppen def.** erreicht man die folgende Dialogbox, um die beiden zu vergleichenden Gruppen über ihre Werte bei der Gruppenvariablen festzulegen:



In unserem Fall sind nur zwei Gruppen vorhanden, die folglich beide teilnehmen sollen.

10.2 Interpretation

Wir erhalten die folgenden deskriptiven Statistiken:

Gruppenstatistiken					
Geschlecht		N	Mittelwert	Standardabweichung	Standardfehler des Mittelwertes
Body Mass Index	Frau	25	20,7488	1,89347	,37869
	Mann	6	22,8078	2,17495	,88792

Bei den Männern fällt der BMI-Mittelwert im H_1 -Sinn um ca. 2 Punkte höher aus.

Zunächst ist die Frage zu klären, welche der beiden angebotenen t-Test – Varianten (*mit* bzw. *ohne* Voraussetzung der Varianzhomogenität) zu verwenden ist. Als Entscheidungshilfe berechnet SPSS den **Levene-Test der Varianzhomogenität**, der in unserem Fall durch eine empirische Überschreitungswahrscheinlichkeit von 0,94 ($> 0,05$) seine Nullhypothese gleicher Varianzen akzeptiert.

Test bei unabhängigen Stichproben										
			Levene-Test der Varianzgleichheit		T-Test für die Mittelwertgleichheit					
			F	Signifikanz	T	df	Sig. (2-seitig)	Mittlere Differenz	Standardfehler der Differenz	95% Konfidenzintervall der Differenz
Body Mass Index	Varianzen sind gleich		,006	,940	-2,329	29	,027	-2,05895	,88417	-3,86727
	Varianzen sind nicht gleich				-2,133	6,937	,071	-2,05895	,96530	-4,34576

Der somit verwendbare klassische t-Test *mit* vorausgesetzter Varianzhomogenität ermittelt eine Überschreitungswahrscheinlichkeit unterhalb der kritischen Grenze von 0,05:

$$p = \frac{0,027}{2} = 0,0135$$

Damit ist die Nullhypothese zu verwerfen, sofern die Voraussetzungen des Tests hinreichend erfüllt sind. Weil ein einseitiges (gerichtetes) Testproblem vorliegt, wäre übrigens auch der bei einem signifikanten Levene-Ergebnis zu verwendende t-Test *ohne* Varianzhomogenitätsannahme zur selben Entscheidung gekommen.


10.3 Prüfung der Voraussetzungen

Nachdem die Varianzhomogenität der Residuen geklärt ist, und deren Unabhängigkeit angenommen werden darf, bleibt von den Voraussetzungen der Analyse noch die Normalität der Residuen zu untersuchen. Die in Abschnitt 7.2 diskutierten Voraussetzungen der linearen Regression gelten auch bei Verwendung von kategorialen Regressoren. Beim t-Test für unabhängige Stichproben kommt *ein dichotomer* Regressor zum Einsatz, wobei die Linearität auf jeden Fall erfüllt ist.

Um die Verteilung der Residuen mit geringem technischem Aufwand per Histogramm beurteilen zu können, führen wir den t-Test für unabhängige Stichproben mit der Prozedur für die lineare Regression erneut durch. Diese Prozedur beherrscht als Spezialfall auch den klassischen t-Test (mit angenommener Varianzhomogenität) und bietet generell die Ausgabe eines Histogramms zu den standardisierten Residuen an. Nach dem Menübefehl


Analysieren > Regression > Linear

wählen wir die **abhängige Variable** BMI und die **unabhängige Variable** GESCHL:




Hätten wir eine Zeichenkettenvariable für das nominalskalierte Merkmal Geschlecht verwendet, wäre übrigens die Verwendung als unabhängige Variable in der Regressionsprozedur gescheitert (vgl. Abschnitt 1.4.3.1).

In der Subdialogbox **Diagramme** fordern wir ein **Histogramm** für die standardisierten Residuen an:



Das resultierende Histogramm gibt wenig Anlass zur Sorge bzgl. der Normalverteilungsannahme:



Die über eine **explorative Datenanalyse** (siehe Abschnitt 8.2) für die abgespeicherten ausgeschlossen-studentisierten Residuen (siehe Abschnitt 9.1.1) durchgeführten Signifikanztests zur Normalitäts-Nullhypothese bestätigen den visuellen Eindruck:¹

Tests auf Normalverteilung						
	a			Shapiro-Wilk		
	Statistik	df	Signifikanz	Statistik	df	Signifikanz
Studentized Deleted Residual	,132	31	,184	,965	31	,383

Signifikanzkorrektur nach Lilliefors

In der Koeffiziententabelle der linearen Regression findet sich erwartungsgemäß das t-Test -Ergebnis wieder, dessen Interpretierbarkeit mittlerweile bestätigt ist:

Koeffizienten ^a							
Modell	Nicht standardisierte Koeffizienten		Standardisierte Koeffizienten	T	Sig.	95,0% Konfidenzintervalle für B	
	Regressionskoeffizient B	Standardfehler	Beta			Untergrenze	Obergrenze
1 (Konstante)	18,690	1,112		16,813	,000	16,416	20,963
Geschlecht	2,059	,884	,397	2,329	,027	,251	3,867

a. Abhängige Variable: Body Mass Index

Durch die Unterschiedlichkeit der beiden Teilstichprobenumfänge wird übrigens keine Voraussetzung des linearen Modells verletzt. Man sollte bei der *Untersuchungsplanung* nach Möglichkeit für gleich große Teilstichproben sorgen, damit der t-Test seine optimal Power bei fixem Gesamtstichprobenumfang erreicht. Bei einer vorhandenen Stichprobe ist es für solche Optimierungsbemühungen zu spät.

10.4 Empirische Effektstärke

Das Ergebnis eines Signifikanztests hängt stark vom Stichprobenumfang ab und sollte daher möglichst durch eine Beurteilung der Effektstärke ergänzt werden, damit ein Ergebnis auf praktische Bedeutsamkeit beurteilt werden kann. Beim t-Test für unabhängige Stichproben ist die Effektstärke d auf Populationsebene unter der Annahme identischer Standardabweichungen folgendermaßen definiert:

$$d := \frac{\mu_1 - \mu_2}{\sigma}$$

Die Differenz der beiden Erwartungswerte wird durch die gemeinsame Standardabweichung dividiert.

Wir beobachten eine starke Verwandtschaft zum Effektstärkenbegriff d_z für den t-Test für abhängige Stichproben (vgl. Abschnitt 1.3.2.4). Nach dem Vorschlag von Cohen (1988, S. 40) gelten außerdem zur Beurteilung der Effektstärken für beide t-Test - Varianten identische Richtwerte:

- kleiner Effekt: $d = 0,2$
- mittlerer Effekt: $d = 0,5$
- großer Effekt: $d = 0,8$

¹ Das Studentisieren ist auch bei einem dichotom-kategorialen Regressor sinnvoll. Es berücksichtigt bei der Standardisierung der Residuen die Hebelwirkungen der Fälle auf die Schätzergebnisse, die bei den Fällen aus der schwächer besetzten Kategorie größer ist.

Zur Schätzung der empirischen Effektstärke eignet sich bei homogenen Varianzen die folgende Formel mit der gemittelten („gepoolten“) Standardabweichung im Nenner:¹


$$\hat{d} := \frac{\bar{x}_1 - \bar{x}_2}{\sqrt{\frac{(n_1 - 1)\hat{\sigma}_1^2 + (n_2 - 1)\hat{\sigma}_2^2}{n_1 + n_2 - 2}}}$$

Für unser Beispiel erhalten wir einen starken Effekt:

$$\hat{d} = \frac{22,8078 - 20,7488}{\sqrt{\frac{(6-1)4,7304 + (25-1)3,5852}{6+25-2}}} = \frac{2,059}{1,9449} = 1,05866104$$

10.5 Grafische Veranschaulichung

Zur grafischen Veranschaulichung des Geschlechtsunterschieds beim BMI eignet sich z.B. das folgende Paar von gruppenspezifischen Box-Plots:




Diese Abbildung ist mit geringem Aufwand über die SPSS-Prozedur zur explorativen Datenanalyse zu erstellen. Öffnen Sie deren Dialogbox mit

Analysieren > Deskriptive Statistiken > Explorative Datenanalyse

und beziehen Sie neben der abhängigen Variablen BMI den Faktor GESCHL ein:

¹ Zur Berechnung der gemittelten Standardabweichung bietet die folgende Webseite <http://www.psychometrica.de/effektstaerke.html#pool> ein bequemes Formular:


	Gruppe 1	Gruppe 2
Standardabweichung	1,89347	2,17495
Gruppengröße (N)	25	6
gepoolte Standardabw. s_{pool}	1,945	




11 Diagrammerstellung am Beispiel des Streudiagramms

Wir haben schon einige grafische Darstellungsmöglichkeiten kennengelernt, die im Rahmen von Statistikprozeduren angeboten werden (z.B. Balkendiagramm, Kreisdiagramm, Histogramm, Boxplot). Im aktuellen Kapitel arbeiten wir erstmals mit dem **Grafik**-Menü und vor allem mit dem Diagrammeditor zur individuellen Nachbearbeitung von Diagrammen.

SPSS-Einsteiger werden vermutlich durch das **Grafik**-Menü leicht irritiert, weil hier gleich *drei* Zugänge angeboten werden:



Über die **alten Dialogfelder**



(verknüpft mit dem SPSS-Kommando GRAPH) oder mit dem Dialog **Diagrammerstellung** (verknüpft mit dem SPSS-Kommando GGRAPH und der *Graphics Programming Language* (GPL)) entstehen Diagramme, die anschließend mit dem **Diagrammeditor** modifiziert werden können. Über die **Auswahl der Diagrammtafelvorgabe** ist ein weiterer Assistent zur Diagrammerstellung verfügbar. Obwohl im Hintergrund ebenfalls das SPSS-Kommando GGRAPH beteiligt ist, gehören die Diagramme zu einer neuen Ausgabekategorie und werden mit dem **Diagrammtafel-Editor** bearbeitet. Ein Blick in das Benutzerhandbuch zu SPSS 22 (siehe IBM Corp. 2013b, S. 191) lässt den Schluss zu, dass der Hersteller von den drei möglichen Einstiegen in die Diagrammproduktion derzeit wohl die **Diagrammerstellung** empfiehlt.

Von den zahlreich angebotenen Diagrammtypen können aus Zeitgründen nur wenige Beispiele behandelt werden. Im aktuellen Kapitel 11 lernen Sie das Streudiagramm inklusive der Optionen zur Erstellung und Nachbearbeitung kennen. Im Abschnitt 13.2 wird ein spezielles Balkendiagramm gestaltet.

11.1 Streudiagramm anfordern


Um die empirische Regression von Gewicht auf Größe und Geschlecht betrachten zu können, fordern wir ein Streudiagramm mit diesen Variablen an. Dies tun wir (mit grundsätzlich identischem Ergebnis) sowohl mit der Dialogbox **Diagrammerstellung** als auch mit einem **alten Dialogfeld**.

11.1.1 Diagrammerstellung


Nach dem Menübefehl

Grafik > Diagrammerstellung

informiert SPSS zunächst darüber, dass bei allen Variablen korrekt deklarierte Messniveaus und bei kategorialen (ordinalen oder nominalen) Variablen außerdem Wertelabels benötigt werden (zur Deklaration von Variablenattributen siehe Abschnitt 3.2.2):



Das Dialogfeld **Diagrammerstellung**



unterstützt zwei Vorgehensweisen zur Definition eines neuen Diagramms:

- Diagrammtyp aus der **Galerie** als Ausgangspunkt wählen und individuell gestalten
- Diagramm aus **Grundelementen** (z.B. Achsensystem, Linie) aufbauen

Wir wählen den vom Hersteller empfohlenen *ersten* Weg:


- Klicken Sie auf die Registerkarte **Galerie**, und wählen Sie den Typ **Streu-/Punkt-diagramm**.
- Befördern Sie das Symbol  zum **gruppierten Streudiagramm** per Doppelklick oder Drag & Drop auf die **Diagrammvorschau** (Entwurfszone) über den Diagrammtypen.
- In der Diagrammvorschau erscheint ein Achsensystem mit Ablageflächen für
 - eine X-Achsen-Variable
 - eine Y-Achsen-Variable
 - eine Gruppierungsvariable (Beschriftung: **Farbe festlegen**)

Außerdem erscheint die zusätzliche Dialogbox **Elementeigenschaften**.

- Bringen Sie nun die drei Variablen GROESSE, GEWICHT und GESCHL in Position:
 - Ziehen Sie aus der Liste in der linken oberen Ecke des Dialogs **Diagrammerstellung** die Variable GROESSE auf die X-Achsen-Ablagefläche.
 - Ziehen Sie die Variable GEWICHT auf die Y-Achsen-Ablagefläche.
 - Ziehen Sie die Variable GESCHL auf die Gruppierungs-Ablagefläche.
 So erhält man für weibliche und männliche Datenpunkte verschiedene Markierungen und kann ggf. geschlechtsbedingte Unterschiede bei der Regression von Gewicht auf Größe erkennen.


Zur Illustration werden künstliche Datenpunkte angezeigt.

- Gehen Sie folgendermaßen vor, um die Variable FNR zur Fallbeschriftung nutzen zu können:
 - Klicken Sie auf die Registerkarte **Gruppen/Punkt-ID**, und markieren Sie das Kontrollkästchen **Punkt-ID-Beschriftung**.
 - Daraufhin erscheint die neue Ablagefläche **Punktbeschriftungsvariable** in der Diagrammvorschau. Ziehen Sie die Variable FNR dorthin.
- Legen Sie einen Titel für das Diagramm fest:
 - Klicken Sie auf die Registerkarte **Titel/Fußnoten**, und markieren Sie das Kontrollkästchen **Titel 1**.
 - Daraufhin erscheint in der Diagrammvorschau der Platzhalter **T1**, und in der Dialogbox **Elementeigenschaften** kann der **Titel 1** markiert und bearbeitet werden, z.B.



Tragen Sie einen Text ein, und quittieren Sie mit einem Mausklick auf den Schalter **Anwenden**.

Nun sollte die Dialogbox **Diagrammerstellung** ungefähr folgendes Bild zeigen:



Nach einem Klick auf den Schalter **OK** wird das Diagramm erstellt. Das Ergebnis ist in Abschnitt 11.2 zu sehen.

Von der Diagrammerstellung erhält man über den Schalter **Einfügen** als Syntax-Äquivalent zu den vorgenommenen Konfigurationen ein GGRAPH-Kommando mitsamt dem darin verwendeten Inline-Code in der GPL (*Graphics Programming Language*), z.B.:

```
GGRAPH
  /GRAPHDATASET NAME="graphdataset" VARIABLES=groesse gewicht geschl fnr
  MISSING=LISTWISE REPORTMISSING=NO
  /GRAPHSPEC SOURCE=INLINE.
BEGIN GPL
  SOURCE: s=userSource(id("graphdataset"))
  DATA: groesse=col(source(s), name("groesse"))
  DATA: gewicht=col(source(s), name("gewicht"))
  DATA: geschl=col(source(s), name("geschl"), unit.category())
  DATA: fnr=col(source(s), name("fnr"), unit.category())
  GUIDE: axis(dim(1), label("Körpergröße (in cm)"))
  GUIDE: axis(dim(2), label("Körpergewicht (in kg)"))
  GUIDE: legend(aesthetic(aesthetic.color.exterior), label("Geschlecht"))
  GUIDE: text.title(label("Regression von Gewicht auf Größe und Geschlecht"))
  SCALE: cat(aesthetic(aesthetic.color.exterior), include("1", "2"))
  ELEMENT: point(position(groesse*gewicht), color.exterior(geschl), label(fnr))
END GPL.
```

Lässt man das GGRAPH-Kommando zusammen mit dem GPL-Code in einem Syntaxfenster ausführen, wird die per Diagrammerstellung gestaltete Grafik neu aufgebaut. Das direkte Ändern

bzw. Verfassen von GGRAPH/GPL - Syntax bietet zwei Vorteile:

- Man gewinnt im Vergleich zum Dialog **Diagrammerstellung** zusätzliche Gestaltungsmöglichkeiten.
- Man kann die Serienproduktion von ähnlichen Diagrammen rationeller erledigen.


Über die GPL informieren das Hilfesystem (siehe: **Reference > GPL Reference**) und ein im Internet frei verfügbares PDF-Dokument (IBM Corp. 2013c). Im Kurs kann die GPL aus Zeitgründen nicht behandelt werden.

11.1.2 Dialogbox Einfaches Streudiagramm


Wer sich mit der **Diagrammerstellung** nicht anfreunden kann, hat in der SPSS-Version 22 auch noch die **alten Dialogfelder** zur Verfügung, z.B. zum Erstellen eines Streudiagramms:

Grafik > Alte Dialogfelder > Streu-/Punkt-Diagramm

In der nach diesem Menübefehl erscheinenden Palette akzeptieren wir für das Streudiagramm mit Gewicht, Größe und Geschlecht die voreingestellte einfache Variante



und wechseln per Mausklick auf den Schalter **Definieren** zur Dialogbox **Einfaches Streudiagramm**, wo die beteiligten Variablen per Drag & Drop oder Transportschalter  ihre Rollen erhalten:



Durch die Verwendung von GESCHL als **Markierungsvariable** werden weibliche und männliche Datenpunkte verschieden dargestellt, so dass geschlechtsbedingte Unterschiede bei der Regression von Gewicht auf Größe ggf. sichtbar werden.

Die Variable FNR soll später im **Datenbeschriftungsmodus** verwendet werden (siehe Abschnitt 11.2).

Nach einem Mausklick auf den Schalter **Titel** tragen wir eine Titelzeile ein:



Quittieren Sie die Subdialogbox mit **Weiter** und die Hauptdialogbox mit **OK**, um das Diagramm zu erstellen.

Das Erstellen eines einfachen Streudiagramms fällt mit dem **alten Dialogfeld** leichter als mit der **Diagrammerstellung** (siehe Abschnitt 11.1.1). Allerdings lassen sich per Diagrammerstellung mehr Darstellungswünsche realisieren. Zum einen bietet der komplexere Dialog mehr Optionen, und zum anderen erhält man nach dem Quittieren des Dialogs einen Block mit editierbarer GPL-Syntax zum Diagramm (siehe Abschnitt 11.1.1).

11.1.3 Auswahl der Diagrammtafelvorlage


Bei der Arbeit mit der **Diagrammerstellung** wählt man zunächst einen Diagrammtyp und besetzt anschließend die dort vorhandenen Rollen durch geeignete Variablen. Bei der **Auswahl der Diagrammtafelvorlage** legt man hingegen erst die Variablen fest und wählt dann zwischen den angebotenen Visualisierungsvorschlägen. Wie man sich leicht vorstellen kann, spielen die deklarierten Messniveaus der Variablen eine wesentliche Rolle für die Zusammenstellung der Vorschlagsliste.

Mit dem Zusatzprogramm *Visualization Designer* (vgl. Abschnitt 2.1) ist es möglich, eigene Diagrammtafelvorlagen zu erstellen, die in SPSS Statistics genutzt werden können und bei entsprechender Passung in der Vorschlagsliste für eine bestimmte Konstellation von ausgewählten Variablen erscheinen.

Nach dem Menübefehl


Grafik > Auswahl der Diagrammtafelvorlage

bietet der folgende Dialog




einen **Basis**- und einen **Detail**-Modus:

- Auf der Registerkarte **Basis** erscheinen nach der Auswahl von Variablen dazu passende Visualisierungsvorschläge zur direkten Übernahme durch Markieren.
- Auf der Registerkarte **Detailliert**



kann man noch Modifikationen vornehmen, z.B. eine Markierungsvariable wählen.


Öffnet man im Ausgabefenster eine durch **Auswahl einer Diagrammtafelvorlage** erstellte Grafik, dann erscheint der **Diagrammtafel-Editor**, z.B.:



Er bietet im Vergleich zum Diagrammeditor (siehe Abschnitt 11.2) sehr eingeschränkte Möglichkeiten und erlaubt z.B. nicht das Ergänzen einer Regressionsgeraden. Wir werden die Diagrammtafel-Technik im Kurs nicht benutzen.

11.2 Streudiagramm per Diagrammeditor modifizieren

Wenn Sie im Ausgabefenster einen Doppelklick auf ein Diagramm setzen, das per **Diagrammerstellung** oder über ein **altes Dialogfeld** entstanden ist, wird es im **Diagrammeditor** geöffnet:




Anschließend werden am Beispiel des Streudiagramms einige allgemeine Bedienungsoptionen des Diagrammeditors vorgestellt. Deren Effekte lassen sich über die Schalter  (mehrstufig) rückgängig machen bzw. wiederherstellen.

Vorweg soll schon verraten werden, wie die Datenbeschriftungen abzuschalten sind, die SPSS übereifrig eingetragen hat, weil wir bei der Diagrammerstellung (siehe Abschnitt 11.1.1) FNR zur **Punktbeschriftungsvariablen** ernannt haben:

- Mausklick auf den Schalter 
- oder Menübefehl **Elemente > Datenbeschriftungen ausblenden**

11.2.1 Eigenschaftsfenster

Zum aktuell im Diagrammeditor markierten Objekt bzw. zur markierten Objektgruppe (erkennbar an einer optischen Hervorhebung) bietet das Eigenschaftsfenster



auf jeweils dynamisch erstellten Registerkarten den Zugriff auf die modifizierbaren Attribute. Bei Bedarf kann das Eigenschaftsfenster per Doppelklick auf ein zu gestaltendes Objekt, über das Symbol , mit der Tastenkombination **Strg+T** oder mit den Menübefehl

Bearbeiten > Eigenschaften

aktiviert werden.

Wer im Beispiel X-Achsenteilstrichwerte im Abstand von 5 cm wünscht, kann so vorgehen:

- X-Achsenteilstrichwerte per Mausklick auf einen Wert markieren



- im Eigenschaftsfenster die Registerkarte **Skala** wählen (siehe oben)
- bei der **ersten Unterteilung** den **benutzerdefinierten** Wert 5 eintragen

- Nach dem **Anwenden** erscheint das Ergebnis:





11.2.2 Markieren von gruppierten Objekten

Sind die Objekte eines Typs gruppiert (z.B. die Datenpunkte in unserem Streudiagramm mit einer Gruppeneinteilung nach Geschlecht), dann wendet SPSS beim Markieren folgende Logik an:


- Ist gerade *kein* Objekt markiert, bewirkt ein Mausklick auf ein beliebiges Objekt aus einer beliebigen Gruppe das Markieren aller Objekte des Typs (aus sämtlichen Gruppen).
- Ein weiterer Mausklick schränkt die Markierung auf die getroffene Gruppe ein.
- Um die Komplettmarkierung zu einer anderen Gruppe wandern zu lassen, setzt man einen Mausklick auf ein Objekt dieser Gruppe.
- Eine alternative Möglichkeit zum Markieren aller Elemente einer Gruppe ist der Mausklick auf das zugehörige Symbol in der Legende, z.B.:



- Ist aktuell eine einzelne Gruppe markiert, kann ein einzelnes *Mitglied* dieser Gruppe durch einen Mausklick markiert werden. Alternativ gelingt die Markierung eines einzelnen Datenpunkts über das Item **Auswählen > Diese Markierung** aus seinem Kontextmenü.
- Sobald ein einzelnes Objekt markiert ist, wandert bei weiteren Mausklicks die Einzelmarkierung über Gruppengrenzen hinweg zum getroffenen Objekt.
- Bei gedrückter **Strg**-Taste ist ein gruppenunabhängiges kumulierendes Markieren möglich.
- Mit dem Lasso-Werkzeug  kann man bei gedrückter linker Maustaste eine Linie um die zu markierenden Objekte (aus beliebigen Gruppen) ziehen, z.B.:



Im Beispiel liegt es nahe, für mindestens eine Gruppe nach vorangegangener Markierung ihrer Datenpunkte das zugehörige Symbol hinsichtlich Form, Größe, Randfarbe und/oder Füllfarbe zu ändern, um die beiden Gruppen besser unterscheidbar zu machen, z.B.:




11.2.3 Menüs und Symbolleisten

Viele Angebote sind über die Untermenüs zu den Items **Optionen** und **Elemente** im Grafikeditor-Hauptmenü sowie über äquivalente Symbolleisten verfügbar (z.B. Anpassungs- oder Interpunktionslinien, Datenbeschriftungen, Legende, Anmerkungen). Außerdem ist zu allen Objekten ein Kontextmenü verfügbar.


Im Beispiel bietet es sich an, über das Symbol  oder den Menübefehl

Elemente > Anpassungslinie bei Gesamtwert

die empirische Regressionsgerade einzeichnen zu lassen:




Bei markierter Regressionsgeraden kann man im Eigenschaftsfenster auf der Registerkarte **Anpassungslinie** die von SPSS übereifrig eingetragene **Beschriftung** mit der Regressionsgleichung entfernen und außerdem die **Konfidenzintervalle** für die **Mittelwerte** anzeigen lassen:



So wird erkennbar, dass die Unsicherheit bzgl. des zu einer bestimmten Größe gehörigen mittleren Gewichts mit der Entfernung von der mittleren Ausprägung des Regressors steigt.

Auf derselben Registerkarte lässt sich auch die **Anpassungsmethode** ändern, z.B. von **Linear** auf **Quadratisch**:




Im Beispiel lässt der erhebliche R^2 -Anstieg vermuten, dass die Regression bei kleinen Personen (oder bei Frauen?) flacher verläuft als bei großen Personen (oder bei Männern?).

Über das Symbol  oder den Menübefehl

Elemente > Anpassungslinie bei Untergruppen

erhält man gruppenspezifische (geschlechtsbedingte) Regressionsgeraden:



Man erkennt in der Grafik einen Geschlechtsunterschied hinsichtlich der Regressionssteigung, der eventuell durch Unterschiede im Körperbau zu erklären ist:



Bei zwei Männern mit 10 cm Größenunterschied besteht möglicherweise ein stärkerer Gewichtsunterschied als bei zwei Frauen mit derselben Größendifferenz. Nach dieser Vermutung *moderiert* Geschlecht den Effekt von Größe auf Gewicht.

Allerdings kennen wir schon eine Alternative zu dieser Deutung: Eventuell folgt die Regression von Gewicht auf Größe unabhängig vom Geschlecht einem quadratischen Modell (siehe oben).

Über die Analyse von Moderatoreffekten mit Hilfe der SPSS-Regressions-Prozedur informiert ein ZIMK-Manuskript (Baltes-Götz 2015a), das auf dem Webserver der Universität Trier von der Startseite (<http://www.uni-trier.de/>) ausgehend folgendermaßen zu finden ist:

IT-Services (ZIMK) > Downloads & Broschüren > Statistik >
Moderatoranalyse per multipler Regression mit SPSS

Überflüssige Objekte lassen sich über ihr Kontextmenü oder (im markierten Zustand) per **Entf**-Taste löschen.

11.2.4 Beschriftungen

Bei vielen Beschriftungen lässt sich nach dem Markieren die Größe des umgebenden Rechtecks über acht Anfasser ändern:



Solche Beschriftungen lassen sich auch verschieben, wobei die Transportfunktionalität des Mauszeigers am Rand aktiv wird, signalisiert durch die Zeigergestalt .

Unbewegliche Texte besitzen einen Markierungsrahmen *ohne* Anfasser, z.B.:


Körpergröße (in cm)

Viele Texte lassen sich ändern. Um in den Eingabemodus zu gelangen, muss man auf das bereits markierte Textfeld einen weiteren Mausklick setzen und erhält bei veränderlichen Texten dann eine Schreibmarke, z.B.:


Körpergröße | (in cm)

Zum Beenden der Texteingabe drückt man die **Enter**-Taste oder setzt einen Mausklick außerhalb des Markierungsrahmens.

Bei der Textformatierung kann alternativ zum Eigenschaftsfenster auch die folgende Symbolleiste verwendet werden:



Über die Schaltfläche  (de)aktiviert man das Werkzeug  zur Datenbeschriftung, das zu angeklickten Datenpunkten den Wert der vereinbarten Fallbeschriftungsvariablen oder aber die laufende Datenfensterzeilennummer in die Grafik einfügt bzw. wieder entfernt, z.B.:



Nach einem rechten Mausklick auf einen Datenpunkt mit dem Fallbeschriftungswerkzeug kann man per Kontextmenü veranlassen, dass die zugehörige Zeile im Datenfenster markiert wird.

11.3 Diagramme verwenden

Wie Tabellen lassen sich auch Diagramme aus dem Ausgabefenster über die Windows-Zwischenablage in andere Anwendungen übertragen (siehe Abschnitt 4.4.4).

Als Ausgabefensterbestandteile lassen sich Diagramme sichern, drucken oder exportieren.

Zur Verwendung als **Vorlage** kann man ein Diagramm aus dem Diagrammeditor mit dem Menübefehl

Datei > Diagrammvorlage speichern


in eine Datei mit der Namenserweiterung **sgt** sichern. Es bestehen etliche Möglichkeiten, eine Vorlage auf andere Diagramme anzuwenden:

- per Diagrammerstellung über **Optionen > Hinzufügen**
- beim Erstellen eines Diagramms über ein **altes Dialogfeld** (siehe Dialogbox **Einfaches Streudiagramm** in Abschnitt 11.1.2)
- im Diagrammeditor über **Datei > Diagrammvorlage zuweisen**
- im SPSS-Optionendialog als Standardvorlage für alle Diagramme (**Bearbeiten > Optionen > Diagramme > Diagrammvorlage**)

Natürlich ist die Verwendung einer Vorlage auch beim Erstellen eines neuen Diagramms per Syntax möglich, z.B.:


```
GRAPH
  /SCATTERPLOT(BIVAR)=groesse WITH gewicht
  /MISSING=LISTWISE
  /TEMPLATE='C:\Program Files\IBM\SPSS\Statistics\22\Looks\APA_Styles.sgt'.
```

SPSS 22 enthält im Ordner **C:\Program Files\IBM\SPSS\Statistics\22\Looks** einige Diagrammvorlagen, z.B. die Vorlage **APA_Styles.sgt** für Diagramme nach den Richtlinien der **American Psychological Association (APA)**:



11.4 Übung

Nach dem „Scheitern“ der differentialpsychologischen Hypothese (siehe Abschnitt 9.1) wird man versuchen, aus den Daten Hinweise für eine mögliche Verbesserung der Hypothese zu gewinnen. Erzeugen Sie ein Streudiagramm mit den Variablen AERGAM und LOT, und verwenden Sie wie in obigem Beispiel GESCHL als Markierungsvariable. Die Manuskriptstichprobe liefert mit eingezeichneten Regressionsgeraden für die Untergruppen das folgende Ergebnis:



Während bei den Frauen offenbar *kein* Zusammenhang zwischen LOT und AERGAM besteht, zeigt sich bei den Männern ein Effekt im Sinne der differentialpsychologischen Hypothese. Allerdings sollten wir die Beobachtung sehr zurückhaltend interpretieren, weil unsere Stichprobe lediglich sechs Männer enthält. Immerhin resultiert bei einer regressionsanalytischen Auswertung für den Moderatoreffekt (siehe Baltes-Götz 2015a) eine relativ kleine Überschreitungswahrscheinlichkeit (0,01):

Koeffizienten^a

Modell		Nicht standardisierte Koeffizienten		Standardisierte Koeffizienten	T	Sig.	95,0% Konfidenzintervalle für B	
		Regressionskoeffizient B	Standardfehler	Beta			Untergrenze	Obergrenze
1	(Konstante)	-19,356	11,285		-1,715	,098	-42,512	3,799
	LOT-Optimismus	7,818	3,121	1,863	2,505	,019	1,414	14,222
	Geschlecht	26,543	10,211	5,426	2,600	,015	5,592	47,494
	Geschlecht * LOT	-7,883	2,860	-5,633	-2,756	,010	-13,751	-2,015

a. Abhängige Variable: Mittel der Ärger-Variablen

Hier haben wir es aber **nicht** mit dem signifikanten Ergebnis eines statistischen Tests zu tun, sondern mit einem deskriptiven Maß zu einer interessanten Vermutung, die sich bei der explorativen Datenanalyse ergeben hat. Eine Testentscheidung über die Moderatorhypothese ist nur in einer unabhängigen Stichprobe möglich.

12 Fälle auswählen


Es kommt durchaus vor, dass man sich bei einer Analyse auf eine Teilstichprobe beschränken möchte. Bei unserer KFA-Studie ist es von Interesse, die Personen mit einem *negativen* KFA-Effekt ($AERGZ < 0$) näher kennen zu lernen. Wir können dazu nach geeigneter Fallauswahl einen Bericht mit interessanten Variablenausprägungen anfordern.

12.1 Auswahl über eine Bedingung


Man kann Fälle in Abhängigkeit von einer Bedingung temporär deaktivieren, aus der Arbeitsdatei entfernen oder in ein neues Datenblatt kopieren. Die zuständige Dialogbox erreichen Sie über den Symbolleistenschalter  oder den Menübefehl:

Daten > Fälle auswählen

Um ein Auswahlkriterium zu formulieren, müssen Sie im Optionenfeld **Auswählen** die Alternative **Falls Bedingung zutrifft** wählen und anschließend die zuständige Subdialogbox mit dem **Falls**-Schalter aktivieren:



Im **Falls**-Dialogfenster ist ein logischer Ausdruck (vgl. Abschnitt 6.5.2) als Auswahlkriterium zu definieren, z.B.:



Wenn Sie nach erfolgreicher Definition des Auswahlkriteriums **Weiter** machen, können Sie im Optionenfeld **Ausgabe** der Hauptdialogbox (siehe oben) entscheiden, was mit den Positiv- bzw. Negativ-Fällen geschehen soll:

- **Nicht ausgewählte Fälle filtern**

SPSS erzeugt aufgrund des logischen Ausdrucks eine Hilfsvariable namens FILTER_\$ mit folgenden Werten:

- 1 falls bei einem Fall der logische Ausdruck wahr ist,
- 0 falls bei einem Fall der logische Ausdruck falsch ist,
- SYSMIS sonst (also bei unbestimmtem Ausdruck).

Diese Variable wird als **Filter** aktiviert, d.h. bis zur Deaktivierung des Filters werden bei allen Analysen nur noch Fälle mit dem Wert 1 bei FILTER_\$ einbezogen. Die in den einstweiligen Ruhezustand versetzten Negativ-Fälle sind im Datenfenster an einer durchgestrichenen Zeilennummer zu erkennen:

	fb	groesse	gewicht	Dekade	idgew	lot	aergam	aergz	bmi	Alter	polymot	filter_\$
1	1	163	51,0	1	63	4,13	6,5	3	19,20	31	1	0
2	1	158	56,0	2	58	3,88	6,5	3	22,43	30	1	0
3	1	174	58,0	1	74	3,63	6,0	4	19,16	31	1	0
4	1	182	77,0	1	82	3,75	4,0	-4	23,25	33	1	1
5	1	180	69,0	1	80	3,88	8,0	0	21,30	33	1	0

Filter wirken sich nur bei statistischen und grafischen Analysen aus. Bei Datentransformationen werden auch die ausgefilterten Fälle einbezogen. Für eine bedingte Datentransformation ist die in Abschnitt 6.5 beschriebene Vorgehensweise zu verwenden.

Wenn ein Filter aktiv ist, wird dies in der Statuszeile angezeigt (siehe Abbildung). Um den Filter später zu deaktivieren, müssen Sie die Dialogbox **Fälle auswählen** erneut aufrufen und im **Auswählen**-Optionenfeld den Ausgangszustand **Alle Fälle** wiederherstellen.

Durch das Einrichten oder Modifizieren eines Filters wird die Variable `FILTER_$` erstellt oder verändert. Folglich fragt SPSS am Ende der Sitzung nach, ob das veränderte Datenblatt gespeichert werden soll. Wenn Sie zustimmen, landet die Variable `FILTER_$` in der Datendatei. Beim nächsten Öffnen dieser Datei ist allerdings *kein* Filter aktiv. Um die durch `FILTER_$` definierte Fallauswahl zu reaktivieren, muss diese Variable in der Dialogbox **Fälle auswählen** als **Filtervariable verwendet** werden. Weil Filtervariablen mit beliebigem Namen akzeptiert werden, kann man in einer SPSS-Datendatei mehrere Filtervariablen bereithalten. Außerdem kann man die einem Filter zugrunde liegende und über den Schalter **Einfügen** im Dialog **Fälle auswählen** verfügbare Syntax abspeichern und später wieder verwenden.

- **Ausgewählte Fälle in neues Dataset kopieren**

Die Fälle mit dem Wert 1 bei `FILTER_$` werden in ein neues Datenblatt kopiert.

- **Nicht ausgewählte Fälle löschen**

Die Fälle mit dem Wert 0 oder `SYSMIS` bei `FILTER_$` werden aus der Arbeitsdatei entfernt. Aus einer eventuell zugeordneten *externen* Datei (z.B. auf der Festplatte) verschwinden die Fälle dabei *nicht*. Überlegen Sie gründlich, ob Sie das teilentleerte Datenblatt irgendwann (z.B. beim Verlassen von SPSS) in die zugeordnete Datei sichern wollen.


Man kann die Positiv-Fälle auch über eine **Zufallsstichprobe** gewinnen oder einen **Fallbereich** festlegen, z.B. zur Beschränkung auf die ersten n Fälle.

12.2 Bericht anfordern

Gelegentlich benötigt man für eine bestimmte Teilmenge von Fällen eine übersichtliche Liste mit den Ausprägungen bestimmter Variablen. Um z.B. für Personen mit negativem AERGF-Wert eine Liste mit den Variablen FNR, AERGO und AERGM zu erhalten, vereinbart man zunächst eine Fallauswahl mit der Filterbedingung „ $AERGF < 0$ “ (siehe Abschnitt 12.1) und fordert dann über

Analysieren > Berichte > Fallzusammenfassungen

die gewünschte Auflistung an:



Wir erhalten die folgende Liste:

Zusammenfassung von Fällen^a

	Fallnummer	Ärger ohne kontrafaktische Alternative	Ärger mit kontrafaktischer Alternative
1	4	6	2
2	15	2	1
Gesamtsumme N	2	2	2

a. Auf die ersten 100 Fälle beschränkt.

13 Analyse von Kreuztabellen

Wir wollen untersuchen, ob weibliche und männliche Hochschüler unterschiedliche Präferenzen bei der Wahl ihres Studienfachs haben.

13.1 Untersuchungsplanung

Unsere Fachbereichsvariable (FB) enthält Information über die Studienfächer der Untersuchungsteilnehmer auf einem angemessenen Aggregationsniveau. Ihre Werte stehen für die folgenden Fachbereiche der Universität Trier:

Fachbereich	Fächer
I	Pädagogik, Philosophie, Psychologie
II	Sprachorientierte Fächer
III	Historische und politische Wissenschaften
IV	BWL, Ethnologie, Informatik, Mathematik, Soziologie, VWL, Wirtsch.-Informatik
V	Jura
VI	Geowissenschaften

Die in unserem „neuen Forschungsprojekt“ empirisch zu prüfende *Nullhypothese* kann so formuliert werden:

Die Merkmale Geschlecht und Fachbereich sind unabhängig voneinander.

Die Unabhängigkeitsbehauptung der Nullhypothese bedeutet z.B., dass sich aus dem Wissen über das Geschlecht eines Untersuchungsteilnehmers keinerlei Information über seine Fachbereichszugehörigkeit ableiten lässt, dass also die bedingten Fachbereichsverteilungen bei Frauen und Männern identisch sind. Zur Illustration des *Unabhängigkeitsbegriffs* wurde hier auf eine Verteilungshomogenität verwiesen. Später folgen noch einige Erläuterungen zu den beiden Begriffen und zu ihrer Beziehung.

Unsere Nullhypotheseformulierung ist „zweiseitig“, wozu es auch gar keine Alternative gibt, weil die Fachbereichsvariable mehr als zwei Stufen hat. Hier ist die (anschließend wegen unzureichender Zellbesetzungen zu bemängelnde) (2×6) - Kreuztabelle mit den Daten aus der Manuskriptstichprobe zu sehen:

Geschlecht	Fachbereich					
	I	II	III	IV	V	VI
Frau	17	0	2	3	0	3
Mann	2	0	0	3	0	1

Bei (2×2) - Kreuztabellen sind aber auch gerichtete Hypothesen möglich (siehe Abschnitt 13.4.5.2). Beschränkt man sich z.B. auf eine Betrachtung der Fachbereiche I und IV, lässt sich die Alternativhypothese formulieren, dass der Frauenanteil im FB I größer sei als im FB IV.

Weil es bei der aktuellen Hypothese um den Zusammenhang zwischen den beiden *nominalskalierten* Merkmalen Fachbereich und Geschlecht geht, wählen wir als Auswertungsmethode die Kreuztabellenanalyse mit χ^2 -Test. Diese Methode ist recht beliebt, wobei Anwendungsfälle gelegentlich durch das wenig empfehlenswerte künstliche Kategorisieren von metrischen Variablen herbeigeführt werden. Hoffentlich trägt die ausführliche Behandlung der Methode im aktuellen Kapitel nicht dazu bei, die Kreuztabellenanalyse als Universalwerkzeug der Statistik erscheinen zu lassen. Sie ist

adäquat zur Untersuchung der Präferenz-Divergenz - Hypothese, weil es hier um die Assoziation von zwei nominalskalierten Merkmalen geht. Man kann die Fragestellung auch so auffassen, dass ...

- ein nominalskaliertes Kriterium (Studienfachpräferenz) aufgeklärt werden soll,
- wobei nur ein einziger Prädiktor interessiert, der ebenfalls nominales Messniveau besitzt (Geschlecht).

Bei vielen Analysen mit einem nominalskalierten Kriterium werden aber Methoden benötigt, die ...

- eine beliebige Anzahl von Prädiktoren erlauben,
- neben nominalskalierten auch metrische Prädiktoren unterstützen, also die in metrischen Prädiktoren enthaltenen Informationen komplett verwerten,
- eine flexible Modellierung ermöglichen (z.B. mit Wechselwirkungen zwischen Prädiktoren).

Mit der **logistischen Regressionsanalyse** steht für kategoriale oder ordinale Kriterien ein Verfahren bereit, das Modelle mit beliebig vielen kategorialen oder metrischen Regressoren erlaubt und auch Wechselwirkungen unterstützt. Nähere Informationen finden Sie z.B. in einem ZIMK-Manuskript (Baltes-Götz 2012), das auf dem Webserver der Universität Trier von der Startseite (<http://www.uni-trier.de/>) ausgehend folgendermaßen zu finden ist:

[IT-Services \(ZIMK\) > Downloads & Broschüren > Statistik >
Logistische Regressionsanalyse mit SPSS](#)

Wer das SPSS-Modul *Data Preparation* zur Verfügung hat, kann sich über den Menübefehl

Transformieren > Optimales Klassieren

dabei unterstützen lassen, metrische Prädiktoren künstlich zu kategorisieren und dabei möglichst viel Vorhersagekraft in Bezug auf ein nominales Kriterium zu erhalten. In der Liste möglicher Anwendungen dieser Technik nennt das Handbuch zum SPSS-Modul *Data Preparation* an erster Stelle das „Präparieren“ von Variablen für die Kreuztabellenanalyse (IBM 2013a, S. 29):

Beispielsweise müssen für die Prozedur „Kreuztabellen“ alle Variablen kategorial sein.


In Ausnahmefällen mag dieses Vorgehen erfolgreich sein, weil man im Vergleich zu einem logistischen Regressionsmodell keine funktionale Form für die Wirkung der ehemals metrischen Regressoren angeben muss. Als Routine der Datenanalyse ist diese Technik nicht akzeptabel, und im Kurs wird sie nicht verwendet.

Leider erweist sich unsere Kursstichprobe bei näherer Betrachtung als ungeeignet zur Prüfung der Präferenz-Divergenz - Hypothese, denn

- Sie ist recht klein (geringe Teststärke).
- Die Stichprobe ist wenig repräsentativ, weil sie nur an SPSS interessierte Personen enthält. Folglich sind die Fachbereiche II, III und V (fast) nicht vertreten (siehe obige Tabelle).

Daher wurde eine Zufallsstichprobe der Größe $n = 283$ aus der Datenbank mit allen Studierenden der Universität Trier im Wintersemester 1993/94 gezogen.¹ Bei jedem Fall wurden die Variablen Geschlecht (GESCHL) und Fachbereich (FB) festgestellt. Die SPSS-Datendatei **fbgeschl.sav** mit den beiden Variablen befindet sich an der im Vorwort für Kursdateien vereinbarten Stelle.

¹ Aufmerksame Leser(innen) werden zu Recht fragen, warum nicht *alle* Trierer Studierenden im damaligen Wintersemester einbezogen wurden. Eine größere Stichprobe bringt stabilere Ergebnisse und hätte in dieser speziellen Situation kaum mehr „gekostet“. Allerdings habe ich aus didaktischen Gründen eine Stichprobe mit „typischem“ Umfang vorgezogen.



Wir können die Stichprobengröße nicht ändern, wollen aber die daraus resultierende Power des geplanten Hypothesentests abschätzen. Dazu verwenden wir erneut das Programm **G*Power 3.1**, das schon bei der Stichprobenumfangsplanung in Abschnitt 1.3 zum Einsatz kam. Auf den Pool-PCs der Universität Trier unter dem Betriebssystem Windows ist G*Power 3.1 folgendermaßen zu starten

Start > Alle Programme > Statistik > GPower

G*Power arbeitet bei der Kreuztabellenanalyse mit dem folgenden Effektstärkeindex W (nach Cohen 1988, S. 215ff)

$$W := \sqrt{\sum_{i=1}^z \sum_{j=1}^s \frac{(p_{ij}^{(1)} - p_{ij}^{(0)})^2}{p_{ij}^{(0)}}}$$

Darin bedeuten:

- z, s = Anzahl der Zeilen bzw. Spalten
- $p_{ij}^{(1)}$ = Wahrscheinlichkeit der Zelle ij unter der Alternativhypothese
- $p_{ij}^{(0)}$ = Wahrscheinlichkeit der Zelle ij unter der Nullhypothese

Unter der Alternativhypothese sind die $z \times s$ Zellwahrscheinlichkeiten unrestringiert und müssen sich lediglich zu Eins aufaddieren. Unter der Nullhypothese ist die Wahrscheinlichkeit der Zelle ij identisch mit dem Produkt aus der Wahrscheinlichkeit der Zeile i und der Wahrscheinlichkeit der Spalte j (siehe Abschnitt 13.3).

Im Effektstärkeindex W werden Diskrepanzen zwischen den Zellwahrscheinlichkeiten unter der Alternativ- bzw. Nullhypothese über alle $(z \times s)$ Zellen der Kreuztabelle aufsummiert. Für jede Zelle ij wird die quadrierte Differenz von $p_{ij}^{(1)}$ und $p_{ij}^{(0)}$ durch die Nullhypothese-wahrscheinlichkeit $p_{ij}^{(0)}$ dividiert. Eine quadrierte Differenz geht also umso stärker in den Index ein, je kleiner die Nullhypothese-wahrscheinlichkeit der Zelle ist. Insgesamt wird ein spezieller Abstand zwischen der Alternativ- und der Nullhypothese-verteilung definiert.

In Abschnitt 13.4.1 wird sich ein enger Zusammenhang herausstellen zwischen dem Effektstärkeindex W und ...

- Pearsons Prüfgröße zur Unabhängigkeitshypothese
- Cramers V (einem Maß der Assoziationsstärke für zwei nominalskalierte Variablen)

Weil zur Präferenz-Divergenz - Hypothese keine Informationen über die Effektstärke in der Population verfügbar sind, nehmen wir einen *mittleren* Wert von $W = 0,3$ nach der von Cohen (1988, S. 227) vorgeschlagenen Konvention

- kleiner Effekt: $W = 0,1$
- mittlerer Effekt: $W = 0,3$
- großer Effekt: $W = 0,5$


als inhaltlich relevant an.

Wir wählen in G*Power 3.1 folgende Einstellungen:

- | | |
|---------------------------------------|--|
| • Test family | χ^2 -Tests |
| • Statistical test | Goodness-of-fit tests Contingency tables |
| • Type of power analysis | Post hoc |
| • Effect size w | 0.3 |
| • α err prob | 0.05 |
| • Total sample size | 283 |
| • Df | 5 |

Warum bei einer Tabelle mit zwei Zeilen und sechs Spalten gerade fünf Freiheitsgrade zustande kommen, erfahren Sie in Abschnitt 13.4.1.

Es resultiert eine erfreulich hohe Power von 0,99:




13.2 Beschreibung der bivariaten Häufigkeitsverteilung

Die SPSS-Dialogbox zur Analyse zweidimensionaler Kontingenztabellen erscheint nach dem Menübefehl:


Analysieren > Deskriptive Statistiken > Kreuztabellen

Wir wählen GESCHL als Zeilen- und FB als Spaltenvariable:



Im Beispiel liegt es nahe, GESCHL als unabhängige und FB als abhängige Variable zu betrachten. Zur Frage, wie in einer solchen Lage die Zeilen- und die Spaltenposition der Tabelle zu vergeben sind, hat sich keine eindeutige Konvention etabliert (vgl. Gehring & Weins 2004, S. 90). Wir verwenden die platzsparende Anordnung.

In der **Zellen**-Subdialogbox kann man u.a. zeilen- und spaltenbezogene **Prozentwerte** für die Zellen der Kontingenztabelle anfordern:



Aufgrund dieser Spezifikationen erhalten wir für unsere Stichprobe die folgende Kreuztabelle:¹

Geschlecht * Fachbereiche an der Universität Trier Kreuztabelle

		Fachbereiche an der Universität Trier						Gesamt
		I	II	III	IV	V	VI	
Frauen	Anzahl	29	26	18	22	26	23	144
	% v on Geschlecht	20,1%	18,1%	12,5%	15,3%	18,1%	16,0%	100,0%
	% v on FB	63,0%	66,7%	50,0%	31,0%	54,2%	53,5%	50,9%
Männer	Anzahl	17	13	18	49	22	20	139
	% v on Geschlecht	12,2%	9,4%	12,9%	35,3%	15,8%	14,4%	100,0%
	% v on FB	37,0%	33,3%	50,0%	69,0%	45,8%	46,5%	49,1%
Gesamt	Anzahl	46	39	36	71	48	43	283
	% v on Geschlecht	16,3%	13,8%	12,7%	25,1%	17,0%	15,2%	100,0%
	% v on FB	100,0%	100,0%	100,0%	100,0%	100,0%	100,0%	100,0%

Durch die Einträge in den Zellen wird die gemeinsame Verteilung der beiden Variablen GESCHL und FB beschrieben:

- Oben ... steht die absolute Häufigkeit der Zelle
Z.B. befanden sich in der Stichprobe 17 Männer aus dem Fachbereich I.
- In der Mitte ... steht der prozentuale Anteil der Zelle an allen Fällen in der zugehörigen Zeile.
Z.B. gehörten von den 139 *männlichen* Untersuchungsteilnehmern 12,2% zum Fachbereich I. Diese auf die Zeile bezogenen relativen Häufigkeiten beschreiben die bedingte Verteilung der Spaltenvariablen (FB) für einen festen Wert der Zeilenvariablen (GESCHL). Wir erhalten z.B. für die Männer die folgende bedingte FB-Verteilung:

I	II	III	IV	V	VI
12,2%	9,4%	12,9%	35,3%	15,8%	14,4%

- Unten ... steht der prozentuale Anteil der Zelle an allen Fällen in der zugehörigen Spalte
Z.B. waren von den 46 Personen aus dem Fachbereich I 37% Männer. Diese auf die Spalte bezogenen relativen Häufigkeiten beschreiben die bedingte Verteilung der Zeilenvariablen (GESCHL) für einen festen Wert der Spaltenvariablen (FB). Wir erhalten z.B. für den Fachbereich I die folgende bedingte Geschlechtsverteilung:

Frauen	63%
Männer	37%


In der **Zellen**-Subdialogbox können auch noch weitere Informationen zu den Zellen angefordert werden (z.B. der prozentuale Anteil an der Gesamtstichprobe, die erwartete Häufigkeit unter der Nullhypothese).

Beim Vergleich der fachbereichsbedingten Geschlechtsverteilungen zeigen sich erhebliche Unterschiede:


- In den Fachbereichen I und II dominieren die Frauen mit einem Anteil von 63% bzw. 66,7%.
- Im Fachbereich IV sind die Frauen mit einem Anteil von 31% in der Minderheit.
- In den übrigen Fachbereichen III, V und VI zeigt sich ein relativ ausgeglichenes Geschlechtsverhältnis.

¹ Die Tabelle wurde mit dem Pivot-Editor (vgl. Abschnitt 9.4) durch Aufheben der Gruppierung Geschlecht und gekürzte Kategorienbeschriftungen etwas schlanker gemacht.


Das folgende gestapelte Balkendiagramm veranschaulicht die fachbereichsbedingten Geschlechtsverteilungen:




Wir erhalten ein Ausgangsprodukt für dieses Diagramm über das Kontrollkästchen **Gruppiertes Balkendiagramm anzeigen** in der **Kreuztabellen**-Dialogbox:




Nach dem Öffnen des Rohlings



im Diagrammeditor (vgl. Abschnitt 11.2) vergeben wir per **Eigenschaften**-Dialog zunächst die **X-Achsen** - Rolle an die Variable FB (**Anwenden** nicht vergessen):




Danach erhält GESCHL die **Stapel**-Rolle:



Über den Schalter , oder den Menübefehl


Optionen > Auf 100 % skalieren

kommen wir dem Ziel schon sehr nahe:




Die restlichen Schritte:


- Bei markierten Balken wählen wir im Eigenschaftsfenster eine passende Balkenbreite:



- Über den Menübefehl **Optionen > Bezugslinie für Y-Achse** wird die 50% - Marke hervorgehoben:




- Über **Elemente > Datenbeschriftungen einblenden** oder den Symbolschalter  sorgen wir bei markierten Balken für eine Anzeige der Prozentwerte. Über die Eigenschaftsfenster-Registerkarte **Textstil** erhalten diese Beschriftungen die **bevorzugte Größe 9**:




Auf der Registerkarte **Zahlenformat** werden null **Dezimalstellen** angeordnet.

- Bei markierter Y-Achse entscheiden wir uns auf der Registerkarte **Zahlenformat** auch bei den Y-Achsen - Teilstrichbeschriftungen für null **Dezimalstellen** und entfernen das **Abschlusszeichen**:



Auf der Registerkarte **Skala** wird das **erste Inkrement** auf den Wert 0,1 gesetzt:



Wegen des Skalierungsfaktors 0,01 (siehe Registerkarte **Zahlenformat**) resultiert eine Beschriftung in 10er-Abständen.

- Schließlich erhält die Y-Achse den passenden Titel **Prozent**.

13.3 Die Unabhängigkeits- bzw. Homogenitätshypothese

Hypothesen zum Zusammenhang zwischen zwei nominalskalierten Merkmalen lassen sich auf letztlich äquivalente Weise durch Verwendung verschiedener wahrscheinlichkeitstheoretischer Begriffe formulieren. Dies soll an unserem Beispiel demonstriert werden, damit Sie die Äquivalenz verstehen und ausnutzen lernen. Es ist ja generell sinnvoll, einen Sachverhalt aus verschiedenen Blickrichtungen zu betrachten.

1. Formulierung: Unabhängigkeitshypothese

- H_0 : Die Merkmale Geschlecht und Fachbereich sind unabhängig,
d.h. die Wahrscheinlichkeit für jedes Verbundereignis (z.B. Mann im Fachbereich V)
ist gleich dem Produkt aus den Wahrscheinlichkeiten der beiden Randereignisse (im
Beispiel: Mann, Fachbereich V).
- H_1 : Die Merkmale Geschlecht und Fachbereich sind abhängig,
d.h. die Wahrscheinlichkeit für mindestens ein Verbundereignis ist ungleich dem
Produkt aus den Wahrscheinlichkeiten der Randereignisse.

2. Formulierung: Homogenitätshypothese

- H_0 : Die Frauenanteile sind in allen Fachbereichen gleich.
- H_1 : Die Frauenanteile sind nicht in allen Fachbereichen gleich.

Man kann leicht zeigen (vgl. Hartung 1989, S. 412): Perfekte Homogenität liegt genau dann vor, wenn die Merkmale Geschlecht und Fachbereich unabhängig sind.

13.4 Testverfahren

13.4.1 Asymptotische χ^2 - Tests

Die bekannteste Prüfgröße zur Testung der Unabhängigkeits- bzw. Homogenitätshypothese ist die folgende χ^2 - Statistik nach Pearson:

$$\chi_P^2 := \sum_{i=1}^z \sum_{j=1}^s \frac{(n_{ij} - m_{ij})^2}{m_{ij}}, \quad \text{mit } m_{ij} := \frac{n_{i.} \cdot n_{.j}}{n}$$

Darin bedeuten:

z, s	=	Anzahl der Zeilen bzw. Spalten
n_{ij}	=	beobachtete Häufigkeit in Zelle ij
m_{ij}	=	geschätzte erwartete Häufigkeit in Zelle ij unter der H_0
$n_{i.}$	=	beobachtete Häufigkeit in Zeile i
$n_{.j}$	=	beobachtete Häufigkeit in Spalte j
n	=	Umfang der Gesamtstichprobe

Die Formel zur Schätzung der erwarteten Häufigkeiten m_{ij} unter der Nullhypothese

$$m_{ij} := \frac{n_{i.} \cdot n_{.j}}{n}$$

ist leicht nachvollziehbar. Zunächst soll die Wahrscheinlichkeit $p_{ij}^{(0)}$ der Zelle ij unter der H_0 bestimmt werden. Da es sich hier um ein Verbundereignis aus zwei *unabhängigen* (H_0 !) Einzelereignissen handelt (Zeile i und Spalte j), ergibt sich $p_{ij}^{(0)}$ als Produkt der Wahrscheinlichkeiten $p_{i.}$ und $p_{.j}$ für die beiden verknüpften Einzelereignisse:

$$p_{ij}^{(0)} = p_{i.} \cdot p_{.j}$$

Die Wahrscheinlichkeiten $p_{i.}$ und $p_{.j}$ sind allerdings nicht bekannt, sondern müssen durch die entsprechenden relativen Häufigkeiten in der Stichprobe geschätzt werden.¹ Die Wahrscheinlichkeit $p_{i.}$ zur Zeile i wird geschätzt durch die relative Häufigkeit der Zeile i in der Stichprobe:

$$\hat{p}_{i.} := \frac{n_{i.}}{n}$$

Analog ergibt sich die geschätzte Wahrscheinlichkeit $p_{.j}$ der Spalte j :

$$\hat{p}_{.j} := \frac{n_{.j}}{n}$$

Damit gilt für die geschätzte Wahrscheinlichkeit der Zelle ij unter der H_0 :

$$\hat{p}_{ij}^{(0)} = \hat{p}_{i.} \cdot \hat{p}_{.j} = \frac{n_{i.}}{n} \cdot \frac{n_{.j}}{n} = \frac{n_{i.} \cdot n_{.j}}{n^2}$$

Die Wahrscheinlichkeit $p_{ij}^{(0)}$ der Zelle ij unter der Nullhypothese lässt sich interpretieren als Erwartungswert der Indikator-Zufallsvariablen X_{ij} zur Zelle (i, j) beim Ziehen *eines* Falles bei gültiger H_0 :

- Tritt die Zelle (i, j) auf, nimmt X_{ij} den Wert Eins an,
- anderenfalls nimmt X_{ij} den Wert Null an.

Werden n Fälle unabhängig gezogen, realisieren sich n unabhängige Zufallsvariablen $X_{ij}^{(k)}$, $k = 1, \dots, n$, mit dem identischem Erwartungswert $p_{ij}^{(0)}$. Deren Summe

$$\sum_{k=1}^n X_{ij}^{(k)}$$

ergibt die Häufigkeit der Zelle ij , so dass der Erwartungswert der Summenvariablen

$$E\left(\sum_{k=1}^n X_{ij}^{(k)}\right) = \sum_{k=1}^n E(X_{ij}^{(k)}) = \sum_{k=1}^n p_{ij}^{(0)} = n \cdot p_{ij}^{(0)}$$

die erwartete Häufigkeit der Zelle ij liefert.

¹ Diese Formulierung geht davon aus, dass man *eine* Stichprobe gezogen und bei jedem Fall die *beiden* Merkmale Geschlecht und Fachbereich beobachtet hat. Ein anderes Stichprobenmodell läge vor, wenn man in jedem Fachbereich eine Stichprobe der festen Größe 50 gezogen und bei jedem Fall das *eine* Merkmal Geschlecht beobachtet hätte. Dann wären die Randwahrscheinlichkeiten der FB-Kategorien bekannt. Allerdings bleiben auch unter dem alternativen Stichprobenmodell alle vorgestellten Rechnungen und Entscheidungsregeln korrekt.

Mit der geschätzten Wahrscheinlichkeit $\hat{p}_{ij}^{(0)}$ ergibt sich die geschätzte erwartete Häufigkeit m_{ij} in Pearsons Teststatistik:

$$m_{ij} = n \cdot \hat{p}_{ij}^{(0)} = n \cdot \frac{n_{i.} \cdot n_{.j}}{n^2} = \frac{n_{i.} \cdot n_{.j}}{n}$$

In Pearsons χ_p^2 -Statistik werden die Abweichungen der beobachteten Häufigkeiten von den geschätzten Erwartungswerten unter der H_0 quadriert. Durch das Quadrieren werden größere Diskrepanzen besonders stark gewichtet. Jede quadrierte Abweichung wird außerdem *normiert*, indem sie durch ihren erwarteten Wert dividiert wird. Steht etwa dem erwarteten Wert 5 die beobachtete Häufigkeit 15 gegenüber, so resultiert die quadrierte und normierte Diskrepanz 20:

$$\frac{(15-5)^2}{5} = 20$$

Dieselbe Abweichung einer beobachteten Häufigkeit 2010 vom erwarteten Wert 2000 erbringt jedoch sinnvollerweise nur eine quadrierte und normierte Diskrepanz von 0,05:

$$\frac{(2010-2000)^2}{2000} = 0,05$$

Der χ_p^2 -Wert ist also offenbar, wie es in Abschnitt 7.1.3 von einer Teststatistik gefordert wird, indikativ für Abweichungen der Stichprobendaten von der Nullhypothese.

Mit $\frac{n_{ij}}{n}$ als geschätzter Wahrscheinlichkeit $\hat{p}_{ij}^{(1)}$ der Zelle (i, j) unter der Alternativhypothese (beliebige Multinomialverteilung der Häufigkeiten in den z -s Zellen) und

$$\frac{m_{ij}}{n} = \frac{n_{i.} \cdot n_{.j}}{n^2} = \frac{n_{i.}}{n} \cdot \frac{n_{.j}}{n} = \hat{p}_{i.} \cdot \hat{p}_{.j}$$

als geschätzter Wahrscheinlichkeit $\hat{p}_{ij}^{(0)}$ der Zelle (i, j) unter der Nullhypothese (siehe oben) zeigt sich ein sehr enger Bezug zwischen Pearsons χ_p^2 -Prüfgröße und dem Effektstärkeindex W (vgl. Abschnitt 13.1):

$$\chi_p^2 = \sum_{i=1}^z \sum_{j=1}^s \frac{(n_{ij} - m_{ij})^2}{m_{ij}} = n \sum_{i=1}^z \sum_{j=1}^s \frac{\left(\frac{n_{ij}}{n} - \frac{m_{ij}}{n}\right)^2}{\frac{m_{ij}}{n}} = n \sum_{i=1}^z \sum_{j=1}^s \frac{(\hat{p}_{ij}^{(1)} - \hat{p}_{ij}^{(0)})^2}{\hat{p}_{ij}^{(0)}} = n\hat{W}^2$$


Die aus einer Stichprobe berechnete Prüfgröße χ_p^2 ist also im Kern ein Schätzer für die quadrierte Effektstärke in der Population und damit bestens geeignet, eine Abweichung der Populationsverteilung von der Nullhypothese aufzudecken.

Außerdem erfüllt die χ_p^2 -Teststatistik nach Pearson auch die Verteilungsbedingung aus Abschnitt 7.1.3, wenn auch nur approximativ. Unter der Nullhypothese ist die χ_p^2 -Statistik asymptotisch, d.h.

für $n \rightarrow \infty$, χ^2 -verteilt mit $df = (z - 1) \cdot (s - 1)$ Freiheitsgraden.¹ Für unsere Kreuztabelle zur Präferenz-Divergenz - Hypothese erhalten wir also: $df = 1 \cdot 5 = 5$.

Folglich kann mit Pearsons χ_p^2 -Statistik nicht nur die Plausibilität der H_0 deskriptiv beurteilt werden, sondern es kann eine empirische Überschreitungswahrscheinlichkeit berechnet und nach den Regeln aus Abschnitt 7.1 ein Signifikanztest durchgeführt werden.

In SPSS wird die χ_p^2 -Statistik samt Signifikanztest mit dem Kontrollkästchen **Chi-Quadrat** in der **Kreuztabellen**-Subdialogbox **Statistik** angefordert:



Zur Beurteilung der empirischen Effektstärke wählen wir zusätzlich **Phi und Cramer-V** (siehe Abschnitt 13.4.2).

Wir erhalten folgende Testergebnisse:

Chi-Quadrat-Tests			
	Wert	df	Asymptotische Signifikanz (2-seitig)
Chi-Quadrat nach Pearson	18,191 ^a	5	,003
Likelihood-Quotient	18,570	5	,002
Zusammenhang linear-mit-linear	3,197	1	,074
Anzahl der gültigen Fälle	283		

a. 0 Zellen (.0%) haben eine erwartete Häufigkeit kleiner 5. Die minimale erwartete Häufigkeit ist 17,68.

Es ergibt sich ein χ_p^2 -Wert von ca. 18,19, der bei $df = 5$ unter der H_0 eine Überschreitungswahrscheinlichkeit (**Asymptotische Signifikanz**) von ca. 0,003 besitzt. Ein χ_p^2 - Wert $\geq 18,19$ bei $df = 5$ ist also unter der H_0 wenig wahrscheinlich. Insbesondere ist die empirisch ermittelte Überschreitungswahrscheinlichkeit deutlich kleiner als die üblicherweise akzeptierte Irrtumswahrscheinlichkeit erster Art von $\alpha = 0,05$. Folglich entscheidet sich der χ_p^2 - Test klar gegen die H_0 . In Abschnitt 7.1 wurde dieses Argumentationsmuster der Inferenzstatistik erläutert.

¹ In diesem Satz treten zwei Symbole mit ähnlicher Gestalt aber verschiedener Bedeutung auf: χ_p^2 steht für eine Prüfgröße, mit χ^2 ist hingegen eine theoretische Verteilung gemeint.

Neben der χ^2_p -Statistik nach Pearson berechnet SPSS noch die alternative Prüfgröße χ^2_{LQ} , die auf dem **Likelihood-Quotienten - Prinzip** basiert. Letztere ist unter der H_0 ebenfalls asymptotisch, d.h. für $n \rightarrow \infty$, χ^2 - verteilt mit $df = (z-1) \cdot (s-1)$ Freiheitsgraden, und trotz unterschiedlicher Herleitung sind beide Statistiken asymptotisch äquivalent, d.h. mit wachsender Stichprobengröße werden sie immer ähnlicher. Während bei größeren Stichproben wegen der asymptotischen Äquivalenz die Entscheidung für eine der beiden Prüfgrößen beliebig ist, sprechen einige Befunde dafür, bei kleineren Stichproben die χ^2_p -Statistik nach Pearson wegen der besseren Verteilungsapproximation zu bevorzugen (siehe z.B. Hartung 1989, S. 439). Damit ist es also vertretbar, die χ^2_p -Statistik nach Pearson grundsätzlich gegenüber der Likelihood-Quotienten - Prüfgröße zu bevorzugen. SPSS liefert stets beide Prüfgrößen. In unserem Fall sind die Unterschiede geringfügig und für die Testentscheidung irrelevant.

Die Pearson- und die Likelihood-Quotienten - Statistik zur Beurteilung der Unabhängigkeits- bzw. Homogenitätshypothese sind nur **asymptotisch**, d.h. für $n \rightarrow \infty$, χ^2 -verteilt. Für die Zulässigkeit der zugehörigen Hypothesentests setzt man üblicherweise voraus, dass alle **erwarteten** Häufigkeiten m_{ij} mindestens gleich 5 sind. SPSS protokolliert daher für jede Kreuztabelle die minimale erwartete Häufigkeit. In unserem Fall beträgt sie 17,682, so dass keine Einwände gegen Tests auf Basis der χ^2_p - bzw. χ^2_{LQ} -Statistik bestehen.

Manche Autoren formulieren etwas schwächere Voraussetzungen für die erwarteten Häufigkeiten. Siegel (1976, S. 107) verlangt z.B. für χ^2_p -Tests mit $df > 1$, dass die beiden folgenden Bedingungen erfüllt sind:

- Weniger als 20% der Zellen haben eine erwartete Häufigkeit kleiner als 5.
- Keine Zelle hat eine erwartete Häufigkeit kleiner als 1.

Neben den beiden Statistiken zur Prüfung der Unabhängigkeits- bzw. Homogenitätshypothese liefert SPSS unter der Bezeichnung **Zusammenhang linear-mit-linear** auch noch den χ^2_{MH} -Wert nach **Mantel-Haenszel** samt Überschreitungswahrscheinlichkeit. Hier geht es um eine Entscheidung zwischen den Hypothesen:

H_0 : Es existiert keine lineare Beziehung zwischen den beiden Variablen.

versus

H_1 : Es existiert eine lineare Beziehung zwischen den beiden Variablen.

Die Prüfgröße basiert auf der Produkt-Moment - Korrelation zwischen den beiden Variablen:

$$\chi^2_{MH} := r^2(n-1)$$

Üblicherweise gilt der Mantel-Haenszel - Test als anwendbar, sofern beide Variablen mindestens ordinale Skalenqualität besitzen (siehe z.B. Norušis 2011b). Da wir zwei nominalskalierte Variablen betrachten, ist diese Statistik bei unserer Tabelle auf jeden Fall sinnlos.

13.4.2 Schätzung der Effektstärke

Zur Beurteilung der empirischen Effektstärke haben wir in der Kreuztabellen-Subdialogbox **Statistik** (siehe Abschnitt 13.4.1) **Phi und Cramer-V** gewählt.

Der bei (2×2) -Tabellen als Zusammenhangsmaß taugliche **Phi-Koeffizient** steht (abgesehen vom Vorzeichen) in folgendem Zusammenhang zu Pearsons χ^2_P -Statistik (siehe z.B. Bortz & Schuster 2010, S. 174)

$$\phi = \sqrt{\frac{\chi^2_P}{n}}$$

Nach einer Rechnung aus Abschnitt 13.4.1 ist ϕ damit ein Schätzer für die Populations-Effektstärke W (vgl. Abschnitt 13.1):

$$\phi = \hat{W}$$

W und ϕ haben den maximalen Wert

$$\sqrt{q-1}$$

mit

$$q := \text{Min}(z, s)$$

Bei $q > 2$ können W und ϕ also größer als Eins werden (Cohen 1988, Abschnitt 7.2). In der Definition von Cramers V wird folgendermaßen für den Maximalwert Eins gesorgt:

$$V := \sqrt{\frac{\chi^2_P}{n(q-1)}} = \sqrt{\frac{\chi^2_P}{n}} \frac{1}{\sqrt{q-1}} = \hat{W} \frac{1}{\sqrt{q-1}}$$


Bei der FB-GESCHL - Analyse (mit $\text{Min}(z, s) = 2$) ist Cramers V identisch mit dem Phi-Koeffizienten, und wir erhalten den Wert 0,254:

Symmetrische Maße			
		Wert	Näherungsweise Signifikanz
Nominal- bzgl.	Phi	,254	,003
Nominalmaß	Cramer-V	,254	,003
Anzahl der gültigen Fälle		283	

Er ist nicht weit entfernt vom Wert 0,3, den wir in Abschnitt 13.1 für den Effektstärkeindex W angenommen haben.

13.4.3 Einzelvergleiche der Spaltenanteile

Nachdem die Nullhypothese identischer Frauenanteile in den Fachbereichen der Universität Trier verworfen werden konnte, sind paarweise Einzelvergleiche von Interesse. Seit der SPSS-Version 19 kann man solche Einzelvergleiche der Spaltenanteile in der Subdialogbox **Zellen** anfordern:



Durch eine Bonferroni-Adjustierung wird dafür gesorgt, dass trotz der Durchführung mehrerer Tests (15 Paarvergleiche bei 6 Fachbereichen) die Wahrscheinlichkeit, bei Gültigkeit sämtlicher Nullhypothesen einen oder mehrere α -Fehler zu begehen, unter 5% bleibt. Allerdings ist das von SPSS angewendete Bonferroni-Verfahren sehr konservativ, z.B. weil auf die Bonferroni-Holm - Verfeinerung verzichtet wird.

Im Beispiel

Geschlecht * Fachbereiche an der Universität Trier Kreuztabelle

			Fachbereiche an der Universität Trier						Gesamt
			I	II	III	IV	V	VI	
Geschlecht	Frauen	Anzahl	29 _a	26 _a	18 _{a, b}	22 _b	26 _{a, b}	23 _{a, b}	144
		% von Geschlecht	20,1%	18,1%	12,5%	15,3%	18,1%	16,0%	100,0%
		% von FB	63,0%	66,7%	50,0%	31,0%	54,2%	53,5%	50,9%
	Männer	Anzahl	17 _a	13 _a	18 _{a, b}	49 _b	22 _{a, b}	20 _{a, b}	139
		% von Geschlecht	12,2%	9,4%	12,9%	35,3%	15,8%	14,4%	100,0%
		% von FB	37,0%	33,3%	50,0%	69,0%	45,8%	46,5%	49,1%
	Gesamt	Anzahl	46	39	36	71	48	43	283
		% von Geschlecht	16,3%	13,8%	12,7%	25,1%	17,0%	15,2%	100,0%
		% von FB	100,0%	100,0%	100,0%	100,0%	100,0%	100,0%	100,0%

Jeder tiefgestellte Buchstabe gibt eine Teilmenge von Fachbereiche an der Universität Trier Kategorien an, deren Spaltenanteile sich auf dem ,05-Niveau nicht signifikant voneinander unterscheiden.

sind nach der konservativen Bonferroni-Methode signifikante Unterschiede für folgende Fachbereichspaare nachzuweisen:

- I vs. IV
- II vs. IV

13.4.4 Exakte Tests

Für die (2×2) - Kreuztabelle gibt es seit Jahrzehnten mit dem **exakten Test von Fisher** eine glänzende Alternative zu den approximativen χ^2 - Tests. Wie sein Name sagt, kommt Fishers Test ohne Approximation aus und ist daher bei jeder Stichprobe anwendbar. Erfreulicherweise bietet SPSS

exakte Tests auch für beliebige ($z \times s$) - Kreuztabellen, sofern das Zusatzmodul **Exact Tests** im Lizenzumfang enthalten ist.

Eine ausführliche Beschreibung (Baltes-Götz 1998) der statistischen Verfahren, die durch das SPSS-Zusatzmodul **Exact Tests** implementiert werden, ist auf dem Webserver der Universität Trier von der Startseite (<http://www.uni-trier.de/>) ausgehend folgendermaßen zu finden:

IT-Services (ZIMK) > Downloads & Broschüren > Statistik >
Exakte Tests mit SPSS

Allerdings sind die asymptotischen Verfahren nun keinesfalls obsolet, weil der exakte Test für ($z \times s$) - Kreuztabellen wegen seines hohen Rechenaufwands nur bei kleinen Stichproben durchführbar ist. Insgesamt steht für die meisten Situationen ein angemessenes Verfahren zur Verfügung:



- Wenn die Anwendbarkeitskriterien für die asymptotischen Verfahren erfüllt sind, sollten Sie den Pearson-Test verwenden.
- Anderenfalls sollten Sie einen exakten Test versuchen.

Wenn bei einer Kreuztabelle die Minimalanforderungen an die erwarteten Häufigkeiten *nicht* erfüllt sind, *und* der exakte Test aufgrund des insgesamt zu großen Stichprobenumfangs scheitert, können Sie die verantwortlichen schwach besetzten Zeilen bzw. Spalten entweder löschen oder miteinander bzw. mit anderen Zeilen/Spalten zusammenlegen.

In einem Anwendungsbeispiel sollen Daten aus dem SPSS-Handbuch zum Modul **Exact Tests** (Mehta & Patel 2011, S. 2) analysiert werden. Es handelt sich um Prüfungsergebnisse weißer, schwarzer, asiatischer und hispanoider Feuerwehrbewerber in einer amerikanischen Kleinstadt. Diese Kreuztabelle


		Hautfarbe				Gesamt
		Weiß	Schwarz	Asiatisch	Mittel- und Südamerika	
Anzahl	Bestanden	5	2	2	0	9
	Unklar	0	1	0	1	2
	Durchgefallen	0	2	3	4	9
	Gesamt	5	5	5	5	20
Prozent	Bestanden	100,0%	40,0%	40,0%	,0%	45,0%
	Unklar	,0%	20,0%	,0%	20,0%	10,0%
	Durchgefallen	,0%	40,0%	60,0%	80,0%	45,0%
	Gesamt	100,0%	100,0%	100,0%	100,0%	100,0%

wurde mit den folgenden Dialogboxen angefordert:




Der Tabellenrohling wurde per Doppelklick im Pivot-Editor (vgl. Abschnitt 9.4) geöffnet und folgendermaßen modifiziert:

- Für die beiden Zeilendimensionen (Testergebnis, Statistik) wurde per Pivot-Werkzeug die Schachtelungsordnung geändert:




- Die Gruppierungszelle zur Testergebnis-Dimension wurde durch Reduktion ihrer Breite (Verschieben des rechten Randes) zum Verschwinden gebracht.
- Die Gruppierungszelle zur Statistik-Kategorie *Prozent* hat eine neue Beschriftung erhalten.

Der interessierende Test zur Nullhypothese, dass die Prüfungsergebnisse von der Hautfarbe unabhängig sind, ist nach einem Mausklick auf den **Statistiken**-Schalter in der Dialogbox zur Kreuztabellenanalyse im folgenden Subdialog über das Kontrollkästchen **Chi-Quadrat** anzufordern:



Im selben Dialog wird über das Kontrollkästchen **Phi und Cramer-V** eine Schätzung der Effektstärke angeboten.

Nach einem Mausklick auf den **Exakt**-Schalter in der Dialogbox zur Kreuztabellenanalyse kann man in der folgenden Subdialogbox die **exakte** Testmethode wählen:



Daraufhin erhält man neben den approximativen Ergebnissen auch exakte Überschreitungswahrscheinlichkeiten für die Pearson- und die Likelihood-Quotienten - Teststatistik. Außerdem führt SPSS noch eine Verallgemeinerung des exakten Tests von Fisher durch, der in seiner klassischen Variante auf (2×2) - Tabellen beschränkt ist:

Chi-Quadrat-Tests

	Wert	df	Asymptotische Signifikanz (2-seitig)	Exakte Signifikanz (2-seitig)	Exakte Signifikanz (1-seitig)	Punkt-Wahrscheinlichkeit
Chi-Quadrat nach Pearson	11,556 ^a	6	,073	,040		
Likelihood-Quotient	15,673	6	,016	,040		
Exakter Test nach Fisher	11,239			,040		
Zusammenhang linear-mit-linear	8,276 ^b	1	,004	,004	,002	,001
Anzahl der gültigen Fälle	20					

a. 12 Zellen (100,0%) haben eine erwartete Häufigkeit kleiner 5. Die minimale erwartete Häufigkeit ist ,50.

b. Die standardisierte Statistik ist 2,877.

Die approximativen χ^2 - Unabhängigkeitstests (Pearson und Likelihood-Quotient) sind nicht anwendbar, weil in allen 12 Zellen die erwartete Häufigkeit kleiner als 5 ist. Wer dieses Problem ignoriert, andererseits aber weiß, dass der Pearson-Test gegenüber dem Likelihood-Quotienten - Test speziell bei kleinen Stichproben wegen der besseren Verteilungsapproximation zu bevorzugen ist, gelangt zu einer falschen Testentscheidung. Der asymptotische Pearson- χ^2 - Test empfiehlt durch eine Überschreitungswahrscheinlichkeit von 0,073, die Nullhypothese beizubehalten. Die exakte Überschreitungswahrscheinlichkeit zur Pearson-Prüfgröße beträgt hingegen 0,04, was zur Ablehnung der Nullhypothese führt.

Die exakten Überschreitungswahrscheinlichkeiten zu den drei in Frage kommenden Signifikanztests müssen nicht in jedem Fall übereinstimmen. Nachträglich die kleinste Überschreitungswahrscheinlichkeit zu wählen, ist *nicht* zulässig. Wer den approximativen Pearson-Test gemäß obiger Empfehlung routinemäßig bei der allgemeinen ($z \times s$) - Kreuztabelle verwendet, sofern er zulässig ist, sollte dessen Prüfgröße auch bei der exakten Berechnung der Überschreitungswahrscheinlichkeit zugrunde legen.

Dass es trotz der winzigen Stichprobe zu einem signifikanten Ergebnis gereicht hat, liegt nicht nur am sensiblen Testverfahren, sondern auch an der erheblichen Effektstärke. Mit dem Phi-Koeffizienten erhalten wir eine geschätzte Effektstärke von 0,76:

Symmetrische Maße

		Wert	Näherungsweise Signifikanz	Exakte Signifikanz
Nominal- bzgl. Nominalmaß	Phi	,760	,073	,040
	Cramer-V	,537	,073	,040
Anzahl der gültigen Fälle		20		

Diese ist nach Cohen (1988, S. 227) und G*Power 3.1 als groß einzustufen (vgl. Abschnitt 13.1).

13.4.5 Besonderheiten bei (2 × 2) - Tabellen

13.4.5.1 Ein klarer Fall für den exakten Test von Fisher

Im Spezialfall der (2 × 2) - Tabelle ist Fishers Test nicht nur *exakt*, sondern er besitzt sogar unter allen „vernünftigen“, nämlich unter den so genannten unverfälschten, Tests die besten Güteeigenschaften. Daher sollten Sie in dieser Situation grundsätzlich Fishers Test verwenden. Die oben beschriebenen Rechenzeitprobleme bei exakten Tests für allgemeine (z × s) - Kreuztabellen treten bei Fishers Test für die (2 × 2) - Tabelle *nicht* auf.

Für eine Teststärkeanalyse mit dem Programm G*Power 3.1 (vgl. Abschnitt 1.3.2) wählt man bei Fishers exaktem Test für die (2 × 2) - Tabelle:

- **Test family:** **Exact**
- **Statistical test:** **Proportions: ... (Fisher's exact test)**

13.4.5.2 Gerichtete Hypothesen

Bei einer (2 × 2) - Tabelle lässt sich auch eine gerichtete (einseitige) Hypothese über den Zusammenhang zwischen den beiden Merkmalen formulieren. Wenn wir uns z.B. beim Vergleich der Frauenanteile unter den Studierenden der Universität Trier auf die Fachbereiche III und IV beschränken, können wir das folgende Testproblem untersuchen:

H_0 : Der Frauenanteil ist im FB IV mindestens genauso groß wie im FB III.

H_1 : Der Frauenanteil ist im FB IV kleiner als im FB III.

Aus den (z.B. per Filterbedingung, vgl. Abschnitt 12) eingeschränkten Beispieldaten (Datei **fbgeschl.sav**) erhalten wir folgende Ergebnisse:

Kreuztabelle

	Fachbereiche an der Universität Trier		Gesamt
	III	IV	
Frauen	18 45,0% 50,0%	22 55,0% 31,0%	40 100,0% 37,4%
Männer	18 26,9% 50,0%	49 73,1% 69,0%	67 100,0% 62,6%
Gesamt	36 33,6% 100,0%	71 66,4% 100,0%	107 100,0% 100,0%

Chi-Quadrat-Tests

	Wert	df	Asymptotische Signifikanz (2-seitig)	Exakte Signifikanz (2-seitig)	Exakte Signifikanz (1-seitig)
Chi-Quadrat nach Pearson	3,689 ^b	1	,055	,061	,044
Kontinuitätskorrektur ^a	2,922	1	,087		
Likelihood-Quotient	3,643	1	,056		
Exakter Test nach Fisher					
Zusammenhang linear-mit-linear	3,655	1	,056		
Anzahl der gültigen Fälle	107				

a. Wird nur für eine 2x2-Tabelle berechnet

b. 0 Zellen (,0%) haben eine erwartete Häufigkeit kleiner 5. Die minimale erwartete Häufigkeit ist 13,46.

Wie wir bereits wissen, beträgt der Frauenanteil im FB III 50% und im FB IV 31%, die deskriptiven Statistiken fallen also klar im Sinne der Alternativhypothese aus. Der nach Abschnitt 13.4.5.1 zu verwendende exakte Test von Fisher liefert für die *zweiseitige* Fragestellung eine Überschreitungswahrscheinlichkeit von 0,061, so dass die Nullhypothese beibehalten werden müsste. Bei *einseitiger* Testung erhalten wir jedoch eine Überschreitungswahrscheinlichkeit von 0,044, so dass die Nullhypothese verworfen werden kann.

Beachten Sie abschließend noch, dass sich bei Fishers Test die einseitige Überschreitungswahrscheinlichkeit *nicht* durch Halbieren der zweiseitigen ergibt. Die in Abschnitt 7.1 für den Spezialfall des t-Tests angegebene Regel zur Berechnung der einseitigen Überschreitungswahrscheinlichkeit aus der zweiseitigen darf also nicht generalisiert werden. Allerdings können Sie sich darauf verlassen, dass SPSS neben der zweiseitigen Überschreitungswahrscheinlichkeit auch die einseitige ausgeben wird, wenn die beiden nicht in einer einfachen Beziehung zueinander stehen.

13.4.5.3 Kontinuitätskorrektur nach Yates

Bei (2×2) - Tabellen berechnet SPSS traditionell auch eine χ^2_Y -Größe mit Kontinuitätskorrektur nach Yates. Sie soll bei kleineren Stichproben der Pearson- χ^2_P - Statistik überlegen sein. Gemäß Abschnitt 13.4.5.1 ist sie allerdings irrelevant, weil in der (2×2) - Situation Fishers exakter Tests in jedem Fall zu bevorzugen ist.

14 Fälle gewichten

Per Voreinstellung bezieht SPSS bei statistischen Auswertungen *alle* Fälle mit dem Gewicht *Eins* ein. In Abschnitt 12 haben Sie schon eine Möglichkeit kennen gelernt, Fälle aufgrund von Filterkriterien temporär oder permanent aus der Arbeitsdatei ausschließen. Nun erfahren Sie, wie man die Fälle individuell gewichtet, so dass sie bei statistischen Analysen unterschiedlichen Einfluss auf die Ergebnisse haben.


14.1 Beispiel

Die Möglichkeit, von Eins verschiedene Fallgewichte zu verwenden, d.h. z.B. einem Fall des Gewicht 16 zuzuschreiben und so zu tun, als seien 16 Fälle mit genau gleichen Variablenausprägungen in der Arbeitsdatei vorhanden, erscheint zunächst sinnlos. Aber erinnern wir uns an die (Geschlecht $\times$ Fachbereich) - Kreuztabelle aus Abschnitt 13. Zur Verwendung in einer späteren Übungsaufgabe betrachten wir hier eine strukturell identische Tabelle, die auf einer anderen Zufallsstichprobe der Größe $n = 153$ beruht:

Geschlecht	Fachbereich					
	I	II	III	IV	V	VI
Frau	16	23	10	12	12	5
Mann	5	10	14	23	16	7

Um mit den in Abschnitt 13 erklärten χ^2 - Tests anhand dieser Stichprobendaten prüfen zu können, ob in den Fachbereichen die Geschlechtsverteilungen verschieden sind, brauchen Sie nach unserem bisherigen Kenntnisstand eine Arbeitsdatei, in der z.B. 16 Fälle mit dem Geschlecht 1 und dem Fachbereich 1 enthalten sind, 23 Fälle mit Geschlecht 1 und Fachbereich 2 usw. Wir haben jedoch lediglich die obige Tabelle zur Verfügung. Statt nun mühselig 153 Fälle im Dateneditor einzutippen, können wir von der Möglichkeit der Fallgewichtung folgendermaßen Gebrauch machen:

- Wir sorgen für ein leeres Datenblatt. Dort definieren wir die Variablen GESCHL (Geschlecht), FB (Fachbereich) und ANZAHL.
- Jede Zelle der (Geschlecht $\times$ Fachbereich) - Kreuztabelle wird im SPSS-Datenblatt als *ein* Fall behandelt. Der erste Fall erhält z.B. für die drei Variablen GESCHL, FB und ANZAHL die Werte 1, 1 und 16:




- Die Fälle werden mit der Variablen ANZAHL gewichtet. Damit tun wir z.B. so, als seien 16 Fälle mit dem Geschlecht 1 und dem Fachbereich 1 vorhanden gewesen. Aber das stimmt ja wirklich. Offenbar ist die Fallgewichtung doch nicht sinnlos.

Um eine Gewichtsvariable zu vereinbaren, rufen wir mit dem Menübefehl

Daten > Fälle gewichten

eine Dialogbox auf, die folgende Optionen anbietet:

- **Fälle nicht gewichten**
Damit wird eine bestehende Gewichtung wieder aufgehoben.
- **Fälle gewichten mit**
Die gewünschte Variable wird mit dem Transportschalter in die Position der **Häufigkeitsvariablen** gebracht, z.B.:



In der Dialogbox wird außerdem angezeigt, ob momentan eine Gewichtungsvariable vereinbart ist. Dieselbe Information erscheint auch in der Statuszeile des Datenfensters (siehe oben).

Beim Einsatz von Gewichtungsvariablen ist noch zu beachten:

- Zur Gewichtung kann natürlich nur eine numerische Variable verwendet werden; diese darf allerdings auch gebrochene Werte enthalten. Negative und fehlende Werte werden auf Null gesetzt, d.h. die betroffenen Fälle werden nicht berücksichtigt, solange die Gewichtungsvariable aktiv ist.
- Ist beim Speichern der Arbeitsdatei eine Gewichtung aktiv, so wird diese mit abgespeichert und ist bei späterer Verwendung der Datendatei in Kraft.
- Bei der in diesem Abschnitt beschriebenen Anwendung der Gewichtungsoption wird dafür gesorgt, dass alle tatsächlich in der Studie vorhandenen Beobachtungen mit dem Gewicht 1 in die Kreuztabellenanalyse eingehen. Wenn die vorhandenen Beobachtungen individuelle Gewichte ($\neq 1$) erhalten, werden natürlich Signifikanztests erheblich beeinflusst. Auf jeden Fall muss dann die Summe der Gewichte gerade den Stichprobenumfang ergeben.

14.2 Übung

Prüfen Sie anhand der Daten aus der Tabelle am Anfang von Abschnitt 14.1 die Nullhypothese, dass die Merkmale Geschlecht und Fachbereich unabhängig sind.

15 Auswertung von Mehrfachwahlfragen

In Abschnitt 1.4.2.3 wurde betont, dass mit einer Mehrfachwahlfrage nicht etwa *ein* Merkmal mit mehreren Ausprägungen erfasst wird, wie es wohl durch manche Köpfe bzw. Alpträume spukt, sondern *mehrere* inhaltlich verwandte, dichotome Merkmale.

Grundsätzlich besteht kein Bedarf an speziellen Auswertungsverfahren für die mit Mehrfachwahlfragen erfassten Variablen. Es ist allerdings gelegentlich sinnvoll, eine Häufigkeits- oder Kreuztabellenanalyse für *alle* Mitglieder einer Familie dichotomer Variablen (ob aus einer Mehrfachwahlfrage entstanden oder wie auch immer) in gleicher Form auszuführen. Für diese Situation bietet SPSS gewisse Rationalisierungsmöglichkeiten, die in diesem Abschnitt vorgestellt werden sollen. Außerdem kann SPSS für die mit einem sparsamen Set aus kategorialen Variablen erfassten dichotomen Merkmale Häufigkeits- und Kreuztabellenanalysen durchführen, ohne dass zuvor die dichotomen Variablen zu den Merkmalen (durch Datentransformationsanweisungen) konstruiert werden müssten (vgl. Abschnitt 15.4).

15.1 Mehrfachantwortsets definieren

Im Teil 3a unseres Fragebogens haben die Teilnehmer für fünf konkrete Motive, den SPSS-Kurs zu besuchen, und eine Restkategorie alles zutreffende angekreuzt. Es liegt nahe, eine kompakte Tabelle zu erstellen, aus der für die einzelnen Motive abzulesen ist, wie häufig sie gewählt worden sind. Man könnte die Zustimmungsfrequenzen bei den Motiv-Variablen mit der längst bekannten Häufigkeitsanalyse (**Analysieren > Deskriptive Statistiken > Häufigkeiten**) bestimmen lassen und die resultierenden Häufigkeitstabellen (eine pro Variable) manuell zusammenfassen. Eine zeitökonomischere Alternative besteht darin, die Kombitabelle von SPSS erstellen zu lassen. Wir erhalten für unsere Daten folgendes Ergebnis:

		Anzahl	Prozent
Motive zur Kursteilnahme	Eigene Studie	23	76,7%
	Bewerbung um Stelle	1	3,3%
	Bewerbung um HIWI-Job	1	3,3%
	Interesse an der EDV	5	16,7%
	Interesse an Statistik	10	33,3%
	Andere Motive	1	3,3%

Es zeigt sich etwa, dass 23 Personen (= 76,7% von den 30 Fällen mit gültigen Werten bei den Motiv-Variablen) dem ersten Motiv zugestimmt haben. Ein Fall, auf den wir später noch eingehen müssen, fand keines der fünf konkreten Motive für sich passend und markierte die Restkategorie (*Andere Motive*).

Zum Erstellen der obigen Tabelle wird eine **Variablengruppe** benötigt, die zuvor definiert werden muss. Wählen Sie dazu den Menübefehl:¹

Daten > Mehrfachantwortsets definieren


In der nun erscheinenden Dialogbox sind folgende Aktionen nötig:

¹ Alternativ können Sie auch den folgenden Menübefehl verwenden:

Analysieren > Tabellen > Mehrfachantwortsets

- Befördern Sie die Variablen MOTIV1 bis MOTIV5 sowie ANDERE in die Liste **Variablen im Set**.
- Wählen Sie im Rahmen **Variablenkodierung** die Option **Dichotomien** mit dem **Gezählten Wert 1**.
- Vereinbaren Sie für das Set den **Namen** *Motive* und das **Label** *Motive zur Kursteilnahme*.

Danach müsste Ihre Dialogbox ungefähr so aussehen:



Nehmen Sie mit **Hinzufügen** das neue Set in die Liste der **Mehrfachantwortensets** auf, und quittieren Sie die Dialogbox mit **OK**.

Auf die beschriebene Weise definierte Mehrfachantwortensets werden in der Arbeitsdatei gespeichert und ggf. in die zugeordnete Datendatei gesichert, so dass sie beim späteren Öffnen der Datei wieder zur Verfügung stehen.

Bei der Set-Definition kommt das SPSS-Kommando MRSETS zum Einsatz, das mit Hilfe der Dialogbox **Mehrfachantwortensets definieren** über den Schalter **Einfügen** erzeugt werden kann, z.B.:

MRSETS

```
/MDGROUP NAME=$Motive LABEL='Motive zur Kursteilnahme'
CATEGORYLABELS=VARLABELS
VARIABLES=motiv1 motiv2 motiv3 motiv4 motiv5 andere VALUE=1
/DISPLAY NAME=[$Motive].
```

Bei wichtigen Sets sollte das definierende MRSETS-Kommando in das Transformationsprogramm zum Erstellen der Fertigdatendatei aufgenommen werden (vgl. Abschnitte 6.1.1 und 6.7).

Über den Menübefehl

Analysieren > Mehrfachantworten > Variablensets definieren

bzw. den zugehörigen Befehl MULT RESPONSE

MULT RESPONSE

```
GROUPS=$Motive 'Motive zur Kursteilnahme' (motiv1 motiv2 motiv3 motiv4
motiv5 andere (1))
/FREQUENCIES=$Motive .
```


ist noch eine ältere Möglichkeit zur Set-Definition verfügbar. Ihr entscheidender Nachteil im Vergleich zur oben beschriebenen Lösung besteht darin, dass die Set-Definitionen beim Schließen des zugehörigen Datenblatts verschwinden, also *nicht* in einer Datendatei gespeichert werden können. Diese veraltete Option zur Set-Definition besitzt aus Traditions- bzw. Kompatibilitätsgründen eine prominente Position im Menüsystem von SPSS und wird leider in vielen Büchern ausschließlich beschrieben (siehe z.B. Bühl, 2012, S. 346ff; Action et al. 2009, S. 166ff).

15.2 Häufigkeitstabellen für Mehrfachantwortsets


Unter Verwendung der Variablengruppe \$MOTIVE (erzeugt per MRSETS-Kommando) lässt sich die in Abschnitt 15.1 präsentierte Tabelle mit den Häufigkeitsverteilungen der Set-Variablen über den Menübefehl

Analysieren > Tabelle > Benutzerdefinierte Tabellen


und den folgenden Dialog anfordern:



Wir befördern die unter der Variablenliste zu findende Variablengruppe \$MOTIVE per Drag & Drop auf die **Zeilen**-Ablagezone:



Um die voreingestellte **Anzahl**-Spalte durch eine Prozentspalte zu ergänzen, klicken wir auf den Schalter **Auswertungsstatistik** und befördern aus der **Statistik**-Liste das Element **Anzahl als Spalten%** in den **Anzeigen**-Bereich:




Wie ändern das vorgeschlagene **Variablenlabel** und quittieren mit dem Schalter **Der Auswahl zuweisen**. Wird anschließend der Dialog **Benutzerdefinierte Tabellen** mit **OK** quittiert, erscheint die fertige Tabelle im Ausgabefenster.

Entfernt man die Variable ANDERE zur Restkategorie der sonstigen Motive aus dem Set \$MOTIVE, dann resultieren folgende Ergebnisse mit abweichenden Prozentwerten:

		Anzahl	Prozent
Motive zur Kursteilnahme	Eigene Studie	23	79,3%
	Bewerbung um Stelle	1	3,4%
	Bewerbung um HIWI-Job	1	3,4%
	Interesse an der EDV	5	17,2%
	Interesse an Statistik	10	34,5%

Des Rätsels Lösung ist eine SPSS-Eigenart bei der Analyse von Mehrfachantwortensets aus dichotomen Variablen: Als gültig werden nur solche Fälle betrachtet, die bei mindestens einer Set-Variablen den zu zählenden Wert besitzen (bei uns also die Eins). Daher wird neben dem Fall 13 mit SYSMIS bei den Variablen MOTIV1 bis MOTIV5 auch der dritte Fall ausgeschlossen, der *alle konkreten Motive verneint*, aber die Restkategorie markiert hat. Folglich wird in obiger Ausgabe z.B. zum Motiv Eins meldet, dass 79,3% der Fälle (23 von 29) zugestimmt hätten. Offenbar erwartet SPSS von einem Mehrfachantwortenset, dass jede redliche Auskunftsperson mindestens einer Option zustimmen muss. Wir haben bei der Fragebogenkonstruktion mit Blick auf die Unterscheidbarkeit von verneinenden und fehlenden Antworten darauf geachtet, die Menge der Antwortmöglichkeiten im Teil 3a zu komplettieren (siehe Abschnitt 1.4.3.2.4). Für diese Befragungstechnik stellt sich nun eine weitere Begründung heraus.


Um ein Balkendiagramm mit den Zustimmunganteilen für alle Motivvariablen




zu produzieren, wählt man nach dem Menübefehl

Grafik > Diagrammerstellung

aus der **Galerie** die **einfachen Balken** und befördert das Mehrfachantwortenset \$MOTIVE auf die **X-Achsen**-Ablagezone:




Im Fenster mit den **Elementeigenschaften** wählt man den **Antwortprozentsatz** als darzustellende **Statistik**:



Die Detailgestaltung wird im Diagrammeditor vorgenommen, z.B.:

- Änderung der Balkenfarbe auf der Registerkarte **Füllung und Rahmen**
- Änderung der Kategorienreihenfolge auf der Registerkarte **Kategorien**
- Beschriftung der Y-Achse

Für die folgende Darstellungsalternative, die bei einer größeren Anzahl von Variablen und/oder längeren Beschriftungen von Vorteil ist, wurde im Diagrammeditor über den Schalter  das Koordinatensystem transponiert:



Außerdem wurde bei markierten Balken auf der Registerkarte **Kategorien** die Reihenfolge der Variablen geändert.

15.3 Kreuztabellen für Mehrfachantwortsets

Wenn wir uns für Geschlechtsunterschiede bei der Zustimmung zu den Motiven interessieren (z.B.: Wer interessiert sich mehr für Statistik?), sind *sechs* (2×2) - Tabellen zu analysieren. Über den aus Kapitel 13 bekannten Menübefehl **Analysieren > Deskriptive Statistiken > Kreuztabellen** erhalten wir z.B. für das Statistikmotiv folgendes Ergebnis:

Interesse an Statistik * Geschlecht Kreuztabelle					
			Geschlecht		Gesamt
			Frau	Mann	
Interesse an Statistik	Nein	Anzahl	15	5	20
		% v von Interesse an Statistik	75,0%	25,0%	100,0%
		% v von Geschlecht	62,5%	83,3%	66,7%
	Ja	Anzahl	9	1	10
		% v von Interesse an Statistik	90,0%	10,0%	100,0%
		% v von Geschlecht	37,5%	16,7%	33,3%
Gesamt		Anzahl	24	6	30
		% v von Interesse an Statistik	80,0%	20,0%	100,0%
		% v von Geschlecht	100,0%	100,0%	100,0%

Weil die Motiv-Variablen nur zwei Ausprägungen haben, sind die Ergebnisse zur Nein-Kategorie überflüssig. Es genügt zu wissen, dass 37,5% von den 24 Frauen und 16,7% von den sechs Männern ein Interesse an Statistik angegeben haben. Unter Verzicht auf die redundanten Zeilen lässt sich eine kompakte Darstellung der Geschlechtsunterschiede bei allen Kursmotiven erstellen:


		Geschlecht					
		Frau		Mann		Gesamt	
		Anzahl	Prozent	Anzahl	Prozent	Anzahl	Prozent
Motive zur Kursteilnahme	Eigene Studie	19	79,2%	4	66,7%	23	76,7%
	Bewerbung um Stelle	1	4,2%	0	0,0%	1	3,3%
	Bewerbung um HIWI-Job	0	0,0%	1	16,7%	1	3,3%
	Interesse an der EDV	3	12,5%	2	33,3%	5	16,7%
	Interesse an Statistik	9	37,5%	1	16,7%	10	33,3%
	Andere Motive	1	4,2%	0	0,0%	1	3,3%
	Gesamt	24	100,0%	6	100,0%	30	100,0%

Beachten Sie bitte: Dies ist nicht eine (6×2) - Kontingenztafel, sondern dies ist eine Kombitabelle mit der Essenz aus sechs (2×2) - Kontingenztafeln.


Um die obige Tabelle anzufordern, öffnen wir über

Analysieren > Tabellen > Benutzerdefinierte Tabellen

erneut die Dialogbox für benutzerdefinierte Tabellen. Ausgehend von dem in Abschnitt 15.2 erreichten Bearbeitungszustand bewegen wir die Variable GESCHL auf die **Spalten**-Ablagezone:



Bei markierter Zeilen- bzw. Spaltendimension (Motive zur Kursteilnahme bzw. Geschlecht) öffnen wir jeweils über den Schalter **Kategorien und Gesamtsummen** den folgenden Dialog



und markieren das Kontrollkästchen **Gesamtsumme**. So resultiert schließlich die oben gezeigte Tabelle.

Auch bei den Kreuztabellen ist die in Abschnitt 15.2 beschriebene MD-Konzeption der SPSS-Mehrfachwahl-Auswertung zu beachten. Wäre nicht die Variable ANDERE Mitglied im Set \$MOTIVE, dann würde SPSS in der Kombitabelle nur noch diejenigen Fälle berücksichtigen, die mindestens ein konkret abgefragtes Motiv bejaht haben.

15.4 Ein sparsames Set kategorialer Variablen expandieren


In Abschnitt 1.4.2.3 wurde das sparsame Set aus kategorialen Variablen für Mehrfachwahlfragen mit sehr vielen Antwortmöglichkeiten zur Vereinfachung der Erfassung empfohlen. Zwar ist diese Datenstruktur kein Nachteil bei den Analyseprozeduren, die in den Abschnitten 15.2 und 15.3 beschrieben wurden, doch ist bei anderen Auswertungen ein vollständiges Set aus dichotomen Variablen erforderlich. In dieser Situation kann man das sparsame Set mit Hilfe der SPSS-Kommandosprache „expandieren“. Die folgenden Kommandos erzeugen zu unseren Variablen METH1 bis METH3 die acht dichotomen Variablen STAT1 bis STAT8, die für jeweils eine bestimmte statistische Methode festhalten, ob sie genannt worden ist (Wert Eins) oder nicht (Wert Null):

```
do repeat stat = stat1 to stat8 /n = 1 to 8.
  do if (meth1 = n) or (meth2 = n) or (meth3 = n).
    compute stat = 1.
  else.
    compute stat = 0.
  end if.
end repeat.
formats stat1 to stat8 (f8.0).
variable width stat1 to stat8 (5).
variable level stat1 to stat8 (nominal).
variable role
  /target stat1 to stat8.
execute.
```


Bei den Daten der Manuskriptstichprobe steht z.B. die Variable STAT2 für die Regressionsanalyse, weil nach dem vervollständigten Kodierplan (vgl. Abschnitt 3.2.8) bei einer der Variablen

METH1 bis METH3 eine Zwei zu notieren war, wenn ein Fall im Fragebogenteil 3b die Regressionsanalyse genannt hatte.

Beim Fall Nr. 17 wurden die genannten Methodenwünsche 8 (= logistische Regression) und 2 (= Regressionsanalyse) folgendermaßen mit dem sparsamen Set kategorialer Variablen METH1 bis METH3 erfasst:



Daraus ergeben sich folgende Werte für die Variablen STAT1 bis STAT8:



In obiger Syntax werden zwei ausgesprochen nützliche Kontrollstrukturen der SPSS-Kommandosprache verwendet:

Schleife für strukturgleiche Transformationen

Die (DO REPEAT - END REPEAT) - Schleife wird achtmal ausgeführt, wobei im i -ten Umlauf die beiden Stellvertreter STAT und N gerade mit dem i -ten Element der jeweils zugehörigen Listen identisch sind.

Fallunterscheidung

In der folgenden Tabelle wird das SPSS-Verhalten beim Ausführen der (DO IF - ELSE - END IF) - Struktur in Abhängigkeit vom Wahrheitswert des logischen Ausdruck beschrieben:

Wert des logischen Ausdrucks	Aktion
wahr , z.B. im ersten Schleifenumlauf bei METH1 = 1, METH2 = 2, METH3 = 0	Das erste COMPUTE-Kommando wird ausgeführt, und die Variable STAT1 erhält den Wert 1.
falsch , z.B. im ersten Schleifenumlauf bei METH1 = 3, METH2 = 5, METH3 = 8	Das zweite COMPUTE-Kommando wird ausgeführt, und die Variable STAT1 erhält den Wert 0.
unbestimmt , z.B. im ersten Schleifenumlauf bei METH1=METH2=METH3=SYSMIS	Die Variable STAT1 behält den Initialisierungswert SYSMIS.

16 Datendateien im Textformat einlesen

Gelegentlich sind Daten auszuwerten, die in Textdateien vorliegen. Dabei können zwei Dateiformate auftreten:

- **separierte Daten**
Für jeden Fall liegen alle Variablen in derselben Reihenfolge vor, wobei zwischen zwei Werten ein Trennzeichen steht.
- **positionierte Daten**
Für jeden Fall liegt eine identische Anzahl von Datenzeilen vor. Jede Variable hat eine individuelle, feste Breite (z.B. 2 Stellen) und eine feste Position (z.B. Zeile 2, Spalten 8-9).

Zum Importieren von Textdatendateien stellt SPSS einen Assistenten zur Verfügung, der mit

Datei > Textdaten lesen

gestartet wird. Er kommt aber auch dann zum Einsatz, wenn Sie nach

Datei > Öffnen > Daten

eine Textdatendatei wählen.

An der im Vorwort vereinbarten Stelle finden Sie die Dateien **kfar-kv-sep.txt** und **kfar-kv-pos.txt** mit separierten bzw. positionierten KFA-Daten von 77 Fällen. Es bietet sich an, diese Daten einzulesen, um die in Abschnitt 11.4 durch grafische Datenexploration gewonnene Moderatorversion der differentialpsychologischen Hypothese anhand einer unabhängigen Stichprobe zu überprüfen.

16.1 Import von separierten Textdaten


Separierte Textdaten lassen sich sehr bequem importieren, zumal sie üblicherweise durch eine Zeile mit den Variablennamen eingeleitet werden. Hier ist der Anfang der Datei **kfar-kv-sep.txt** zu sehen:

FNR	GESCHL	GEBJ	FB	GROESSE	GEWICHT	AERGO	AERGM	LOT1	LOT2	...
1	1	77	1	158	48	6	6	4	3	...
2	1	77	1	159	55	4	8	3	4	...
3	1	74	4	160	48	3	8	4	3	...
4	1	75	1	165	78	2	2	5	5	...
.	.	.	.	.	.	.	.	.	.	...
.	.	.	.	.	.	.	.	.	.	...

Gehen Sie folgendermaßen vor, um die Daten zu importieren:

Textimport-Assistenten starten und Datei auswählen


Nach dem Start des Textimport-Assistenten ist zunächst die Eingabedatei zu wählen:



Der Textimportassistent unterstützt die Kodierungen UTF-8 sowie ANSI (lokale Kodierung) und erkennt diese Kodierungen automatisch.

Schritt 1


Im ersten Schritt zeigt der Assistent den Anfang unserer Datei und akzeptiert ggf. ein **vordefiniertes Format** aus früheren Assistenteneinsätzen, das die Dateistruktur beschreibt.



Da wir auf eine solche Vorarbeit nicht zurückgreifen können, machen wir **Weiter**.


Schritt 2

Im zweiten Schritt informieren wir den Assistenten darüber, dass **Trennzeichen** für Ordnung in der Datei sorgen, und dass die erste Zeile die **Variablennamen** enthält:




Schritt 3

Der erste Fall befindet sich in der zweiten Zeile der Datei (hinter der einleitenden Zeile mit den Variablennamen), und jeder Fall belegt genau eine Zeile:




Schritt 4

SPSS erkennt korrekt, dass in der Datei **kfar-kv-sep.txt** nur der **Tabulator** als Trennzeichen zum Einsatz kommt:



Schritt 5

Im fünften Assistentenschritt ist für alle Variablen zu prüfen, ob die automatische Erkennung des **Datenformats** erfolgreich war:



Schritt 6

Der Assistent bietet zwei Möglichkeiten zum Konservieren einer Dateispezifikation:


- **Dateiformat für zukünftige Verwendung speichern?**

Es entsteht eine Textassistent-Formatdatei (Erweiterung **.tpf**), die bei einem späteren Assistenteneinsatz im ersten Schritt angegeben werden kann (siehe oben).

- **Soll die Syntax eingefügt werden?**

Das für den Datenimport verantwortliche GET DATA – Kommando wird in ein Syntaxfenster geschrieben. Es bietet sich an, zusätzliche Kommandos zu ergänzen, z.B. zum Deklarieren von MD-Indikatoren, die in den Textdaten vorhanden sind. Später kann mit Hilfe des entstandenen SPSS-Programms der Import mit allen erforderlichen Zusatzmaßnahmen automatisiert ausgeführt werden.

Es spricht nichts dagegen, beide Konservierungsoptionen zu verwenden:



In der vom Textimport-Assistenten erzeugten Syntax spielt das GET DATA – Kommando die entscheidende Rolle.

In der Datei **kfar-kv-sep.txt** sind alle Fälle komplett. Generell dürfen Sie nach dem Einlesen von separierten Textdaten auf keinen Fall die Deklaration der eventuell vorhandenen **MD-Indikatoren** vergessen. Dies sollte per Syntax mit dem Kommando MISSING VALUES geschehen, z.B.:

`MISSING VALUES geschl lot1 to lot12 (9).`

Weil das Kommando MISSING VALUES (nicht nur beim Einlesen von Textdaten) von großer Bedeutung ist, soll seine allgemeine Syntax noch beschrieben werden:

MISSING VALUES {varlist | ALL} (valuelist) [[/]{varlist | ALL} ...]

varlist Dieser Platzhalter steht für eine Liste vorhandener Variablen, deren MD-Indikatoren festgelegt werden sollen (vgl. Abschnitt 18.1.5.2).

valuelist Dieser Platzhalter steht für eine Liste von Werten, die als MD-Indikatoren vereinbart werden sollen. In der Werteliste sind folgende Schlüsselwörter erlaubt:

- LO, LOWEST
Kleinster Wert
- HI, HIGHEST
Größter Wert

- THRU

Verbindungswort für Wertebereiche, z.B.:

7 THRU 9

7 THRU HI

Durch eine leere Werteliste werden für die betroffenen Variablen alle benutzerdefinierten MD-Indikatoren aufgehoben, z.B.:

MISSING VALUES partei ().

In der Syntaxbeschreibung werden folgende generelle Regeln verwendet:

- Ist von mehreren Ausdrücken genau einer zu wählen, werden diese Ausdrücke zwischen geschweiften Klammern und voneinander durch senkrechte Striche getrennt präsentiert.
- Eckige Klammern schließen optionale Ausdrücke ein

16.2 Import von positionierten Textdaten (feste Breite)

Die Datei **kfar-kv-pos.txt** enthält dieselben KFA-Daten, die in Abschnitt 16.2 aus einer separierten Datei gelesen wurden. Hier sind die Werte eines Falles auf zwei Zeilen verteilt, und jede Variable hat eine feste Position im Datensatz eines Falles (z.B. Variable AERGO in Zeile 2, Spalten 5-6).

```
11 177115848
12  6 6 431214542432 110000
21 177115955
22  4 8 343335442442 110010
31 174416048
32  3 8 433224443342 100010
41 175116578
42  2 2 553125544531 100100
. . . . .
. . . . .
```

Die für uns relevanten Variablen haben folgende Positionen:


Variable	Datenzeile	Spalten
GESCHL	1	5
AERGO	2	5-6
AERGM	2	7-8
LOT01-LOT12	2	10-21

Alle übrigen Variablen können wir ignorieren.

Gehen Sie folgendermaßen vor, um die relevanten Daten zu importieren:

Textimport-Assistenten starten und Datei auswählen


Nach dem Start des Textimport-Assistenten ist zunächst die Eingabedatei zu wählen:



Der Textimportassistent unterstützt die Kodierungen UTF-8 sowie ANSI (lokale Kodierung) und erkennt diese Kodierungen automatisch.

Schritt 1


Im ersten Schritt zeigt der Assistent den Anfang unserer Datei und akzeptiert ggf. ein **vordefiniertes Format** aus früheren Assistenteneinsätzen, das die Dateistruktur beschreibt.



Da wir auf eine solche Vorarbeit *nicht* zurückgreifen können, machen wir **Weiter**.

Schritt 2


Im zweiten Schritt teilen wir mit, dass die Variablen in unserer Eingabedatei feste Positionen bzw. eine **feste Breite** besitzen:



Von der Möglichkeit, in der **ersten Zeile der Datei die Variablennamen** zu transportieren, wird in unserem Beispiel kein Gebrauch gemacht.


Schritt 3

Da unsere Datei keinen Vorspann enthält, **befindet sich der erste Fall** in Zeile 1. Allerdings befindet er sich dort nicht komplett, weil jeweils zwei **Zeilen einen Fall darstellen**:



Schritt 4


Nun müssen wir die Positionen der einzulesenden Variablen durch Setzen, Verschieben und Löschen von Trennlinien festlegen, wobei alle Zeilen eines Falles hintereinander angezeigt werden. Der Assistentenvorschlag orientiert sich an Leerzeichen und würde im Beispiel zu 7, teilweise unbrauchbaren Variablen führen:



Hinweise zur Benutzung der Trennlinien:

- Neue Trennlinie einfügen
Klicken Sie innerhalb der Datenzone auf die gewünschte Spaltenposition.
- Trennlinie verschieben
Klicken Sie innerhalb der Datenzone auf die Trennlinie und verschieben Sie diese bei fest gehaltener Maustaste.
- Trennlinie löschen
Trennlinie per Mausklick markieren und anschließend **Trennung löschen**


So kann im Beispiel das Einlesen der Variablen GESCHL, AERGO, AERGM und LOT1 bis LOT12 vorbereitet werden:



Schritt 5

Im fünften Assistentenschritt können Sie die von SPSS erkannten bzw. vorgeschlagenen Variablenamen ändern und ein **Datenformat** festlegen. Zum Umbenennen ist jeweils genau eine Spalte zu markieren. Das Datenformat lässt sich auch für eine markierte Variablenliste wählen.

Mit dem speziellen Datenformat **Nicht importieren** können überflüssige Variablen ausgeschlossen werden, z.B.:



Schritt 6

Im letzten Assistentendialog werden die schon in Abschnitt 16.2 vorstellten Optionen zum Konvertieren der Importspezifikation angeboten.

Das vom Textimport-Assistenten erzeugte GET DATA – Kommando verwendet eine Spaltenzählung ab **0**. So erhält z.B. die in der fünften Spalte der ersten Zeile eines Falles befindliche Variable GESCHL die Spaltenpositionsangabe 4-4.

```
GET DATA  /TYPE=TEXT
           /FILE="U:\Eigene Dateien\SPSS\kfar-kv-pos.txt"
           /ENCODING='Locale'
           /FIXCASE=2
           /ARRANGEMENT=FIXED
           /FIRSTCASE=1
           /IMPORTCASE=ALL
           /VARIABLES=
           /1 geschl 4-4 F1.0
           F2 5-12 F8.0
           /2 aergo 4-5 F2.0
           aergm 6-7 F2.0
           lot1 8-9 F2.0
           lot2 10-10 F1.0
           lot3 11-11 F1.0
           lot4 12-12 F1.0
           lot5 13-13 F1.0
           lot6 14-14 F1.0
           lot7 15-15 F1.0
```

```

lot8 16-16 F1.0
lot9 17-17 F1.0
lot10 18-18 F1.0
lot11 19-19 F1.0
lot12 20-20 F1.0
F17 21-27 F7.0.
CACHE.

```

Auch nach dem Einlesen von positionierten Textdaten dürfen Sie auf keinen Fall die Deklaration der dort eventuell verwendeten **MD-Indikatoren** vergessen. Dies sollte per Syntax mit dem Kommando MISSING VALUES geschehen, das in Abschnitt 16.2 beschrieben wird, z.B.:

```
MISSING VALUES geschl lot1 to lot12 (9).
```

In der Datei **kfar-kv-pos.txt** sind allerdings alle Fälle komplett.

16.3 Überprüfung der revidierten differentialpsychologischen Hypothese

Um mit den in Abschnitt 16.2 bzw. Abschnitt 16.1 importierten Daten die revidierte differentialpsychologische Hypothese prüfen zu können, sind zunächst einige Datentransformationen erforderlich, wobei wir die erforderlichen Kommandos teilweise aus dem Transformationsprogramm **kfat.sps** übernehmen können:

```

* Labels für GESCHL.
VARIABLE LABELS geschl Geschlecht.
VALUE LABELS geschl 1 'Frau' 2 'Mann'.

* LOT-Fragen umkodieren.
RECODE
  lot3 lot4 lot5 lot12 (5=1) (4=2) (2=4) (1=5) .
EXECUTE .


* LOT berechnen.
COMPUTE lot = MEAN.6(lot1,lot3,lot4,lot5,lot8,lot9,lot11,lot12) .
VARIABLE LABELS lot 'LOT-Optimismus' .
EXECUTE .

* AERGAM berechnen.
COMPUTE aergam = (aergo + aergm)/2 .
VARIABLE LABELS aergam 'Mittel der Ärger-Variablen' .
EXECUTE .

* Produktvariable für die Moderatorhypothese.
COMPUTE geslot = geschl * lot.
VARIABLE LABELS geslot 'GESCHL * LOT'.
EXECUTE .

```

Auch in der neuen Stichprobe scheint das Geschlecht die Regression von AERGAM auf LOT im erwarteten Sinn zu moderieren:



Allerdings wird der Interaktionseffekt in der Moderatoranalyse *nicht* signifikant:

Koeffizienten ^a							
Modell	Nicht standardisierte Koeffizienten		Standardisierte Koeffizienten	t	Sig.	Konfidenzintervall für B (95,0%)	
	B	Standardfehler	Beta			Untergrenze	Obergrenze
1 (Konstante)	,773	5,562		,139	,890	-10,313	11,858
LOT-Optimismus	1,761	1,493	,413	1,180	,242	-1,214	4,737
Geschlecht	3,670	4,130	,949	,889	,377	-4,561	11,900
GESCHL * LOT	-1,150	1,118	-1,120	-1,029	,307	-3,378	1,077

a. Abhängige Variable: Mittel der Ärger-Variablen

Zwar darf die die angegebene Überschreitungswahrscheinlichkeit zum Produktterm ($p = 0,307$) halbiert werden, weil sie zu einem zweiseitigen Test gehört, doch liegt auch das einseitige p-Level deutlich über der kritischen Grenze 0,05.

Weitere Versuche zur Rettung der differentialpsychologischen Hypothese könnten sich z.B. auf eventuelle Mängel bei der Operationalisierung der theoretischen Begriffe (Ärger und Optimismus) konzentrieren. Allerdings muss auch die theoretische Fundierung kritisch hinterfragt werden.


17 Einstellungen modifizieren

Das Standardverhalten von SPSS für Windows lässt sich auf vielfältige Weise den individuellen Bedürfnissen anpassen, was wir bei passender Gelegenheit auch schon getan haben.

Über den Menübefehl

Bearbeiten > Optionen

erhalten Sie die folgende Dialogbox mit Optionen zur SPSS-Konfiguration:




17.1 Allgemein

Auf dem Registerblatt **Allgemein** sind u.a. folgende Optionen von Relevanz:


Variablenlisten

Bei den Listen auswählbarer Variablen in Dialogboxen verwendet SPSS folgende Voreinstellungen:

- Besitzt eine Variable ein Label, wird dieses vorrangig präsentiert, und der Variablenname erscheint hinter dem Label zwischen eckigen Klammern. Dabei werden manche Dialogboxen zur Analysespezifikation etwas unübersichtlich, z.B.:



Mit der Option **Namen anzeigen** im Bereich **Variablenlisten** kann man auf die kompaktere Darstellung *ohne* Labels umschalten, was bei Verwendung aussagekräftiger Variablennamen zu empfehlen ist, z.B.:



- Per Voreinstellung sind die Variablen in Dialogboxen genauso angeordnet wie in der **Datei**. Dies erlaubt in der Regel ein bequemes Arbeiten, weil gemeinsam zu analysierende und damit in Dialogboxen gemeinsam auszuwählende Variablen oft in der Arbeitsdatei hintereinander stehen. Bei der Arbeit mit einer unbekannten Datendatei findet man (namentlich bekannte) Variablen jedoch leichter bei **alphabetischer** Sortierung.

17.2 Sprache

Auf dem Registerblatt **Sprache** sind u.a. folgende Optionen von Relevanz:

Sprache der Ausgabe bzw. Benutzerschnittstelle


SPSS erlaubt für die **Ausgabe** (Beschriftung der Tabellen) und für die **Benutzerschnittstelle** (Menüs und Dialogboxen) die Wahl zwischen diversen Sprachen.

Zeichenkodierung für Daten und Syntax

SPSS 22 kann bei Texten in Daten- und Syntaxdateien den Unicode-Zeichensatz unterstützen, sodass z.B. kyrillische oder japanische Zeichen möglich sind. Beim ersten Start erkundigt sich SPSS 22, ob Sie mit dem den Unicode oder mit der Kodierung gemäß Windows-Standard arbeiten wollen. Auf der Registerkarte **Sprache** lässt sich die Kodierung umschalten, sofern kein nichtleeres Dateneditorfenster geöffnet ist.

17.3 Ausgabe

Auf dem Registerblatt **Ausgabe** kann man z.B. veranlassen, dass in Pivot-Tabellen die Wertbeschriftungen ignoriert und stattdessen die Werte selbst angezeigt werden:



Außerdem kann man als Anzeigemethode für verallgemeinerte lineare gemischte Modelle und nichtparametrische Tests die etwas unpraktische Modellanzeige durch **Pivot-Tabellen und Diagramme** ersetzen.

17.4 Dateispeicherorte

Auf dem Registerblatt **Dateispeicherorte** kann man u.a. einstellen:

Startordner für die Dialogfelder "Öffnen" und "Speichern"

Auf den Pool-PCs an der Universität Trier eignet sich der Ordner

U:\Eigene Dateien\SPSS

Sitzungsjournal

Per Voreinstellung protokolliert SPSS alle Kommandos, die Sie während einer Sitzung per Dialogbox oder via Syntaxfenster abschicken, in einer so genannten **Journaldatei**. Diese Datei kann sehr nützlich sein, weil sie die Kommando-Äquivalente zu praktisch allen Arbeiten früherer Sitzungen enthält. Per Voreinstellung wird beim Start einer SPSS-Sitzung eine vorhandene Journaldatei *nicht* überschrieben, sondern die neuen Kommandos werden am Ende angehängt. Falls die Datei zu groß wird, muss sie gelegentlich verkleinert oder gelöscht werden. Man kann aber auch im Rahmen **Sitzungsjournal** den voreingestellten Öffnungsmodus **Anhängen** abändern auf **Überschreiben**. Dann wird die Journaldatei zu Beginn jeder Sitzung neu erstellt, wobei gegebenenfalls der alte Inhalt überschrieben wird.

18 Anhang

18.1 Weitere Hinweise zur SPSS-Kommandosprache

In Kapitel 1 wurden nur sehr oberflächliche Hinweise zur SPSS-Kommandosprache gegeben. Diese sollten genügen für Anwender, die nicht frei programmieren, sondern nur gelegentlich ein von SPSS automatisch erzeugtes Kommando modifizieren wollen. Der aktuelle Abschnitt ist für ambitionierte Anwender(innen) gedacht, die bereit sind, SPSS-Programme zu schreiben, ...

- um auch die ausschließlich per Syntax verfügbaren SPSS-Leistungen nutzen zu können,
- um rationeller mit SPSS zu arbeiten.

Eine vollständige Dokumentation der Kommandosprache finden Sie als PDF-Dokument mit ca. 2200 Seiten im Hilfesystem von SPSS über

Hilfe > Befehlssyntax-Referenz

Dieses Dokument ist nicht nur ein gutes Nachschlagewerk mit Details zu allen Kommandos, sondern bietet im Kapitel *Universals* auch eine Einführung in generelle Themen im Zusammenhang mit Kommandos, Dateien, Variablen und Transformationen. Wertvolle Informationen bietet auch die syntaxorientierte Einführung von Levesque & IBM Corp. (2011) in die Datenverwaltung mit SPSS.


18.1.1 Hilfsmittel für das Arbeiten mit der SPSS-Kommandosprache

Das wichtigste Hilfsmittel für das Arbeiten mit der SPSS-Kommandosprache ist die *Command Syntax Reference*, die als PDF-Dokument über das Hilfesystem verfügbar ist:

Hilfe > Befehlssyntax-Referenz

Hier findet man ausführliche Beschreibungen der SPSS-Kommandos mit zahlreichen Beispielen und wertvollen Literaturhinweisen zu den realisierten statistischen Methoden.

Das Syntaxfenster zum Erstellen oder Modifizieren von SPSS-Kommandos



erscheint bei Bedarf spontan nach einem Mausklick auf den in vielen Dialogboxen vorhandenen **Einfügen**-Schalter, um die automatisch erzeugte, zur Dialogbox äquivalente Syntax aufzunehmen. Über den Menübefehl

Datei > Neu > Syntax

lässt sich jederzeit ein Syntaxfenster explizit anfordern. Das Öffnen einer vorhandenen Syntaxdatei über

Datei > Öffnen > Syntax

oder


Datei > Zuletzt verwendete Dateien

dürfte in der routinierten Praxis den meistverwendeten Weg zum Syntaxfenster darstellen.

Das Syntaxfenster erleichtert die Bearbeitung von Kommandos u.a. durch

- eine Navigationszone zur Orientierung in längeren Programmen
- Zeilennummern
- farbliche Unterscheidung verschiedener Syntaxbestandteile
- eine intelligente Syntaxvervollständigung
- Haltepunkte

Außerdem bietet es ein bequemes Verfahren, Syntaxinformationen zu einem konkreten Kommando anzufordern: Setzen Sie die Schreibmarke auf das Kommando, und klicken Sie dann auf das Symbol . Zum FREQUENCIES-Kommando, das der **Häufigkeiten**-Dialogbox zugrunde liegt, erscheint z.B. die folgende Erläuterung:




Sie startet mit dem Syntaxdiagramm zum beschriebenen Kommando. Wie ein solches Syntaxdiagramm zu lesen ist, beschreibt der folgende Abschnitt.

18.1.2 Interpretation von Syntaxdiagrammen

Mit einem Syntaxdiagramm wird die allgemeine Form eines Kommandos definiert und somit festgelegt, wie konkrete Beispiele gebildet werden müssen. Solche Syntaxdiagramme werden auch im weiteren Verlauf dieses Abschnitts benutzt, um Bestandteile der SPSS-Kommandosprache zu erläutern. In den Syntaxdiagrammen treten einige Metazeichen auf (z.B. "[", "{"), die nicht zur Kommandosprache selbst gehören, sondern diese Sprache beschreiben. Die Bedeutung dieser Metazeichen müssen Sie kennen, um Syntaxdiagramme richtig interpretieren zu können. Im Hilfesystem finden Sie eine Erläuterung, indem Sie nach

Hilfe > Themen > Suchen

den Suchbegriff *Syntax Diagrams* in das aktive Textfeld eintippen und dann einen Doppelklick auf das Thema **Commands** setzen:



18.1.3 Aufbau von SPSS-Programmen

Welche Kommandos SPSS für das Erstellen von Programmen bereithalten muss, ergibt sich aus unseren Zielvorstellungen: Wir möchten SPSS anweisen, ...

- empirischen Daten in ein Datenblatt einzulesen,
- gegebenenfalls Variablen zu verändern oder neue Variablen zu erstellen,
- eventuell ein modifiziertes Datenblatt in eine Datendatei zu schreiben,
- statistische Analysen oder grafische Darstellungen vorzunehmen.

Darüber hinaus haben wir gelegentlich Sonderwünsche hinsichtlich der Arbeitsweise von SPSS.

Orientiert an den gerade skizzierten Teilaufgaben kann man die verfügbaren SPSS-Kommandos in folgende Gruppen einteilen:

- **Dateidefinitions-Kommandos**

Sie dienen zum Einlesen von Daten in ein Datenblatt. Als Beispiel haben wir das GET-Kommando kennen gelernt. Wenn ein Programm kein Dateidefinitions-Kommando enthält, wenn es also nicht selbst für das Einlesen seiner Daten sorgt, kann es natürlich nur ausgeführt werden, wenn zuvor eine Arbeitsdatei erzeugt worden ist.

- **Transformations-Kommandos**

Diese Kommandos dienen zur Veränderung oder Neuberechnung von Variablen bzw. zur Auswahl von Fällen für die weitere Verarbeitung.

- **Prozedur-Kommandos**

Damit werden statistische Analysen, grafische Präsentationen oder Dateibearbeitungen (z.B. Sortieren der Fälle) angefordert. Ein Beispiel ist das FREQUENCIES-Kommando. Als Spezialfall gehört auch das Kommando SAVE, das den Inhalt der Arbeitsdatei in eine Datendatei sichert, zu den Prozedur-Kommandos.

- **Dienst-Kommandos**

Damit kann man u.a. die Arbeitsweise von SPSS beeinflussen (z.B. Startwert des Pseudozufallszahlengenerators setzen) und verschiedene Informationen anfordern.

In folgendem SPSS-Programm treten Kommandos aus allen Gruppen auf:

<code>comment Größe und Gewicht.</code>	Dienst-Kommando
<code>get file = 'kfar.sav'.</code>	Dateidef.-Kommando
<code>frequencies var = groesse gewicht /statistics = all /histogram = normal.</code>	Prozedur- Kommando
<code>compute ideal = groesse - 100.</code>	Transformations- Kommando
<code>t-test pairs = gewicht ideal.</code>	Prozedur- Kommando

Ein SPSS-Programm darf selbstverständlich beliebig viele Prozeduren verwenden oder auch mehrere Daten-Sets definieren und jeweils durch Transformationen verändern.

18.1.4 Aufbau eines einzelnen SPSS-Kommandos

Die wichtigsten Regeln für SPSS-Befehle:

- Ein Kommando besteht aus seinem Namen und den zugehörigen Spezifikationen:

kommandoname spezifikationen

- Der **Kommandoname** kann aus einem Wort bestehen oder aus mehreren Wörtern.
Beispiele: - FREQUENCIES
 - GET DATA
- Die **Spezifikationen** dürfen enthalten:
 - Schlüsselwörter (z.B. VARIABLES)
 - Variablennamen
 - Zahlen
 - Zeichenfolgen (z.B. Variablenlabel)
 - Operatoren (z.B. "+")
 - spezielle Begrenzungszeichen: / () = ' "

Zwischen diesen Elementen ist mindestens ein Leerzeichen erforderlich. Ausnahme:

Die speziellen Begrenzungszeichen, die arithmetischen Operatoren und manche Vergleichsoperatoren (z.B. ">") sind selbstbegrenzend, d.h. davor und danach sind keine Leerzeichen nötig (aber erlaubt).

Statt eines Leerzeichens darf man meist verwenden:

- beliebig viele Leerzeichen,
- ein Komma,
- einen Zeilenwechsel, wobei aber keine Leerzeile entstehen darf.

Dies ermöglicht eine übersichtliche Programmgestaltung.

- Jedes Kommando muss in einer neuen Zeile beginnen und mit einem Punkt enden. Die Kommandos müssen dabei keinesfalls in der ersten *Spalte* beginnen, sondern dürfen eingerückt werden. Von dieser Möglichkeit sollte man z.B. bei Schleifen-Konstruktionen Gebrauch machen.

Beispiel: do repeat mc=mc001 to mc100.
 compute mc=normal(1).
 end repeat.

Hier werden 100 unabhängige, normalverteilte Zufallsvariablen erzeugt. Durch das Einrücken wird deutlich gemacht, dass die COMPUTE-Anweisung innerhalb der DO REPEAT - Schleife steht.

- Ein Kommando kann sich über beliebig viele Fortsetzungszeilen erstrecken. *Innerhalb* eines Kommandos sind aber keine Leerzeilen erlaubt.
- Eine Syntaxzeile sollte maximal 256 Zeichen enthalten, um in allen Kontexten ausführbar zu sein.
- Die Verwendung von Groß- oder Kleinbuchstaben ist beliebig.
- Schlüsselwörter dürfen meist bis auf die ersten drei Zeichen abgekürzt werden.
Beispiel: "fre" für "frequencies"
- Bei den meisten Kommandos sind die Spezifikationen in Subkommandos unterteilt. Diese beginnen mit einem Subkommando-Namen, meist gefolgt von einem Gleichheitszeichen, und sind durch Schrägstriche voneinander getrennt.

Beispiel: `frequencies var=lot01 /format=notable
/statistics=all.`

Merken Sie sich aus dieser Liste für den Anfang vor allem:

JEDES KOMMANDO MUSS IN EINER NEUEN ZEILE BEGINNEN UND MIT EINEM PUNKT ENDEN.

18.1.5 Regeln für Variablenlisten

18.1.5.1 Abkürzende Spezifikation einer Serie von Variablen

In Transformations- oder Prozedurkommandos soll häufig eine Folge **bereits existierender** und **in der Arbeitsdatei hintereinander stehender** Variablen angesprochen werden. Dies ermöglicht das **aufrufende TO**, dessen Syntax im Folgenden erläutert wird:

<code>vara TO varb</code>

vara, varb Namen bereits vorhandener Variablen, wobei *vara* in der Arbeitsdatei vor *varb* stehen muss.

Beispiele: - `frequencies var=alter to beruf.`
 Für alle Variablen, die in der Arbeitsdatei von ALTER bis BERUF positioniert sind, werden Häufigkeitstabellen erstellt.
 - `frequencies var=frage1 to frage3.`
 Wenn in der Arbeitsdatei zwischen FRAGE1 und FRAGE3 1500 beliebig benannte Variablen stehen, dann bewirkt dieses Kommando 1502 Häufigkeitstabellen!

18.1.5.2 Der Platzhalter varlist

In folgendem Syntaxdiagramm wird der in SPSS-Kommandos häufig auftretende Platzhalter *varlist* definiert:

<code>{varname varname_1 TO varname_2} [{...}]</code>

varname, Variablennamen
varname_1,
varname_2

Beispiel: `missing values nieder01 to hoehe ozon mess1 to mess4 (9).`
 Hier wird mit dem MISSING VALUES - Kommando für alle aufgelisteten Variablen die 9 als MD-Indikator vereinbart.

Literaturverzeichnis

- Action, C., Miller, R., Fullerton, D. & Maltby, J. (2009). *SPSS for Social Scientists* (2nd ed.). Basingstoke: Palgrave MacMillan.
- Akreml, L. & Baur, N. (2011). Kreuztabellen und Kontingenzanalysen. In: Akreml, L., Baur, N. & Fromm, S. (Hrsg.). *Datenanalyse mit SPSS für Fortgeschrittene 1*. (3 Aufl.). Wiesbaden: VS Verlag.
- Antonakis, J., Bendahan, S., Jacquart, P. & Lalive, R. (2010). On making causal claims: A review and recommendations. *The Leadership Quarterly*, 21, 1086–1120.
- Backhaus, K., Erichson, B., Plinke, W. & Weiber, R. (2008). *Multivariate Analysemethoden* (12. Aufl.). Berlin: Springer.
- Baltes-Götz, B. (1998). *Exakte Tests mit SPSS*. Online-Dokument: <http://www.uni-trier.de/index.php?id=22571>
- Baltes-Götz, B. (2012). *Logistische Regressionsanalyse mit SPSS*. Online-Dokument: <http://www.uni-trier.de/index.php?id=22513>
- Baltes-Götz, B. (2013a). *Analyse von hierarchischen linearen Modellen mit der SPSS-Prozedur MIXED*. Online-Dokument: <http://www.uni-trier.de/index.php?id=39127>
- Baltes-Götz, B. (2013b). *Behandlung fehlender Werte in SPSS und Amos*. Online-Dokument: <http://www.uni-trier.de/index.php?id=23239>
- Baltes-Götz, B. (2014). *Lineare Regressionsanalyse mit SPSS*. Online-Dokument: <http://www.uni-trier.de/index.php?id=22489>
- Baltes-Götz, B. (2015a). *Mediator- und Moderatoranalyse per multipler Regression mit SPSS*. Online-Dokument: <http://www.uni-trier.de/index.php?id=22528>
- Baltes-Götz, B. (2015b). *Generalisierte lineare Modelle und GEE-Modelle in SPSS*. Online-Dokument: <http://www.uni-trier.de/index.php?id=51455>
- Baltes-Götz, B. (2016a). *R-Pakete und -Syntax in SPSS verwenden*. Online-Dokument: <http://www.uni-trier.de/index.php?id=44476>
- Baltes-Götz, B. (2016b). *Online-Umfragen mit Enterprise Feedback Suite Survey*. Online-Dokument: <http://www.uni-trier.de/index.php?id=52985>
- Baur, N. & Fromm, S. (2011). Nützliche Software und Fundorte für Daten. In: Akreml, L., Baur, N. & Fromm, S. (Hrsg.). *Datenanalyse mit SPSS für Fortgeschrittene 1*. (3 Aufl.). Wiesbaden: VS Verlag.
- Bortz, J. & Döring, N. (2005). *Forschungsmethoden und Evaluation* (3. Aufl.). Berlin: Springer.
- Bortz, J. & Schuster, C. (2010). *Statistik für Human- und Sozialwissenschaftler* (7. Aufl.). Berlin: Springer.
- Box, G. E. P. (1979). Robustness in the Strategy of Scientific Model Building. In R. L. Launer & G. N. Wilkinson (Eds.). *Robustness in Statistics*, pp. 201-236. New York: Academic Press.
- Brandstätter, E. (1999). Konfidenzintervalle als Alternative zu Signifikanztests. *Methods of Psychological Research Online*, Vol.4, No.2. Online-Dokument (abgerufen am 12.10.2014): <http://www.dgps.de/fachgruppen/methoden/mpr-online/issue7/art3/article.html>

- Brosius, F. (2013). *SPSS 21*. Heidelberg: mitp.
- Brüderl, J. (2010). Kausalanalyse mit Paneldaten. In C. Wolf & H. Best (Hrsg.). *Handbuch der sozialwissenschaftlichen Datenanalyse*, S. 963-994, Wiesbaden: VS Verlag.
- Bühner, M & Ziegler, M (2009). *Statistik für Psychologen und Sozialwissenschaftler*. München: Pearson.
- Bühl, A. (2012). *SPSS 20. Einführung in die moderne Datenanalyse* (13. Aufl.). München: Pearson.
- Cohen, J. (1988). *Statistical Power Analysis for the Behavioral Sciences* (2nd ed.). New York: Academic Press.
- Cohen, J., Cohen, P., West, S.G. & Aiken, L. (2003). *Applied Multiple Regression/Correlation Analysis for the Behavioral Sciences* (3rd ed.). Mahwah: Lawrence Erlbaum Associates.
- Efron, B. (1982). *The jackknife, the bootstrap and other resampling plans*. Philadelphia: SIAM-Monograph #38.
- Eid, M., Gollwitzer, M. & Schmitt, M. (2013). *Statistik und Forschungsmethoden* (3. Aufl.). Weinheim: Beltz.
- Faul, F., Erdfelder, E., Lang, A.-G., & Buchner, A. (2007). G*Power 3: A flexible statistical power analysis program for the social, behavioral, and biomedical sciences. *Behavior Research Methods*, 39, 175-191.
- Faul, F., Erdfelder, E., Buchner, A. & Lang, A.-G. (2009). Statistical power analyses using G*Power 3.1: Tests for correlation and regression analyses. *Behavior Research Methods*, 41(4), 1149-1160.
- Field, A. (2013). *Discovering Statistics Using SPSS* (4rd ed.). London: Sage.
- Gehring, U.W. & Weins, C. (2004). *Grundkurs Statistik für Politologen* (4. Aufl.). Wiesbaden: VS Verlag.
- Griffith, A. (2010). *SPSS For Dummies*, (2nd ed.). Indianapolis, Indiana: Wiley.
- Hartung, J. (1989). *Statistik* (7. Auflage). München: Oldenbourg.
- IBM Corp. (2013a). *IBM SPSS Data Preparation 22*. Online-Dokument: <http://pic.dhe.ibm.com/infocenter/spssstat/v22r0m0/index.jsp>
- IBM Corp. (2013b). *IBM SPSS Statistics 22 Core-System-Benutzerhandbuch*. Online-Dokument: <http://pic.dhe.ibm.com/infocenter/spssstat/v22r0m0/index.jsp>
- IBM Corp. (2013c). *GPL Reference Guide for IBM SPSS Statistics*. Online-Dokument (abgerufen am 15.10.2014): ftp://public.dhe.ibm.com/software/analytics/spss/documentation/statistics/22.0/en/client/Manuals/GPL_Reference_Guide_for_IBM_SPSS_Statistics.pdf
- Jacob, R., Heinz, A. & Décieux, J.P. (2013). *Umfrage* (3. Aufl.). München: Oldenbourg.
- Kahneman, D. & Miller, D.T. (1986) Norm theory: comparing reality to its alternatives. *Psychological Review*, 93, 136-153.
- Kerchoff, A.C. (1974). *Ambition and attainment*. Rose Monograph Series.

- Levesque, R. & IBM Corp. (2011). *Programming and Data Management for SPSS Statistics 20*. Online-Dokument (abgerufen am 12.10.2014):
https://www.ibm.com/developerworks/mydeveloperworks/wikis/home?lang=en#/wiki/We70df3195ec8_4f95_9773_42e448fa9029/page/Books%20and%20Articles
- Liang, K. & Zeger, S.L. (1986). Longitudinal data analysis using generalized linear models. *Biometrika*, 73(1), 13–22.
- Lück, D (2011). Mängel im Datensatz beseitigen. In: Akremi, L., Baur, N. & Fromm, S. (Hrsg). *Datenanalyse mit SPSS für Fortgeschrittene 1*. (3 Aufl.). Wiesbaden: VS Verlag.
- MacCallum, R.C., Zhang, S., Preacher, K.J. & Rucker, D.D. (2002). On the practice of dichotomization of quantitative variables. *Psychological Methods*, 7(1), 19-40.
- Mehta, C.R. & Patel, N.R (2011). *IBM SPSS Exact Tests*. Online-Dokument:
<http://publib.boulder.ibm.com/infocenter/spssstat/v20r0m0/index.jsp>
- Norušis, M.J. (2012a). *IBM SPSS Statistics 19 Guide to Data Analysis*. Upper Saddle River, NJ: Prentice Hall.
- Norušis, M.J. (2012b). *IBM SPSS Statistics 19 Statistical Procedures Companion*. Upper Saddle River, NJ: Prentice Hall.
- Norušis, M.J. (2012c). *IBM SPSS Statistics 19 Advanced Statistical Procedures*. Upper Saddle River, NJ: Prentice Hall.
- Pedhazur, E.J. & Pedhazur Schmelkin L. (1991). *Measurement, design, and analysis. An integrated approach*. Hillsdale, NJ: Lawrence Erlbaum.
- Rasch, B., Frieze, M., Hofmann, W. & Naumann, E. (2010). *Quantitative Methoden* (Band 1 und 2). Berlin: Springer.
- Raudenbush, S. W. & Bryk, A. S. (2002). *Hierarchical Linear Models* (2nd ed.). Thousand Oaks, CA: Sage.
- Rumsey, D. (2008). *Übungsbuch Statistik für DUMMIES*. Weinheim: Wiley.
- Scheier, M.F. & Carver, C.S. (1985). Optimism, Coping, Health: Assessment and implications of generalized outcome expectancies. *Health Psychology*, 4, 219-247.
- Schnell, R., Hill, P. B. & Esser, E. (2008). *Methoden der empirischen Sozialforschung* (8. Aufl.). München: Oldenbourg.
- Siegel, S. (1976). *Nichtparametrische statistische Methoden*. Frankfurt: Fachbuchhandlung für Psychologie
- Snijders, T. A. B. & Bosker, R. L. (2012). *Multilevel Analysis*. Los Angeles, CA: Sage.
- Statistisches Bundesamt. (2010). *Statistik und Wissenschaft. Demografische Standards*. Online-Dokument (abgerufen am 09.06.2014):
https://www.destatis.de/DE/Methoden/StatistikWissenschaftBand17.pdf?__blob=publicationFile
- Tabachnik, B.G. & Fidell, L.S. (2012). *Using multivariate statistics* (6th ed.). Boston: Pearson.
- Wallis, W.A. & Roberts, H.V. (1956). *Statistics, a new approach*. Glencoe, Ill.: The Free Press.
- Warner, R.M. (2013). *Applied statistics: from bivariate through multivariate techniques* (2nd ed.). Thousand Oaks, CA: SAGE Publications.

Wentura, D. (2004). Ein kleiner Leitfaden zur Teststärke-Analyse. Online-Dokument:
<http://www.uni-saarland.de/fak5/excops/download/POWER.pdf>

Stichwortregister

A		Boxplot	175
Ablehnungsbereich		C	
Abschlusstest	12	CAPI	55
Achsenteilstriche	224	CATI	55
ALLBUS	8	Chi-Quadrat-Statistik	246
Alpha-Fehler	4, 12, 18, 167	Clopper-Pearson	
Alphanumerische Variablen	34	Vertrauensintervall für Anteile	109
Alternativhypothese	3, 164	COMMENT-Kommando	125
American Psychological Association	230	COMPUTE-Kommando	140, 142
Amos	44, 194	Convenience Sample	13
AND-Operator	152	CONVERT	135
Angelpunkte	176	COUNT-Kommando	155
Anstehende Transformationen	140	Cramers V	249, 251
Anwärterliste	81	D	
APA	230	Data Collection Data Entry	44
Arbeitsdatei	56	Data Preparation	78
speichern	69	DATASET NAME	119
Artefakt	16	Dateidefinitions-Kommandos	288
Assistent		Daten suchen	102
zum Textimport	270	Datenblatt	56
Ausblenden		Datendatei	
von Kategorien	206	Öffnen	80
Ausgabeblock	87	Sichern	69
Ausgabefenster	46, 86, 200	Dateneditor	28, 55
designiertes	91	Dateneditorfenster	46
Mehrere verwenden	91	Dateneingabe	73
Neues anfordern	91	Datenerfassung	52
Ausreißer	95, 175	automatisierte	52
Ausrichtung	60	manuelle	54
Auswahl der Diagrammtafelvorgabe	221	per Datenbankprogramm	54
Automatisierte Datenerfassung	52	per SPSS-Dateneditor	55
B		Datenlexikon	56
Balkendiagramme	82	Datenmatrix	28
Bedienoberfläche	116	Datenschutz	29
Bedingte Datentransformation	149	Daten-Set	56
Begrüßungsdialog	46	Datensicherheit	128
Beobachtungseinheit	9	Datentransformation	14, 127
Bequemlichkeitsstichprobe	13	bedingte	149
Berichte	234	Datumsvariablen	34
Beschriftung	58	Deklarationsteil	56
Beta-Fehler	4, 13, 18, 168	Demografische Merkmale	24
Body Mass Index	148	Determinationskoeffizient	23
Bonferroni	252	Dezimalstellen	58
Bootstrapping	184	in Pivot-Tabellen	208

Dezimaltrennzeichen	146
Diagrammerstellung	217
Diagrammtafel-Editor	222
Diagrammvorlagen	229
Diagrammvorschau	218
Dienst-Kommandos	288
Differentialpsychologische Hypothese	230
DIW	8
DO IF	149
DO IF - Kommando	269
DO REPEAT - Kommando	269

E

Effektstärke	19, 169, 198, 213, 249, 251
Kreuztabellenanalyse	238
EFS Survey	53
Eigenschaftsfenster	224
Einfügen	
Fall	75
Variable	64
Eingeschränkt numerische Variablen	33
Einseitiger Test	24
Einstellungen modifizieren	282
Einstichproben - t-Test	19, 164
Einstichproben-t-Test	148
Erfassungsfehler	77
Exact Tests - Modul	253
Exakte Tests	252
Excel	54
EXECUTE-Kommando	133, 139
Explorative Datenanalyse	175, 176
Exportieren	90
Externe Validität	9, 13, 15, 84

F

Fall	
einfügen	75
erschieben	75
löschen	75
Fälle	
auflisten	234
ausfiltern	232
gewichten	258
Fälle auswählen	232
Fallidentifikation	29
Falls-Subdialogbox	149
Fehlende Werte	34, 59, 145
Rechenregeln für ...	147
Fehler	

erster Art	4, 12, 167
zweiter Art	4, 13, 168
Fertigdatendatei	72, 127
Filter	232, 233
FILTER_\$	233
Filterführung	55
Fishers exakter Test	171, 256
Fokus	
im Ausgabefenster	86
FORMATS-Kommando	161
FREQUENCIES-Kommando	116, 120
Funktionen	143
ABS	143
arithmetische	143
EXP	143
für fehlende Werte	145
LN	143
MAX	144
MEAN	144
MEDIAN	144
MIN	144
NMISS	145
NORMAL	145
NVALID	145
Pseudozufallszahlgeneratoren	145
RND	143
SD	144
SQRT	143
statistische	144
SUM	144
UNIFORM	145
VALUE	145

G

G*Power 3.1	18, 22, 193, 199, 238, 256
GEE-Modell	174
GEE-Modelle	10
g-Effektstärkeindex	199
Generalisierbarkeit	15, 84
Generalisierte lineare gemischte Modelle	10
GENESIS	8
Gepoolte Standardabweichung	214
Gerichtete	
Hypothesen	12
Gerichtete Hypothese	24
Gerichtete Hypothesen	
für (2 × 2) - Tabellen	256
GESIS-Institut	8
GET DATA - Kommando	274, 279
GET-Kommando	119
Getrimmtes Mittel	184

GGRAPH-Kommando	216
GPL	216, 219
Graphics Programming Language	216, 219
GRAPH-Kommando	216
Gruppenbildung	130
Gruppenvergleiche	210
Gruppierte Daten	100
Gruppierungen	
in einer Pivot-Tabelle	204
Gruppierungsfaktor	10
GSS	9

H

Haltepunkt	123
Handbücher	50
Häufigkeitsanalyse	81, 83
Hauptausgabefenster	91
Hilfesystem	48
Histogramm	92
Homogenitätshypothese	246
Homoskedastizität	174
Hypothesen	8, 11
Hypothesentests	3, 164

I

Inferenzstatistik	164
Initialisierung numerischer Variablen	130
Interquartilsbereich	95, 176
Intervallniveau	16
Intervallschätzung	2, 104
ISSP	8

J

Jeffreys	
Vertrauensintervall für Anteile	109
Jeffreys-Vertrauensintervall	107
Journaldatei	284

K

Kategorien	
ausblenden	206
Kategorienliste	32
KFA-Hypothese	15
Klassenbildung	11
Kodierplan	14, 27, 40
Kodierung	33
Kolmogorov-Smirnov - Test	177, 179

Kommandosprache	116, 124, 269, 285
Kommentare in SPSS-Programmen	125, 160
Konfidenzintervall	2
Konfidenzniveau	104
Kontinuitätskorrektur nach Yates	257
Kreuztabellen	236
Kritischer Wert	167
Kurtosis	97

L

Leerzeilen	160
Lernprogramm	49
Levene-Test	211
Life Orientation Test	21
Likelihood Quotient	
Vertrauensintervall für Anteile	109
Likelihood-Quotienten-Test für	
Kreuztabellen	250
Lineares gemischtes Modell	10
Linearitätsannahme	173
LMM	10
Logische Operatoren	152
Logischer Ausdruck	151, 152, 232
Auswertungsreihenfolge	153
unbestimmter	151
Wahrheitstafeln	153
Löschen	
Fall	75
Variable	64
LOT	136

M

Mantel-Haenszel-Statistik	250
Maß	60
MAXQDA	33
MD-Indikator	34
Median	93
Mediator	6
Mehrebenenanalyse	174
Mehrfachantwortenset	
definieren	260
Definieren	260
Häufigkeiten	262
Kreuztabellen	266
Mehrfachantwortset	30, 31
Mehrfachwahlfragen	260
sparsames Set aus kateg. Variablen	30
vollständiges Set aus dichot. Variablen	30
Mehrfachwahl-Fragen	30

Menüzeile	47
Mersenne-Twister	146, 187
Messniveau	60
Messwiederholungsfaktor	10, 16
MISSING VALUES - Kommando	290
Missing-Data-Indikator	34
Mittelwert	94
Modellanzeige	112
Modellierung	5
Moderatoreffekt	228
Modus	93
MRSETS	261
MULT RESPONSE	262

N

Nationales Bildungspanel	8
Navigationsbereich	86, 87
Neyman und Pearson	4, 164
Nichtparametrischer Lagevergleich	180
NMISS	156
Nominalskalenniveau	34
Normalitätsannahme	173
Normalverteilung	105
Normalverteilungsannahme	179
Normalverteilungstests	177, 179
NOT-Operator	152
Nullhypothese	3, 164
Numerische Funktionen	<i>Siehe Funktionen</i>
Numerische Variablen	33
Numerischer Ausdruck	143
Auswertungsprioritäten	146

O

Offene Fragen	32
Öffnen	
Datendatei	80
Ökologische Validität	11
Online-Datenerhebung	52
Operationalisierung	11
Ordinatenabschnitt	22, 173
OR-Operator	152

P

Panelsstudie	10
Parameterschätzung	2
Pearsons Chi-Quadrat-Statistik	246
PERMISSIONS	129

Phi-Koeffizient	251
Pivot-Editor	200
Plausibilitätsprüfungen	55
Population	1, 9
Positionierte Daten	275
Power	18, 170
t-Test zum Regressionskoeffizienten	193
Poweranalyse	
Post hoc	193
Pretest	42
Probabilistische Gesetze	1
Prozedur-Kommandos	288
Prüfgröße	165
Pseudozufallszahlengenerator	145
Punktschätzung	2

Q

Qualitativen Datenanalyse	33
Questback	53

R

Ratingskalen	16
RECODE-Kommando	130
Regressionsanalyse	189, 192
Repräsentativität	53
Repräsentativität der Stichprobe	237
Residualkategorien	35
Rohdatendatei	72, 127
Rolle einer Variablen	61
Rückgängig-Befehl	
im Datenfenster	75

S

SamplePower	18, 44
SAV-Dateien	70
SAVE-Kommando	158
Schätzmethoden	2
Schiefe	95
Schreibschutz	129
SEED	146
SELECT IF	140
Separierte Daten	270
Shapiro-Wilk - Test	177
Shapiro-Wilk - Test	179
Signifikanztestlogik nach Neyman und	
Pearson	4, 164
Skalenniveau	11, 34, 60

SOEP	8	zweiseitiges	170
Sortierung bei Variablenlisten	283	Teststärke	170, 193
Spaltenbreite	208	t-Test zum Regressionskoeffizienten	193
Spaltenformat	58	Teststatistik	165, 248
Spannweite	94	Text Analytics for Surveys	33, 44
Speichern		Textassistent-Formatdatei	273
Arbeitsdatei	69	Textdatendateien	270
SPSS		Textimport-Assistent	270
Einzelplatzlizenz	45	TO	144
Kommandosprache	116, 124, 268	TO-Schlüsselwort	290
Programm	72, 116, 117, 118	Transformations-Kommandos	288
Prozessor	116	Transformationsprogramm	72, 117, 127, 157
Syntax	124	Transformieren	
SPSS Data Collection Data Entry	54	Berechnen	140
SPSS im Internet	51	Umkodieren	130
SPSS-Datendatei		Zählen	155
Öffnen	80	t-Test	
Sichern	69	für eine Stichprobe	19, 148, 164
Standardabweichung	95	für unabhängige Stichproben	210
Standardfehler	106, 166	für verbundene Stichproben	17, 166
der Schiefe	96	Tukey-Angelpunkte	176
Statista	9	t-Verteilung	166
Statistik-Assistent	49		
Statistisches Bundesamt	8	U	
StatTransfer	80	Überschreitungswahrscheinlichkeit	165
Statuszeile	47	Umkodieren	130
Stichprobe	13	Umlaute	
Stichprobenmodell	247	in Variablennamen	39
Stichprobenumfang	18	Unabhängigkeit	164
Streudiagramm	217	von Residuen	10
String-Variablen	34	Unabhängigkeitshypothese	246
Strukturierung	29	Ungerichtete	
Subkommando	289	Hypothesen	12
Suchen		Unicode-Zeichensatz	45, 283
Daten	102	Unipark	53
Symbolleiste	47	Unkorreliertheit der Residuen	174
Syntaxdiagramm	287	Untersuchungsdesign	10
Syntaxfenster	117, 123, 285	Untersuchungsplanung	9, 15
Kommandos ausführen	121		
Syntax-Regeln	124	V	
SYSMIS	35, 73, 75, 103, 147	VALUE LABELS – Kommando	160
Systemdefiniert fehlend	35	Variable	28
System-Missing	35, 134	einfügen	64
		löschen	64
T		verschieben	65
Tabellenvorlagen	209	Variablen	
Teilausgabe	87	abgeleitete	29
Teilnehmerliste	81	Variablenattribute	58
Testproblem		Variablendefinition	57

Variablenlabel	58	W	
Variablenlisten	282, 290		
Variablennamen	29, 39	Wahrheitstafeln	153
Variablentypen	33, 58	Wahrheitswert	153
Varianz	94	Wertbeschriftungen	59, 73
Varianzhomogenität	174	Wertelabels	59, 68, 73
Varlist	290	Wilcoxon-Test	180
Verfälschter Test	170	Wölbung	97
Vergleich	152	Z	
Vergleichsoperatoren	152		
Verschieben		Zählen von Werten	155
Fall	75	Zählvariablen	92
Variable	65	Zeichenfolgenvariable	34
Vertrauensintervall	2, 94, 104	Zeichenfolgevariable	36
Getrimmtes Mittel	184	Zelleneigenschaften	208
Mittelwert	182	Zentraler Grenzwertsatz	105, 191
Viewer	46, 86, 200	Zufällige Teilstichprobe ziehen	234
Visualization Designer	44, 221	Zufallszahlengenerator	145
Visuelle Klassierung	136	Zweiseitiges Testproblem	170
Vorlagen		Zwischenablage	88
Diagrammen	229		
Vorzeichentest	180, 197		